

Universitatea Națională de Știință și Tehnologie Politehnica București  
Centrul Universitar Pitești  
Școala Doctorală Interdisciplinară - Domeniul Matematică  
Str. Târgul din Vale nr. 1  
110040 Pitești, România

# Integralele Choquet și Sugeno. Teorie și aplicații.

The Choquet and Sugeno integrals. Theory and Applications.

Student doctorand Irina - Mădălina MANEA (GIURGESCU)  
Adresă de e-mail: [madalina\\_giurgescu@yahoo.com](mailto:madalina_giurgescu@yahoo.com)

## Rezumatul tezei de doctorat

Sub îndrumarea Prof. dr. Mirela ȘTEFĂNESCU și a Prof. dr. Ion  
CHIȚESCU

Pitești, 2023

# Cuprins

|                                                                                                                |           |
|----------------------------------------------------------------------------------------------------------------|-----------|
| <b>Introducere</b>                                                                                             | <b>5</b>  |
| <b>1 Preliminarii</b>                                                                                          | <b>8</b>  |
| 1.1 Măsuri generalizate . . . . .                                                                              | 8         |
| 1.1.1 Noțiuni teoretice generale . . . . .                                                                     | 8         |
| 1.1.2 Funcții măsurabile. Spații măsurabile . . . . .                                                          | 11        |
| 1.2 Integrala Choquet . . . . .                                                                                | 12        |
| 1.3 Integrala Sugeno . . . . .                                                                                 | 14        |
| <b>2 Aplicație în economie a integralei Choquet: În căutarea Investitorilor Virtuali</b>                       | <b>16</b> |
| 2.1 Introducere . . . . .                                                                                      | 16        |
| 2.2 Rezultate . . . . .                                                                                        | 17        |
| 2.2.1 Setări Generale . . . . .                                                                                | 17        |
| 2.2.2 Prospectarea Investitorilor Virtuali . . . . .                                                           | 17        |
| 2.2.3 Caz Numeric și Concluzii . . . . .                                                                       | 18        |
| <b>3 Aplicații în psihologie ale integralei Choquet</b>                                                        | <b>25</b> |
| 3.1 Deschiderea . . . . .                                                                                      | 26        |
| 3.1.1 Determinarea unei măsuri și utilizarea ei pentru a afla nivelul de Deschidere al subiecților . . . . .   | 26        |
| 3.1.2 Utilizarea mai multor măsuri cunoscute pentru a afla nivelul de Deschidere al subiecților . . . . .      | 30        |
| 3.2 Anxietatea . . . . .                                                                                       | 32        |
| 3.2.1 Folosind mai multe măsuri monotone cunoscute pentru a afla nivelul de Anxietate al subiecților . . . . . | 33        |
| 3.2.2 Determinarea unei măsuri și utilizarea ei pentru a afla nivelul de Anxietate al subiecților . . . . .    | 38        |

|          |                                                                                                            |           |
|----------|------------------------------------------------------------------------------------------------------------|-----------|
| <b>4</b> | <b>Calculul aproximativ al integralei Sugeno</b>                                                           | <b>45</b> |
| 4.1      | Rezultate generale . . . . .                                                                               | 45        |
| 4.2      | Funcții Simple Pozitive, Funcții Elementare Pozitive și Integralele lor Sugeno .                           | 47        |
| 4.3      | Metode în Doi Pași pentru Calcularea Integralelor Sugeno . . . . .                                         | 48        |
| 4.3.1    | Notatii și Estimări Unificate . . . . .                                                                    | 48        |
| 4.3.2    | Calcul folosind Metoda Simplă în Doi Pași . . . . .                                                        | 51        |
| 4.3.3    | Calcul folosind Teorema de Convergență Iterată . . . . .                                                   | 52        |
| 4.3.4    | Remarci referitoare la Metoda în Doi Pași în cazul Funcțiilor Mărginite.<br>Reducerea Calculului . . . . . | 53        |
| 4.3.5    | Aplicația Finală . . . . .                                                                                 | 55        |
|          | <b>Concluzii</b>                                                                                           | <b>59</b> |
|          | <b>Dezvoltări viitoare</b>                                                                                 | <b>60</b> |
|          | <b>Bibliografie</b>                                                                                        | <b>61</b> |

**Cuvinte și fraze cheie:** Măsuri monotone, Măsuri nonaditive, Funcții măsurabile, Integrale nonlineare, Integrala Choquet, Integrala Sugeno, Limita unei secvențe generalizate, Calcul aproximativ, Fuziune de date, Instrument de agregare, Problema inversă a fuziunii de informații, Exploatarea datelor, Deschidere, Anxietate, Modelul BigFive, EEG, HighAlpha, HighBeta, LowAlpha, LowBeta, Delta, MidGamma, NeuroSky, Unde, Investor virtual.

**2020 Clasificarea disciplinelor de matematică (Mathematics Subject Classification):** 03E72, 28A25, 28E10, 94D05

# Introducere

**Obiectivul general.** Scopul acestei teze de doctorat este de a dezvolta noi direcții pentru aplicațiile teoriei măsurii generalizate, numită și teoria fuzzy, folosind integralele Choquet și Sugeno.

**Considerații generale.** Teoria măsurii este o ramură a analizei matematice care studiază măsurile, funcțiile măsurabile și integralele. O măsură este o funcție care asociază un număr unei submulțimi a unei mulțimi date. Această noțiune a fost dezvoltată datorită necesității de a efectua integrarea pe mulțimi arbitrare, și nu doar pe intervalele reale pe care se integra de obicei.

Teoria măsurii generalizată a apărut din teoria clasică a măsurii prin procesul de generalizare(vezi [4], [11], [17], [20], [39], [40], [48], [55], [56], [63], [64]). Măsurile clasice sunt funcții pe mulțimi nonnegative cu valori reale, fiecare definită pe o clasă specifică de submulțimi ale unei mulțimi universale date, care satisfac anumite cerințe axiomatice. Una dintre aceste cerințe, crucială pentru măsurile clasice, este cunoscută sub numele de cerința aditivității. Această cerință este, în principiu, ca măsura reuniunii (finită sau infinită numărabilă) a oricărei familii recunoscute de mulțimi care sunt disjuncte în perechi, să fie egală cu suma măsurilor mulțimilor individuale din reunire. În teoria măsurii generalizate, cerința de aditivitate este înlocuită cu o cerință considerabil mai slabă. Orice funcție definită pe o mulțime cu valori reale  $\mu$  dintr-o clasă dată de mulțimi care 'dispare' pe mulțimea vidă (a.î.  $\mu(\emptyset) = 0$  este acceptată în teoria măsurii generalizate ca măsură (vezi[64]). O ramură crucială a teoriei măsurii generalizate o reprezintă integralele nonlineare. Cele mai semnificative integrale nonlineare sunt integrala Choquet și integrala Sugeno(vezi [3], [5], [6], [13], [16], [18], [19], [27], [33], [43], [64], [65]). În literatura de specialitate, anumiți matematicieni folosesc denumirile: teoria fuzzy, măsuri fuzzy sau de integrale fuzzy.

**Motivația** studiului prezentat în această teză este dată de faptul că teoria fuzzy și integralele fuzzy au o aplicabilitate foarte mare într-o varietate de domenii. În ultimii ani, mulți matematicieni au fost interesați să găsească diverse aplicații ale teoriei fuzzy

și ale integralelor fuzzy.

În consecință, am ales ca zonă de studiu pentru această teză, măsurile generalizate și integralele Choquet și Sugeno, tratate din punct de vedere al teoriei și al aplicațiilor.

Am ales domeniul economic, mai precis piața de capital. Am ales acest domeniu, deoarece nu este suficient acoperit în literatura de specialitate din punctul de vedere al teoriei fuzzy.

Am creat un nou model matematic de decizie, bazat pe teoria fuzzy, mai precis integrala Choquet (vezi[12]).

Modelul nostru matematic poate fi utilizat în diverse situații de decizie, în diverse domenii ale economiei.

Un alt domeniu ales de noi a fost cel al psihologiei, care nu este suficient acoperit în literatura de specialitate din punctul de vedere al teoriei fuzzy. Un alt motiv pentru care am ales psihologia este acela că este un domeniu vast, în care cercetarea este continuă, iar neuroștiința este în continuă dezvoltare.

Am dezvoltat câteva modele matematice bazate pe teoria fuzzy în domeniul psihologiei. Mai precis, am folosit integrala Choquet pentru a determina nivelul de deschidere (vezi [23], [24] și [26]) și nivelul de anxietate (vezi [14] și [25]) pentru anumiți subiecți voluntari utilizați în procesul nostru de cercetare.

Nu în ultimul rând, am ales domeniul calculului aproximativ, deoarece acesta fusese deja abordat pentru integrala Choquet (vezi[9]). Scopul nostru principal a fost să furnizăm anumite proceduri practice pentru calculul aproximativ (cu precizie prealocată) al integralei Sugeno a unei funcții măsurabile pozitive generale care respectă o măsură generalizată monotonă (vezi[10]). În acest scop, folosim metodele noastre în doi pași (metoda simplă în doi pași și metoda topologică folosind teorema de convergență iterată). Metodele menționate mai sus reduc calculul general la calcul binecunoscut în cazul finit discret, care poate fi realizat cu metode asistate de calculator.

**Descrierea tezei.** Această teză este dedicată studiului de noi direcții ale aplicațiilor teoriei măsurii generalizate, folosind integralele Choquet și Sugeno.

Direcțiile studiate de noi sunt: teoria deciziei, aplicații în domeniul Data Mining (instrument de fuziune) și calcul aproximativ, în următoarele domenii: piața de capital ca domeniu specific al economiei, psihologiei și calculelor matematice.

În zona pieței de capital am colaborat cu o companie din domeniu, numită Confident Invest.

În domeniul psihologiei am colaborat cu psihologii Institutului de Studii, Cercetare, Dezvoltare și Inovare al Facultății Titu Maiorescu din București, precum și cu specialiști

ai Academiei Tehnice Militare din București.

În **Capitolul 1**, intitulat **Preliminarii**, menționăm notații și terminologii folosite în această teză. Mai exact, introducem principalele concepte legate de Teoria Măsurii Generalizate, cele mai importante fiind legate de măsurile generalizate, integralele nonliniare Choquet și Sugeno.

**Capitolul 2**, intitulat **Aplicație în economie a integralei Choquet: În căutarea Investitorilor Virtuali**, este dedicat studiului unui nou model matematic de decizie bazat pe teoria fuzzy, mai precis integrala Choquet, într-o anumită ramură a economiei, mai exact, în piața de capital. Introducem o metoda de selectare a celor mai probabili viitori clienți investitori (investitori virtuali) ai unei companii de brokeraj din piața de capital.

Rezultatele prezentate în acest capitol pot fi găsite în [12].

În **Capitolul 3**, intitulat **Aplicații în psihologie ale integralei Choquet**, este dedicat studiului bazat pe teoria fuzzy, mai precis integrala Choquet, în psihologie. Mai exact, introducem câteva modele matematice care descriu modul în care sunt procesate undele de tip EEG pentru a caracteriza nivelul de Deschidere și nivelul de Anxietate.

Rezultatele pentru Deschidere pot fi găsite în [23], [24], [26] și pentru Anxietate în [14], [25].

**Capitolul 4**, intitulat **Calculul aproximativ al integralei Sugeno**, este dedicat studiului unei proceduri practice pentru calcularea aproximativă (cu precizie preasignată) a integralei Sugeno a unei funcții măsurabile pozitive generale care respectă o măsură generalizată monotonă. În acest scop, folosim metodele noastre în doi pași (metoda simplă în doi pași și metoda topologică folosind teorema de convergență iterată). Metodele menționate mai sus reduc calculul general la calcul binecunoscut în cazul finit discret, care poate fi realizat cu metode asistate de calculator.

Rezultatele acestui capitol au fost publicate în [10].

# Chapter 1

## Preliminarii

În acest capitol, prezentăm notațiile și noțiunile teoretice utilizate în această teză. Introducem principalele concepte legate de Teoria Măsurii Generalizate, cele mai importante fiind legate de măsurile generalizate, integralele nonliniare Choquet și Sugeno.

### 1.1 Măsuri generalizate

Considerând o mulțime nevidă  $T$  și o clasă de mulțimi  $\mathbf{F} \subset \mathcal{P}(T)$  astfel încât  $\emptyset \in \mathbf{F}$ , spunem că funcția  $\mu : \mathbf{F} \rightarrow \overline{\mathbb{R}}_+$  este o *măsură generalizată* (sau o *măsură monotonă*) dacă are următoarele proprietăți:

1.  $\mu(\emptyset) = 0$
2.  $\mu(A) \leq \mu(B)$ , unde  $A, B \in \mathbf{F}$  și  $A \subset B$ .

#### 1.1.1 Noțiuni teoretice generale

Prin  $\mathbb{N}$  înțelegem mulțimea  $\{0, 1, 2, \dots\}$  și prin  $\mathbb{N}^*$  înțelegem  $\mathbb{N} \setminus \{0\}$ . Folosim notațiile:  $\mathbb{R}_+ = [0, \infty)$ ,  $\overline{\mathbb{R}}_+ = [0, \infty] = \mathbb{R}_+ \cup \{\infty\}$ .

**Definiția 1.1.** Clasa tuturor submulțimilor lui  $X$  se numește mulțimea părților lui  $X$ , și se notează  $\mathcal{P}(X)$  a.î.  $\mathcal{P}(X) = \{A | A \subset X\}$ . (vezi[64])

**Definiția 1.2.** Dacă  $E$  este o mulțime, mulțimea acelor elemente ale lui  $X$  care nu sunt în  $E$  se numește complementara lui  $E$ . Se notează  $\overline{E}$ . (vezi[64])

**Definiția 1.3.** O clasă nevidă  $\mathbf{R}$  se numește *inel* dacă și numai dacă  $\forall E, F \in \mathbf{R}$ ,  $E \cup F \in \mathbf{R}$  și  $E - F \in \mathbf{R}$ . (vezi[64])

**Definiția 1.4.** O clasă nevidă  $\mathbf{R}$  se numește *algebră* dacă și numai dacă  $\forall E, F \in \mathbf{R}$  avem  $E \cup F \in \mathbf{R}$ ,  $E - F \in \mathbf{R}$  și  $\overline{E} \in \mathbf{R}$ . (vezi[64])

**Teorema 1.1.**[vezi[64]] O algebră este un inel care îl conține pe  $X$  și invers, un inel care îl conține pe  $X$  este o algebră.

**Propoziția 1.1.**[vezi[64]] Dacă  $\mathbf{R}$  este un inel, atunci  $\mathbf{R} \cup \{E | \overline{E} \in \mathbf{R}\}$  este o algebră.

**Definiția 1.5.** O clasă nevidă  $\mathbf{F}$  se numește  $\sigma$ -inel dacă și numai dacă  $\forall E, F \in \mathbf{F}$  avem  $E - F \in \mathbf{F}$  și  $\forall E_i \in \mathbf{F}, i = 1, 2, \dots$  avem  $\bigcup_{i=1}^{\infty} E_i \in \mathbf{F}$ . (vezi[64])

**Definiția 1.6.** O  $\sigma$ -algebră (sau  $\sigma$ -câmp) este un  $\sigma$ -inel care îl conține pe  $X$ . (vezi[64])

**Propoziția 1.2.**[vezi[64]] Dacă  $\mathbf{F}$  este un  $\sigma$ -inel, atunci  $\mathbf{F} \cup \{E | \overline{E} \in \mathbf{F}\}$  este o  $\sigma$ -algebră.

Fie  $X$  o mulțime nevidă și fie  $\mathbf{C}$  o clasă nevidă de submulțimi ale lui  $X$ . Fie  $\mu : \mathbf{C} \rightarrow [0, \infty]$  o funcție nenegativă extinsă cu valori reale.

Facem următoarele acorduri(vezi[64]):

$$0 \times \infty = \infty \times 0 = 0$$

$$\frac{1}{\infty} = 0$$

$$\infty - \infty = 0$$

$$\sum_{i \in \emptyset} a_i = 0, \text{ unde } \{a_i\} \text{ este o secvență de numere reale.}$$

**Definiția 1.7.** Funcția  $\mu : \mathbf{C} \rightarrow [0, \infty]$  se numește *măsură generalizată* pe  $(X, \mathbf{C})$  dacă și numai dacă  $\mu(\emptyset) = 0$  când  $\emptyset \in \mathbf{C}$ . (vezi [64])

**Definiția 1.8.** Funcția  $\mu : \mathbf{C} \rightarrow [0, \infty]$  se numește *măsură monotonă* pe  $(X, \mathbf{C})$  dacă și numai dacă satisface următoarele cerințe(vezi[64]):

1.  $\mu(\emptyset) = 0$  când  $\emptyset \in \mathbf{C}$
2.  $E \in \mathbf{C}, F \in \mathbf{C}$  și  $E \subset F$  implică  $\mu(E) \leq \mu(F)$ .

*Note:* Pentru măsurile monotone definite mai sus, în literatura de specialitate se mai folosește și denumirea de *măsuri fuzzy*. (vezi[64])

*Remarci:*

1. O măsură monotonă  $\mu$  se numește *semicontinuuă inferior* (sau *semicontinuuă de jos*) dacă și numai dacă  $\{E_n\} \subset \mathbf{C}$ ,  $E_1 \subset E_2 \subset \dots$  și  $\bigcup_{n=1}^{\infty} E_n \in \mathbf{C}$  implică  $\lim_n \mu(E_n) = \mu(\bigcup_{n=1}^{\infty} E_n)$ .
2. O măsură monotonă  $\mu$  se numește *semicontinuuă superior* (sau *semicontinuuă de sus*) dacă și numai dacă  $\{E_n\} \subset \mathbf{C}$ ,  $E_1 \supset E_2 \supset \dots$ ,  $\mu(E_1) < \infty$  și  $\bigcap_{n=1}^{\infty} E_n \in \mathbf{C}$  implică  $\lim_n \mu(E_n) = \mu(\bigcap_{n=1}^{\infty} E_n)$ .
3. Dacă o măsură satisface 1) și 2) atunci ea se numește *măsură monotonă continuă*.

Orice măsură  $\sigma$ -aditivă (adică clasică) este în același timp continuă inferior și continuă superior. (vezi[64])

**Definiția 1.9.** O măsură monotonă  $\mu$  se numește *normalizată* dacă și numai dacă  $X \in \mathbf{C}$  și  $\mu(X) = 1$ . (vezi[64])

**Definiția 1.10.** Fie  $\mu : \mathbf{C} \rightarrow [0, \infty]$ .  $\mu$  se numește *aditivă* dacă și numai dacă  $\mu(E \cup F) = \mu(E) + \mu(F)$ , unde  $E, F \in \mathbf{C}$ ,  $E \cup F \in \mathbf{C}$  și  $E \cap F = \emptyset$ . (vezi[64])

**Definiția 1.11.** Fie  $\mu : \mathbf{C} \rightarrow [0, \infty]$ .  $\mu$  se numește *superaditivă* dacă și numai dacă  $\mu(E \cup F) \geq \mu(E) + \mu(F)$ , unde  $E, F \in \mathbf{C}$ ,  $E \cup F \in \mathbf{C}$  și  $E \cap F = \emptyset$ . (vezi[64])

**Definiția 1.12.** Fie  $\mu : \mathbf{C} \rightarrow [0, \infty]$ .  $\mu$  se numește *subaditivă* dacă și numai dacă  $\mu(E \cup F) \leq \mu(E) + \mu(F)$ , unde  $E, F \in \mathbf{C}$ ,  $E \cup F \in \mathbf{C}$ . (vezi[64])

**Definiția 1.13.**  $\mu$  se numește *finit aditivă* dacă și numai dacă  $\mu(\bigcup_{i=1}^n E_i) = \sum_{i=1}^n \mu(E_i)$ , unde  $\{E_1, \dots, E_n\}$  este o clasă de mulțimi disjuncte din  $\mathbf{C}$ , a căror reuniune este tot în  $\mathbf{C}$ . (vezi[64])

**Definiția 1.14.**  $\mu$  se numește *numărabil aditivă* dacă și numai dacă  $\mu(\bigcup_{i=1}^{\infty} E_i) = \sum_{i=1}^{\infty} \mu(E_i)$ , unde  $\{E_n\}$  este o secvență de mulțimi disjuncte din  $\mathbf{C}$ , a căror reuniune este tot în  $\mathbf{C}$ . (vezi[64])

**Definiția 1.15.**  $\mu$  se numește *subtractivă* dacă și numai dacă  $E \in \mathbf{C}$ ,  $F \in \mathbf{C}$  și  $E \subset F$ ,  $F - E \in \mathbf{C}$ ,  $\mu(E) < \infty$  implică  $\mu(F - E) = \mu(F) - \mu(E)$ . (vezi[64])

**Definiția 1.16.**  $\mu$  se numește *măsură pe  $\mathbf{C}$*  dacă și numai dacă ea este numărabil aditivă și există  $E \in \mathbf{C}$  astfel încât  $\mu(E) < \infty$ . (vezi[64])

**Definiția 1.17.** Fie  $\mu$  o măsură pe  $\mathbf{C}$ . Spunem că o mulțime  $E$  din  $\mathbf{C}$  are *măsură finită* dacă și numai dacă  $\mu(E) < \infty$ . (vezi[64])

**Definiția 1.18.** Fie  $\mu$  o măsură pe  $\mathcal{C}$ . Spunem că o mulțime  $E$  din  $\mathcal{C}$  are măsură  $\sigma$ -finită dacă și numai dacă există o secvență de mulțimi  $\{E_n\}$  din  $\mathcal{C}$  astfel încât  $E \subset \bigcup_{n=1}^{\infty} E_n$  și  $\mu(E_n) < \infty$ ,  $n=1,2,\dots$  (vezi[64])

**Definiția 1.19.**  $\mu$  este finită, respectiv  $\sigma$ -finită dacă și numai dacă pentru orice  $E$  din  $\mathcal{C}$ , oricare  $\mu(E)$  este finită, respectiv  $\sigma$ -finită. (vezi[64])

**Definiția 1.20.**  $\mu$  este completă dacă și numai dacă  $E \in \mathcal{C}$ ,  $F \subset E$  și  $\mu(E) = 0$  implică  $F \in \mathcal{C}$ . (vezi[64])

### 1.1.2 Funcții măsurabile. Spații măsurabile

**Definiția 1.21.** Perechea  $(X, \mathbf{F})$  se numește spațiu măsurabil, unde  $\mathbf{F}$  este un  $\sigma$ -inel sau o  $\sigma$ -algebră. (vezi[64])

**Definiția 1.22.** Tripletul  $(X, \mathbf{F}, \mu)$  se numește spațiu măsurabil generalizat (spațiu măsurabil monoton), dacă  $(X, \mathbf{F})$  este un spațiu măsurabil și  $\mu : \mathbf{F} \rightarrow \overline{\mathbb{R}_+}$  este o măsură monotonă. (vezi[64])

Fie  $(X, \mathbf{F})$  un spațiu măsurabil,  $\mu : \mathbf{F} \rightarrow [0, \infty)$  o măsură monotonă (sau o măsură monotonă continuă, semicontinuă), și  $\mathbf{B}$  un câmp Borell pe  $(-\infty, \infty)$ .

**Definiția 1.23.** O funcție cu valori reale pe  $X$ ,  $f : X \rightarrow (-\infty, \infty)$ , este  $\mathbf{F}$ -măsurabilă (sau simplu "măsurabilă" dacă nu există confuzii) dacă și numai dacă

$$f^{-1}(B) = \{x | f(x) \in B\} \in \mathbf{F} \quad (1.1)$$

pentru orice mulțime Borel  $B \in \mathbf{B}$ . Mulțimea tuturor funcțiilor  $\mathbf{F}$ -măsurabile se notează cu  $\mathbf{G}$ . Mulțimea tuturor funcțiilor  $\mathbf{F}$ -măsurabile va fi notată cu  $\mathbb{M}_+(\mathbf{F})$ . (vezi[64])

**Teorema 1.2.**[vezi[64]] Dacă  $f : X \rightarrow (-\infty, \infty)$  este o funcție cu valori reale, atunci următoarele afirmații sunt echivalente:

- (1)  $f$  este măsurabilă;
- (2)  $\{x | f(x) \geq \alpha\} \in \mathbf{F}$  pentru oricare  $\alpha \in (-\infty, \infty)$ ;
- (3)  $\{x | f(x) > \alpha\} \in \mathbf{F}$  pentru oricare  $\alpha \in (-\infty, \infty)$ ;
- (4)  $\{x | f(x) \leq \alpha\} \in \mathbf{F}$  pentru oricare  $\alpha \in (-\infty, \infty)$ ;
- (5)  $\{x | f(x) < \alpha\} \in \mathbf{F}$  pentru oricare  $\alpha \in (-\infty, \infty)$ .

**Corolarul 1.1.**[vezi[64]] *Dacă  $f$  este o funcție măsurabilă, atunci  $\{x|f(x) = \alpha\} \in \mathbf{F}$  pentru oricare  $\alpha \in (-\infty, \infty)$ .*

**Teorema 1.3.**[vezi[64]] *Dacă  $\{f(n)\}$  este o secvență de funcții măsurabile, și*

$$\begin{aligned} h(x) &= \sup_n \{f_n(x)\}, \\ g(x) &= \inf_n \{f_n(x)\}, \end{aligned}$$

*pentru orice  $x \in X$ , atunci  $h$  și  $g$  sunt măsurabile.*

**Corolarul 1.2.**[vezi[64]] *Dacă  $\{f(n)\}$  este o secvență de funcții măsurabile, și*

$$\begin{aligned} \overline{f}(x) &= \overline{\lim}_n \{f_n(x)\}, \\ \underline{f}(x) &= \underline{\lim}_n \{f_n(x)\}, \end{aligned}$$

*atunci  $\overline{f}$  și  $\underline{f}$  sunt măsurabile. În plus, dacă există  $\lim_n f_n$ , atunci, este de asemenea măsurabilă.*

## 1.2 Integrala Choquet

Fie  $(X, \mathbf{F}, \mu)$  un spațiu măsurabil. în care,  $X$  este o mulțime nevidă,  $\mathbf{F}$  este o  $\sigma$ -algebră a submulțimilor lui  $X$ , și  $\mu : \mathbf{F} \rightarrow [0, \infty)$  este o măsură clasică, nonnegativă și  $\sigma$ -aditivă cu  $\mu(A) < \infty$  pentru cel puțin un  $A \in \mathbf{F}$ .  $X$  se numește mulțime universală și poate să nu fie neapărat finită. În acest capitol, presupunem că  $\mu$  este  $\sigma$ -finită, și că există  $\{A_i\} \subset \mathbf{F}$ , astfel încât  $\mu(A_i) < \infty$  pentru orice  $i = 1, 2, \dots$  și  $\cup_{i=1}^{\infty} A_i = X$ .(vezi[64])

**Definiția 1.24.** *O funcție  $s : X \rightarrow (-\infty, \infty)$  de forma  $\sum_{i=1}^m a_i \chi_{A_i}$  se numește funcție simplă, unde fiecare  $a_i$  este o constantă reală,  $A_i \in \mathbf{F}$ , și  $\chi_{A_i}$  este o funcție caracteristică a lui  $A_i$ ,  $i = 1, 2, \dots, m$ .(vezi[64])*

**Definiția 1.25.** *Fie  $f$  o funcție măsurabilă nonnegativă definită pe  $X$ . Integrala Lebesgue a lui  $f$  care respectă măsura  $\mu$  este definită astfel*

$$\int f d\mu = \lim_{j \rightarrow \infty} \int s_j d\mu = \lim_{j \rightarrow \infty} \sum_i^{m_j} a_{ji} \mu(A_{ji}) \quad (1.2)$$

*unde oricare  $s_j = \sum_i^{m_j} a_{ji} \chi_{A_{ji}}$  este o funcție simplă și  $\{s_j\}$  este un șir nedescrescător cu  $\lim_{j \rightarrow \infty} s_j = f$ .(vezi [64])*

**Definiția 1.26.** *Integrala Choquet a unei funcții măsurabile nonnegative  $f$  care respectă o măsură monotonă  $\mu$  pe o mulțime măsurabilă  $A$ , notată cu  $(C) \int_A f d\mu$ , este definită prin formula:*

$$(C) \int_A f d\mu = \int_0^\infty \mu(F_\alpha \cap A) d\alpha, \quad (1.3)$$

unde  $F_\alpha = \{x | f(x) \geq \alpha\}$  for  $\alpha \in [0, \infty)$ . Dacă  $A = X$ , atunci notația uzuală pentru  $(C) \int_X f d\mu$  este  $(C) \int f d\mu$ . (vezi[64])

**Teorema 1.4.**[vezi[64]] Fie  $\mu(A)$  finită. Atunci,

$$(c) \int_A f d\mu = \int_0^\infty \mu(F_{\alpha+} \cap A) d\alpha, \quad (1.4)$$

unde  $F_{\alpha+} = \{x | f(x) > \alpha\}$  pentru  $\alpha \in [0, \infty)$ .

Spre deosebire de integrala Lebesgue, integrala Choquet este în general nonliniară și respectă integrandul său datorită nonaditivității lui  $\mu$ . În acest sens, putem avea

$$(c) \int (f + g) d\mu \neq (C) \int f d\mu + (C) \int g d\mu \quad (1.5)$$

pentru anumite funcții măsurabile nonnegative  $f$  și  $g$ . (vezi[64])

**Teorema 1.5.**[vezi[64]] Fie  $f$  și  $g$  funcții măsurabile nonnegative pe  $(X, \mathbf{F}, \mu)$ ,  $A$  și  $B$  mulțimi măsurabile și fie  $a$  o constantă reală nonnegativă. Atunci,

- (1)  $(C) \int_A 1 d\mu = \mu(A)$
- (2)  $(C) \int_A f d\mu = (C) \int f \cdot \chi_A d\mu$
- (3) Dacă  $f \leq g$  pe  $A$ , atunci  $(C) \int_A f d\mu \leq (C) \int_A g d\mu$
- (4) Dacă  $A \subset B$  atunci  $(C) \int_A f d\mu \leq (C) \int_B f d\mu$ ;
- (5)  $(C) \int_A a f d\mu = a \cdot (C) \int_A f d\mu$

**Teorema 1.6.**[vezi[64]]  $(C) \int_A f d\mu = 0$  dacă  $\mu(\{x | f(x) > 0\} \cap A) = 0$ , a.î.,  $f = 0$  pe  $A$  aproape peste tot; invers, dacă măsura monotonă  $\mu$  este continuă inferior și  $(C) \int_A f d\mu = 0$ , atunci  $\mu(\{x | f(x) > 0\} \cap A) = 0$ .

**Teorema 1.7.**[vezi[64]] Pentru orice constantă  $c$  care satisface  $f + c \geq 0$ , avem:

$$(C) \int_A (f + c) d\mu = (C) \int_A f d\mu + c \cdot \mu(A). \quad (1.6)$$

Acum vom considera un spațiu general măsurabil.

Reamintim faptul că o funcție  $\mathbf{F}$ -simplu pozitivă este o funcție  $f : X \rightarrow \mathbf{R}_+$  de forma  $f = \sum_{i=1}^n a_i \varphi(A_i)$ , unde  $A_i \in \mathbf{F}$ ,  $a_i \in \mathbf{R}_+$  și  $\varphi(A_i)$  este funcția caracteristică(indicator) pe  $A_i$ , pentru orice  $i$ . Putem considera că mulțimile  $A_i$  sunt are reciproc disjuncte și că  $a_1 \leq a_2 \leq \dots \leq a_n$ . (vezi[64])

De asemenea, fie  $\mu : \mathbf{F} \rightarrow \mathbf{R}_+$  o măsură monotonă. Atunci, se poate demonstra că integrala Choquet a lui  $f$  care respectă  $\mu$  este egală cu  $(C) \int f d\mu = \sum_i^n (a_i - a_{i-1})\mu(A_i \cup A_{i+1} \cup \dots \cup A_n)$  cu convenția  $a_0 = 0$ . Această formulă este coerentă, a.î. valoarea pe care o furnizează depinde doar de  $f$ .(vezi[64])

Cea mai populară utilizare a formulei anterioare este în cazul  $X = \{1, 2, \dots, n\}$  și  $\mathbf{F} = \mathbf{P}(X)$ . Astfel, considerăm o permutare  $\{1_*, 2_*, \dots, n_*\}$  a lui  $\{1, 2, \dots, n\}$  astfel încât  $f(1_*) \leq f(2_*) \leq \dots \leq f(n_*)$  avem (cu convenția  $f(0_*) = 0$ ):

$$(C) \int f d\mu = \sum_i^n (f(i_*) - f((i-1)_*))\mu(i_*, (i+1)_*, \dots, n_*).(\text{vezi}[64])$$

### 1.3 Integrala Sugeno

Considerăm un spațiu monoton măsurabil  $(T, \mathcal{T}, \mu)$  și o funcție  $f \in M_+(\mathcal{T})$  a.î.  $f : T \rightarrow \mathbf{R}$  este măsurabilă și pozitivă. Pentru orice  $\alpha \in \mathbf{R}_+$  definim mulțimea

$$F_\alpha(f) = \{t \in T \mid f(t) \geq \alpha\} \in \mathcal{T}.$$

Scriem de multe ori  $F_\alpha$  în loc de  $F_\alpha(f)$ . Acest lucru ne permite să considerăm funcția  $\varphi : \mathbf{R}_+ \rightarrow \overline{\mathbf{R}}_+$ , dată prin  $\varphi(\alpha) = \mu(F_\alpha(f))$ , care este descrescătoare.(vezi[64])

Pentru oricare  $\emptyset \neq A \subset \mathbf{R}_+$ , scriem

$$\sup_{\alpha \in A} \alpha \wedge \mu(F_\alpha(f)) \stackrel{\text{def}}{=} \sup \{ \alpha \wedge \mu(F_\alpha(f)) \mid \alpha \in A \}.(\text{vezi}[64])$$

**Definiția 1.27.** Integrala Sugeno a lui  $f$  care respectă  $\mu$  este

$$(S) \int f d\mu \stackrel{\text{def}}{=} \sup_{\alpha \in [0, \infty)} \alpha \wedge \mu(F_\alpha(f)) \in \overline{\mathbf{R}}_+.(\text{vezi}[64])$$

În cazul  $(S) \int f d\mu < \infty$ , spunem că  $f$  este integrabilă Sugeno respectând  $\mu$ .(vezi[64])

Este clar că

$$\text{a) } (S) \int f d\mu = \sup_{\alpha \in (0, \infty)} \alpha \wedge \mu(F_\alpha(f)).(\text{vezi}[64])$$

b)  $(S) \int f d\mu \leq \mu(T)$ , prin urmare, în cazul  $\mu(T) < \infty$ , oricare  $f \in M_+(\mathcal{T})$  este integrabilă Sugeno respectând  $\mu$ .(vezi[64])

c) Dacă  $f, g$  sunt în  $M_+(\mathcal{T})$ ,  $f \leq g$ , avem

$$(S) \int f d\mu \leq (S) \int g d\mu.(\text{vezi}[64])$$

În consecință, dacă  $g$  este integrabilă Sugeno, rezultă că și  $f$  este integrabilă Sugeno.

d) Pentru oricare  $a \in \mathbf{R}_+$ , integrala Sugeno a funcției constante egală cu  $a$  este

$$(S) \int a d\mu = a \wedge \mu(T). (\text{vezi}[64])$$

**Teorema 1.8.**[vezi[64]] *Asumăm că  $f, g$  sunt integrabile Sugeno respectând  $\mu$ . În cazul în care există  $0 < \varepsilon < \infty$  astfel încât  $|f(x) - g(x)| \leq \varepsilon$  pentru orice  $x \in T$ , avem*

$$\left| (S) \int f d\mu - (S) \int g d\mu \right| \leq \varepsilon.$$

**Corolarul 1.3.**[vezi[64]] *Fie  $(f_n)_n$  un șir de funcții integrabile Sugeno care respectă  $\mu$  și fie  $f$  o funcție integrabilă Sugeno care respectă  $\mu$ . Asumăm că  $f_n \xrightarrow[n]{u} f$ . Atunci*

$$(S) \int f_n d\mu \xrightarrow[n]{} (S) \int f d\mu.$$

**Teorema 1.9.**[vezi[64]] *Asumăm că  $\mu$  este continuă inferior. Atunci, pentru orice șir  $(f_n)_n \subset M_+(\mathcal{T})$  și pentru orice  $f \in M_+(\mathcal{T})$  astfel încât  $f_n \nearrow_n f$ , avem*

$$(S) \int f d\mu = \lim_n (S) \int f_n d\mu = \sup_n (S) \int f_n d\mu.$$

Integrala Sugeno este nonliniară, nefiind (pozitivă) omogenă.

## Chapter 2

# Aplicație în economie a integralei Choquet: În căutarea Investitorilor Virtuali

În acest capitol descriem un model matematic nou, de decizie, bazat pe teoria fuzzy, mai exact, bazat pe integrala Choquet.

Modelul nostru poate fi folosit în diverse situații de decizie, în diverse domenii ale economiei, dar noi am ales pentru cercetările noastre rezultatele dintr-un anumit domeniu al economiei, mai exact, din domeniul pieței de capital.

În cele ce urmează, vom descrie cum anume am folosit integrala Choquet în domeniul pieței de capital. Mai exact, vom descrie un model matematic de decizie folosit pentru a selecta cei mai probabili viitori clienți investitori (investitori virtuali) ai unei anumite companii de brokeraj din cadrul pieței de capital. Am lucrat în colaborare cu o companie numită Confident Invest. Aceasta este o companie de brokeraj din cadrul pieței de capital din România.

Rezultatele prezentate au fost publicate în [12].

### 2.1 Introducere

Confident Invest încearcă să găsească răspunsurile la două întrebări prin interpretarea răspunsurilor la alte întrebări pe care compania le solicită, în mod legal. Mai exact, compania realizează profilurile de risc ale clienților prin aplicarea unui chestionar. Profilele de risc ale clientului se realizează prin furnizarea a 15 întrebări, fiecare cu 4 tipuri de răspunsuri, de la dezacordul total până la acordul absolut. Răspunsurile sunt reprezen-

tate prin numere întregi de la 0 la 3. Astfel, 0 reprezintă dezacord total și 3 reprezintă acord absolut. Ținta noastră a fost să determinăm răspunsul la întrebarea cheie „Rareori îmi fac griji pentru finanțe”, pe baza răspunsurilor la chestionar.

Confident Invest ne-a oferit răspunsurile la întrebările pentru 60 de potențiali investitori, precum și valorile pragurilor prealocate pentru a putea calcula valorile țintă. Pentru a calcula valorile, am creat un program C++.

## 2.2 Rezultate

### 2.2.1 Setări Generale

În continuare,  $(I, \Sigma)$  va fi un spațiu măsurabil și  $\mu : \Sigma \rightarrow \mathbb{R}_+$  va fi o măsură monotonă. Pentru orice  $i \in I$ , vom considera o mulțime nevidă  $X_i$  și fie  $X \stackrel{\text{def}}{=} \prod_{i \in I} X_i$ . De asemenea, pentru orice  $i \in I$ , fie funcția  $\nu_i : X_i \rightarrow \mathbb{R}_+$ . Apoi, pentru orice  $x = (x_i)_{i \in I}$ , considerăm funcția  $f_x : I \rightarrow \mathbb{R}_+$ , dată prin  $f_x(i) = \nu_i(x_i)$ .

Presupunerea noastră majoră va fi că, pentru orice  $x \in X$ , funcția  $f_x$  este integrabilă Choquet respectând măsura  $\mu$ .

Integrala Choquet  $(C) \int f_x d\mu$ , calculată pentru toți  $x \in \prod_{i \in I} X_i$ , va fi instrumentul nostru de extragere a datelor (de fuziune).

### 2.2.2 Prospectarea Investitorilor Virtuali

Considerăm  $I = \{1, 2, \dots, n\}$ ,  $n \in \mathbb{N}$ , ca fiind mulțimea indecșilor asigurați întrebărilor la care posibili investitori sunt rugați să răspundă. Caz numeric  $n = 15$ .

Spațiul nostru măsurabil este  $(I, \Sigma)$ , cu  $I$  descris mai sus și cu  $\Sigma = \mathcal{P}(I)$ .

Acceptăm existența unei măsuri monotone  $\mu : \Sigma \rightarrow \mathbb{R}_+$ . Cazul numeric pentru  $\mu$  este dat în cele ce urmează.

$$\mu(E) = \begin{cases} 0 & \text{dacă } E = \emptyset \\ 0.3 & \text{dacă } 0 < |E| \leq 4 \\ 0.5 & \text{dacă } 4 < |E| \leq 10 \\ 0.7 & \text{dacă } 10 < |E| \leq 14 \\ 1 & \text{dacă } |E| = 15 \end{cases} \quad (2.1)$$

Pentru orice  $i \in I$ ,  $X_i$  va exista mulțimea finită a tuturor răspunsurilor posibile la întrebarea numărul  $i$ . Deci, orice posibil investor  $x$  care va răspunde la setul de în-

trebări, va fi identificat astfel:  $x \equiv (x_i)_{i \in I} = (x_1, x_2, \dots, x_n)$ . Aici, pentru orice  $i \in I$ ,  $x_i$  este răspunsul dat de  $x$  la întrebarea numărul  $i$ .

Caz numeric: pentru orice  $i \in I$ , avem  $\nu_i(X_i) \subset \{0, 1, 2, 3\}$ . Semnificația fiind  $\nu_i(t) = 0$  pentru "total neadevărat",  $\nu_i(t) = 1$  pentru "parțial adevărat",  $\nu_i(t) = 2$ , pentru "în general adevărat",  $\nu_i(t) = 3$  pentru "total adevărat".

Procedură: Pentru orice posibil investitor  $x \equiv (x_1, x_2, \dots, x_n)$ , formăm funcția  $f_x : I \rightarrow \mathbb{R}_+$  dată prin  $f_x(i) = \nu_i(x_i)$ . "Disponibilitatea" unui posibil investitor  $x$  pentru a deveni un investitor real este evaluată prin numărul

$$\nu(x) \stackrel{\text{def}}{=} (C) \int f_x(i) d\mu(i) = (C) \int \nu_i(x_i) d\mu(i). \quad (2.2)$$

Decizia (previziunea) cu privire la posibilitatea ca  $x$  să devină un client investitor real se va lua cu ajutorul următoarelor praguri:

$$\begin{aligned} \nu(x) \in [0, 0.5) &\rightarrow x \text{ este un investitor sigur} \\ \nu(x) \in [0.5, 1) &\rightarrow x \text{ este un investitor potențial} \\ \nu(x) \in [1, 2) &\rightarrow x \text{ este un investitor neutru} \\ \nu(x) \in [2, 3] &\rightarrow x \text{ este un investitor slab (aproape} \\ &\text{niciodată, } x \text{ nu va investi).} \end{aligned} \quad (2.3)$$

### 2.2.3 Caz Numeric și Concluzii

Testul (chestionarul):

1. Îmi păstrez toate e-mailurile.
2. Materia mea preferată la școală a fost matematica.
3. Prefer să fac ordine în garderobă decât să mă uit la televizor.
4. Prefer să lucrez singur decât să lucrez în echipă.
5. Mă consider independent.
6. În general, organizez evenimentul când sunt invitat cină sau la film.
7. Sunt deranjat de oamenii care nu muncesc din greu.
8. Nu las niciodată nimic neterminat.

9. În general, nu conduc foarte repede.
10. Nu-mi plac sporturile competitive.
11. Nu-mi place să mă uit la filme de groază.
12. Nu sunt dornic să văd oameni noi.
13. Nu sunt niciodată anxios când aștept liftul.
14. Nu port niciodată lucruri la modă.
15. Nu sunt acuzat niciodată că am un temperament coleric.

Răspunsurile clienților:

Table 2.1: Răspunsurile clienților

| Nr | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 |
|----|---|---|---|---|---|---|---|---|---|----|----|----|----|----|----|
| 1  | 1 | 1 | 0 | 2 | 2 | 1 | 2 | 2 | 2 | 0  | 0  | 1  | 0  | 0  | 1  |
| 2  | 2 | 3 | 1 | 2 | 1 | 1 | 2 | 2 | 2 | 1  | 2  | 1  | 0  | 1  | 3  |
| 3  | 2 | 1 | 1 | 2 | 3 | 2 | 3 | 3 | 1 | 0  | 1  | 1  | 1  | 1  | 1  |
| 4  | 2 | 3 | 2 | 1 | 1 | 1 | 1 | 1 | 1 | 0  | 1  | 1  | 0  | 2  | 1  |
| 5  | 1 | 1 | 0 | 0 | 2 | 2 | 1 | 1 | 2 | 1  | 3  | 0  | 1  | 0  | 1  |
| 6  | 0 | 2 | 0 | 1 | 2 | 2 | 3 | 3 | 0 | 1  | 0  | 1  | 0  | 1  | 1  |
| 7  | 0 | 1 | 2 | 1 | 3 | 0 | 1 | 2 | 2 | 0  | 1  | 0  | 0  | 1  | 1  |
| 8  | 3 | 0 | 1 | 0 | 2 | 0 | 0 | 1 | 0 | 1  | 0  | 0  | 0  | 0  | 2  |
| 9  | 3 | 0 | 2 | 0 | 1 | 0 | 2 | 3 | 2 | 0  | 1  | 0  | 2  | 1  | 1  |
| 10 | 1 | 0 | 2 | 2 | 2 | 0 | 2 | 3 | 3 | 3  | 3  | 2  | 1  | 1  | 0  |
| 11 | 0 | 1 | 0 | 1 | 2 | 0 | 1 | 1 | 1 | 0  | 1  | 2  | 1  | 1  | 1  |
| 12 | 0 | 0 | 2 | 1 | 3 | 0 | 1 | 2 | 3 | 0  | 0  | 0  | 1  | 0  | 2  |
| 13 | 0 | 0 | 2 | 0 | 1 | 0 | 2 | 0 | 1 | 2  | 0  | 0  | 0  | 0  | 0  |
| 14 | 2 | 1 | 0 | 0 | 2 | 1 | 2 | 1 | 0 | 0  | 1  | 1  | 0  | 1  | 3  |
| 15 | 1 | 0 | 1 | 1 | 2 | 1 | 0 | 3 | 1 | 1  | 1  | 0  | 1  | 0  | 1  |
| 16 | 2 | 2 | 3 | 0 | 2 | 2 | 2 | 2 | 1 | 1  | 2  | 0  | 2  | 0  | 2  |

Table 2.1: Răspunsurile clienților

| Nr | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 |
|----|---|---|---|---|---|---|---|---|---|----|----|----|----|----|----|
| 17 | 2 | 0 | 1 | 2 | 2 | 1 | 1 | 2 | 0 | 0  | 3  | 1  | 0  | 0  | 1  |
| 18 | 0 | 0 | 0 | 0 | 0 | 3 | 3 | 3 | 0 | 3  | 3  | 3  | 0  | 0  | 1  |
| 19 | 1 | 0 | 2 | 0 | 3 | 0 | 2 | 3 | 0 | 0  | 3  | 0  | 0  | 1  | 2  |
| 20 | 0 | 2 | 1 | 2 | 3 | 2 | 3 | 2 | 1 | 0  | 0  | 0  | 0  | 0  | 0  |
| 21 | 2 | 1 | 1 | 3 | 2 | 1 | 3 | 3 | 0 | 1  | 1  | 0  | 1  | 0  | 0  |
| 22 | 1 | 0 | 3 | 3 | 3 | 2 | 2 | 3 | 0 | 0  | 3  | 0  | 0  | 0  | 2  |
| 23 | 0 | 3 | 0 | 0 | 3 | 2 | 2 | 2 | 3 | 0  | 3  | 0  | 0  | 0  | 1  |
| 24 | 1 | 3 | 1 | 1 | 2 | 1 | 1 | 0 | 2 | 0  | 3  | 1  | 1  | 1  | 1  |
| 25 | 1 | 1 | 0 | 2 | 2 | 2 | 2 | 2 | 1 | 1  | 1  | 1  | 2  | 2  | 1  |
| 26 | 3 | 3 | 0 | 1 | 2 | 0 | 1 | 3 | 3 | 3  | 3  | 0  | 1  | 0  | 2  |
| 27 | 1 | 3 | 1 | 3 | 3 | 0 | 1 | 1 | 1 | 3  | 3  | 1  | 2  | 0  | 1  |
| 28 | 0 | 0 | 1 | 0 | 0 | 0 | 1 | 1 | 1 | 1  | 3  | 0  | 1  | 0  | 3  |
| 29 | 3 | 0 | 3 | 0 | 3 | 0 | 3 | 3 | 2 | 0  | 2  | 1  | 1  | 0  | 1  |
| 30 | 0 | 3 | 1 | 1 | 3 | 1 | 3 | 3 | 3 | 0  | 0  | 3  | 1  | 1  | 1  |
| 31 | 0 | 0 | 1 | 0 | 3 | 2 | 2 | 2 | 2 | 3  | 1  | 1  | 2  | 0  | 3  |
| 32 | 0 | 0 | 2 | 2 | 1 | 2 | 1 | 1 | 2 | 0  | 0  | 1  | 2  | 0  | 0  |
| 33 | 1 | 3 | 2 | 0 | 0 | 1 | 2 | 3 | 1 | 0  | 1  | 1  | 3  | 3  | 2  |
| 34 | 1 | 1 | 3 | 3 | 3 | 2 | 1 | 2 | 3 | 1  | 3  | 3  | 3  | 3  | 1  |
| 35 | 2 | 2 | 1 | 0 | 1 | 1 | 2 | 2 | 1 | 1  | 2  | 0  | 1  | 2  | 0  |
| 36 | 0 | 0 | 2 | 0 | 3 | 1 | 1 | 2 | 1 | 0  | 0  | 0  | 1  | 0  | 0  |
| 37 | 0 | 1 | 2 | 0 | 3 | 0 | 3 | 2 | 0 | 0  | 0  | 0  | 1  | 0  | 0  |
| 38 | 2 | 2 | 2 | 2 | 2 | 1 | 2 | 2 | 1 | 1  | 3  | 1  | 1  | 1  | 1  |
| 39 | 3 | 0 | 0 | 0 | 3 | 0 | 1 | 3 | 1 | 0  | 2  | 1  | 1  | 0  | 2  |
| 40 | 3 | 0 | 2 | 0 | 1 | 0 | 1 | 3 | 1 | 0  | 2  | 0  | 2  | 0  | 2  |
| 41 | 1 | 0 | 0 | 0 | 3 | 2 | 2 | 3 | 1 | 0  | 0  | 0  | 1  | 0  | 0  |
| 42 | 1 | 3 | 0 | 2 | 2 | 1 | 1 | 1 | 1 | 1  | 1  | 1  | 0  | 0  | 0  |
| 43 | 1 | 0 | 0 | 0 | 0 | 2 | 1 | 1 | 3 | 1  | 1  | 0  | 1  | 2  | 2  |

Table 2.1: Răspunsurile clienților

| Nr | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 |
|----|---|---|---|---|---|---|---|---|---|----|----|----|----|----|----|
| 44 | 2 | 0 | 2 | 1 | 2 | 0 | 1 | 2 | 1 | 0  | 3  | 0  | 2  | 1  | 1  |
| 45 | 2 | 0 | 0 | 0 | 1 | 2 | 2 | 2 | 3 | 2  | 3  | 0  | 2  | 2  | 0  |
| 46 | 1 | 3 | 0 | 1 | 2 | 2 | 2 | 3 | 1 | 0  | 3  | 0  | 2  | 0  | 1  |
| 47 | 1 | 1 | 3 | 0 | 2 | 1 | 2 | 2 | 0 | 0  | 0  | 1  | 1  | 0  | 0  |
| 48 | 0 | 2 | 1 | 0 | 1 | 2 | 0 | 2 | 0 | 3  | 3  | 0  | 0  | 0  | 3  |
| 49 | 1 | 1 | 0 | 2 | 2 | 1 | 1 | 0 | 1 | 0  | 3  | 2  | 1  | 0  | 2  |
| 50 | 0 | 0 | 0 | 0 | 1 | 3 | 3 | 2 | 0 | 0  | 0  | 0  | 0  | 0  | 0  |
| 51 | 2 | 1 | 0 | 1 | 3 | 1 | 1 | 0 | 0 | 2  | 2  | 1  | 2  | 1  | 3  |
| 52 | 2 | 1 | 2 | 1 | 2 | 0 | 0 | 2 | 1 | 1  | 3  | 1  | 2  | 0  | 2  |
| 53 | 2 | 2 | 1 | 3 | 1 | 1 | 1 | 2 | 2 | 2  | 3  | 1  | 2  | 2  | 1  |
| 54 | 0 | 3 | 1 | 0 | 1 | 0 | 2 | 1 | 0 | 1  | 0  | 0  | 0  | 0  | 0  |
| 55 | 1 | 0 | 0 | 1 | 3 | 1 | 1 | 2 | 2 | 1  | 2  | 0  | 1  | 0  | 2  |
| 56 | 0 | 3 | 3 | 0 | 2 | 0 | 1 | 3 | 1 | 0  | 3  | 0  | 0  | 0  | 2  |
| 57 | 1 | 1 | 2 | 1 | 3 | 0 | 1 | 3 | 1 | 0  | 3  | 0  | 1  | 0  | 2  |
| 58 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 0 | 2 | 1  | 3  | 2  | 0  | 0  | 1  |
| 59 | 2 | 2 | 1 | 1 | 1 | 3 | 2 | 1 | 3 | 1  | 3  | 0  | 1  | 1  | 0  |
| 60 | 2 | 2 | 2 | 0 | 0 | 1 | 2 | 3 | 2 | 1  | 0  | 0  | 1  | 0  | 1  |

Rezultate și concluzii:

Table 2.2: Rezultate și concluzii

| Nr | Valoare | Tipul investitorului |
|----|---------|----------------------|
| 1  | 0.8     | investor potențial   |
| 2  | 1.5     | investor neutru      |
| 3  | 1.3     | investor neutru      |
| 4  | 1.3     | investor neutru      |
| 5  | 1.1     | investor neutru      |

Table 2.2: Rezultate și concluzii

| Nr | Valoare | Tipul investitorului |
|----|---------|----------------------|
| 6  | 1.1     | investor neutru      |
| 7  | 1.1     | investor neutru      |
| 8  | 1.3     | investor neutru      |
| 9  | 1.3     | investor neutru      |
| 10 | 1.3     | investor neutru      |
| 11 | 1.2     | investor neutru      |
| 12 | 1.3     | investor neutru      |
| 13 | 0.6     | investor potențial   |
| 14 | 1.5     | investor neutru      |
| 15 | 1.1     | investor neutru      |
| 16 | 1.3     | investor neutru      |
| 17 | 1.1     | investor neutru      |
| 18 | 1.5     | investor neutru      |
| 19 | 1.3     | investor neutru      |
| 20 | 0.9     | investor potențial   |
| 21 | 1.1     | investor neutru      |
| 22 | 1.3     | investor neutru      |
| 23 | 1.1     | investor neutru      |
| 24 | 1.3     | investor neutru      |
| 25 | 1.2     | investor neutru      |
| 26 | 1.3     | investor neutru      |
| 27 | 1.3     | investor neutru      |
| 28 | 1.5     | investor neutru      |
| 29 | 1.1     | investor neutru      |
| 30 | 1.7     | investor neutru      |
| 31 | 1.5     | investor neutru      |
| 32 | 1       | investor neutru      |

Table 2.2: Rezultate și concluzii

| Nr | Valoare | Tipul investitorului |
|----|---------|----------------------|
| 33 | 1.7     | investor neutru      |
| 34 | 2       | investor slab        |
| 35 | 1       | investor neutru      |
| 36 | 1.1     | investor neutru      |
| 37 | 1.1     | investor neutru      |
| 38 | 1.6     | investor neutru      |
| 39 | 1.3     | investor neutru      |
| 40 | 1.3     | investor neutru      |
| 41 | 1.1     | investor neutru      |
| 42 | 1.1     | investor neutru      |
| 43 | 1.3     | investor neutru      |
| 44 | 1.3     | investor neutru      |
| 45 | 1.3     | investor neutru      |
| 46 | 1.3     | investor neutru      |
| 47 | 1.1     | investor neutru      |
| 48 | 1.5     | investor neutru      |
| 49 | 1.3     | investor neutru      |
| 50 | 0.9     | investor potențial   |
| 51 | 1.7     | investor neutru      |
| 52 | 1.3     | investor neutru      |
| 53 | 1.8     | investor neutru      |
| 54 | 0.9     | investor potențial   |
| 55 | 1.3     | investor neutru      |
| 56 | 1.3     | investor neutru      |
| 57 | 1.3     | investor neutru      |
| 58 | 1.3     | investor neutru      |
| 59 | 1.1     | investor neutru      |

Table 2.2: Rezultate și concluzii

| Nr | Valoare | Tipul investitorului |
|----|---------|----------------------|
| 60 | 1.1     | investor neutru      |

## Chapter 3

# Aplicații în psihologie ale integralei Choquet

În acest capitol, prezentăm câteva modele matematice bazate pe teoria fuzzy în domeniul psihologiei. Mai precis, descriem modul în care am folosit integrala Choquet pentru a determina nivelul de Deschidere și nivelul de Anxietate pentru anumiți subiecți voluntari utilizați în cercetarea noastră.

Am lucrat în colaborare cu psihologii Institutului de Studii, Cercetare, Dezvoltare și Inovare al Universității Titu Maiorescu din București, precum și cu specialiști ai Academiei Tehnice Militare din București.

Specialiștii în psihologie cu care am colaborat au realizat diverse studii privind undele EEG, măsurători specifice psihologice, modelul BigFive, deschiderea, anxietatea (vezi [7], [15], [30], [31], [32], [49], [50], [51], [53], [54], [61]).

Specialiștii în psihologie afirmă că Deschiderea se caracterizează prin undele EEG Delta și MidGamma (vezi [44]).

Studiile psihologilor arată că există o relație interactivă între Anxietate și doi factori din teoria Big Five, și anume extraversia și nevroticismul. Mai exact, Anxietatea are o relație pozitivă cu nevroticismul și o relație negativă cu extraversia (vezi [22], [44]).

Specialiștii în psihologie cu care am colaborat indică faptul că anxietatea se caracterizează prin undele LowAlpha, HighAlpha, LowBeta și HighBeta.

Menționăm că am plecat de la premisa că studiile, descoperirile și datele furnizate de specialiștii în psihologie cu care am colaborat sunt certe, că modelele matematice descrise în acest capitol sunt fixe, ele putând fi ușor adaptate noilor descoperiri ale psihologilor în domeniile studiate de noi.

Rezultatele prezentate aici au fost publicate în [14],[23], [24], [25], [26].

### 3.1 Deschiderea

În acest subcapitol descriem două metode prin care se determină nivelul de Deschidere al unor subiecți:

- a) determinarea unei măsuri și utilizarea ei pentru a afla nivelul de Deschidere al subiecților;
- b) folosind mai multe măsuri cunoscute pentru a afla nivelul de Deschidere al subiecților.

Ca tehnică matematică, integralele neliniare sunt utilizate ca a instrument de fuziune.

#### 3.1.1 Determinarea unei măsuri și utilizarea ei pentru a afla nivelul de Deschidere al subiecților

##### 3.2.1.1 Un model matematic care caracterizează nivelul de Deschidere

Aici descriem o procedură de calculare a unei măsuri (un instrument de agregare), prin utilizarea datelor rezultate din măsurători și concluziile asupra subiecților în ceea ce privește deschiderea.

Demonstrația detaliată a acestei proceduri poate fi găsită în subsecțiunea 3.3.2.

Rezultatele prezentate aici au fost publicate în [24].

#### STABILIREA PROBLEMEI

Considerăm  $X = \{x_1, x_2, \dots, x_n\}$  o mulțime de surse de informații, numite atribute.

Informațiile numerice preluate din toate atributele pot fi privite ca o funcție

$f : X \rightarrow (-\infty, \infty)$  numită observator sau înregistrare a atributelor care vor fi scrise  $f(x_1), \dots, f(x_n)$ .

Dacă facem  $l$  observații, anume  $f_1, \dots, f_l$  cu  $f_i : X \rightarrow \mathbb{R}$ , vom avea tabelul complet de date:

$$\begin{pmatrix} f_1(x_1) & f_1(x_2) \cdots & f_1(x_n) & y_1 \\ f_2(x_1) & f_2(x_2) \cdots & f_2(x_n) & y_2 \\ \vdots & \vdots \cdots & \vdots & \vdots \\ f_l(x_1) & f_l(x_2) \cdots & f_l(x_n) & y_l \end{pmatrix} \text{ unde orice } y_i \in \mathbb{R}, i = 1, 2, \dots, l \text{ este informația cuprinsă.}$$

Anume, pentru datele de intrare  $f_1(x_1), \dots, f_l(x_n)$  vom obține o ieșire și anume  $y_i$ . Numim  $l$  dimensiunea bazei de date.

Lucrăm în cazul particular în care instrumentul de fuziune este integrala Choquet.

Mai exact, pentru orice  $i = 1, 2, \dots, l$  avem

$$y_i = (C) \int f_i dy$$

unde  $y$  este o măsură monotonă  $y : \mathcal{P}(T) \rightarrow R_+$ .

În cazul nostru, avem două variabile, anume undele Delta și MidGamma ( $n=2$ ).

În plus, avem  $l$  măsurători, mai exact mediile măsurărilor efectuate pe 80 de subiecți ( $l=80$ ).

Cunoaștem valorile de intrare  $f_i(x_j)$ ,  $i = 1, 2, \dots, l$ ;  $j = 1, 2, \dots, n$  și valorile de ieșire  $y_i$ :  $i = 1, 2, \dots, l$ .

Prin anumite mijloace, încercăm să determinăm măsura  $y$ , anume încercăm să determinăm valorile lui  $y(E)$ ,

$E \in \mathcal{P}^*(T)$  unde  $\mathcal{P}^*(T) = \{E \subset T | E \neq \emptyset\}$ . Este evident că  $\mathcal{P}^*(T)$  are  $2^n - 1$  elemente.

În cazul nostru, valorile de ieșire sunt reprezentate de clasificările date de psihologi referitoare la fiecare subiect.

Acestea sunt reprezentate prin grade de la 0 la 6.

Orice număr  $j \in \{1, 2, \dots, 2^n - 1\}$  se poate scrie într-o unică reprezentare binară

$$j = \overline{j_n j_{n-1} \dots j_1} \quad \left( \stackrel{\text{def}}{=} \right) j_1 + 2j_2 + 2^2j_3 + \dots + 2^{n-1}j_n = 2^{n-1}j_n + 2^{n-2}j_{n-1} + \dots + 2j_2 + j_1$$

(cel puțin un  $j_i \neq 0$ ,  $j_i \in \{0, 1\}$ ).

Deci, cele  $t = 2^n - 1$  mulțimi  $E \in \mathcal{P}^*(T)$  vor fi numerotate astfel:

$$E_1, E_2, \dots, E_{2^n-1}.$$

Astfel, dacă avem  $E_j$ , cu  $j = \overline{j_n j_{n-1} \dots j_1}$ , regula de apartenență este  $x_i \in E_j$  dacă și numai dacă  $j_i = 1$ .

Fie formula alternativă:

$$(C) \int f dy = \sum_{j=0}^{2^n-1} b_j y(E_j) \quad (1)$$

unde pentru orice  $j=1, 2, \dots, n$ ,

$$b_j = \begin{cases} \min_{x_i \in E_j} f(x_i) - \max_{x_i \in T \setminus E_j} f(x_i), & \text{dacă } \min_{x_i \in E_j} f(x_i) - \max_{x_i \in T \setminus E_j} f(x_i) \geq 0 \\ 0, & \text{dacă } \min_{x_i \in E_j} f(x_i) - \max_{x_i \in T \setminus E_j} f(x_i) < 0 \end{cases}$$

cu convenția  $\max_{x \in \emptyset} f(x) = 0$  (pentru  $E_{2^n-1} = T$ ).

Prin urmare, putem considera un sistem de  $l$  ecuații cu  $t$  necunoscute (în cazul nostru  $t=2^n - 1$ , elementele necunoscute fiind  $y(E_j)$ ,  $j=1, 2, \dots, 2^n - 1$ ) :

$$\sum_{j=1}^t b_{pj} y(E_j) = y_p$$

Acest sistem apare deoarece pentru  $p=1, 2, \dots, t$ , avem  $y_p = (C) \int f_p dy = \sum_{j=1}^t b_{pj} y(E_j)$  (2). Mai precis,  $b_{pj}$  este  $b_j$  din (1) pentru  $f_p$  în loc de  $f$ .

Rezolvând problema (aproximativ) de la (2) rezultă:

$$X = \begin{pmatrix} b_{11} & b_{12} \dots & b_{1t} \\ b_{21} & b_{22} \dots & b_{2t} \\ \dots & \dots & \dots \\ b_{l1} & b_{l2} \dots & b_{lt} \end{pmatrix}$$

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_l \end{pmatrix}$$

Luăm în considerare soluția (avem o soluție aproximativă)

$$A = \begin{pmatrix} t_1^0 \\ t_2^0 \\ \vdots \\ t_t^0 \end{pmatrix}$$

Atunci  $X^T X A = X^T Y$  (3)

Lucrăm pentru  $l \geq m$  și considerăm că  $X^T X$  este non-singulară, putem deduce din (3)

$$A = (X^T X)^{-1} X^T Y \quad (4)$$

Rezultatul returnat (care reprezintă măsura) de către programul C++:

$$\mu(E) = \begin{cases} 0, & E = \emptyset \\ 0.00000250551, & E = \{x_1\} \\ 0, & E = \{x_2\} \\ 0.00000564078, & E = \{x_1, x_2\} \end{cases}$$

Am verificat dacă măsurarea calculată este monotonă. În acest caz vorbim despre una monotonă.

### 3.2.1.2 Utilizarea unei măsuri generalizate pentru a determina nivelul de Deschidere

Descriem aici o procedură de calculare a nivelului de deschidere pentru anumiți subiecți, folosind o măsură obținută prin procedura descrisă în 3.2.1.1. Aceste niveluri de deschidere calculate au fost comparate cu clasificările obținute de psihologi prin teste standard.

Rezultatele prezentate aici au fost publicate în [26].

## INTRODUCERE

Am folosit procedura descrisă în Subsect. 3.2.1.1, cu valorile undelor EEG pentru 80 de subiecți și am calculat următoarea măsură:

$$\mu(E) = \begin{cases} 0, & E = \emptyset \\ 0.0000143333, & E = \{x_1\} \\ 0.0000406178, & E = \{x_2\} \\ 0.0000471675, & E = \{x_1, x_2\} \end{cases}$$

Valorile de ieșire sunt reprezentate de clasificări date de psihologi pentru subiecți. Acestea sunt reprezentate prin note de la 0 la 100.

## DESCRIEREA REZULTATELOR

Am folosit măsura obținută  $\mu$  pentru a decide nivelul de deschidere pentru 10 noi subiecți.

Folosind formula  $y_p = (C) \int f_p d\mu$ , obținem rezultatele:

Table 3.1: Rezultate

| Nr | Valorile Calculate | Rezultatele psihologilor |
|----|--------------------|--------------------------|
| 1  | 16.8855            | 20                       |
| 2  | 0.0000406178       | 0                        |
| 3  | 3.93688            | 5                        |
| 4  | 21.251             | 20                       |
| 5  | 11.8435            | 10                       |
| 6  | 1.36402            | 2                        |
| 7  | 13.82312           | 20                       |
| 8  | 18.3126            | 20                       |
| 9  | 16.3625            | 20                       |
| 10 | 39.0766            | 40                       |

### 3.1.2 Utilizarea mai multor măsuri cunoscute pentru a afla nivelul de Deschidere al subiecților

#### 3.2.2.1 O metodă de diagnosticare a Deschiderii folosind integralele nonliniare

Descriem un model matematic prin care se procesează nivelul undelor de tip EEG, pentru a caracteriza nivelul de deschidere. Ideea noastră a fost să folosim integrala Choquet care respectă o măsură monotonă. Luăm în considerare datele rezultate din măsurătorile undelor EEG pentru un grup de subiecți. Descriem o procedură prin care utilizând diferite măsuri monotone (obținute prin procedura descrisă la 3.2.1.1.) calculăm nivelul de deschidere al unui subiect folosind integrala Choquet. Pentru fiecare pacient avem nivelul de deschidere dat de psihologi. Comparăm rezultatele obținute prin aceasta metodă cu rezultatele psihologilor. Dintre toate măsurile utilizate, alegem măsura care oferă cele mai apropiate rezultate de cele reale.

Rezultatele prezentate aici au fost publicate în [23].

#### DETERMINAREA GRADULUI DE DESCHIDERE

Am făcut  $l=14$  măsurători. Acestea sunt cele  $l=14$  funcții  $f_1, f_2, \dots, f_{14}$ . Cele  $n=2$  atribute măsurate sunt  $x_1 = \text{Delta}$ ,  $x_2 = \text{MidGamma}$ .

Anume, pentru fiecare dintre cele 14 măsurători (linii), am obținut valorile de intrare  $f_p(x_1), f_p(x_2)$  și valorile de ieșire  $y_p$ ,  $p = 1, 2, \dots, 14$ .

Valorile de intrare sunt mediile măsurătorilor efectuate pe 14 subiecți. Valorile de ieșire sunt obținute folosind clasificarea dată de către psihologi subiecților (măsurați individual). Aceste valorile de ieșire sunt reprezentate prin note, de la 0 la 100.

Am considerat  $t = 8$  măsuri monotone. Utilizând fiecare măsură  $\mu_k$  ( $k = 1, t$ ), pentru fiecare subiect  $p$ , am calculat nivelul de deschidere  $z_{k,p}$  ( $k = 1, \dots, t$  and  $p = 1, \dots, 14$ ). Pentru oricare  $k = 1, t$  și pentru oricare  $p = 1, 14$  avem:

$$z_{k,p} = (C) \int f_p d\mu_k$$

Pentru fiecare măsură  $\mu_k$ , am comparat prin Metoda celor mai mici pătrate, rezultatele obținute prin metoda noastră cu rezultatele obținute de către psihologi. De fapt, pentru fiecare măsură  $\mu_k$ , am calculat  $E_k = \sum_{p=1}^{14} (z_{k,p} - y_p)^2$ .

Am considerat măsurile:

$$\mu_1(E) = \begin{cases} 0, & E = \emptyset \\ 0.0000143333, & E = \{x_1\} \\ 0.0000406178, & E = \{x_2\} \\ 0.0000471675, & E = \{x_1, x_2\} \end{cases},$$

$$\mu_2(E) = \begin{cases} 0, & E = \emptyset \\ 0.0000245333, & E = \{x_1\} \\ 0.0000507178, & E = \{x_2\} \\ 0.00671685, & E = \{x_1, x_2\} \end{cases},$$

$$\mu_3(E) = \begin{cases} 0, & E = \emptyset \\ 0.000014, & E = \{x_1\} \\ 0.00004, & E = \{x_2\} \\ 0.000047, & E = \{x_1, x_2\} \end{cases},$$

$$\mu_4(E) = \begin{cases} 0, & E = \emptyset \\ 0.001, & E = \{x_1\} \\ 0.00004, & E = \{x_2\} \\ 0.002, & E = \{x_1, x_2\} \end{cases},$$

$$\mu_5(E) = \begin{cases} 0, & E = \emptyset \\ 0.03, & E = \{x_1\} \\ 0.1, & E = \{x_2\} \\ 0.2, & E = \{x_1, x_2\} \end{cases},$$

$$\mu_6(E) = \begin{cases} 0, & E = \emptyset \\ 0.21, & E = \{x_1\} \\ 0.22, & E = \{x_2\} \\ 0.3, & E = \{x_1, x_2\} \end{cases},$$

$$\mu_7(E) = \begin{cases} 0, & E = \emptyset \\ 0.00000249806, & E = \{x_1\} \\ 0, & E = \{x_2\} \\ 0.00000558338, & E = \{x_1, x_2\} \end{cases}$$

$$\mu_8(E) = \begin{cases} 0, & E = \emptyset \\ 0.0123, & E = \{x_1\} \\ 0.6178, & E = \{x_2\} \\ 0.7675, & E = \{x_1, x_2\} \end{cases}.$$

Pentru  $k=1$ , am obținut  $E_1 = \sum_{p=1}^{14} (z_{1,p} - y_p)^2 = 1704.34$ .

Pentru  $k=2$ , am obținut  $E_2 = \sum_{p=1}^{14} (z_{2,p} - y_p)^2 = 106.418$ .

Pentru  $k=3$ , am obținut  $E_3 = \sum_{p=1}^{14} (z_{3,p} - y_p)^2 = 1761.04$ .

Pentru  $k=4$ , am obținut  $E_4 = \sum_{p=1}^{14} (z_{4,p} - y_p)^2 = 1.36172 \cdot 10^7$ .

Pentru  $k=5$ , am obținut  $E_5 = \sum_{p=1}^{14} (z_{5,p} - y_p)^2 = 7.82091 \cdot 10^{10}$ .

Pentru  $k=6$ , am obținut  $E_6 = \sum_{p=1}^{14} (z_{6,p} - y_p)^2 = 4.44816 \cdot 10^{11}$ .

Pentru  $k=7$ , am obținut  $E_7 = \sum_{p=1}^{14} (z_{7,p} - y_p)^2 = 11257.1$ .

Pentru  $k=8$ , am obținut  $E_8 = \sum_{p=1}^{14} (z_{8,p} - y_p)^2 = 9.06956 \cdot 10^{11}$ .

Am ales măsura care oferă cel mai apropiat rezultat de cel real. De fapt, am ales minimul valorilor lui  $E_k$ . Acesta este  $E_2$ .

Deci,  $\mu_2$  este o măsură monotonă care oferă cel mai apropiat rezultat raportat la rezultatele psihologilor legate de deschidere. Acesta este un motiv bun pentru a alege  $\mu_2$  ca măsură „bună” pentru viitoarele măsurători.

## 3.2 Anxietatea

În acest subcapitol descriem două metode prin care se determină nivelul de Anxietate al unor subiecți:

- a) folosind mai multe măsuri monotone cunoscute pentru a afla nivelul de Anxietate al subiecților;
- b) determinarea unei măsuri și utilizarea ei pentru a afla nivelul de Anxietate al subiecților.

Ca tehnică matematică, integralele nonliniare sunt utilizate ca a instrument de fuziune. Terminologia folosită în această secțiune poate fi găsită în [14] și [25].

### 3.2.1 Folosind mai multe măsuri monotone cunoscute pentru a afla nivelul de Anxietate al subiecților

#### 3.3.1.1 CĂTRE O METODĂ DE DIAGNOSTICARE A ANXIETĂȚII FOLOSIND INTEGRALA CHOQUET

În această subsecțiune, descriem un model matematic prin care nivelul undelor de tip EEG este procesat pentru a caracteriza nivelul de anxietate. Ideea noastră a fost să folosim integrala Choquet care respectă o măsură monotonă. Am luat în considerare datele rezultate din măsurătorile undelor EEG pentru un grup de subiecți. Am descris o procedură prin care utilizăm diferite măsuri monotone pentru a calcula nivelul de anxietate al unui subiect folosind integrala Choquet. Pentru fiecare pacient avem nivelul de anxietate dat de psihologi. Pentru fiecare pacient comparăm rezultatele obținute prin această metodă cu rezultatele psihologilor. Dintre toate măsurile folosite, am ales măsura care a oferit cele mai apropiate rezultate față de cele reale.

Rezultatele prezentate aici au fost publicate în [25].

#### DETERMINAREA GRADULUI DE ANXIETATE

Am realizat  $l=14$  măsurători. Acestea sunt cele  $l=14$  funcții  $f_1, f_2, \dots, f_{14}$ . Cele  $n=4$  attribute măsurate sunt  $x_1 = LowAlpha$ ,  $x_2 = HighAlpha$ ,  $x_3 = LowBeta$ ,  $x_4 = HighBeta$ . De fapt, pentru oricare dintre cele 14 măsurători (linii), am obținut valorile de intrare  $f_p(x_1), f_p(x_2), f_p(x_3), f_p(x_4)$  și valorile de ieșire  $y_p$ ,  $p = 1, 2, \dots, 14$ . Valorile de intrare sunt mediile măsurătorilor efectuate pe 14 subiecți. Valorile de ieșire sunt obținute folosind clasificarea dată de către psihologi subiecților (individual măsurați). Aceste valorile de ieșire sunt reprezentate prin note, de la 0 la 100.

Am considerat  $t = 8$  funcții monotone. Utilizând fiecare măsură  $\mu_k$  ( $k = 1, t$ ), pentru fiecare subiect  $p$ , am calculat nivelul de anxietate  $z_{k,p}$  ( $k = 1, \dots, t$  și  $p = 1, \dots, 14$ ). Pentru fiecare  $k = 1, t$  și pentru fiecare  $p = 1, 14$  avem:  $z_{k,p} = (C) \int f_p d\mu_k$ . Pentru fiecare măsură  $\mu_k$ , am comparat rezultatele obținute prin metoda noastră cu rezultatele psihologilor, folosind Metoda celormai mici pătrate. Mai exact, pentru fiecare măsură  $\mu_k$ , am calculat  $E_k = \sum_{p=1}^{14} (z_{k,p} - y_p)^2$ .

Am considerat măsurile:

$$\mu_1(E) = \left\{ \begin{array}{l} 0, \quad E = \emptyset \\ 0.0000143333, \quad E = \{x_1\} \\ 0.0000406178, \quad E = \{x_2\} \\ 0.0000471675, \quad E = \{x_1, x_2\} \\ 0.00000472641, \quad E = \{x_3\} \\ 0.0000143333, \quad E = \{x_1, x_3\} \\ 0.0000406178, \quad E = \{x_2, x_3\} \\ 0.0000955576, \quad E = \{x_1, x_2, x_3\} \\ 0.0000254858, \quad E = \{x_4\} \\ 0.0000320333, \quad E = \{x_1, x_4\} \\ 0.0000406178, \quad E = \{x_2, x_4\} \\ 0.0000471675, \quad E = \{x_1, x_2, x_4\} \\ 0.000225524, \quad E = \{x_3, x_4\} \\ 0.000225524, \quad E = \{x_1, x_3, x_4\} \\ 0.000616894, \quad E = \{x_2, x_3, x_4\} \\ 0.000616894, \quad E = \{x_1, x_2, x_3, x_4\} \end{array} \right. , \mu_2(E) = \left\{ \begin{array}{l} 0, \quad E = \emptyset \\ 0.0000245333, \quad E = \{x_1\} \\ 0.0000507178, \quad E = \{x_2\} \\ 0.00671685, \quad E = \{x_1, x_2\} \\ 0.00000972621, \quad E = \{x_3\} \\ 0.000246333, \quad E = \{x_1, x_3\} \\ 0.000606178, \quad E = \{x_2, x_3\} \\ 0.01955576, \quad E = \{x_1, x_2, x_3\} \\ 0.0000324858, \quad E = \{x_4\} \\ 0.000329333, \quad E = \{x_1, x_4\} \\ 0.00606178, \quad E = \{x_2, x_4\} \\ 0.051675, \quad E = \{x_1, x_2, x_4\} \\ 0.0625524, \quad E = \{x_3, x_4\} \\ 0.725524, \quad E = \{x_1, x_3, x_4\} \\ 0.816894, \quad E = \{x_2, x_3, x_4\} \\ 0.916894, \quad E = \{x_1, x_2, x_3, x_4\} \end{array} \right. ,$$

$$\mu_3(E) = \left\{ \begin{array}{l} 0, \quad E = \emptyset \\ 0.000014, \quad E = \{x_1\} \\ 0.00004, \quad E = \{x_2\} \\ 0.000047, \quad E = \{x_1, x_2\} \\ 0.0000047, \quad E = \{x_3\} \\ 0.0000145, \quad E = \{x_1, x_3\} \\ 0.000048, \quad E = \{x_2, x_3\} \\ 0.000095, \quad E = \{x_1, x_2, x_3\} \\ 0.000025, \quad E = \{x_4\} \\ 0.000032, \quad E = \{x_1, x_4\} \\ 0.0000406, \quad E = \{x_2, x_4\} \\ 0.0000471, \quad E = \{x_1, x_2, x_4\} \\ 0.0002, \quad E = \{x_3, x_4\} \\ 0.00023, \quad E = \{x_1, x_3, x_4\} \\ 0.000616, \quad E = \{x_2, x_3, x_4\} \\ 0.0006168, \quad E = \{x_1, x_2, x_3, x_4\} \end{array} \right. , \mu_4(E) = \left\{ \begin{array}{l} 0, \quad E = \emptyset \\ 0.001, \quad E = \{x_1\} \\ 0.00004, \quad E = \{x_2\} \\ 0.002, \quad E = \{x_1, x_2\} \\ 0.0003, \quad E = \{x_3\} \\ 0.003, \quad E = \{x_1, x_3\} \\ 0.0005, \quad E = \{x_2, x_3\} \\ 0.006, \quad E = \{x_1, x_2, x_3\} \\ 0.00002, \quad E = \{x_4\} \\ 0.004, \quad E = \{x_1, x_4\} \\ 0.006, \quad E = \{x_2, x_4\} \\ 0.01, \quad E = \{x_1, x_2, x_4\} \\ 0.02, \quad E = \{x_3, x_4\} \\ 0.03, \quad E = \{x_1, x_3, x_4\} \\ 0.04, \quad E = \{x_2, x_3, x_4\} \\ 0.05, \quad E = \{x_1, x_2, x_3, x_4\} \end{array} \right. ,$$

$$\mu_5(E) = \left\{ \begin{array}{l} 0, \quad E = \emptyset \\ 0.03, \quad E = \{x_1\} \\ 0.1, \quad E = \{x_2\} \\ 0.2, \quad E = \{x_1, x_2\} \\ 0.02, \quad E = \{x_3\} \\ 0.04, \quad E = \{x_1, x_3\} \\ 0.3, \quad E = \{x_2, x_3\} \\ 0.4, \quad E = \{x_1, x_2, x_3\} \\ 0.008, \quad E = \{x_4\} \\ 0.07, \quad E = \{x_1, x_4\} \\ 0.5, \quad E = \{x_2, x_4\} \\ 0.6, \quad E = \{x_1, x_2, x_4\} \\ 0.7, \quad E = \{x_3, x_4\} \\ 0.8, \quad E = \{x_1, x_3, x_4\} \\ 0.9, \quad E = \{x_2, x_3, x_4\} \\ 0.95, \quad E = \{x_1, x_2, x_3, x_4\} \end{array} \right. , \mu_6(E) = \left\{ \begin{array}{l} 0, \quad E = \emptyset \\ 0.21, \quad E = \{x_1\} \\ 0.22, \quad E = \{x_2\} \\ 0.3, \quad E = \{x_1, x_2\} \\ 0.009, \quad E = \{x_3\} \\ 0.35, \quad E = \{x_1, x_3\} \\ 0.429, \quad E = \{x_2, x_3\} \\ 0.54, \quad E = \{x_1, x_2, x_3\} \\ 0.01, \quad E = \{x_4\} \\ 0.25, \quad E = \{x_1, x_4\} \\ 0.26, \quad E = \{x_2, x_4\} \\ 0.47, \quad E = \{x_1, x_2, x_4\} \\ 0.1, \quad E = \{x_3, x_4\} \\ 0.6, \quad E = \{x_1, x_3, x_4\} \\ 0.7, \quad E = \{x_2, x_3, x_4\} \\ 0.8, \quad E = \{x_1, x_2, x_3, x_4\} \end{array} \right. ,$$

$$\mu_7(E) = \left\{ \begin{array}{l} 0, \quad E = \emptyset \\ 0.91, \quad E = \{x_1\} \\ 0.8, \quad E = \{x_2\} \\ 0.92, \quad E = \{x_1, x_2\} \\ 0.94, \quad E = \{x_3\} \\ 0.95, \quad E = \{x_1, x_3\} \\ 0.96, \quad E = \{x_2, x_3\} \\ 0.97, \quad E = \{x_1, x_2, x_3\} \\ 0.98, \quad E = \{x_4\} \\ 0.99, \quad E = \{x_1, x_4\} \\ 0.995, \quad E = \{x_2, x_4\} \\ 0.997, \quad E = \{x_1, x_2, x_4\} \\ 0.998, \quad E = \{x_3, x_4\} \\ 0.9984, \quad E = \{x_1, x_3, x_4\} \\ 0.9989, \quad E = \{x_2, x_3, x_4\} \\ 0.99993, \quad E = \{x_1, x_2, x_3, x_4\} \end{array} \right. , \mu_8(E) = \left\{ \begin{array}{l} 0, \quad E = \emptyset \\ 0.0123, \quad E = \{x_1\} \\ 0.6178, \quad E = \{x_2\} \\ 0.7675, \quad E = \{x_1, x_2\} \\ 0.0004, \quad E = \{x_3\} \\ 0.02, \quad E = \{x_1, x_3\} \\ 0.62, \quad E = \{x_2, x_3\} \\ 0.79, \quad E = \{x_1, x_2, x_3\} \\ 0.00002, \quad E = \{x_4\} \\ 0.1, \quad E = \{x_1, x_4\} \\ 0.65, \quad E = \{x_2, x_4\} \\ 0.83, \quad E = \{x_1, x_2, x_4\} \\ 0.85, \quad E = \{x_3, x_4\} \\ 0.879, \quad E = \{x_1, x_3, x_4\} \\ 0.895, \quad E = \{x_2, x_3, x_4\} \\ 0.9, \quad E = \{x_1, x_2, x_3, x_4\} \end{array} \right. .$$

Pentru  $k=1$ , am obținut  $E_1 = \sum_{p=1}^{14} (z_{1,p} - y_p)^2 = 1.07048$ .

Pentru  $k=2$ , am obținut  $E_2 = \sum_{p=1}^{14} (z_{2,p} - y_p)^2 = 1.01876 \cdot 10^{10}$

Pentru  $k=3$ , am obținut  $E_3 = \sum_{p=1}^{14} (z_{3,p} - y_p)^2 = 1.02563$ .

Pentru  $k=4$ , am obținut  $E_4 = \sum_{p=1}^{14} (z_{4,p} - y_p)^2 = 3.47604 \cdot 10^7$ .

Pentru  $k=5$ , am obținut  $E_5 = \sum_{p=1}^{14} (z_{5,p} - y_p)^2 = 3.14793 \cdot 10^{10}$ .

Pentru  $k=6$ , am obținut  $E_6 = \sum_{p=1}^{14} (z_{6,p} - y_p)^2 = 2.47029 \cdot 10^{10}$ .

Pentru  $k=7$ , am obținut  $E_7 = \sum_{p=1}^{14} (z_{7,p} - y_p)^2 = 1.74603 \cdot 10^{11}$ .

Pentru  $k=8$ , am obținut  $E_8 = \sum_{p=1}^{14} (z_{8,p} - y_p)^2 = 8.42105 \cdot 10^{10}$ .

Am ales acea măsură care a furnizat cele mai apropiate rezultate de cele reale. Mai exact, am ales minimul valorilor lui  $E_k$ . Aceasta este  $E_3$ .

### 3.2.2 Determinarea unei măsuri și utilizarea ei pentru a afla nivelul de Anxietate al subiecților

#### 3.3.2.1 Folosind integrala Choquet pentru determinarea gradului de Anxietate

În această subsecțiune, introducem un model matematic care descrie modul în care sunt procesate undele de tip EEG pentru a caracteriza nivelul de anxietate. Ideea noastră principală este să folosim integrala Choquet care respectă o măsură monotonă adecvată pentru a caracteriza nivelul de anxietate. Această măsură a fost obținută folosind măsurătorile valorilor undelor EEG efectuate pe 70 de subiecți și nivelurile corespunzătoare de anxietate (stabilite de psihologi) acestor subiecți. Pentru a ne verifica modelul matematic (instrumentul de agregare) l-am folosit pentru a determina nivelul de anxietate al altor 10 subiecți, comparând rezultatele noastre cu rezultatele oferite de psihologi (comparația ne-a validat rezultatele).

Rezultatele prezentate aici au fost publicate în [14].

#### UTILIZAREA INTEGRALEI CHOQUET PENTRU A REZOLVA PROBLEMA INVERSĂ A FUNZIUNII INFORMAȚIILOR

##### Formula de Liniarizare pentru Calculul Integralei Choquet Discret Finit

Ne vom ocupa de cazul în care  $T$  este finită.

Pentru orice  $E \in P^*(T)$ , definim

$$a_E \stackrel{\text{def}}{=} \min_{x_p \in E} f(x_p) - \max_{x_q \in T \setminus E} f(x_q)$$

cu convenția  $\max_{x_q \in \emptyset} f(x_q) = 0$  (în cazul  $E = T$ ).

Apoi, definim

$$b_E = \begin{cases} a_E, & a_E \geq 0, \\ 0, & a_E < 0 \end{cases}$$

Se vede că  $b_E = a_E^+$ .

**Teorema 3.1.** *Avem formula*

$$(C) \int f d\mu = \sum_{E \in P^*(T)} b_E \mu(E) \quad (3.1)$$

### Enumerarea canonică a lui $P^*(t)$

Orice număr  $j = 1, 2, \dots, 2^n - 1$  poate fi scris în mod unic în formă binară

$$j = \overline{j_n j_{n-1} \dots j_1} = j_1 + 2j_2 + 2^2 j_3 + \dots + 2^{n-1} j_n$$

unde toți  $j_i \in \{0, 1\}$  și cel puțin unul  $j_i \neq 0$ .

Regula de apartenență este următoarea:

$$x_i \in E_{\overline{j_n j_{n-1} \dots j_1}} \Leftrightarrow j_i = 1$$

(a.î.  $E_{\overline{j_n j_{n-1} \dots j_1}} = \cup_{j_i=1} \{x_i\}$ )

Această regulă de apartenență generează exact  $2^n - 1$  mulțimi diferite.

Putem vedea că formula (3.1) din Theorem 3.1 poate fi scrisă în forma

$$(C) \int f d\mu = \sum_{j=0}^{2^n-1} b_{E_j} \mu(E_j) \quad (3.2)$$

unde orice  $j = 1, 2, \dots, 2^n - 1$  este scris în forma  $\overline{j_n j_{n-1} \dots j_1}$ .

### Rezolvarea Problemei Inverse a Fuziunii Informațiilor în acest caz (Identificarea Măsurii Monotone Utilizate pentru a Genera Instrumentul de Agregare)

Vom lua în considerare elementele  $x_i$  ale unei mulțimi  $T = \{x_1, x_2, \dots, x_n\}$  ca sursă de informații, de exemplu, orice  $x_i$  este un subiect al observației noastre. Orice observație a tuturor subiecților din  $T$  va fi considerată ca o funcție  $f : T \rightarrow \mathbb{R}$ . Vom face  $l$  observații  $f_1, f_2, \dots, f_l$ , obținând pentru orice astfel de observație  $f_i : T \rightarrow \mathbb{R}$  valorile  $f_i(x_j), j = 1, 2, \dots, n$  și concluzia (care este numerică)  $y_i \in \mathbb{R}$ . De fapt, valorile  $f_i(x_j)$  și valorile  $y_i$  sunt intrările în sistem (oricare  $y_i$  este o valoare a țintei de fuziune).

Acceptăm existența unei măsuri monotone  $\mu : P(T) \rightarrow \mathbb{R}_+$  astfel încât

$$y_p = (C) \int f_p d\mu, p = 1, 2, \dots, l \quad (3.3)$$

Acționând în spiritul problemei inverse a fuziunii de informații, putem considera că un obiect necunoscut este măsura  $\mu$ .

Trebuie să rezolvăm sistemul liniar ( $l$  ecuații cu  $2^n - 1$  necunoscute).

$$\sum_{j=1}^{2^n-1} b_{p_j} \mu(E_j) = y_p, p = 1, 2, \dots, l \quad (3.4)$$

Avem, pentru orice  $p = 1, 2, \dots, l$  și orice  $j = 1, 2, \dots, 2^n - 1$ ,  $b_{p_j} = b_{E_j}^p$ , a.î.  $b_{p_j} = a_{E_j}^p$  dacă  $a_{E_j}^p \geq 0$  și  $b_{p_j} = 0$  dacă  $a_{E_j}^p < 0$ , unde  $a_{E_j}^p = \min_{x_t \in E_j} f_p(x_t) - \max_{x_t \notin E_j} f_p(x_t)$ .

Considerăm matricile

$$X \stackrel{\text{def}}{=} \begin{pmatrix} b_{11} & b_{12} & \cdots & b_{1m} \\ b_{21} & b_{22} & \cdots & b_{2m} \\ & & \ddots & \\ b_{l1} & b_{l2} & \cdots & b_{lm} \end{pmatrix}, \text{ de tipul } (l, m = 2^n - 1)$$

$$Y \stackrel{\text{def}}{=} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_l \end{pmatrix}, \text{ de tipul } (l, 1)$$

și matricea soluție (aproximativă)

$$A = \begin{pmatrix} t_1^0 \\ t_2^0 \\ \vdots \\ t_m^0 \end{pmatrix}, \text{ de tipul } (m = 2^n - 1, 1)$$

$$X^T X A = X^T Y \quad (3.5)$$

În cazul (de dorit) particular când  $X^T X$  este inversabilă, soluția  $A$  este dată prin

$$A = (X^T X)^{-1} X^T Y \quad (3.6)$$

### Corectarea rezultatelor:

Soluția aproximativă  $\nu$  trebuie să fie o măsură monotonă. Verificarea acestui fapt se face astfel: pentru orice  $E \in P^*(T)$ ,  $E \neq T$ , trebuie să avem

$$0 \leq \nu(E) \leq \nu(E \cup \{x_i\}), \text{ pentru oricare } x_i \in T - E$$

Dacă nu este cazul (adică apar valori negative ale lui  $\nu(E)$ , sau apar probleme de monotonie), modificăm  $\nu$  astfel (este posibil ca unii dintre pașii următori să nu fie necesari):

1. Întâi, toate (posibilele) valori strict negative ale lui  $\nu(E)$  să fie înlocuite cu 0.
2. Apoi, dacă există  $E, F$  în  $P^*(T)$  astfel încât  $E \subset F$  și  $\nu(E) > \nu(F)$ , atunci modificăm  $\nu(E)$ , înlocuind valoarea  $\nu(E)$  cu

$$\max\{\nu(G) | G \subset E \text{ și } \nu(G) \leq \min\{\nu(H) | E \subset H\}\}$$

(mulțimea nu este vidă, conținând  $0 = \nu(\emptyset)$ ).

3. Procedura de la 2. continuă pentru acele  $\nu(E)$  modificate, până când perechile "greșite" ( $E, F$ ) de mai sus, nu mai apar deloc.

La final, obținem măsura monotonă  $\mu$  care va fi numită "măsura corectă".

## DETERMINAREA GRADULUI DE ANXIETATE

### Ideea principală

#### Crearea Instrumentului (Măsura). Problema inversă

Am realizat măsurători pentru  $l = 70$  subiecți. Am construit  $l = 70$  funcții  $f_1, f_2, \dots, f_{70}$ . Cele  $n = 4$  attribute măsurate sunt  $x_1 = LowAlpha, x_2 = HighAlpha, x_3 = LowBeta, x_4 = HighBeta$ . Pentru fiecare dintre cele 70 măsurători (linii), am obținut valorile de intrare:  $f_p(x_1), f_p(x_2), f_p(x_3), f_p(x_4)$  și valorile  $y_p, p = 1, 2, \dots, 70$ . Valorile de intrare  $y_p$  sunt clasificările date de psihologi pentru subiecți (măsurați individual), reprezentate prin note, de la 0 la 6 (însemnând că 0 este cel mai puțin anxios și 6 este cel mai anxios).

Pentru oricare  $p = 1, 2, \dots, 70$  avem:

$$y_p = (C) \int f_p d\mu \quad (3.7)$$

Folosind cele descrise, am determinat "măsura"  $\nu$ . A fost necesar ca  $\nu$  să se modifice (ușor)(vezi Corectarea Rezultatelor) și am obținut măsura corectă  $\mu$ , ale cărei valori  $\mu(E)$ , dispuse în ordinea lexicografică menționată mai sus, sunt următoarele:

$$\mu(E) = \begin{cases} 0 & \text{dacă } E = \emptyset \\ 0.0000208904, & \text{dacă } E = \{x_1\} \\ 0.0000104939, & \text{dacă } E = \{x_2\} \\ 0.000047098, & \text{dacă } E = \{x_1, x_2\} \\ 0.0000398943, & \text{dacă } E = \{x_3\} \\ 0.000230985, & \text{dacă } E = \{x_1, x_3\} \\ 0.000142402, & \text{dacă } E = \{x_2, x_3\} \\ 0.000230985, & \text{dacă } E = \{x_1, x_2, x_3\} \\ 0.0000143691, & \text{dacă } E = \{x_4\} \\ 0.0000357572, & \text{dacă } E = \{x_1, x_4\} \\ 0.0000143691, & \text{dacă } E = \{x_2, x_4\} \\ 0.000047098, & \text{dacă } E = \{x_1, x_2, x_4\} \\ 0.0000398943, & \text{dacă } E = \{x_3, x_4\} \\ 0.000230985, & \text{dacă } E = \{x_1, x_3, x_4\} \\ 0.000142402, & \text{dacă } E = \{x_2, x_3, x_4\} \\ 0.000230985, & \text{dacă } E = \{x_1, x_2, x_3, x_4\} \end{cases}$$

Măsura a fost calculată utilizând un program C++.

### Utilizarea Instrumentului (Măsura) Obținut pentru a Determina Nivelul de Anxietate al altor Subiecți. Problema Directă

Utilizăm măsura obținută  $\mu$  pentru a decid enivelul de anxietate pentru 10 noi subiecți. Facem  $l = 10$  măsurători. Valorile măsurătorilor sunt furnizate in fișiere CSV. Pentru fiecare subiect  $p$ ,  $p = 1, 2, \dots, 10$ , obținem valorile  $f_p(x_i)$ ,  $i = 1, 2, 3, 4$  ca în cele descrise anterior. În acest caz, datele de intrare sunt  $f_p(x_i)$  și măsura  $\mu$ . De asemenea, mai avem și concluziile psihologilor pentru acești noi subiecți care vor fi comparate cu rezultatele noastre. Mai exact, măsurând cei  $l = 10$  noi subiecți, am obținut valorile  $f_p(x_1), f_p(x_2), f_p(x_3), f_p(x_4), p = 1, 2, \dots, 10$ . Vezi Tabelul 3.2

Table 3.2: Noi subiecți

| No | Low Alpha | High Alpha | Low Beta | High Beta |
|----|-----------|------------|----------|-----------|
| 1. | 33738.85  | 26911.79   | 15911.23 | 15827.22  |

Table 3.2: Noi subiecți

| No  | Low Alpha | High Alpha | Low Beta | High Beta |
|-----|-----------|------------|----------|-----------|
| 2.  | 11360.2   | 8108.433   | 9596.968 | 11737.35  |
| 3.  | 35170.35  | 23910.76   | 17211.32 | 12380.47  |
| 4.  | 36224.77  | 27315.48   | 16978.18 | 21143.96  |
| 5.  | 10658.68  | 7869.542   | 8243.346 | 7708.505  |
| 6.  | 33411.1   | 22809.05   | 21446.92 | 14769.47  |
| 7.  | 36568.82  | 23903.5    | 14545.97 | 19463.21  |
| 8.  | 33738.85  | 26911.79   | 15911.23 | 15827.22  |
| 9.  | 41482.67  | 27173.99   | 18173.78 | 19565.17  |
| 10. | 51089.42  | 27487.33   | 19538.43 | 20055.94  |

Clasificările date de psihologi acestor subiecți (măsurări individual), sunt reprezentate prin grade, de la 0 la 6 (cu semnificația că 0 este cel mai puțin anxios și 6 cel mai anxios). Vezi Tabelul 3.3

Table 3.3: Grade

| No  | Grades |
|-----|--------|
| 1.  | 4      |
| 2.  | 2      |
| 3.  | 5      |
| 4.  | 5      |
| 5.  | 2      |
| 6.  | 5      |
| 7.  | 4      |
| 8.  | 4      |
| 9.  | 5      |
| 10. | 5      |

Folosind formula (3.7), am obținut concluziile (datele de ieșire):

$$y_1 = 4.33598 \approx 4,$$

$$y_2 = 2.28522 \approx 2,$$

$$y_3 = 4.52631 \approx 5,$$

$$y_4 = 4.59469 \approx 5,$$

$$y_5 = 1.95455 \approx 2,$$

$$y_6 = 5.23955 \approx 5,$$

$$y_7 = 4.06521 \approx 4,$$

$$y_8 = 4.33598 \approx 4,$$

$$y_9 = 4.92068 \approx 5,$$

$$y_{10} = 5.38052 \approx 5.$$

# Chapter 4

## Calculul aproximativ al integralei Sugeno

În acest capitol descriem o procedură pentru calculul aproximativ al integralei Sugeno.

Scopul nostru principal este de a furniza proceduri practice pentru calcularea aproximativă (cu precizie prealocată) a integralei Sugeno a unei funcții măsurabile pozitive generale în raport cu o măsură generalizată monotonă. În acest scop, folosim metodele noastre în doi pași (metoda simplă în doi pași și metoda topologică folosind teorema de convergență iterată).

Metodele menționate mai sus reduc calculul general la calculul bine-cunoscut în cazul finit discret, care se poate face cu metode asistate de calculator.

Prezentul capitol se bazează pe [9].

Rezultatele prezentate aici au fost publicate în [10].

### 4.1 Rezultate generale

**Definiția 4.1.** Definim pentru un spațiu măsurabil monoton  $(T, \mathcal{T}, \mu)$  și pentru o funcție  $f \in M_+(\mathcal{T})$ , **Condiția (G)**:  $\lim_{\alpha \rightarrow \infty} \mu(F_\alpha(f)) = 0$ .

Din nou, fie  $(T, \mathcal{T}, \mu)$  un spațiu măsurabil monoton și  $f \in M_+(\mathcal{T})$ . Avem

**Lema 4.1.** *Avem echivalența*

a)  $((S) \int f d\mu = \infty) \Leftrightarrow (\mu(F_\alpha) = \infty \text{ pentru oricare } 0 < \alpha < \infty)$ .

*Prin urmare*

b)  $((S) \int f d\mu < \infty) \Leftrightarrow (\text{Deci exista } 0 < \alpha < \infty \text{ a. i. } \mu(F_\alpha) < \infty)$ .

**Definiția 4.2.** Pentru oricare  $i \in \mathbf{R}_+$ , definim  $i$ -trunchierea lui  $f$ , care este funcția  $\underline{f}(i) : T \rightarrow \mathbf{R}_+$  dată prin  $\underline{f}(i)(t) = f(t)$ , în cazul  $f(t) \leq i$  și  $\underline{f}(i)(t) = i$ , în cazul

$f(t) > i$ .

**Teorema 4.1. (Teorema Reducerii)**

1. Asumăm că  $\mu(T) < \infty$ . Atunci

$$(S) \int f d\mu = \sup_{\alpha \in (0, \mu(T)]} \alpha \wedge \mu(F_\alpha) \leq \mu(T) < \infty.$$

2. Asumăm că  $f$  este mărginită, și anume că  $f(t) \leq M$  pentru oricare  $t \in T$ , unde  $M \in \mathbf{R}_+$ . Atunci

$$(S) \int f d\mu = \sup_{\alpha \in (0, M]} \alpha \wedge \mu(F_\alpha) \leq M < \infty.$$

3. Fie  $i \in \mathbf{R}_+$  și  $\underline{f}(i)$   $i$ -trunchierea lui  $f$ . Atunci

$$a) (S) \int \underline{f}(i) d\mu = \sup_{\alpha \in (0, i]} \alpha \wedge \mu(F_\alpha(f)).$$

b) În cazul  $\mu(T) \leq i < \infty$ , avem

$$(S) \int f d\mu = (S) \int \underline{f}(i) d\mu.$$

**Teorema 4.2. (Calcul Sharp)**

I. Asumăm că există  $\alpha_0 \in \mathbf{R}_+$  astfel încât  $\alpha_0 = \mu(F_{\alpha_0})$ . Atunci,

1.  $(\alpha > \alpha_0 \Rightarrow \mu(F_\alpha) < \alpha)$  și  $(\alpha < \alpha_0 \Rightarrow \mu(F_\alpha) > \alpha)$ ;
2.  $\alpha_0 = (S) \int f d\mu$ .

Spunem că avem un calcul sharp al  $(S) \int f d\mu$ , utilizând o unică soluție  $\alpha_0$  a ecuației  $\alpha = \mu(F_\alpha)$ .

II. Caz particular.

Asumăm că  $(S) \int f d\mu < \infty$  (a.î. există  $0 < \alpha < \infty$  astfel încât  $\mu(F_\alpha) < \infty$ , vezi Lema 4.1). De asemenea, asumăm că funcția  $u : [0, \infty) \rightarrow [0, \infty]$ , definită prin  $u(\alpha) = \mu(F_\alpha)$ , este continuă (a.î.  $\lim_{\alpha \rightarrow t} u(\alpha) = u(t)$  pentru oricare  $t \in [0, \infty)$ ). Atunci, există un unic  $\alpha_0 \in [0, \infty)$  astfel încât  $u(\alpha_0) = \alpha_0$ , prin urmare  $\alpha_0 = (S) \int f d\mu$ .

**Teorema 4.3.** Asumăm că există  $\alpha_0 \geq 0$  astfel încât  $\alpha_0 \geq \mu(F_{\alpha_0})$  (am văzut că, în cazul Condiției (G) este îndeplinit faptul că  $\alpha_0$  există). Atunci, pentru orice  $\alpha \geq \alpha_0$  avem

$$(S) \int f d\mu = (S) \int \underline{f}(\alpha) d\mu$$

unde  $\underline{f}(\alpha)$  este  $\alpha$ -trunchierea lui  $f$ .

**Corolarul 4.1.** Asumăm că Condiția (G) este îndeplinită. Atunci, pentru orice  $0 < \varepsilon < 1$ , există  $n \in \mathbf{N}$  astfel încât

$$(S) \int f d\mu = (S) \int \underline{f}(n) d\mu$$

unde  $\underline{f}(n)$  este  $n$ -trunchierea lui  $f$  (prin urmare  $\lim_n (S) \int \underline{f}(n) d\mu = (S) \int f d\mu$ ).

## 4.2 Funcții Simple Pozitive, Funcții Elementare Pozitive și Integralele lor Sugeno

**Teorema 4.4.** Pentru  $f = \sum_{i=1}^n a_i \varphi_{A_i}$  o funcție simplă pozitivă avem (vezi de exemplu [28]):

$$a) (S) \int f d\mu = \max_{i=1}^n a_i \wedge \mu(F_{a_i}(f)).$$

b) Dacă  $a_1 \leq a_2 \leq \dots \leq a_n$ , avem  $F_{a_i}(f) = A_i \cup A_{i+1} \cup \dots \cup A_n$  pentru oricare  $i = 1, 2, \dots, n$ , prin urmare

$$(S) \int f d\mu = \max_{i=1}^n a_i \wedge \mu(A_i \cup A_{i+1} \cup \dots \cup A_n).$$

### Caz Particular (Cazul discret finit)

Putem aplica Teorema 4.4 pentru spațiul particular monoton măsurabil  $(T, \mathcal{T}, \mu)$ , unde  $T = \{x_1, x_2, \dots, x_n\}$ , cu  $x_i$  distincte,  $\mathcal{T} = \mathcal{P}(T)$  și  $\mu$  o măsură monotonă arbitrară. Fie  $f : T \rightarrow \mathbf{R}_+$  (prin urmare  $f \in M_+(\mathcal{T})$ ) și redenumim punctele distincte  $x_1, x_2, \dots, x_n$  în forma  $x_1^*, x_2^*, \dots, x_n^*$  astfel încât  $f(x_1^*) \leq f(x_2^*) \leq \dots \leq f(x_n^*)$ . Rezultă că  $(S) \int f d\mu = \max_{i=1}^n f(x_i^*) \wedge \mu(\{x_i^*, x_{i+1}^*, \dots, x_n^*\})$ .

**Teorema 4.5.** Fie  $f = \sum_{i=1}^{\infty} a_i \varphi_{A_i}$  o funcție pozitivă elementară cu  $a_1 \leq a_2 \leq \dots \leq a_n \leq \dots$ . Atunci

$$(S) \int f d\mu = \sup_{i=1}^{\infty} a_i \wedge \mu(A_i \cup A_{i+1} \cup \dots \cup A_n \cup \dots).$$

**Teorema 4.6.** Asumăm faptul că măsura  $\mu$  este continuă inferior. Atunci

$$(S) \int f d\mu = \lim_n (S) \int f_n d\mu = \sup_n (S) \int f_n d\mu,$$

unde  $f_n = \sum_{i=1}^n a_i \varphi_{A_i}$  pentru orice  $n$ .

**Definiția 4.3.** Funcția  $\underline{f}(i)$  se numește  $i$ -discretizarea lui  $f$ .

### 4.3 Metode în Doi Pași pentru Calcularea Integralelor Sugeno

Putem considera un spațiu monoton măsurabil  $(T, \mathcal{T}, \mu)$  și o funcție  $f \in M_+(\mathcal{T})$  astfel încât *Condiția (G) pentru  $f$  și  $\mu$  este îndeplinită*. Așa cum am văzut, asta implică faptul că  $f$  este integrabilă Sugeno respectând  $\mu$ . Fie

$$u \stackrel{def}{=} (S) \int f d\mu.$$

Scopul nostru este să calculăm  $u$  aproximativ cu o eroare prescrisă. La final, introducem câteva notații și estimări unificate.

#### 4.3.1 Notații și Estimări Unificate

*Strategia Trunchiere – Discretizare (STD)*

Pentru  $i \in \mathbf{N}$ ,

$$u(i) \stackrel{def}{=} (S) \int \underline{f}(i) d\mu$$

unde  $\underline{f}(i) = i - \text{trunchierea lui } f$ . Pentru  $n \in \mathbf{N}^*$ ,

$$u(i, n) \stackrel{def}{=} (S) \int f(i, n) d\mu$$

unde  $f(i, n)$  este  $n$  – discretizarea lui  $\underline{f}(i)$ . Așa cum am văzut în [9]:

$$f(i, n) = \sum_{m=0}^{i-1} \sum_{p=1}^n a(m, n, p) \cdot \varphi_{A(m, n, p)} + i \cdot \varphi_{f^{-1}([i, \infty))} \quad (4.1)$$

Explicitat, avem

$$\begin{aligned} f(i, n) = & \left[ 0 \cdot \varphi_{f^{-1}([0, \frac{1}{n}))} + \frac{1}{n} \cdot \varphi_{f^{-1}([\frac{1}{n}, \frac{2}{n}))} + \dots + \frac{n-1}{n} \cdot \varphi_{f^{-1}([\frac{n-1}{n}, 1))} \right] + \\ & \left[ 1 \cdot \varphi_{f^{-1}([1, 1+\frac{1}{n}))} + \dots + \left( 1 + \frac{n-1}{n} \right) \cdot \varphi_{f^{-1}([1+\frac{n-1}{n}, 2))} \right] + \dots + \\ & + \left[ (i-1) \cdot \varphi_{f^{-1}([i-1, i-1+\frac{1}{n}))} + \dots + \left( i-1 + \frac{n-1}{n} \right) \cdot \varphi_{f^{-1}([i-1+\frac{n-1}{n}, i))} \right] + \end{aligned}$$

$$\begin{aligned}
& + i \cdot \varphi_{f^{-1}([i, \infty))} \stackrel{def}{=} \left[ 0 \cdot \varphi_{A_1} + \frac{1}{n} \cdot \varphi_{A_2} + \dots + \frac{n-1}{n} \cdot \varphi_{A_n} \right] + \\
& + \left[ 1 \cdot \varphi_{A_{n+1}} + \left( 1 + \frac{1}{n} \right) \cdot \varphi_{A_{n+2}} + \dots + \left( 1 + \frac{n-1}{n} \right) \cdot \varphi_{A_{2n}} \right] + \dots + \\
& + \left[ (i-1) \cdot \varphi_{A_{(i-1)n+1}} + \dots + \left( i-1 + \frac{n-1}{n} \right) \cdot \varphi_{A_{in}} \right] + i \cdot \varphi_{A_{in+1}}.
\end{aligned}$$

Am scris  $f(i, n)$  în ordine strict crescătoare a valorilor posibile ale acesteia. Observăm că:

$$\begin{aligned}
A_1 \cup A_2 \cup \dots \cup A_{in+1} &= T, \quad A_2 \cup A_3 \cup \dots \cup A_{in+1} = f^{-1} \left( \left[ \frac{1}{n}, \infty \right) \right), \\
A_3 \cup A_4 \cup \dots \cup A_{in+1} &= f^{-1} \left( \left[ \frac{2}{n}, \infty \right) \right), \dots, \\
A_{in+1} &= f^{-1} \left( \left[ \frac{in}{n}, \infty \right) \right) = f^{-1}([i, \infty)).
\end{aligned}$$

Conform Teoremei 4.4, avem

$$\begin{aligned}
u(i, n) &= \max \left\{ \frac{1}{n} \wedge \mu \left( f^{-1} \left( \left[ \frac{1}{n}, \infty \right) \right) \right), \frac{2}{n} \wedge \mu \left( f^{-1} \left( \left[ \frac{2}{n}, \infty \right) \right) \right), \dots, \right. \\
& \left( 1 - \frac{1}{n} \right) \wedge \mu \left( f^{-1} \left( \left[ 1 - \frac{1}{n}, \infty \right) \right) \right), 1 \wedge \mu \left( f^{-1}([1, \infty)) \right), \\
& \left( 1 + \frac{1}{n} \right) \wedge \mu \left( f^{-1} \left( \left[ 1 + \frac{1}{n}, \infty \right) \right) \right), \dots, (i-1) \wedge \mu \left( f^{-1}([i-1, \infty)) \right), \\
& \left( i-1 + \frac{1}{n} \right) \wedge \mu \left( f^{-1} \left( \left[ i-1 + \frac{1}{n}, \infty \right) \right) \right), \dots, \\
& \left. \left( i-1 + \frac{n-1}{n} \right) \wedge \mu \left( f^{-1} \left( \left[ i-1 + \frac{n-1}{n}, \infty \right) \right) \right), i \wedge \mu \left( f^{-1}([i, \infty)) \right) \right\}.
\end{aligned}$$

Prin urmare,

$$u(i, n) = \max_{p=1}^{in} \frac{p}{n} \wedge \mu \left( F_{\frac{p}{n}}(f) \right) \quad (4.2)$$

(aici, avem o diviziune de puncte  $\frac{1}{n} < \frac{2}{n} < \dots < \frac{p}{n} < \dots < \frac{in}{n} = i$ ).

*Strategia Discretizare – Trunchiere (SDT)*

Pentru  $i \in \mathbf{N}^*$ ,

$$u(i) \stackrel{def}{=} (S) \int \underline{f}(i) d\mu$$

unde  $\underline{f}(i) = i$  – discretizarea lui  $f$ . Pentru  $n \in \mathbf{N}$ ,

$$u(i, n) \stackrel{def}{=} (S) \int f(i, n) d\mu$$

unde  $f(i, n)$  este  $n$  – trunchierea lui  $\underline{f}(i)$ . Cum am văzut în [9]:

$$f(i, n) = \sum_{m=0}^{n-1} \sum_{p=1}^i a(m, i, p) \cdot \varphi_{A(m, i, p)} + n \cdot \varphi_{f^{-1}([n, \infty))}$$

(formula este valabilă pentru orice măsură monotonă). Procedând similar ca în cazul (STD) obținem

$$u(i, n) = \max_{p=1}^{in} \frac{p}{i} \wedge \mu \left( F_{\frac{p}{i}}(f) \right) \quad (4.3)$$

(aici, avem o diviziune de puncte  $\frac{1}{i} < \frac{2}{i} < \dots < \frac{p}{i} < \dots < \frac{in}{i} = n$ ).

Formula (4.3) poate fi obținută din formula (4.2) interschimbând  $i$  și  $n$  (în sens invers (4.3) → (4.2) este de asemenea valid). Mai exact (observăm și că  $f(i, n)$  calculat pentru (SDT) este egal cu  $f(n, i)$  calculat pentru (STD)):

$$u(i, n) \text{ calculat pentru (SDT)} = u(n, i) \text{ calculat pentru (STD)}.$$

Deci, este nevoie de un singur program de calcul.

Formula (4.2) și (4.3) pot fi reținute ușor, ambele având forma

$$u(i, n) = \max_{p=1}^{in} \alpha_p \wedge \mu \left( F_{\alpha_p}(f) \right).$$

Aici  $(\alpha_1, \alpha_2, \dots, \alpha_{in})$  este o pânză echidistantă cu densitate  $\frac{1}{n}$  (în cazul (STD)) sau  $\frac{1}{i}$  (în cazul (SDT)) și mărime  $in$ . Densitatea se referă la procedura de discretizare și mărimea ține de procedura de trunchiere.

Pentru a simplifica calculul lui  $u(i, n)$ , este folositor să procedăm astfel:

a) Pentru orice  $a, b$  în  $\mathbf{R}_+$  este indicat să se calculeze  $a \vee b$  și  $a \wedge b$  folosind formulele  $a \vee b = \frac{1}{2}(a + b + |a - b|)$  și  $a \wedge b = \frac{1}{2}(a + b - |a - b|)$ .

b) Pentru  $a_1, a_2, \dots, a_n$  în  $\mathbf{R}_+$ ,  $n \geq 3$ , pentru a calcula  $\max_{i=1}^n a_i$ , este indicat să se continue secvențial (folosind și punctul a)):  $\max_{i=1}^2 a_i = a_1 \vee a_2 \stackrel{def}{=} A_2$ ,  $\max_{i=1}^3 a_i = A_2 \vee a_3 \stackrel{def}{=} A_3, \dots$ ,  $\max_{i=1}^n a_i = A_{n-1} \vee a_n \stackrel{def}{=} A_n$ .

*Estimări în cazul (STD)*

a) Dacă  $i_0 \geq \mu(F_{i_0}(f))$ , atunci  $u = u(i)$  pentru orice  $i \geq i_0$  (conform Teoremei 4.3).

b)  $|u(i) - u(i, n)| = u(i) - u(i, n) \leq \frac{1}{n}$  pentru orice  $i$  (conform (4.1) și Teoremei 1.8, Secțiunea 1.3). Avem  $\lim_n u(i, n) = u(i)$  uniform care respectă  $i$  (conform Corolarului 1.3, Secțiunea 1.3).

*Estimări în cazul (SDT)*

a)  $|u - u(i)| = u - u(i) \leq \frac{1}{i}$  (conform (4.1) și Teoremei 1.8, Secțiunea 1.3).

b) Dacă  $n_0 \geq \mu(F_{n_0}(f))$ , atunci  $u(i) = u(i, n)$  pentru oricare  $i$  și oricare  $n \geq n_0$ . Această afirmație este justificată după cum urmează. Pentru oricare  $i$ , avem  $\underline{f}(i) \leq f$ , prin urmare  $F_{n_0}(\underline{f}(i)) \subset F_{n_0}(f)$  și aceasta implică  $\mu(F_{n_0}(\underline{f}(i))) \leq \mu(F_{n_0}(f)) \leq n_0$ . Apoi, Teorema 4.3 implică  $u(i) = (S) \int \underline{f}(i) d\mu = (S) \int f(i, n_0) d\mu = u(i, n_0) = (S) \int f(i, n) d\mu = u(i, n)$ , if  $n \geq n_0$ .

Întorcându-ne la targetul nostru, calculul aproximativ  $u \stackrel{def}{=} (S) \int f d\mu$ , considerăm un număr stabilit  $0 < \varepsilon < 1$ . Trebuie să aflăm  $i$  și  $n$  astfel încât

$$|u - u(i, n)| = u - u(i, n) < \varepsilon.$$

Acest lucru se va face fie folosind metoda simplă în doi pași, fie folosind metoda teoremei de convergență iterată și estimările de mai sus.

**4.3.2 Calcul folosind Metoda Simplă în Doi Pași**

Pentru orice  $i$  și  $n$  în  $\mathbf{N}^*$ , avem

$$\begin{aligned} |u - u(i, n)| &= \left| (S) \int f d\mu - (S) \int f(i, n) d\mu \right| \leq \\ &\leq \left| (S) \int f d\mu - (S) \int \underline{f}(i) d\mu \right| + \left| (S) \int \underline{f}(i) d\mu - (S) \int f(i, n) d\mu \right|. \end{aligned}$$

În cazul (STD):

Putem lua  $i_0$  astfel încât  $\mu(F_{i_0}(f)) \leq i_0$ , deci condiția  $\mu(F_i(f)) \leq i$  este îndeplinită pentru orice  $i \geq i_0$  iar asta duce la

$$(S) \int f d\mu = (S) \int \underline{f}(i) d\mu.$$

Putem lua  $n$  astfel încât  $\frac{1}{n} < \varepsilon$  (de exemplu  $n = \lceil \frac{1}{\varepsilon} \rceil + 1$ ) iar asta duce la (pentru orice  $i$ )

$$\left| (S) \int \underline{f}(i) d\mu - (S) \int f(i, n) d\mu \right| < \varepsilon.$$

În final, avem  $|u - u(i, n)| < \varepsilon$ .

În cazul (SDT):

Putem lua  $i$  astfel încât  $\frac{1}{i} < \varepsilon$  (de exemplu  $i = \left[\frac{1}{\varepsilon}\right] + 1$ ) și asta duce la

$$\left| (S) \int f d\mu - (S) \int \underline{f}(i) d\mu \right| < \varepsilon.$$

Putem lua  $n_0$  astfel încât  $\mu(F_{n_0}(f)) \leq n_0$  (deci condiția  $\mu(F_n(f)) \leq n$  este îndeplinită pentru orice  $n \geq n_0$ ) iar asta duce la (pentru orice  $i$  și orice  $n \geq n_0$ )

$$(S) \int \underline{f}(i) d\mu = (S) \int f(i, n) d\mu.$$

La final, avem  $|u - u(i, n)| < \varepsilon$ .

### 4.3.3 Calcul folosind Teorema de Convergență Iterată

#### Teorema de Convergență Iterată

Fie  $(X, d)$  un spațiu imetric. Asumăm că  $(u(i, n))_{i, n \geq 1}$  este o secvență dublă în  $X$  astfel încât:

a) Pentru orice  $i \in \mathbf{N}^*$ , există  $\lim_n u(i, n) = u(i) \in X$ .

b) Există  $\lim_i u(i) = u \in X$ .

Atunci, există o funcție crescătoare  $\sigma : \mathbf{N}^* \rightarrow \mathbf{N}^*$  (cu  $\sigma(\mathbf{N}^*) = \mathbf{N}^*$ ) astfel încât  $\lim_n u(\sigma(n), n) = u$  (sintetic:  $\lim_i \lim_n u(i, n) = \lim_n u(\sigma(n), n) = u$ ).

**Algoritmul. Viteza de convergență**

Pasul 1. Definim secvența strict crescătoare  $(n_i)_i$  astfel încât

$$(n \geq n_i) \Rightarrow \left( d(u(i, n), u(i)) < \frac{1}{i} \right).$$

Pasul 2. Definim secvența strict crescătoare  $(i_p)_p$  astfel încât

$$(i \geq i_p) \Rightarrow \left( d(u(i), u) < \frac{1}{p} \right).$$

Pasul 3. Definim

$$p(\varepsilon) = \left[ \frac{2}{\varepsilon} \right] + 1.$$

Pasul 4. Definim

$$n(\varepsilon) = n_{i_{p(\varepsilon)}} + 1.$$

Pasul 5. Calculăm

$$\sigma(n(\varepsilon)) = \sigma(n_{i_{p(\varepsilon)}} + 1) = i_{p(\varepsilon)}.$$

Pasul 6. Aproximarea "bună" este

$$u(\sigma(n(\varepsilon)), n(\varepsilon)) = u(i_{p(\varepsilon)}, n_{i_{p(\varepsilon)}} + 1)$$

a.î.  $u(i, n)$  cu  $i = i_{p(\varepsilon)}, n = n_{i_{p(\varepsilon)}} + 1$  și avem

$$d(u, u(i, n)) < \varepsilon. \square$$

Aplicăm algoritmul astfel:

- În cazul *Strategiei Trunchiere – Discretizare*, știm că  $|u(i, n) - u(i)| \leq \frac{1}{n}$  pentru orice  $i$  și trebuie să avem, pentru  $n \geq n_i$ , inegalitatea  $|u(i, n) - u(i)| < \frac{1}{i}$ . Va fi suficient să avem  $\frac{1}{n} < \frac{1}{i}$ , i.e.  $n > i$ . Putem lua  $(n_i)_i$  dat prin  $n_i = i + 1$ . De asemenea, știm că dacă  $i_0 \geq \mu(F_{i_0})$ , avem  $u(i) = u$  pentru orice  $i \geq i_0$ . Trebuie să avem  $|u(i) - u| < \frac{1}{p}$  pentru orice  $i \geq i_p$ . Putem lua  $i_p = i_0 + p$ .
- În cazul *Strategiei Discretizare – Trunchiere*, știm că, dacă  $n_0 \geq \mu(F_{n_0})$ , avem  $u(i, n) = u(i)$ , pentru orice  $i$  și orice  $n \geq n_0$  și trebuie să avem  $|u(i, n) - u(i)| < \frac{1}{i}$  pentru  $n \geq n_i$ . Putem lua  $n_i = n_0 + i$ . De asemenea, știm că  $|u(i) - u| < \frac{1}{i}$  și trebuie să avem, pentru  $i \geq i_p$ ,  $|u(i) - u| < \frac{1}{p}$ . Va fi suficient să avem  $\frac{1}{i} < \frac{1}{p}$ , a.î.  $i > p$ . Putem lua  $i_p = p + 1$ .  $\square$

#### 4.3.4 Remarci referitoare la Metoda în Doi Pași în cazul Funcțiilor Mărginite. Reducerea Calculului

**Reducerea Calculului pentru Metoda Simplă în Doi Pași**

– În cazul *Strategiei Trunchiere – Discretizare*, luăm  $i_0 \in \mathbf{N}^*$  astfel încât  $i_0 \geq M$ , prin urmare  $(S) \int f d\mu = (S) \int \underline{f}(i_0) d\mu$ . Atunci, pentru orice  $n \in \mathbf{N}^*$ :

$$|u - u(i_0, n)| = \left| (S) \int f d\mu - (S) \int \underline{f}(i_0, n) d\mu \right| \leq$$

$$\begin{aligned}
&\leq \left| (S) \int f d\mu - (S) \int \underline{f}(i_0) d\mu \right| + \left| (S) \int \underline{f}(i_0) d\mu - (S) \int f(i_0, n) d\mu \right| = \\
&= \left| (S) \int \underline{f}(i_0) d\mu - (S) \int f(i_0, n) d\mu \right| \leq \frac{1}{n}.
\end{aligned}$$

Luăm  $n$  astfel încât  $\frac{1}{n} < \varepsilon$  (e.g.  $n = \left[\frac{1}{\varepsilon}\right] + 1$ ) și avem

$$|u - u(i_0, n)| < \varepsilon$$

(doar  $u(i_0, n)$  poate fi calculat).

– În cazul *Strategiei Discretizare – Trunchiere*, luăm  $n_0 \in \mathbf{N}^*$  astfel încât  $n_0 \geq M$ , prin urmare  $n_0 \geq \underline{f}(i)$  pentru orice  $i \in \mathbf{N}^*$ , avem  $(S) \int f(i, n_0) d\mu = (S) \int \underline{f}(i) d\mu$ . În consecință, pentru orice  $i \in \mathbf{N}^*$ :

$$\begin{aligned}
|u - u(i, n_0)| &= \left| (S) \int f d\mu - (S) \int f(i, n_0) d\mu \right| \leq \\
&\leq \left| (S) \int f d\mu - (S) \int \underline{f}(i) d\mu \right| + \left| (S) \int \underline{f}(i) d\mu - (S) \int f(i, n_0) d\mu \right| = \\
&= \left| (S) \int f d\mu - (S) \int \underline{f}(i) d\mu \right| \leq \frac{1}{i}.
\end{aligned}$$

Luăm  $i$  astfel încât  $\frac{1}{i} < \varepsilon$  (e.g.  $i = \left[\frac{1}{\varepsilon}\right] + 1$ ) și avem

$$|u - u(i, n_0)| < \varepsilon$$

(doar  $u(i, n_0)$  poate fi calculat).  $\square$

### Reducerea Calculului pentru Teorema de Convergență Iterată

– În cazul *Strategiei Trunchiere – Discretizare*, luăm  $i_0 \in \mathbf{N}^*$  astfel încât  $i_0 \geq M$  și din nou vedem că  $|u(i_0, n) - u(i_0)| \leq \frac{1}{n}$ . Putem lua  $n_i = i + 1$ . Avem  $u(i) = u(i_0) = u$  pentru  $i \geq i_0$ , prin urmare inegalitatea  $|u(i) - u| < \frac{1}{p}$  este validă pentru orice  $i \geq i_0$ . Putem lua  $i_p = i_0 + p$  pentru a avea o secvență strict crescătoare.

– În cazul *Strategiei Discretizare – Trunchiere*, luăm  $n_0 \in \mathbf{N}^*$  astfel încât  $n_0 \geq M$ . Avem  $u(i, n) = u(i, n_0) = u(i)$  for any  $n \geq n_0$  și orice  $i \in \mathbf{N}^*$  (pentru că  $n_0 \geq \underline{f}(i)$  pentru orice  $i \in \mathbf{N}^*$ ). Putem lua  $n_i = n_0 + i$  pentru a avea o secvență strict crescătoare. Pentru că  $|u(i) - u| < \frac{1}{i}$ , putem lua  $i_p = p + 1$ .  $\square$

### 4.3.5 Aplicația Finală

Începem prin a defini, pentru orice  $p \in \mathbf{N}^*$ , mulțimea  $A_p \stackrel{\text{def}}{=} \bigcup_{n=p}^{\infty} [n, n + \frac{1}{2^n}]$ . De asemenea, fie  $A \stackrel{\text{def}}{=} A_1$ . Dacă  $m$  este o măsură Lebesgue pe  $\mathbf{R}$ , avem  $m(A) = 1$  și  $m(A_p) = \frac{1}{2^{p-1}}$  pentru orice  $p \in \mathbf{N}^*$ .

#### Prima Parte.

Considerăm funcția  $h : [1, \infty) \rightarrow \mathbf{R}_+$  dată prin

$$h(x) = \begin{cases} x, & \text{dacă } x \in A \\ 1, & \text{dacă } x \notin A \end{cases}.$$

Putem calcula  $F_\alpha \stackrel{\text{def}}{=} F_\alpha(h)$  pentru orice  $\alpha \in \mathbf{R}_+$ . Pentru  $0 \leq \alpha \leq 1$ , avem  $F_\alpha = [1, \infty)$ . Pentru  $1 < \alpha \leq 1 + \frac{1}{2}$ , avem  $F_\alpha = [\alpha, 1 + \frac{1}{2}] \cup A_2$  și pentru  $1 + \frac{1}{2} < \alpha < 2$ , avem  $F_\alpha = A_2$ . Continuăm, pentru  $n \geq 2$ , avem:

- pentru  $n \leq \alpha \leq n + \frac{1}{2^n}$ ,  $F_\alpha = [\alpha, n + \frac{1}{2^n}] \cup A_{n+1}$ ;
- pentru  $n + \frac{1}{2^n} < \alpha < n + 1$ ,  $F_\alpha = A_{n+1}$ .

Considerând un spațiu măsurabil monoton  $([1, \infty), \mathcal{T}, \mu)$ , unde  $\mathcal{T}$  = mulțime Borel pe  $[1, \infty)$  și  $\mu : \mathcal{T} \rightarrow \overline{\mathbf{R}}_+$  este o măsură Lebesgue pe  $[1, \infty)$ , vedem că:

- pentru  $0 \leq \alpha \leq 1$ ,  $\mu(F_\alpha) = \infty$ ;
- pentru  $1 < \alpha \leq 1 + \frac{1}{2}$ ,  $\mu(F_\alpha) = 2 - \alpha$ ;
- pentru  $1 + \frac{1}{2} < \alpha < 2$ ,  $\mu(F_\alpha) = \frac{1}{2}$

și, dacă  $n \geq 2$ :

- pentru  $n \leq \alpha \leq n + \frac{1}{2^n}$ ,  $\mu(F_\alpha) = n + \frac{1}{2^{n-1}} - \alpha$ ;
- pentru  $n + \frac{1}{2^n} < \alpha < n + 1$ ,  $\mu(F_\alpha) = \frac{1}{2^n}$ .

Acum, putem demonstra că  $(S) \int h d\mu = 1$ . Într-adevăr, pentru  $0 \leq \alpha \leq 1$ , avem  $\mu(F_\alpha) = \infty > \alpha$ , prin urmare  $\alpha \wedge \mu(F_\alpha) = \alpha$ . Pentru  $\alpha > 1$ , putem vedea că  $\mu(F_\alpha) < \alpha$ , prin urmare  $\alpha \wedge \mu(F_\alpha) = \mu(F_\alpha)$ . Este adevărat, întâi, pentru  $1 < \alpha < 1 + \frac{1}{2}$ , unde  $\mu(F_\alpha) = 2 - \alpha < \alpha$ . Apoi, dacă  $\alpha \geq 1 + \frac{1}{2}$ , luăm  $1 < \alpha_0 < 1 + \frac{1}{2}$  și avem  $\mu(F_\alpha) \leq \mu(F_{\alpha_0}) < \alpha_0 < \alpha$ . Cu aceste valori, putem vedea că  $\alpha \wedge \mu(F_\alpha) < 1$  pentru orice  $\alpha \neq 1$ , prin urmare  $1 = 1 \wedge \mu(F_1) = \sup_{\alpha \in [0, \infty)} \alpha \wedge \mu(F_\alpha) = (S) \int h d\mu$ . Este de notat faptul că calculul  $(S) \int h d\mu$  nu este "sharp", pentru că  $(S) \int h d\mu = 1$  nu este o soluție a ecuației  $\alpha = \mu(F_\alpha)$  (această ecuație nu are soluție).

#### A Doua Parte.

Bazându-ne pe Prima Parte, vom studia un exemplu mai complicat. Spațiul măsurabil

luat în considerare va fi  $(T, \mathcal{T}, \mu)$ , unde  $T = [0, \infty)$ ,  $\mathcal{T}$  = o mulțime Borel pe  $[0, \infty)$  și  $\mu : \mathcal{T} \rightarrow \overline{\mathbf{R}}_+$  va fi o măsură Lebesgue. Vom studia funcția  $f : [0, \infty) \rightarrow \mathbf{R}_+$ , definită prin (vezi Prima Parte)

$$f(x) = \begin{cases} h(x), & \text{dacă } x \in [1, \infty) \\ \tan\left(\frac{\pi}{2}x\right), & \text{dacă } x \in [0, 1) \end{cases}.$$

Rezultă că, pentru orice  $x \in \mathbf{R}_+$ , avem  $F_\alpha(f) = A_\alpha \cup B_\alpha$ , unde

$$A_\alpha = F_\alpha(h) = \{x \in [1, \infty) \mid f(x) = h(x) \geq \alpha\}$$

și

$$B_\alpha = \left\{x \in [0, 1) \mid f(x) = \tan\left(\frac{\pi}{2}x\right) \geq \alpha\right\} = \left[\frac{2}{\pi} \arctan \alpha, 1\right)$$

cu  $\mu(B_\alpha) = 1 - \frac{2}{\pi} \arctan \alpha$ . Pentru că  $\mu(F_\alpha(f)) = \mu(A_\alpha) + \mu(B_\alpha)$ , pentru orice  $\alpha \in \mathbf{R}_+$ , vedem că:

- pentru  $0 \leq \alpha \leq 1$ ,  $\mu(F_\alpha) = \infty$ ;
- pentru  $1 < \alpha \leq 1 + \frac{1}{2}$ ,  $\mu(F_\alpha) = 3 - \alpha - \frac{2}{\pi} \arctan \alpha$ ;
- pentru  $1 + \frac{1}{2} < \alpha < 2$ ,  $\mu(F_\alpha) = \frac{3}{2} - \frac{2}{\pi} \arctan \alpha$ ;

și, dacă  $n \geq 2$ :

- pentru  $n \leq \alpha \leq n + \frac{1}{2^n}$ ,  $\mu(F_\alpha) = n + 1 + \frac{1}{2^{n-1}} - \alpha - \frac{2}{\pi} \arctan \alpha$  (în particular,  $\mu(F_n) = 1 + \frac{1}{2^{n-1}} - \frac{2}{\pi} \arctan n \xrightarrow{n} 0$  și Condiția (G) este îndeplinită);
- for  $n + \frac{1}{2^n} < \alpha < n + 1$ ,  $\mu(F_\alpha) = 1 + \frac{1}{2^n} - \frac{2}{\pi} \arctan \alpha$ .

Se poate verifica că funcția  $\alpha \rightarrow \mu(F_\alpha)$  este continuă pe  $(1, \infty)$ . Vom folosi o estimare preliminară, anume, pentru orice  $2 \leq n \in \mathbf{N}$ :

$$\mu(F_n) = 1 + \frac{1}{2^{n-1}} - \frac{2}{\pi} \arctan n \leq 1 + \frac{1}{n} - \frac{2}{\pi} \arctan n = 1 + \frac{1}{n} - \frac{2}{\pi} \left( \frac{\pi}{2} - \arctan \frac{1}{n} \right) =$$

$$= \frac{1}{n} + \frac{2}{\pi} \arctan \frac{1}{n} < \frac{1}{n} + \frac{2}{\pi} \frac{1}{n} < \frac{2}{n}.$$

Acum, ne pregătim să calculăm  $(S) \int f d\mu$  aproximativ, folosind metoda celor doi pași. Calculul va fi dat cu o eroare mai mică decât  $\varepsilon = \frac{1}{100}$ .

### Calcul cu Metoda Simplă a celor Doi Pași

- În cazul *Strategiei Trunchiere - Discretizare*, putem lua  $i_0 = 2$ , pentru că, în acest caz,  $\mu(F_{i_0}) < i_0$  (vezi estimarea preliminară :  $\mu(F_{i_0}) < \frac{2}{i_0}$ ) și orice  $i \geq 2$  va fi satisfăcător. De asemenea, luăm  $n = \left[\frac{1}{\varepsilon}\right] + 1 = 101$ . Aproximarea "bună" este  $u(i, n) =$

$u(2, 101)$ .

– În cazul *Strategiei Discretizare – Trunchiere*, calculele sunt similare cu cele din cazul (STD), interschimbând  $i$  și  $n$ .

Folosind un program JavaScript obținem (evident, egale) valorile

$$u(2, 101) = 1.2178217821782178 \text{ (STD)}$$

$$u(101, 2) = 1.2178217821782178 \text{ (SDT)}.$$

### Calcul folosind Teorema de Convergență Iterată

Conform algoritmului, putem lua  $p(\varepsilon) = \left\lceil \frac{2}{\varepsilon} \right\rceil + 1 = 200 + 1 = 201$ .

– În cazul *Strategiei Trunchiere – Discretizare*, putem lua  $n_i = i + 1$ ,  $i_p = i_0 + p$  și  $i_0 = 2$ . Conform algoritmului:

$$i_{p(\varepsilon)} = i_0 + p(\varepsilon) = 2 + 201 = 203$$

$$n(\varepsilon) = n_{i_{p(\varepsilon)}} + 1 = n_{203} + 1 = 203 + 1 + 1 = 205$$

$$\sigma(n(\varepsilon)) = i_{p(\varepsilon)} = 203.$$

Aproximarea "bună" este

$$u(\sigma(n(\varepsilon)), n(\varepsilon)) = u(203, 205).$$

Utilizând un program JavaScript am obținut valoarea

$$u(203, 205) = 1.2177295007254347.$$

– În cazul *Strategiei Discretizare – Trunchiere*, putem lua  $i_p = p + 1$ ,  $n_i = n_0 + i$  și  $n_0 = 2$ . Conform algoritmului:

$$i_{p(\varepsilon)} = i_{201} = 202.$$

$$n(\varepsilon) = n_{i_{201}} + 1 = 2 + i_{201} + 1 = 2 + 202 + 1 = 205$$

$$\sigma(n(\varepsilon)) = i_{p(\varepsilon)} = 202.$$

Aproximarea "bună" este

$$u(\sigma(n(\varepsilon)), n(\varepsilon)) = u(202, 205).$$

Utilizând un program JavaScript am obținut valoarea

$$u(202, 205) = 1.2177295007254347.$$

### Remarcă Finală.

De fapt, calculul  $(S) \int f d\mu$  poate să fie făcut brusc. Anume, *folosind calculul aproximativ anterior*, am văzut că  $(S) \int f d\mu \in (1, 1 + \frac{1}{2})$ . Acest lucru ne determină să căutăm o soluție  $\alpha_0 \in (1, 1 + \frac{1}{2})$  a ecuației  $\alpha = \mu(F_\alpha(f))$  și această soluție va fi cu siguranță egală cu  $(S) \int f d\mu$ . Pentru  $\alpha \in (1, 1 + \frac{1}{2})$ , ecuația  $\alpha = \mu(F_\alpha(f))$  devine

$$\left(\alpha = 3 - \alpha - \frac{2}{\pi} \arctan \alpha\right) \Leftrightarrow \left(\alpha + \frac{1}{\pi} \arctan \alpha = \frac{3}{2}\right).$$

Ultima ecuație are soluție unică  $\alpha_0 \in (1, 1 + \frac{1}{2})$ . Într-adevăr, considerând funcția continuă strict crescătoare  $\varphi : \mathbf{R}_+ \rightarrow \mathbf{R}$ ,  $\varphi(\alpha) = \alpha + \frac{1}{\pi} \arctan \alpha$ , avem  $\varphi(1) = 1 + \frac{1}{4} < \frac{3}{2}$  și  $\varphi(\frac{3}{2}) = \frac{3}{2} + \frac{1}{\pi} \arctan \frac{3}{2} > \frac{3}{2}$ , deci există  $\alpha_0$  (unică) astfel încât  $\varphi(\alpha_0) = \frac{3}{2}$ .

Rezolvând numeric ecuația  $\alpha + \frac{1}{\pi} \arctan \alpha = \frac{3}{2}$  obținem soluția  $\alpha_0 = 1.21872201352426$  (folosind Matlab) care confirmă rezultatul precedent.

# Concluzii

În această teză, am studiat noi direcții de aplicare a teoriei măsurii generalizate, folosind integralele Choquet și Sugeno, în următoarele domenii: economie - piața de capital, psihologie și calcul aproximativ.

În domeniul economic am studiat un nou model de decizie matematică bazat pe integrala Choquet. Am introdus o metodă de selectare a celor mai probabili viitori clienți investitori (investitori virtuali) ai unei companii de brokeraj pe piața de capital. Considerăm că această metodă este nouă și poate fi folosită în diverse situații de decizie.

În domeniul psihologiei am studiat câteva modele matematice bazate pe integrala Choquet, descriind modul în care sunt procesate undele de tip EEG pentru a caracteriza nivelul de Deschidere și nivelul de Anxietate. Modelele au fost validate comparând valorile lor cu valorile determinate prin utilizarea metodelor clasice (teste psihologice). Am construit modele de agregare, folosind datele rezultate din măsurătorile subiecților. Am folosit integrale nonliniare (integrala Choquet) ca instrument de fuziune (Data mining). Aceste modele matematice pot fi considerate modele de învățare automată. În câțiva ani, în funcție de rezultatele cercetărilor din domeniul psihologiei, aceste modele pot fi rafinate și aprobate și pot deveni utile tuturor categoriilor de psihologi.

În domeniul calculului aproximativ am studiat o procedură practică pentru calculul aproximativ al integralei Sugeno a unei funcții măsurabile pozitive generale care respectă o măsură generalizată monotonă. Am folosit metode în doi pași (metoda simplă în doi pași și metoda topologică folosind teorema de convergență iterată). Aceste metode reduc calculul general la calculul bine-cunoscut în cazul discret finit, care poate fi realizat cu metode asistate de calculator.

# Dezvoltări viitoare

Scopul acestei teze de doctorat este de a dezvolta noi direcții de aplicații ale teoriei măsurii generalizate, numită și teoria fuzzy, folosind integralele Choquet și Sugeno. Am dezvoltat noi modele matematice în domeniile pieței de capital, psihologiei și calculului aproximativ.

Bazându-ne pe modelele matematice dezvoltate, putem continua cercetările în domeniile abordate.

În domeniul economic putem continua crearea unui model de decizie în domeniul bancar. De exemplu, un model pentru o bancă care trebuie să selecteze cei mai eligibili clienți pentru a acorda credite imobiliare.

În domeniul psihologiei, putem continua cercetările folosind un nou aparat de tip NeuroSky, cu doi senzori activi, pentru măsurarea undelor EEG (am folosit un aparat cu un singur senzor activ). Un inconvenient major al modelelor create de noi este că măsura este recalculată de fiecare dată, iar cu un volum foarte mare de date, avem nevoie de putere mare de calcul. În acest sens, metoda noastră poate fi rafinată, încercăm să reutilizăm vechea măsură și noile date pentru a calcula o măsură nouă, mai precisă. O altă direcție viitoare este folosirea teoriei măsurii generalizate și a integralelor nonliniare pentru a face predicții cu privire la crizele pacienții cu epilepsie, deoarece există cercetări de specialitate care arată că undele EEG se modifică la pacienții cu epilepsie, înainte de o nouă criză.

O idee de dezvoltare viitoare legată de integrala Sugeno, ar fi folosirea metodei prezentate în această teză pentru a reface calculele din anumite lucrări de specialitate în care măsurile au fost discretizate forțat și ulterior utilizate pentru calcul.

# Bibliografie

1. American Psychiatric Association, Diagnostic and Statistical Manual of Mental Disorders, DSM-5, 5th edition, Washington DC, 2013.
2. O.M.Bazanov, D.Vernon, Interpreting EEG alpha activity, Neuroscience and Biobehavioral Reviews, vol. 44, pp 94–110, 2014.
3. G. Beliakov, M. Gagolewski, S. James, DC optimization for constructing discrete Sugeno integrals and learning nonadditive measures, Optimization, Published online: 26 Dec 2019, <https://doi.org/10.1080/02331934.2019.1705300>.
4. G. Beliakov, S. James, J.-Z. Wu, Discrete Fuzzy Measures. Computational Aspects, Springer, 2020.
5. M. Boczek, M. Kaluszka, Sharp bounds of Jensen type for the generalized Sugeno integral, arXiv: 1809.08303v1 [math.FA], 21 Sep 2018.
6. L. M. De Campos, M. Jorge Bolaños, Characterization and comparison of Sugeno and Choquet integrals, Fuzzy Sets and Systems, vol.52, pp. 61-67, 1992.
7. E. Catană, G.C. Costache, D. Petre, S. Ilie, R.V. Paraschiv, 3D Reality Perception By Operator And Sensors, Proceeding of National Conference Energy And Ballistic Systems – SEB 2013, Military Technical Academy, Bucharest, 2013
8. A. Chisholm, An Introduction to Capital Markets: Products, Strategies, Participants, John Wiley & Sons, 2002.
9. I. Chițescu, A. Plăvițu, Computing Choquet integrals, Fuzzy Sets and Systems, vol. 327, pp 46-68, 2017.
10. I. Chițescu, **M. Giurgescu (Manea)**, A. Plăvițu, Computing Sugeno integrals, Fuzzy Sets and Systems, vol. 465, 2023, <https://doi.org/10.1016/j.fss.2023.03.016>.

11. I. Chițescu, D. Stănică, A.Plăvițu, Existence and uniqueness of countable  $\lambda$ -measures with preassigned values, *Fuzzy Sets and Systems*, vol. 244, pp. 1-19, 2014.
12. I. Chițescu, **M. Giurgescu (Manea)**, T. Paraschiv, Looking for Virtual Investors, *Proceedings of Fifth International Congress of Information and Communication Technology*, Springer, London, England, vol.1, pp. 119-128, September 2020, <https://doi.org/10.1007/978-981-15-5856-6>.
13. I. Chițescu, The Sugeno integral. A point of view, *Information Sciences*, vol. 582, pp. 648-664, 2022.
14. I. Chițescu, **M. Giurgescu (Manea)**, T. Paraschiv, Using the Choquet integral for the determination of the Anxiety degree, *Research Square*, <https://doi.org/10.21203/rs.3.rs-1027357/v1>.
15. M. Chraif, R.V. Paraschiv R.V., Specific Measurement In Psychology, *Proceeding of The International Conference Education and Creativity for a Knowledge-Based Society*, Titu Maiorescu University, Bucharest, Romania, pp. 139-144, 2015
16. M. Couceiro, D. Dubois, H. Prade, T. Waldhauser, Decision-Making with Sugeno Integrals: Bridging the Gap Between Multicriteria Evaluation and Decision Under Uncertainty, *Order* 33, pp 517-535, 2016.
17. D. Dubois, H. Fargier, A. Rico, Commuting Double Sugeno Integrals, *International Journal of Uncertainty Fuzziness and Knowledge-Based Systems*, vol.27, pp 1-38, 2019.
18. D. Dubois, H. Prade, A. Rico, B. Teheux, Generalized Sugeno Integrals, In: 16—th International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems (IPMU 2016), Eindhoven, Netherlands, pp 363-374, 2016.
19. D. Dubois, H. Prade, A. Rico, B. Teheux, Generalized qualitative Sugeno Integrals, *Information Sciences* vol.415-416, pp 429-445, 2017.
20. D. Dubois, A. Rico, New axiomatization of discrete quantitative and qualitative possibilistic integrals, *Fuzzy Sets and Systems* vol.343, pp 3-19, 2018.
21. N. Dunford, J. Schwartz, *Linear Operators. Part I*, Interscience Publishers, Inc., 1967.

22. G.Gennady, G.Knyazev, EEG correlates of personality types, *Netherlands Journal of Psychology*, vol. 62(2), pp 78-87, 2006.
23. **M. Giurgescu (Manea)**, I. Chițescu, T. Paraschiv, C Ștefan, A diagnostication method of Openness using the nonlinear integrals, *Politehn. Univ. Bucharest Sci. Bull. Ser. A Appl. Math. Phys.*, Vol. 82, pp. 231-234, Iss. 1, 2020.
24. **M. Giurgescu (Manea)**, I. Chițescu, C.M. Milea, A mathematical model which characterizes the level of Openness, *Proceedings of The International Conference Education and Creativity for a Knowledge-Based Society*, XIIth Edition, Titu Maiorescu University, Bucharest, Romania, November 2018, <https://ssrn.com/author=3343042>
25. **M. Giurgescu (Manea)**, Towards a diagnostication method of anxiety using the Choquet integral, *Proceedings of The Technical-Scientific Conference of Students, Masters and PhD Students*, vol.1, Technical University of Moldova, Chișinău, Republic of Moldova, March 2019.
26. **M. Giurgescu (Manea)**, I. Chițescu, T. Paraschiv, Using a generalized measure to determine the Openness level, *Proceedings of the International Conference Education and Creativity for a Knowledge-Based Society*, XIVth Edition, Titu Maiorescu University, Bucharest, Romania, November 2020.
27. M. Grabisch, T. Murofushi, M. Sugeno (editors), *Fuzzy Measures and Integrals. Theory and Applications*, PhysicaVerlag, 2000.
28. M.Grabisch, *Set Functions, Games and Capacities in Decision Making*, Springer, 2016.
29. A.M.Grass, F.A.Gibbs, A Fourier transform of the electroencephalogram, *J.Neurophysiol*, vol.1, pp 521–526, 1938.
30. D.Grigore, R.V. Paraschiv R.V, L.O. Anghelina, Multiple Stimuli Action On The GSR Functions Involved in the Remote Motion Command and Control, *Proceeding of International Conference Greener and Safer Energetic and Ballistic Systems (GSEBS)*, Military Technical Academy, Bucharest, Romania, 26 – 27 May 2016.
31. D. Grigore, R.V. Paraschiv, Signal Processing GSR For Motion Control, *Proceedings of the International Conference Education and Creativity for a Knowledge-Based Society*, Titu Maiorescu University, Bucharest, Romania, pp. 169-178, 2016.

32. D. Grigore, G.C. Costache, C. Ștefan, R.V. Paraschiv, Waking Capacity Evaluation By Direct Measurement, Proceedings of the International Conference Education and Creativity for a Knowledge-Based Society, Titu Maiorescu University, Bucharest, Romania, pp. 105-111, 2014.
33. R. Halaš, R. Mesiar, J. Pócs, A new characterization of the discrete Sugeno integral, Information Fusion, vol. 29, pp 84-86, 2016.
34. T.Harmony, The functional significance of delta oscillations in cognitive processing, Frontiers in Integrative Neuroscience, <https://doi.org/10.3389/fnint.2013.00083>.
35. D.E.Hinkle, W.Wiersma, S.G.Jurs, Applied Statistics for the Behavioral Sciences, 5th edition, Houghton Mifflin Company, Boston, New York, 2003.
36. J.W. Hughes, C.M. Stoney, Depressed mood is related to high-frequency heart rate variability during stressors, Psychosomatic Medicine, vol.62, pp.796-803, 2000.
37. H. Jasper, Report of committee on methods of clinical exam in EEG, Electroencephalogr. Clin. Neurophysiol, vol.10, 1958.
38. N. Kane, J. Acharya, S. Benickzy, L. Caboclo, S. Finnigan, P. W. Kaplan, H. Shibasaki, R. Pressler, M. J A M van Putten, A revised glossary of terms most commonly used by clinical electroencephalographers and updated proposal for the report format of the EEG findings, Revision 2017, Corrected 2019, Clin.Neurophy.Pract, vol.4, 133, 2019.
39. J. Kawabe, The bounded convergence in measure theorem for nonlinear integral functionals, Fuzzy Sets and Systems, vol.271, pp 31-42, 2015.
40. J. Kawabe, Weak convergence of nonadditive measures based on nonlinear integral functionals, Fuzzy Sets and Systems, vol.289, pp 1-15, 2016.
41. J. L. Kelley, General Topology, American Book – Van Nostrand – Reinhold, 1955.
42. G.Knyazev, E.Merkulova, A.Savostyanov, A.Bocharov, A.Saprigyn, Personality and EEG correlates of reactive social behavior, Neuropsychologia, vol. 124, pp 98-107, 2019.
43. C.M. Milea, I. Chițescu, **M. Giurgescu (Manea)**, Applications of the Laplace transform and Choquet's integral, Proceedings of The International Conference Education and Creativity for a Knowledge-Based Society, XIIth Edition, Titu Maiorescu University, Bucharest, Romania, November 2018.

44. E. Niedermeyer and F. Lopes da Silva, eds, *Electroencephalography, Basic Principles, Clinical Applications and Related Fields*, 4th edition. Lippincott, Williams and Wilkins, Philadelphia, Pennsylvania, 1999.
45. E. Niedermeyer, F. Lopes da Silva, eds, *The normal EEG of the waking adult*, 4<sup>th</sup> edition, Lippincott, Williams and Wilkins, Philadelphia, Pennsylvania, 1999.
46. P.L. Nunez, *Neocortical Dynamics and Human EEG Rhythms*, Oxford University Press, New York, pp 179, 1995.
47. E. Pap (editor), *Handbook of Measure Theory*, two volumes, Elsevier, North Holland, 2002.
48. E. Pap, *Null-Additive Set Functions*, Kluwer, 1995.
49. R. V. Paraschiv, A. Constantin, **M. Giurgescu (Manea)**, Contributions to studying attention focalized, by processing EEG type waves, *Proceedings of The International Conference Education and Creativity for a Knowledge-Based Society*, XIIth Edition, Titu Maiorescu University, Bucharest, Romania, November 2018.
50. R.V. Paraschiv, Study on EEG wave amplitude measured with a sensor and academic performance, *Proceedings of The International Conference Education and Creativity for a Knowledge-Based Society*, Titu Maiorescu University, Bucharest, Romania, 2018.
51. T. Paraschiv, D. Postolea, C. Petrescu, *Biocybernetics*, Titu Maiorescu University, Bucharest, pp.19-30, 2015.
52. D.J. Paulus, S. Vanwoerden, P.J. Norton, C. Sharp, From neuroticism to anxiety. Examining unique contributions of three transdiagnostic vulnerability factors, *Personality and Individual Differences*, vol. 94, pp 38-43, 2016.
53. D. Postolea, C. Stefan, D. Ionescu, R.V. Paraschiv R.V., *Brain-Computer Interface And Applications In Robotics*, *Proceeding of National Conference "Energy And Ballistic Systems - SEB 2013"*, Military Technical Academy, 2013;
54. D. Postolea, A.I. Urichianu, R.V. Paraschiv, *Statistical Methods For Processing Of Biosignals*, *Proceeding of International Conference Greener and Safer Energetic and Ballistic Systems (GSEBS)*, Military Technical Academy, Bucharest, Romania, 2015.

55. D. Ralescu, G. Adams, The Fuzzy Integral, J. Math. Analysis Appl. vol.75, pp. 562-570, 1980.
56. G. Shafer, A Mathematical Theory of Evidence, Princeton University Press, 1976.
57. F.W. Sharbrough, Nonspecific abnormal EEG patterns, Chapter. 12, Electroencephalography, Basic Principles, Clinical Applications, and Related Fields, Eds E. Niedermeyer and F. Lopes Da Silva, 4<sup>th</sup> edn., Lippincott, Williams and Wilkins, Philadelphia, Pennsylvania, 1999.
58. H.W. Shipton, EEG analysis: a history and a prospectus, Annual Review of Biophysics and Bioengineering, vol. 4, pp 1–15, 1975.
59. B. Stroustrup, The C++ Programming Language, 4th edition. Addison-Wesley Professional, 2013.
60. M. Sugeno, Theory of Fuzzy Integrals and its Applications. A Dissertation Submitted in Partial Fulfillment of the Requirements for the Degree of Doctor Engineering at Tokyo Institute of Technology, 1974.
61. V.I. Tănase, M. Puiu, C. Petrescu, R.V. Paraschiv, Investigating, Using NeuroSky and GSR, Caution-Contemplation Indicators and Stability-Instability, Proceedings of The International Conference Education and Creativity for a Knowledge-Based Society, Titu Maiorescu University, Bucharest, Romania, 2013.
62. M. Teplan, Fundamentals of EEG measurements, Measmt Sci. Rev., vol.2(2), 2002.
63. Z.Wang, G. J. Klir, Fuzzy Measure Theory, Springer, 1992.
64. Z.Wang, G. J. Klir, Generalized Measure Theory, Springer, 2009.
65. Z.Wang, R. Yang, K-S. Leung, Nonlinear Integrals and Their Applications in Data Mining, World Scientific, 2010.
66. S. Weber, Decomposable measures and integrals for Archimedean t-conorms, J. Math. Anal., vol.101, pp. 114-138, 1984.
67. L.A.Zadeh, Fuzzy algorithms, Information and Control, San Diego, vol. 12(2), pp. 94-102, 1968.
68. L.A.Zadeh, Fuzzy logic=computing with words, IEEE Transactions on Fuzzy Systems, vol. 4(2), pp. 103-111, 1996.

69. L.A.Zadeh, Fuzzy sets, Information and Control, San Diego, vol. 8(3), pp. 338-353, 1965.
70. L.A.Zadeh, Quantitative fuzzy semantics, Information Sciences, vol. 3(2), pp. 159-176, 1971.