

Determinarea de semnături pentru consumatori casnici pe baza datelor înregistrate de contoarele inteligente

Teză destinată obținerii
titlului științific de doctor inginer
la
Universitatea Politehnica Timișoara
în domeniul Ingineria sistemelor
de către

Ing. Dadiana-Valeria CĂIMAN

Conducător științific: prof.univ.dr.ing.Toma-Leonida DRAGOMIR

Seriile Teze de doctorat ale UPT sunt:

- | | |
|---|--|
| 1. Automatică | 9. Inginerie Mecanică |
| 2. Chimie | 10. Știința Calculatoarelor |
| 3. Energetică | 11. Știința și Ingineria Materialelor |
| 4. Ingineria Chimică | 12. Ingineria sistemelor |
| 5. Inginerie Civilă | 13. Inginerie energetică |
| 6. Inginerie Electrică | 14. Calculatoare și tehnologia informației |
| 7. Inginerie Electronică și Telecomunicații | 15. Ingineria materialelor |
| 8. Inginerie Industrială | 16. Inginerie și Management |

Universitatea Politehnica Timișoara a inițiat seriile de mai sus în scopul diseminării expertizei, cunoștințelor și rezultatelor cercetărilor întreprinse în cadrul Școlii doctorale a universității. Seriile conțin, potrivit H.B.Ex.S Nr. 14 / 14.07.2006, tezele de doctorat susținute în universitate începând cu 1 octombrie 2006.

Copyright © Editura Politehnica – Timișoara, 2013

Această publicație este supusă prevederilor legii dreptului de autor. Multiplicarea acestei publicații, în mod integral sau în parte, traducerea, tipărirea, reutilizarea ilustrațiilor, expunerea, radiodifuzarea, reproducerea pe microfilme sau în orice altă formă este permisă numai cu respectarea prevederilor Legii române a dreptului de autor în vigoare și permisiunea pentru utilizare obținută în scris din partea Universității Politehnica Timișoara. Toate încălcările acestor drepturi vor fi penalizate potrivit Legii române a drepturilor de autor.

România, 300159 Timișoara, Bd. Republicii 9,
Tel./fax 0256 403823
e-mail: editura@edipol.upt.ro

Cuvânt înainte

Teza de doctorat a fost elaborată pe parcursul activității mele în cadrul Departamentului de Automatică și Informatică Aplicată al Universității Politehnica Timișoara.

Drumul ce a dus la finalizarea acestei teze a fost lung, finalizarea lucrării producându-se după mai mulți ani de activitate în universitate. Cred însă, că experiența acumulată în universitate mi-a conferit anumite avantaje. Pot spune că unul dintre acestea a fost răbdarea și abordarea pozitivă a tuturor situațiilor în care m-am regăsit pe parcursul elaborării tezei de doctorat. Întodeauna, o abordare motivată optimist ajută la rezolvarea problemei în sine.

Mulțumiri deosebite se cuvin conducătorului de doctorat prof.dr.ing. Toma-Leonida Dragomir atât pentru sprijinul acordat cât și pentru răbdarea necesară pentru a mă însoți pe acest drum ce în anumite momente părea fără șanse de a-și atinge obiectivul. De asemenea, doresc să mulțumesc domnei ș.l. dr.ing. Petrică Dorina care m-a ajutat să devin un cadru didactic universitar dedicat, și care de-a lungul celor aproape 20 de ani de colaborare mi-a acordat votul ei de încredere indiferent de situațiile în care m-am regăsit. Nu în ultimul rând mulțumesc familiei și în special surorii mele Simona pentru perseverența cu care mi-a repetat de câte ori a fost nevoie că atingerea unor obiective indiferent de natura lor necesită disciplină, acest element cheie ce trebuie să recunosc că a fost dificil de aplicat.

Nu pot încheia fără a menționa bucuria ce mă însoțește în acest demers de finalizare a tezei la care au contribuit alături de conducătorul de doctorat, prof.dr. ing.Toma-Leonida Dragomir, membrii comisiei de îndrumare: ș.l.dr.ing. Dorina Petrică, prof.dr.ing. Ioan Silea și ș.l.dr.ing. Sorin Nanu.

Timișoara, septembrie 2021

Dadiana-Valeria CĂIMAN

Căiman, Dadiana-Valeria

Determinarea de semnături pentru consumatori casnici pe baza datelor înregistrate de contoarele inteligente

Teze de doctorat ale UPT, Seria X, Nr. YY, Editura Politehnica, 2021, 132 pagini, 48 figuri, 15 tabele.

Cuvinte cheie:

contor de energie inteligent, traiectorie tensiune-curent, semnătură consumator casnic, algoritm genetic, algoritm de tip PSO, regresie neliniară.

Rezumat,

Teza își propune investigarea posibilității de obținere a unor semnături pentru consumatorii casnici prin măsurarea tensiunii și curentului (a traiectoriei tensiune-curent) cu o frecvență de eșantionare redusă. Metodologia de lucru se bazează pe definirea unui set de patru clase de consumatori funcție de alura traiectoriei tensiune-curent, fiecărei clase corespunzându-i o funcție suport (model matematic) distinctă. Estimarea valorilor parametrilor funcțiilor suport se face prin regresie neliniară folosind ca algoritmi de optimizare AG și algoritmi PSO. Validarea unei semnături se face prin comparare cu datele experimentale. Metodologia este aplicată practic la semnături pentru consumatori simpli; semnături echivalente pentru consumatori 2-multipli; semnături asociate consumatorilor componenți ai unor consumatori 2-multipli. Rezultatele experimentale au fost folosite și în scop comparativ vizând în principal eficiența algoritmilor de optimizare și aplicativitatea metodologiei pentru consumatori multipli de puteri diferite.

CUPRINS

CUPRINS	5
LISTĂ DE ACRONIME	8
LISTĂ DE NOTAȚII	9
LISTA FIGURILOR	11
LISTA TABELELOR.....	13
1. INTRODUCERE	14
2. PROBLEMATICA SEMNĂTURILOR CONSUMATORILOR CASNICI ȘI ÎNCADRAREA TEMEI DE CERCETARE	17
2.1. Problematika semnăturilor consumatorilor casnici.....	17
2.1.1. Descriptori electrici.....	18
2.1.2. Instrumente de calcul folosite pentru obținerea semnăturilor	19
2.1.3. Baze de date de consum utilizate pentru testarea instrumentelor de calcul.....	20
2.1.4. Cercetări raportate în literatura de specialitate	20
2.2. Încadrarea obiectivelor tezei în preocupările existente în domeniu.....	29
3. FUNDAMENTAREA METODOLOGIEI APLICATE ÎN TEZĂ.....	31
3.1. Terminologie	31
3.2. Algoritmi de optimizare folosiți pentru calcularea valorilor parametrilor funcțiilor suport.....	33
3.2.1. Algoritmi genetici	34
3.2.2. Algoritmi de tip PSO.....	35
3.3. Regresie neliniară.....	36
3.4. Clase de semnături.....	38
3.4.1. Clasa tangentă discontinuă	40
3.4.2. Clasa tangentă continuă	43
3.4.3. Clasa elipsă	45
3.4.4. Clasa hibridă.....	48
3.5. Delimitarea obiectului cercetării	50
3.6. Gestionarea datelor achiziționate de contor și algoritmi de optimizare folosiți pentru parametrizarea funcției suport prin regresie	52
3.6.1. Alocarea punctelor folosite pentru determinarea semnăturii	52
3.6.2. Algoritmii de optimizare și funcția fitness.....	57

6 CUPRINS

3.7.	Determinarea semnăturii.....	59
3.7.1.	Determinarea semnăturii pentru un consumator simplu.....	59
3.7.2.	Determinarea semnăturii pentru un consumator 2-multiplu	60
3.7.3.	Organigrama metodei de generare a semnăturilor	64
4.	STUDII DE CAZ	67
4.1.	Condițiile de măsurare și schema de măsurare.....	67
4.1.1.	Schema de măsurare	68
4.1.2.	Condiții de măsurare.....	68
4.2.	Semnătura	69
4.3.	Studii de caz de obținere a semnăturilor unor consumatori simpli folosind algoritmi genetici	70
4.3.1.	Studiul de caz 1 (CS1)	71
4.3.2.	Studiul de caz 2 (CS2)	73
4.3.3.	Studiul de caz 3 (CS3)	75
4.3.4.	Studiul de caz 4 (CS4)	77
4.3.5.	Concluzii la studiile de caz CS1, CS2, CS3 și CS4 bazate pe folosirea algoritmilor genetici	80
4.4.	Extinderea studiilor de caz pentru consumatori simpli folosind un algoritm PSO	81
4.5.	Compararea rezultatelor din cazurile CS1 – CS4 cu cele din cazurile CS1* – CS4*.....	87
4.6.	Studii de caz pentru consumatori de tip $c-2.m$ folosind AG	88
4.6.1.	Studiul de caz 5 (CS5)	89
4.6.2.	Studiul de caz 6 (CS6)	92
4.6.3.	Concluzii la studiile de caz CS5 și CS6.....	96
4.7.	Extinderea studiilor de caz pentru $c-2.m$ folosind un algoritm de tip PSO (CS5*, CS6*)	97
4.8.	Compararea rezultatelor din cazurile CS5 – CS6 cu cele din cazurile CS5* – CS6*.....	99
4.9.	Implementarea MATLAB.....	100
5.	Concluzii.....	101
	Bibliografie.....	103
Anexa A.	Funcții suport asociate claselor k	109
Anexa B.	Valorile parametrilor soluțiilor din studiile de caz din capitolul 4	111
Anexa C.	Implementarea Matlab.....	116
C.1	Funcții MATLAB de implementare a funcțiilor suport și condiții de adecvare.	116

C.1.1.	Implementarea funcției suport pentru clasa tangentă ($k=1$).....	116
C.1.2.	Implementarea funcției suport pentru clasa tangentă discontinuă ($k = 2$).....	117
C.1.3.	Implementarea funcției suport pentru clasa elipsă ($k = 3$)	117
C.1.4.	Implementarea funcției suport pentru clasa hibridă ($k = 4$)	118
C.1.5.	Condiții de adecvare	119
C.1.6.	Generarea funcțiilor suport asociate unei combinații	121
C.2	Implementarea MATLAB a algoritmului de alocare	122
C.3	Implementarea calculării valorii parametrilor semnăturilor folosind algoritmi de optimizare	130

LISTĂ DE ACRONIME

ACSF2	—	Appliance Consumption Signature - Fribourg 2
AG	—	algorithm genetic
AMI	—	Advance Metering Infrastructure
BLUED	—	Building-Level fully-labeled dataset for Electricity Disaggregation
CNN	—	convolutional neural network
COOL	—	Controlled On/Off Loads Library
DBSCAN	—	Density-based spatial clustering of applications with noise
ECJ	—	Java-based Evolutionary Computation Research System
FF - NN	—	fedforward neural network
FFT	—	Fast Fourier transform
FIT- PS	—	Frequency Invariant Transformation of Periodic Signals
GEATbx	—	The Genetic and Evolutionary Algorithm Toolbox for Matlab
GIS	—	Geographic Information System
HELD1	—	Home Equipment Laboratory Dataset
HEMS	—	Home Energie Management System
HSV	—	hue, saturation, value
IMR	—	Intrusive Load Monitoring
LSTM network	—	long short-term memory network
NILM	—	Non-Intrusive Load Monitoring
PLAID	—	Plug-Load Appliance Identification Dataset
PSOt	—	Particle Swarm Optimization Toolbox
PSO	—	particle swarm optimization
REDD	—	Reference Energy Disaggregation Dataset
RMS	—	root mean square
SAX	—	Symbolic Aggregate approXimation
UK-DALE	—	UK- Domestic Appliance-Level Electricity
WHITED	—	Worldwide Household and Industry Transient Energy Dataset

LISTĂ DE NOTAȚII

$c-1.m$	—	consumator simplu
$c-n.m$	—	consumator n-multiplu
CSn	—	caz de studiu $n=1...6$ (algoritm folosit AG)
CSn*	—	caz de studiu $n=1...6$ (algoritm folosit PSO)
$C_{\alpha\beta}$	—	perechea de funcții suport α, β
$C_{\alpha\beta}^{\theta}$	—	perechea de funcții suport α, β din rularea independentă θ care corespunde lui $\min\{F_{\alpha\beta,r,p_1}\}_{\alpha\beta=\{11,12, \dots, 44\}}$
$c.s-e$	—	consumator simplu echivalent
$F_{\alpha\beta,r,p}$	—	fitnessul minim ce corespunde perechii $C_{\alpha\beta}$ de pondere p și ramură r
$F_{\alpha\beta,r,p,\theta}$	—	fitnessul minim ce corespunde perechii $C_{\alpha\beta}$ de pondere p și ramură r asociat rulării independente θ
F_r	—	cel mai mic fitness din mulțimea $\{F_{p,r}\}$ unde $p \in P$
$F_{p,r}$	—	fitnessul corespunzător ponderii p și ramurii r
$f_{p,r,max}$	—	scorul maxim
$f_{p,r,\alpha\beta}$	—	frecvența de apariție a perechii $C_{\alpha\beta}$ de pondere p și ramură r într-un set de m rulări independente
$i(v)$	—	dependența între curentul absorbit i și tensiunea de alimentare v
$i^o(v)$	—	a „o”-a dependență $i(v)$
$i^o_r(v)$	—	a „o”-a dependență $i(v)$ asociată ramurii r
$i(t)$	—	valori momentane ale curentului
i_j	—	valoarea măsurată a curentului corespunzătoare valorii măsurate v_j a tensiunii
$i_{\alpha\beta,r,p}(v)$	—	curentul total absorbit corespunde perechii $C_{\alpha\beta}$ de pondere p și ramură r (valoare estimată)
K	—	mulțimea ce conține cele 4 clase $K = \{1, 2, 3, 4\}$
k	—	tipul clasei
M_r	—	mulțimea punctelor de măsură asociate ramurii r
N_r	—	numărul de puncte de măsură asociat ramurii r
r	—	tipul ramurii
\mathcal{P}	—	mulțimea valorilor lui p
p	—	parametru de ponderare a componentelor perechii $\{\alpha, \beta\}$
$S_k(v)$	—	funcția suport asociată clasei k
$S_{k,r}(v)$	—	funcția suport asociată clasei k ramura r
SG	—	smart grid
SM	—	smart meter
$v(t)$	—	tensiunea de la borne la un moment de timp t
V	—	constantă de atenuare a valorilor de tensiune măsurate (3.46)
v_j	—	valoarea tensiunii la borne la momentul t_j
$\alpha\beta$	—	pereche de clase $\{\alpha, \beta\}$
$\Pi_{k,r}$	—	parametrii asociați funcției suport $S_{k,r}$
$\Pi_{k,r,p}$	—	parametrii asociați funcției suport de clasă k , pondere p și ramură r

10 LISTĂ DE NOTAȚII

$\Pi_{k,r,p,\theta}$	—	parametrii asociați funcției suport de clasă k , pondere p și ramură corespunzătoare rulării independente θ
θ	—	index rulare independentă.

LISTA FIGURILOR

Fig.3.1. Mulțimile M , M_a , M_d și curbele de regresie: a) Mulțimea M de puncte măsurate; b) Mulțimile M_a și M_d obținute prin alocare; c) curbele de regresie S_a , S_d	38
Fig.3.2. Norul de puncte M — albastru —vs. funcție suport — roșu — pentru un consumator din-clasa tangentă discontinuă	40
Fig.3.3. Parametrizări ale funcției tangentă discontinuă: a), b) Clasa tangentă discontinuă; c), d) clasa tangentă continuă.....	42
Fig.3.4. Norul de puncte M vs. graficul funcției suport pentru un consumator din clasa tangentă continuă	43
Fig.3.5. Norul de puncte M vs. funcție suport pentru un consumator din clasa elipsă.	45
Fig.3.6. Elipsa rotită și graficele factorilor de corecție 1 și 2.....	47
Fig.3.7. Parametrizări asociate funcției suport S_{3_r}	47
Fig.3.8. Norul de puncte M vs. graficul funcției suport pentru un consumator din clasa hibridă.	48
Fig.3.9. Consumatorul $c-n.m$ în contextul obținerii semnăturii sale.	51
Fig.3.10. Imagini ale unui nor de puncte rezultat din măsurători: a) puncte $\{(v(t), i(t))\}$ discrete; b) puncte $\{(v(t), i(t))\}$ unite în ordinea succesiunii.	53
Fig.3.11. Organigrama algoritmului de alocare	54
Fig.3.12. Reprezentare grafică: a) mulțimile M_a , M_d , M_{s_r} , M_{D_r} , M_m ; b) zone verticale, respectiv orizontale.	55
Fig. 3.13 Organigrama metodei de determinare de semnătură.....	65
Fig.4.1. Schema de măsurare.....	68
Fig.4.2. a) Succesiune de valori măsurate ale tensiunii de la bornele unui televizor LCD (eșantioanele 20-90). b) Punctele măsurate cărora le corespunde succesiunea de la punctul a.	69
Fig.4.3. Algoritm de determinare a semnăturii.	69
Fig.4.4. a) Nor rezultat din măsurători; b) Submulțimile M_a și M_d	71
Fig.4.5. Variația fitnessului pe clase specifice k . a.) Ramura ascendentă. b.) Ramura descendentă. ($k=1$ roșu, $k=2$ negru, $k=3$ albastru, $k=4$ roz).....	72
Fig.4.6. Semnătura unui televizor LCD: a) Ramura ascendentă a semnăturii vs. M_a ; b) Ramura descendentă a semnăturii vs. M_d ; c) Semnătura consumatorului. ..	73
Fig.4.7. CS2: a) Nor rezultat din măsurători; b) Submulțimile M_a și M_d	73
Fig.4.8. Variația fitnessului pe clase k : a.) Ramura ascendentă. b.) Ramura descendentă.	74
Fig.4.9. Semnătură laptop1: a) Ramura ascendentă a semnăturii vs. M_a ; b) Ramura descendentă a semnăturii vs. M_d ; c) Semnătura consumatorului.	75
Fig.4.10. a) Nor rezultat din măsurători, b) Submulțimile M_a și M_d	75
Fig.4.11. Variația fitnessului pe clasele k . a.) Ramura ascendentă. b.) Ramura descendentă. ($k=1$ roșu, $k=2$ negru, $k=3$ albastru, $k=4$ roz).....	76
Fig.4.12. CS3 - Semnătură frigider: a) Ramura ascendentă a semnăturii vs. M_a ; b) Ramura descendentă a semnăturii vs. M_d ; c) Semnătura dispozitivului electric.76	76
Fig.4.13. CS4 - Aspirator: a) Mulțime M ; b) Mulțimea M_a și M_d	77

12 LISTA FIGURILOR

Fig.4.14. CS4 - Variația fitnessului pentru cele 4 clase k . a.) Ramura ascendentă. b.) Ramura descendentă. ($k=1$ roșu, $k=2$ negru, $k=3$ albastru, $k=4$ roz)	77
Fig.4.15. CS4 - Semnătură aspirator: a) Ramura ascendentă a semnăturii vs. M_a ; b) Ramura descendentă a semnăturii vs. M_d ; c) Semnătura dispozitivului electric fără corecție f_{cor2} ; d) Semnătura consumatorului cu corecție f_{cor2}	79
Fig.4.16. CS4 - Semnătură aspirator: $k = 4$, $F_a = 0.16990$; $F_d = 0.13963$;	80
Fig. 4.17 CS1* - CS4*: Variațiile fitnessului pe clase k . Ramura ascendentă - $Fitness_a$, ramura descendentă $Fitness_d$	84
Fig. 4.18 CS1* - CS4*: Reprezentare grafică a semnăturilor asociate clasei hibride pentru cei 4 consumatori; stânga ramura ascendentă, semnătură (roșu) versus M_a , (albastru) dreapta ramura descendentă, semnătură (roșu) versus M_d (albastru).	85
Fig. 4.19 CS1* - CS4*: Semnăturile celor 4 consumatori	86
Fig.4.20. CS5: a) Norul de puncte măsurate; b) Mulțimile de puncte M_a și M_d	89
Fig.4.21. Semnătura unui c.s-e de clasă $k = 4$ pentru CS5: a) Ramura ascendentă; b) Ramura descendentă; c) Ansamblul.	89
Fig.4.22. CS5 - soluția pentru ramura ascendentă în varianta 3: a) Componentele semnăturii; b) Suma componentelor raportată la M_a	90
Fig.4.23. O alegere nevalidată pentru ramura ascendentă din CS5, varianta 3: a) Suma componentelor raportată la M_a ; b) Componentele semnături.	91
Fig.4.24. CS5 - soluția pentru ramura descendentă în varianta 3: a) Semnătura descendentă descompusă pe componente, b) Semnătura descendentă raportată la M_d	91
Fig.4.25. CS5 - Soluție potențială pentru ramura descendentă: a) Semnătura descendentă descompusă în componente; b) Semnătura descendentă raportată la M_d	91
Fig.4.26. Soluția „pereche de consumatori simpli” pentru c-2.m. -ul din CS5: a) Semnătură consumator simplu 1; b) Semnătură consumator simplu 2.	92
Fig.4.27. CS6: a) Norul de puncte măsurate; b) Mulțimile de puncte M_a și M_d	92
Fig.4.28. Semnătura unui c.s-e de clasă $k = 4$ pentru CS6: a) Ramura ascendentă, b) Ramura descendentă; c) Ansamblul.	93
Fig.4.29. CS6 - soluția pentru ramura ascendentă în varianta 3: a) Descompunere pe ramura ascendentă; b). Semnătura ramurii ascendentă raportată la M_a	94
Fig.4.30. Semnăturile corespunzătoare fitnessului minim pentru CS6, ramura ascendentă, versiunea 3: a) Descompunere pe ramura ascendentă; b) Semnătura ramurii ascendente raportată la M_a	94
Fig.4.31. Soluția pentru CS6, ramura descendentă, versiunea 3: a) Descompunere pe ramura descendentă; b) Semnătura ramurii descendente raportată la M_d . .	95
Fig.4.32. Soluția „pereche de consumatori simpli” pentru consumatorul 2-multiplu în CS6: a) Semnătură consumator 1; b) Semnătură consumator 2.	95
Fig. 4.33 Soluția 2 pentru CS6: a) Descompunere pe ramura ascendentă. b) Descompunere pe ramura descendentă. c.) Consumator simplu 1. d.) Consumator simplu 2. e.) Semnătură consumator 2-multiplu versus $M_a \cup M_d$. .	96
Fig. 4.34 Semnătură c.s-e adoptat. a.) LCD+DELL. b.) Aspirator+HP.	98
Fig. 4.35. CS6*: a) și b) Semnăturile consumatorilor simpli componenți ai c-2.m (a- Semnătură consumatorul 1, b-semnătură consumatorul 2), c) Suma semnăturilor consumatorilor simpli (roșu) vs. setul de măsurători (albastru). .	98

LISTA TABELELOR

Tabel 2.1: Semnături/algoritmi de identificare a dispozitive.....	20
Tabel 3.1: Fitnessuri și parametri de semnături pentru rulările independente corespunzătoare unui p și unui r date.	63
Tabelul 3.2: Frecvențele maxime ale combinațiilor analizate pentru ramura r și fitnessurile minime asociate.....	64
Tabelul 4.1: CS1 - Frecvențele de apariție ale claselor k pentru ramurile a și d și fitnessurile minime asociate.....	72
Tabelul 4.2: CS2 - Frecvențele de apariție a claselor k pentru ramura r și fitnessurile minime asociate.	74
Tabelul 4.3: CS3 - Frecvențele de apariție ale claselor k pentru ramura r și fitnessurile minime asociate.....	75
Tabelul 4.4: CS4 - Frecvențele de apariție a claselor specifice k pentru ramura r și fitnessurile minime asociate.....	77
Tabelul 4.5: Frecvențele de apariție ale claselor k pentru ramurile r și fitnessurile minime corespunzătoare claselor.....	82
Tabel 4.6 Indicatori de performanță AG/PSO	87
Tabelul 4.7: Valorile fitnessurilor c.s-e (varianta 1) pentru CS5.	89
Tabelul 4.8: CS5 - Frecvențele maxime ale combinațiilor analizate pentru ramurile a și d și fitnessurile minime asociate.....	90
Tabelul 4.9: Valorile fitnessurilor consumatorilor simpli echivalenți (varianta 1) pentru CS6.	93
Tabelul 4.10: CS6 - Frecvențele maxime ale combinațiilor analizate pentru ramurile a și d și fitnessurile minime asociate acestora.	93
Tabel 4.11 Valorile fitnessurilor consumatorilor simpli echivalenți (varianta 1) pentru CS5*, CS6*	97
Tabel 4.12 Rezultate c.2-m varianta 1, varianta 3.....	99

1. INTRODUCERE

Conceptul de rețea inteligentă sau smart grid este folosit uzual în literatura de specialitate cu referire la tot ceea ce înseamnă gestionarea digitalizată "inteligentă" a energiei, implicând ca principali participanți clientul, piața de energie, furnizorul de servicii, structurile de gestionare a fluxului de energie (generarea, transportul și distribuția energiei). Gestionarea fluxului de energie include, la rândul ei, diverse sisteme, cum sunt sistemele de contorizare inteligentă (smart metering - SM), sistemele SCADA cu module de analiză a datelor de consum achiziționate, module de control al fluxului de energie (algoritmi de optimizare) și module de predicție (ce includ și predicția a necesarului de energie), sisteme de informații geografice (GIS), sisteme de asigurare a diferitelor tipuri de interacțiuni etc. Elementul central al sistemelor de SM electrice îl constituie contorul inteligent care face parte din infrastructura de măsurare inteligentă (Advance Metering Infrastructure - AMI) a rețelei inteligente.

Poziționarea contorului inteligent în rețeaua de energie electrică este la client. În cadrul tezei, termenul client are conotația de zonă rezidențială, pe parcursul lucrării nefăcându-se referiri la alt sector consumator de energie electrică. Mai mult, din sectorul rezidențial sunt urmăriți doar consumatorii casnici de largă utilizare cum sunt televizoarele, aspiratoarele, laptopurile, frigiderule etc. Doi dintre factorii determinanți care au dus la creșterea semnificativă ale consumului de energie casnic în zonele rezidențiale sunt sporirea diversității dispozitivelor casnice și creșterea numărului acestora (TV-uri, laptopuri, PC-uri, instalații de climatizare, instalații de încălzire etc). În prezent cuantumul consumului de energie electrică din sectorul rezidențial în consumul total de energie electrică a ajuns la valori ridicate: 16% în SUA [1], 25% în Uniunea Europeană [2], 28.2% în România [3] etc. Datorită creșterii continue a consumului de energie în sectorul rezidențial, acestuia i s-a acordat o atenție tot mai mare din perspectiva investigării căilor de reducere a consumului, de către toți factorii interesați, inclusiv de cercetarea științifică. Actualitatea științifică a temei tezei este susținută și de articolele menționate în bibliografie, din care 73% sunt publicate în perioada 2018-2021.

Conceptul de rețea inteligentă presupune implicarea consumatorului casnic în gestionarea energiei electrice caracterizabilă, la modul general, prin profilul de consum. Utilitatea investigării profilului de consum a dispozitivelor casnice este subliniată în lucrările [4], [5]. Ele semnaleză importanța clientului și faptul că fără o participare activă a acestuia reducerea de consum s-ar putea să nu justifice investiția necesară instalării contoarelor inteligente și realizării infrastructurii necesare pentru a se atinge potențialul maxim al rețelei. Studiul prezentat în [4] răspunde la o seamă de întrebări legate de aspectele ce trebuie luate în calcul din punctul de vedere al avantajelor pe care le poate aduce dezvoltarea unor algoritmi de identificare a consumatorilor casnici. Obținerea unor informații legate de consumul dispozitivelor casnice poate aduce avantaje clientului, pieței de energie și furnizorului de servicii, tema furnizând o importantă arie de cercetare și dezvoltare. Din perspectiva clientului este important că el ar putea reduce consumul de energie, ceea ce s-ar reflecta într-un cost mai mic al facturii de energie, dacă ar beneficia de posibilitatea de a accesa informații furnizate de o aplicație de investigare a profilului de consum, aplicație care,

totodată, ar genera un set de recomandări personalizate, ar răspunde la unele cerințe specifice ale clientului, ar detecta unele anomalii de funcționare [5] și ar permite integrarea în sisteme inteligente de management a energiei capabile să gestioneze atât consumul, cât și comanda eventualelor surse de energie alternativă. Tot acest context descris reprezintă, indiscutabil, o reală provocare pentru domeniile de cercetare și dezvoltare, implicând contribuții continue la dezvoltarea și perfecționarea aplicațiilor de tipul celor menționate: crearea de consumatori mai performanți din punctul de vedere al curbei de consum, actualizarea standardelor, elaborarea de noi algoritmi de predicție a consumului bazați pe modele ale pieței de energie etc. Teza de doctorat se înscrie în acest demers complex.

Obiectivul general al tezei este studierea posibilității de a determina semnături pentru consumatori casnici folosind măsurători efectuate la o frecvență de achiziție redusă potrivit capabilităților contoarele inteligente actuale. Această idee pledează pentru necomplicarea infrastructurii de măsurare, facilitând o asimilare rapidă de soluții bazate pe procedeele expuse în teză. Ca *obiective specifice*, teza urmărește realizarea de investigații experimentale de tip noninvaziv, folosirea de descriptori electrici purtători de semnătură obținabili din rezultatele măsurătorilor brute și definirea unor clase de semnături care să permită gruparea consumatorilor funcție de traiectoria tensiune curent.

Teza conține 5 capitole, ansamblul având o structură liniară în cadrul căreia capitolele se subordonează succesiv.

După acest prim capitol introductiv, în al doilea capitol se prezintă problematica semnăturilor consumatorilor în contextul preocupărilor existente în domeniu, delimitându-se particularitatea demersului de „determinare a semnăturilor consumatorilor casnici folosind măsurători efectuate cu o frecvență joasă de eșantionare”.

Capitolul 3 conține fundamentarea teoretică a demersului prin introducerea unei metodologii de lucru. Secțiunea 3.1 prezintă terminologia curentă a domeniului studiat și propune termeni specifici metodelor dezvoltate. Următoarele două secțiuni, 3.2, 3.3, se referă la algoritmi de optimizare folosiți (algoritmul genetic (AG) și algoritmul de tip PSO) pentru estimarea parametrilor semnăturilor prin regresie neliniară. În secțiunea 3.4 se procedează la clasificarea unor consumatori casnici pe baza alurii traiectoriei tensiune-curent distingându-se 4 clase: tangentă, tangentă discontinuă, elipsă și hibridă. Următoarea secțiune, 3.5, sintetizează ca obiect al cercetării problematica caracterizării prin semnături a consumatorilor casnici prin asociere de funcții suport și estimare a valorilor parametrilor funcțiilor suport prin regresie neliniară folosind ca algoritmi de optimizare AG și algoritmi PSO. Secțiunea 3.6 tratează gestionarea datele achiziționate de la contor folosind un algoritm de alocare ce selectează din mulțimea de puncte măsurate submulțimile pe puncte ce redau de o manieră cât mai puțin distorsionată traiectoria tensiune-curent a consumatorului. Odată reținută traiectoria prin mulțimea acestor puncte în secțiunea 3.7 se propun mai multe metode de calcul a semnăturilor pentru consumatori simpli și consumatori multipli.

Capitolul 4 conține partea experimentală a tezei în care se aplică metodologia propusă în capitolul anterior în cursul mai multor studii de caz. Ele se referă la 4 consumatori simpli (laptop, frigider, aspirator, televizor) și 2 consumatori multipli. Studiile de caz au urmărit dincolo de ideea validării metodelor de generare a semnăturilor și compararea performanțelor de estimare a parametrilor folosind AG și algoritmi de tip PSO.

Ultimul capitol conține concluziile, menționează articolele publicate de autoare în problematica tezei și sugerează direcții ulterioare de cercetare în domeniu.

Pe lângă cele 5 capitole teza conține și trei anexe (A, B, C). În Anexa A sunt concentrate funcțiile suport asociate celor patru clase de consumatori, în Anexa B se dau parametrii semnăturilor generate în studiile de caz, iar în Anexa C sunt prezentate secvențe de cod Matlab relevante din punctul de vedere al implementării metodei de determinare a semnăturilor.

2. PROBLEMATICA SEMNĂTURILOR CONSUMATORILOR CASNICI ȘI ÎNCADRAREA TEMEI DE CERCETARE

În acest capitol se abordează subiectul semnăturilor consumatorilor casnici și se încadrează tematica tezei în această problematică. Prezentarea problematicii tezei se face prin raportare la literatura de specialitate, în special cea referitoare la descriptorii consumatorilor electrici, la instrumentele de calcul folosite pentru obținerea de semnături și identificarea consumatorilor, respectiv la bazele de date de consum.

2.1. Problematika semnăturilor consumatorilor casnici

Conștientizarea clientului-consumator vizavi de profilul energetic aferent spațiului rezidențial ocupat de acesta constituie un obiectiv de actualitate în încercarea de a reduce consumul casnic de curent electric. Împlicarea clientului poate fi încurajată de furnizorii de energie prin măsuri cum sunt: corelarea prețului energiei electrice cu intervalele orare în care se realizează consumul, bonificarea furnizării de energie verde în rețea etc. Din punct de vedere investigativ se consideră că orice client-consumator are un profil de consum și că elementul esențial în generarea profilului de consum îl constituie comportarea din punct de vedere electric a dispozitivelor casnice. Un mijloc de caracterizare a profilului de consum îl reprezintă semnăturile consumatorilor. Acest mod de abordare motivează alegerea temei tezei — *„Determinarea de semnături de consum ale consumatorilor casnici pe baza datelor înregistrate de contoarele inteligente”*.

Conform documentării bibliografice întreprinse a rezultat, că preocupările legate de caracterizarea consumului energetic în domeniul rezidențial prin semnături au debutat în 1992 cu articolul lui Hart [6]. El folosește admitanța și planul complex de reprezentare a puterii active pentru a grupa diferite tipuri de dispozitive casnice. Hart definește noțiunea de semnătură a unui dispozitiv electric cu înțelesul de mărime fizică/ansamblu de mărimi fizice, corelate sau necorelate, care prin valorile lor sau modul de variație în timp amprentează dispozitivul. Alternativ, mărimile de amprentare sunt denumite descriptori. Ulterior, în literatură, titulatura de semnătură s-a transferat mulțimii valorilor parametrilor asociați descriptorilor sau unor mărimi derivate din aceștia, menținându-se ca element definitoriu caracterul de unicitate.

Identificarea unui dispozitiv electric prin semnătură se realizează parcurgând trei pași:

- i) *Detectarea unui eveniment, în particular de tip on/off sau off/on, căruia i se asociază semnătura.*

Un consumator se poate găsi în diferite regimuri de funcționare caracterizate prin diferite forme de variație a tensiunii de la borne și a curentului absorbit în raport cu timpul, respectiv a curentului în funcție de tensiune. Spre deosebire de un model matematic dinamic, semnătura unui consumator se modifică de la un regim de funcționare la altul corelând pentru un regim de funcționare dat variațiile unora dintre mărimile ce caracterizează funcționarea sistemului. În mod obișnuit semnăturile se asociază fie unor regimuri staționare, cum este regimul cvasistaționar armonic, fie unor regimuri particulare corespunzătoare proceselor de conectare sau deconectare a consumatorilor de la sursa de alimentare. În acest context, denumim eveniment procesele care au loc pe parcursul unui regim de funcționare, iar prin „detectarea evenimentului” conștientizarea regimului de funcționare.

- ii) *Alegerea descriptorilor electrici folosiți pentru definirea semnăturii.*
- iii) *Obținerea semnăturii prin aplicarea de algoritmi adecvați (calcularea valorilor parametrilor asociați descriptorilor).*
- iv) *Identificarea consumatorului pe baza semnăturii.*

Dezideratul demersului îl reprezintă precizarea efectivă a tipului de consumator pe baza semnăturii. Nu întodeauna procesul descris mai sus se finalizează cu o identificare efectivă a consumatorului simplu, de tipul „consumatorul este un laptop”. Unii algoritmi permit doar o încadrare a consumatorilor în grupe stabilite în funcție de diferitele caracteristici sau parametri ai descriptorilor aleși, de tipul „consumatorul aparține grupei 1”, ce poate fi urmată sau nu de o personalizare a lui în cadrul grupei.

În următoarele 4 secțiuni se sintetizează modul în care problematica semnăturilor consumatorilor casnici se reflectă în literatura de specialitate. Primele 3 secțiuni rezumă aspecte referitoare la: descriptorii electrici folosiți, algoritmi de identificare a consumatorilor respectiv bazele de date ce conțin măsurători de tensiune și curent folosite în validarea algoritmilor de identificare. A patra secțiune prezintă în mod cronologic moduri de abordare prezente în literatura de specialitate începând cu lucrarea lui Hart din 1992 și până în prezent. Odată cu menționarea diferiților descriptori se enumeră și algoritmi de identificare folosiți de diverși autori, respectiv metodele de detectare a evenimentelor. La final, se fac referiri la modalitățile de implementare a sistemelor de identificare.

2.1.1. Descriptori electrici

Unul din pașii esențiali în procesul de identificare a unui consumator electric este alegerea descriptorului electric ce va fi folosit ca semnătură sau pentru asocierea unei semnături. Întrucât într-o rețea electrică mărimile măsurabile sunt tensiunea și curentul, toți descriptorii ce caracterizează consumul sunt calculați din serii de timp pentru tensiune, respectiv pentru curent [7]. În funcție de regimul de funcționare ales pentru achiziție, regimul permanent armonic (regim cvasistaționar) sau regimul tranzitoriu, se disting: descriptori asociați regimului permanent armonic, respectiv descriptori asociați regimului tranzitoriu. În cazul operării cu primul tip de descriptori

achiziția se poate face la frecvențe de sub 1 kHz. În cazul celui de al doilea tip de descriptori, pentru ca seria de timp tensiune/curent să înglobeze caracteristicile regimului tranzitoriu sunt însă necesare frecvențe de achiziție de ordinul kHz-ilor.

Cei mai folosiți descriptori de regim permanent armonic sunt:

- i) puterea activă,
- ii) puterea reactivă,
- iii) puterea aparentă,
- iv) factorul de putere,
- v) forma de undă $i(t)$ a curentului,
- vi) forma de undă $v(t)$ a tensiunii și armonicile de tensiune,
- vii) traiectoria tensiune-curent.

La aceștia se adaugă și indicatori cum sunt: admitanța instantanee, impedanța, forma de undă a puterii instantanee etc..

Ca descriptori ai regimului tranzitoriu menționăm [8]:

- i) variația puterii instantanee în regim tranzitoriu,
- ii) variația amplitudinii de putere,
- iii) durata regimului tranzitoriu,
- iv) durata supraîncărcării (putere) etc..

În cele ce urmează accentul este pus pe descriptorul *traiectorie tensiune-curent* care corelează tensiunea de la bornele unui consumator cu curentul absorbit. Acest descriptor, folosit la construirea de semnături în cea mai mare parte a studiilor din literatură, este utilizat pentru obținerea de semnături și în cadrul cercetărilor prezentate în această teză de doctorat. În secțiunea 2.1.4 sunt precizați și alți descriptori utilizați pentru generarea de semnături.

2.1.2. Instrumente de calcul folosite pentru obținerea semnăturilor

Identificarea consumatorilor prin semnături face uz de instrumente de calcul denumite frecvent în literatură „algoritmi de identificare”. Conform [9] aceștia se bazează în principal pe:

- i) metode de optimizare clasice,
- ii) metode statistice și probabilități,
- iii) „machine learning”¹/ „pattern recognition” ,
- iv) „deep learning” (cu antrenarea rețelei — de tip „supervised”/fără antrenarea rețelei — „unsupervised”),
- v) procesare de semnale,
- vi) algoritmi evoluționiști,
- vii) procesare de limbaj.

Enumerarea de mai sus balează în ultimă instanță algoritmi încadrați în spectrul larg al metodelor matematice folosite în inteligența artificială, identificarea devenind în fapt o problemă de optimizare.

¹ Pentru diverși algoritmi din domeniul inteligenței artificiale s-au folosit termenii consacrați din limba engleză; ei fiind trecuți între ghilimele. S-a adoptat această manieră de referire, având în vedere folosirea ei și în literatura de specialitate scrisă în limba română.

2.1.3. Baze de date de consum utilizate pentru testarea instrumentelor de calcul

Bazele de date de consum conțin informații referitoare la comportamentul electric al unei rezidențe sau al unei zone rezidențiale. Avantajul volumului mare de informații este diminuat de faptul că scenariile înregistrate sunt obținute folosind echipamente hardware mai pretențioase decât cele realizate cu contoare electrice inteligente.

Ca exemple de baze de date ce conțin măsurători de tensiune și curent folosite ca suport în studiile de caz prezentate în literatura de specialitate menționăm [10]:

- baze de date ce au frecvența de achiziție mare:
 - REDD — Reference Energy Disaggregation Dataset — 16.5 kHz,
 - PLAID — Plug-Load Appliance Identification Dataset — 30 kHz,
 - WHITED — Worldwide Household and Industry Transient Energy Dataset — 44.1 kHz, per dispozitiv,
 - UK-DALE — UK- Domestic Appliance-Level Electricity — 16 kHz,
 - BLUED BLUED — Building-Level fully-labeled dataset for Electricity Disaggregation — 12 kHz,
 - HELD1 — Home Equipment Laboratory Dataset — 4 kHz,
 - COOL — Controlled On/Off Loads Library — 100 kHz;
- baze de date ce au frecvența de achiziție mică:
 - ACSF2 — Appliance Consumption Signature- Fribourg 2 — 1 Hz, 10 Hz,
 - Tracebase 1 Hz.

Un alt mod de abordare a datelor de consum este sugerat de Ancelmo în [11]. El propune o bază de date rezultată din simulări în cadrul cărora consumatorii și sursele sunt modelate folosind circuite electrice.

2.1.4. Cercetări raportate în literatura de specialitate

Problematika semnăturilor consumatorilor electrici este de dată relativ recentă în sensul că după un prim articol apărut în 1992, tematica a revenit în actualitate peste 15 ani. În Tabel 2.1 sunt sintetizați, ca rezultat al studierii literaturii de specialitate, principalii descriptori, baze de date și algoritmi utilizați în identificarea semnăturilor dispozitivelor sau în clasificarea acestora.

Tabel 2.1: Semnături/algoritmi de identificare a dispozitive.

Tipul semnăturii	Frecvența de achiziție	Algoritmul de obținere a semnăturii	Articol/autor	Anul apariției
(1)	(2)	(3)	(4)	(5)
-planul complex PQ	Frecvență mică	-„Clustering Method”	[6] Hart	1992
-descriptorii geometrici ai traiectoriei V-I	nespecificată	-„Hierarchical Clustering”	[12] Lam	2007

- <i>descriptorii geometrici ai traiectoriei V-I</i> -reprezentarea în complex a puterii -armonicile undei de curent	REDD 16.5 kHz	-„Feed-Forward Artificial Neural Network” -„Artificial Neural Network”+„Evolutionary Algorithm” -„Support Vector Method” -„Adaptive Boost”	[13] Hassan	2014
-seria de timp putere activă convertită într-o secvență de caractere folosind metoda „Symbolic Aggregate approximation”	Frecvență mare (kHz)	-„k-Means Clustering Algorithm”	[14] Miller	2015
- <i>descriptorii geometrici ai traiectoriei V-I</i> , puterea activă, puterea reactivă, factorul de putere, distorsiunea armonică totală	REDD 16.5 kHz	-grupare — „Hierarchical Clustering”; identificare — Clasificarea Naïve Bayes	[15] Iksan	2016
-curba tensiune-curent non-activ; -forma de undă a curentului non-activ	2.1 kHz	—	[16] Teshome	2016
<i>descriptorii ai imaginii traiectoriei V-I</i> : -6 descriptorii derivați din matricea binară asociată traiectoriei V-I)	30.72 kHz, 7.68 kHz, 3.84 kHz	-„Supervised Self Organization Map”	[17] Du	2016
- „componente necorelate ale subspațiului putere” al puterii active extrase folosind transformata Karhunen-Loeve și metoda „High Resolution Spectral Feature Extraction”	REDD -variația putere activă agregată (per casă și per dispozitiv) 0.5 Hz Tracebase -variație putere activă per dispozitiv 1 Hz	Algoritmul de grupare „Mean-Shift Clustering Algorithm” și algoritmul de clasificare Bayesian	[18] Welikala	2016
- curba tensiune-curent (v(t), i(t))-stocată într-o matrice (valorile de curent ale eșantioanelor) de dimensiune redusă folosind „Frequency Invariant Transformation of Periodic Signals” (FIT-PS)	BLUED 12 kHz	-detectare de evenimente	[19] Held	2016
- curba FIT-PS; - armonicile puterii active/reactive;	HELD1 4 kHz	-„k-Nearest Neighbors” -„Naive Bayes”	[20] Weishaar	2016

22 PROBLEMATICA SEMNĂTURILOR CONSUMATORILOR CASNICI ȘI ÎNCADRAREA TEMEI DE CERCETARE - 2

- puterea activă/ reactivă		-„Support Vector Machine”		
- puterea activă/puterea reactivă; - forma de undă a curentului; - forma de undă curent, tensiune; - <i>descriptorii geometrici ai trajectoriei V-I</i> - armonicile de curent; - <i>descriptori ai regimului tranzitoriu:</i> variația amplitudinii puterii la pornire și oprire, durata regimului tranzitoriu; durata supracreșterii; - semnătura hibridă constituită din cummul descriptorilor enumerați mai sus.	PLAID 30 kHz	-„k-Nearest Neighbors” -„Artificial Neural Network” -„Clasificarea Naive Bayes” -„Support vector machine” -„Decision Tree Classifier”	[21] Azaza	2017
- șirul amplitudinilor armonicilor de curent impare de ordin 1, 3, 5	50 kHz	-are la bază principiul superpoziției (însurarea descriptorilor în vederea obținerii combinației potrivite)	[22] Bouhours	2017
- seria de timp a puterii active medii calculată pe diferite intervale de timp (6 s, 30 s, 60 s, 5 min, 15 min)	REDD 1Hz - la nivel de dispozitiv; 15 kHz și 1 Hz - semnal agregat; UK-DALE 1/6 Hz - la nivel de dispozitiv; 16 kHz - semnal agregat	-„Factorial Hidden Markov Model” -„Sparse Matrix Processing”	[23] Huang	2017
- <i>descriptorii geometrici ai trajectoriei V-I, variația admitanței instantanee</i>	REDD 16.5 kHz; Date laborator 6.4 5kHz	-„Support Vector Machine” (SVM)	[24] Wang	2018
<i>descriptori ai imaginii trajectorie V-I:</i> -coeficienți Fourier eliptici utilizați în recunoașterea conturului exterior al trajectoriei I-V, -matrice binară;	PLAID 30 kHz	-„Random Forests” (coeficienți Fourier eliptici) -„Convolutional Neural Networks”	[25] De Baets	2018

-matrice definită în funcție de numărul de intersecții între curbă și o celulă; -imagine pixelată ponderată definită de numărul de puncte ale traiectoriei incluse într-o celulă		(descriptori ai imaginii traiectorir V-I)		
<i>descriptori ai imaginii traiectoriei V-I:</i> -imagine pixelată ponderată (numărul de puncte ale traiectoriei incluse într-o celulă)	PLAID 30 kHz WHITED 44.1 kHz	-„Convolutional Neural Networks”	[26] De Baets	2018
<i>descriptori ai imaginii traiectoriei V-I:</i> -coeficienți Fourier eliptici calculați pentru conturul exterior al imaginii V-I	PLAID 30 kHz	-Regresie Logistică -„Convolutional Neural Networks” -„Random Forest	[27] De Baets	2018
<i>Descriptori ai imaginii traiectoriei V-I:</i> -Imaginea V-I codificată prin culoare	PLAID 30 kHz WHITED 44.1 kHz	-„Convolutional Neural Network”	[28] Liu	2018
- variația de tensiune respectiv curent în formă primară	PLAID 30 kHz	-Rețele Neuronale	[29] Barsim	2018
- puterea activă și reactivă; - puterea activă și reactivă, respectiv viteza și accelerația acestora; -puterea activă, puterea reactivă, RMS tensiune, RMS curent, defazajul, frecvența; -puterea activă, puterea reactivă, RMS tensiune, RMS curent, defazajele, frecvențele, vitezele și accelerațiile celor 6	ACSF2 1 -10 Hz	-„k-Nearest Neighbors” -„Support Vector Machine” -„Random Forest” -„Gaussian Mixture Models”	[30] Ghorbanpour	2018
-puterea activă, puterea aparentă, factorul de putere, valorile curentului și tensiunii	nespecificat	-„Random Forest” -„k-Nearest Neighbors”	[31] Khan	2018
-puterea activă (se consideră doar dispozitivele cu un consum mare de putere)	UK-DALE 16 KHz	-„Very Deep One dimensional Convolutional Neural Network”	[32] Dash	2018
-variația în timp a curentului consumat; -combinația defazaj-admitanță; -descriptorii specifici analizei spectrale, traiectoria V-I, variația curentului în timp	PLAID 30 kHz, WHITED 44.1 kHz, BLUED 12 kHz, UK-DALE 16 kHz	-„k-Nearest Neighbor”	[33] Kahl	2018

24 PROBLEMATICA SEMNĂTURILOR CONSUMATORILOR CASNICI ȘI ÎNCADRAREA TEMEI DE CERCETARE - 2

<p><i>descriptori ai imaginii traiectorie V-I:</i> -reducerea imaginii traiectoriei V-I la cadranele 1 și 3 din reprezentare</p>	<p>REDD 16.5 kHz</p>	<p>-„Principal Component Analysis”- transformata Karhunen-Loeve și „k-Nearest Neighbor Algorithm”.</p>	<p>[34] Yang</p>	<p>2019</p>
<p><i>descriptori ai imaginii traiectorie V-I</i> -imaginea traiectoriei tensiune-curent prelucrată folosind rețele neuronale siameze</p>	<p>PLAID 30 kHz WHITED 44.1 kHz</p>	<p>-grupare dispozitive necunoscute DBSCAN</p>	<p>[35] De Baets</p>	<p>2019</p>
<p>-modelarea curentului primelor trei armonici impare sub forma unor vectori ce includ defazajele și amplitudinile</p>	<p>50 kHz</p>	<p>-are la bază principiul superpoziției (însurare de descriptori în vederea obținerii combinației potrivite)</p>	<p>[36] Bouhouras</p>	<p>2019</p>
<p>-descriptorii de putere aleși pe baza teoremei lui Bayes</p>	<p>1 min</p>	<p>-algoritmul de clasificare Bayes</p>	<p>[37] Yan</p>	<p>2019</p>
<p>-factorul de amortizare al unei de curent, armonici de curent (frecvență, amplitudine, curent)</p>	<p>COOL 100 kHz</p>	<p>-metoda Prony</p>	<p>[38] Ancelmo</p>	<p>2019</p>
<p>Descriptori ai imaginii traiectoriei V-I Graf ponderat recurent</p>	<p>PLAID 30 kHz COOL 100 kHz</p>	<p>-„Convolutional Neural Network”</p>	<p>[39] Faustine</p>	<p>2020</p>
<p>-traiectoriei V-I</p>	<p>REDD 16.5 kHz PLAID 30 kHz</p>	<p>-„Asymmetric Deep supervised Hashing”</p>	<p>[40] Han</p>	<p>2021</p>
<p>-Imaginea traiectoriei V-I cu fundalul colorat funcție de puterea activă și reactivă</p>	<p>-</p>	<p>-„Random Forest”</p>	<p>[41] Wang</p>	<p>2021</p>
<p>-2 descriptori rezultați din curbura traiectoriei V-I</p>	<p>PLAID 30 kHz</p>	<p>-Rețele neuronale</p>	<p>[42] Rodrigues</p>	<p>2021</p>

Luând ca bornă temporală de început anul 1992, al apariției lucrării lui Hart [6], din ultima coloană a tabelului de mai sus, se constată, pe de-o parte, că problematica determinării semnăturilor a revenit în actualitate în ultimii 15 ani, iar pe de altă parte, că aceasta s-a diversificat pe parcursul ultimilor ani. Totodată, urmărind a doua coloană a tabelului, remarcăm că studiile efectuate se bazează pe achiziții de date experimentale la frecvențe mari, de regulă de zeci de kHz, astfel că *investigarea*

obținerii de semnături la frecvențe de achiziție mici este o problemă deschisă. Teza de doctorat se înscrie tocmai în această nișă de cercetare.

Pentru a evidenția modul de utilizare a diferiților descriptori în cercetările menționate în literatura de specialitate, în principal a descriptorului *trajectorie tensiune-curent*, articolele citate în tabel sunt grupate mai jos pe două direcții. Prima direcție este destinată descriptorului *trajectorie tensiune-curent*, a doua grupează alți descriptori mai des folosiți. În cadrul fiecărei direcții prezentarea respectă ordinea cronologică de publicare a articolelor.

a) Descriptorul trajectorie tensiune – curent

Conceptul de trajectorie tensiune-curent apare pentru prima oară în [12], Lam asociind semnătura unui set de opt identificatori geometrici ai curbei V-I cu scopul de a grupa dispozitivele electrice folosind metode de tip „Hierarchical Clustering”.

Ulterior, în [13], Hassan folosește 6 din identificatorii introduși de Lam precum și un identificator suplimentar denumit „span”, definit ca diferență între maximumul și minimumul trajectoriei V-I. Datorită proporționalității cu puterea activă, „span-ul” este utilizat pentru detecția de evenimente. Algoritmii de clasificare aplicați de Hassan sunt: „Feed-Forward Artificial Neural Network”, „Artificial Neural Network” + „Evolutionary Algorithm”, „Suport Vector Method” și „Adaptive Boost”. Performanțele celor trei algoritmi sunt evaluate și în funcție de două alte tipuri de semnături bazate pe reprezentarea în complex a puterii și pe armonicile de curent. În cazul folosirii ca semnătură a trajectoriei tensiune-curent se obțin performanțe bune.

În [15], Iksan folosește ca semnătură, cu o precizie de clasificare de 91%, un set hibrid de caracteristici format din 3 identificatori geometrici asociați trajectoriei V-I la care adaugă distorsiunea armonică totală. Metoda de grupare utilizată este „Hierarchical Clustering”. Adăugarea celor 3 descriptori geometrici crește precizia de grupare cu 35.58%.

În [16], Teshome descompune traectoria tensiune-curent, folosind teoria lui Fryze, în curba tensiune-curent activ, folosită în identificare, și curba tensiune-curent non-activ.

În [17], Du propune în funcție de trajectoriile V-I o clasificare în 7 categorii a consumatorilor, respectiv un set de 6 caracteristici derivate din imaginea binară (valori specifice pentru anumite celule/seturi de celule din matricea binară, folosindu-se, de fapt, 2 celule și 3 coloane) ce formează prin combinare semnături. Ca algoritm de identificare/clasificare se folosește „Supervised Self Organization Map”.

În [21], Azaza folosește ca semnătură combinații de descriptori electrici, pentru identificare mai mulți algoritmi. Descriptorii avuți în vedere sunt: descriptorii de putere (puterea activă, puterea reactivă), forma de undă a curentului, traectoria tensiune-curent (asimetria curbei, sensul de parcurgere al curbei), armonicile de curent (FFT – amplitudinea curentului la diferite frecvențe), descriptorii ai regimului tranzitoriu (variația amplitudinii de putere la pornire și oprire, durata regimului tranzitoriu, durata supracreșterii de putere). De asemenea, se consideră și cazul în care semnătura este constituită din cumulul descriptorilor enumerați mai sus. În final, autorul concluzionează că eroarea de recunoaștere depinde atât de algoritm cât și de tipul semnăturii și atenționează asupra cazurilor pentru care semnătura compusă (nr. maxim de parametri) nu generează eroarea de recunoaștere minimă.

În [24], L. Wang consideră identificatorii propuși de Lam, „span”-ul introdus de Hassan și variația admitanței instantanee. El folosește variația puterii reactive pentru

detecția unui eveniment. Ca algoritm de identificare se utilizează algoritmul „support vector machine”. Rata de identificare este foarte bună pentru o frecvență de achiziție situată în intervalul 9 - 18 kHz și scade abrupt pentru valori mai mici de 2 kHz.

În [26], De Baets consideră ca semnătură imaginea pixelată ponderată a traiectoriei tensiune curent (o matrice în care fiecărei celule i se asociază un număr echivalent cu numărul de puncte ale traiectoriei ce îi aparțin). Clasificarea se realizează folosind metoda rețelelor neuronale convoluționale. În [27] se utilizează descriptorii Fourier eliptici calculați pentru conturul exterior al imaginii tensiune curent. Clasificarea se testează pe 3 algoritmi: regresie logistică, rețele neuronale convoluționale, random forest. În ambele articole se prelucrează înregistrări per dispozitiv. În [25] într-o primă etapă se procedează la extragerea înregistrărilor aferente unui dispozitiv (tensiune, curent) dintr-un semnal agregat folosind detecția unui eveniment. A doua etapă reia elementele expuse în [26], [27] pe înregistrările obținute în prima etapa.

În [28], Liu folosește o mapare binară a traiectoriei urmată de colorare, folosind spațiul de culori HSV. Ca algoritm de clasificare se utilizează „Convolutional Neural Network”, pre-antrenat pe un set de date asociate recunoașterii vizuale.

În [29], Barsim utilizează valorile tensiunilor momentane și valorile curentului momentan în formă primară pentru a antrena o rețea neurală, antrenare ce oferă posibilitatea realizării unei identificări a dispozitivelor electrice. Pentru ca identificarea să dea rezultate bune, datele trebuie achiziționate la o frecvență de cel puțin 4 kHz.

În [34], Yang reduce imaginea traiectoriei V-I folosind un algoritm de reducere a imaginii — „image pyramid reduction”, luând în considerare doar cadranele 1 și 3 din reprezentare (se lucrează cu consumatori inductivi și rezistivi). Algoritmul de clasificare se bazează pe „Principal Component Analysis” și „k-Nearest Neighbor Algorithm”.

În [35], De Baets își propune detectarea unor consumatori casnici ale căror semnături nu au fost incluse în antrenarea inițială a algoritmului de identificare. Semnătura în acest caz este considerată imaginea binară a traiectoriei tensiune-curent. În generarea semnăturii se folosesc rețele neuronale siameze. Algoritmul „Density-Based Spatial Clustering” este folosit în clasificare pentru a determina punctele de tip — „outliers” echivalate cu consumatori necunoscuți.

În [43], Kholeif studiază influența pe care o are variația tensiunii de alimentare (supratensiuni), datorată unor perturbații în rețea, asupra traiectoriei tensiune-curent. Rezultatele studiului arată că variațiile de tensiune nu afectează dimensiunea și forma traiectoriei, dar afectează semnătura, adică cei 8 parametri ce descriu geometria curbei.

Din expunerea de mai sus se desprind două concluzii. În primul rând se constată că descriptorul traiectorie tensiune-curent poate fi caracterizat în mai multe moduri:

- prin perechile $(v(t), i(t))$ în formă neprelucrată;
- prin parametri geometrici specifici curbei tensiune-curent asociate;
- prin imaginea curbei traiectoriei tensiune-curent.

În al doilea rând se constată că în implementarea metodelor de identificare pot fi considerate și combinații ale descriptorului amintit mai sus cu alți descriptori electrici asociați unui regim cvasistaționar sau unui regim tranzitoriu.

Totodată, s-a observat că atunci când în procesul de identificare este implicată traiectoria tensiune-curent în una din variantele prezentate mai sus frecvențele de achiziție a tensiunii și a curentului variază în domeniul [30 kHz, 44.1 kHz].

b) Alți descriptori electrici

În [18], Welikala folosește ca descriptor puterea activă.

În [30], Ghorbanpour propune folosirea unei semnături ce include pe lângă descriptorii cum ar fi puterea, defazajul, frecvența, erorile medii pătratice ale tensiunii și curentului, și vitezele însoțite de accelerațiile acestor descriptori generate din valorile lor momentane (derivatele de ordin unu respectiv doi în raport cu timpul), parametrii folosiți în mod tradițional în recunoașterea vocală. În acest sens, articolul propune mai multe semnături compuse ce se folosesc apoi în diferiți algoritmi de dezagregare, stabilindu-se diferite rate de precizie în identificarea dispozitivelor. Se propun 4 semnături cu grade de complexitate diferite, bazate pe:

- 1) puterea activă și reactivă;
- 2) puterea activă și reactivă, respectiv viteza și accelerația acestora determinate din valorile lor momentane;
- 3) puterea activă, puterea reactivă, RMS tensiune, RMS curent, defazajul, frecvența;
- 4) puterea activă, puterea reactivă, RMS tensiune, RMS curent, defazajul, frecvența + viteza și accelerația fiecăruia determinate din valorile lor momentane.

Algoritmii de dezagregare utilizați sunt „k-Nearest Neighbors”, „Support Vector Machine”, „Random Forest”, „Gaussian Mixture Models. Cea mai bună acuratețe se obține pentru combinația (semnătura 4), „Random Forest”.

În [22], Bouhouras propune ca semnătură a consumatorului simplu șirul amplitudinilor armonicilor de curent impare de ordin 1, 3, 5. În [36], același autor extinde semnătura prin modelarea curentului primelor trei armonici impare sub forma unor vectori ce includ defazajele și amplitudinile acestora.

În [37], Yan folosește ca semnătură descriptorul de putere: seria de timp pentru puterea activă. Din această serie se pot extrage: intervale de variație a puterii active (dispozitive multi-state), descriptori ce depind de obiceiurile locatarilor (interval de funcționare a dispozitivului, frecvență și durată de utilizare), sau un set rezultat din combinarea parametrilor de mai sus. Modul în care este stabilit setul de parametri ce definesc semnătura pentru un dispozitiv electric implică calcularea probabilității de identificare cu un dispozitiv folosind teorema lui Bayes. De exemplu, dacă probabilitatea pentru puterea activă este de peste 98% pentru un dispozitiv și sub 30% pentru restul, identificarea se face doar pe baza intervalului de variație a puterii active (se consideră că dispozitivele au mai multe stări). În caz contrar, la parametrul putere activă sunt adăugați alți descriptori de putere până în momentul satisfacerii condiției mai sus menționate sau epuizării parametrilor luați în calcul.

În [31], Khan utilizează ca semnături un set de parametri ce includ descriptorii de putere, curent, tensiune: puterea activă, puterea aparentă, factorul de putere, valorile curentului și ale tensiunii.

În [32], Dash folosește ca semnătură puterea activă consumată considerând numai dispozitive electrice cu un consum semnificativ de energie.

În [23], Huang propune ca semnătură seria de timp putere activă medie calculată pe diferite intervale de timp de la 6s la 15min. Articolul arată, pentru diferiți

algoritmi de identificare, o scădere neliniară a performanțelor odată cu creșterea intervalelor de calcul a puterii active medii.

În [19], Held definește ca semnătură o matrice de curent în care, pe linii, sunt puse date eșantionate în cursul unei perioade. Înainte de a genera matricea se realizează o sincronizare a eșantionării curentului cu tensiunea pe baza trecerilor prin zero ale tensiunii, pentru a nu pierde informațiile legate de defazajul dintre tensiune și curent. Metoda elimină regimul tranzitoriu făcând posibilă reducerea dimensiunii matricei de calcul. Metoda poartă numele de Frequency Invariant Transformation of Periodic Signals (FIT-PS).

În [20], Weishaar folosește 3 algoritmi de identificare, „k-Nearest Neighbor Algorithm”, Bayes, „Support Vector Machine”, și trei semnături, FIT-PS, armonicile puterii active/reactive respectiv puterea activă/reactivă. Rezultatele pentru semnătura FIT-PS au o precizie cu 10% mai bună decât celelalte două.

În [44] se consideră algoritmi „FF (feedforward) neural network” și „LSTM (long short-term memory) network” (rețea neuronală recurentă utilizată în deep learning) în combinație cu semnăturile din [20]. Rezultatele cele mai bune, o precizie de identificare de 88%, se obțin în cazul semnăturilor de tip FIT-PS cu algoritmul LSTM.

În [14], Miller folosește seria de timp putere activă discretizată căreia îi asociază litere care ulterior formează cuvinte ce fac posibilă determinarea unor modele (paternuri). Metoda aplicată poartă numele de „Symbolic Aggregate approxImation” — SAX. Cuvinte sunt grupate ulterior folosind algoritmul k-mean clustering.

În [33], Kahl prezintă 3 studii de caz prin care investighează care descriptori generează cele mai bune performanțe. Bazele de date cu care lucrează în primele două cazuri sunt PLAID, WHITED, BLUED, UK-DALE.

Primul studiu de caz include evaluarea performanțelor pentru 36 de descriptori electrici de sine stătători în corelație cu algoritmul de clasificare „1-Nearest Neighbor”. Pentru toate cele 4 baze de date cele mai bune rezultate se obțin în cazul în care descriptorul considerat este variația în timp a curentului consumat.

Al doilea studiu de caz consideră 2 descriptori electrici în corelație cu algoritmul „k-Nearest Neighbor”. Cele mai bune rezultate obținute au fost: pentru PLAID combinația putere activă-putere reactivă, pentru WHITED combinația defajaz-admitanță, pentru BLUED combinația putere aparentă-defajaz, pentru UK-DALE-putere activă, raportul între amplitudinea maximă a curentului la pornire (descriptor al regimului tranzitoriu) și valoarea curentului în regim cvasistaționar.

Al treilea caz implică gruparea unui set de descriptori electrici arătându-se că numărul mare de descriptori nu reface neapărat performanțe mai bune. Seturile alese au avut câte 4, 8 sau 9 descriptori. Cele mai bune performanțe au rezultat în cazul semnăturii ce include: descriptori specifici analizei spectrale, traiectoria V-I, variația curentului în timp, corelate cu algoritmul „k-Nearest Neighbor” pe baza de date WHITED.

În [38] autorii folosesc ca descriptori o combinație între mărimi caracteristice regimului tranzitoriu — factorul de amortizare corespunzător undei de curent, respectiv a regimului permanent armonic — conținutul de armonici din unda de curent (frecvență, amplitudine, defajaz). Lucrul cu componente ce caracterizează regimul tranzitoriu impune o frecvență de achiziție mare, astfel baza de date aleasă este COOL — 100 kHz.

În vederea evaluării performanțelor descriptorilor aleși vizavi de clasificare se folosesc cinci variante ale metodei Prony.

În majoritatea cazurilor detectarea unui eveniment (on/off sau trecerea consumatorului dintr-o stare în alta) se face pe baza modificărilor apărute la nivelul puterii și/sau al span-ului [13]. Ca urmare, pentru a detecta tranzițiile consumatorilor între stări sunt necesare măsurători ale puterii agregate (ex. la nivel de apartament pentru consumatorii domestici) pe intervale de timp. De Baets, în [35], consideră că, în principiu, detectarea unui eveniment este un efect secundar al algoritmului de identificare.

Din punctul de vedere al tipului de implementare a sistemelor de identificare se disting: metodele de tip NILM („Non-Intrusive Load Monitoring”), când datele sunt preluate de la un singur senzor (preferabil contorul de energie electrică inteligent) [6], [45], respectiv metodele de tip IMR („Intrusive Load Monitoring”). În această ultimă categorie se încadrează sistemele HEMS („Home Energy Management System”) — [46], [47], [48], [49] — sisteme ce impun o investiție destul de consistentă din partea consumatorului.

2.2. Încadrarea obiectivelor tezei în preocupările existente în domeniu

Obiectivul general al tezei, *determinarea de semnături de consum ale consumatorilor casnici pe baza datelor înregistrate de contoarele inteligente*, se înscrie în domeniul de investigare a semnăturilor unor dispozitive electrice prezente în zona de consum rezidențial.

Obiectivele specifice au fost alese în urma studiului bibliografic expus în secțiunea anterioară astfel încât să se încadreze în preocupările existente în domeniu. Enumerăm mai jos pe cele ce au definit direcțiile de studiu din teză:

- Recurgerea la investigații experimentale cu caracter noninvaziv. Acest fapt a impus alegerea unor componente hardware capabile să asigure condiții de lucru similare cu cele existente la contoarele inteligente.
- Folosirea de descriptori electrici purtători de semnătură, obtenabili prin măsurători, care să necesite o prelucrare cât mai redusă a datelor experimentale. În cazul de față s-au folosit valorile momentane neprelucrate ale tensiunii la borne respectiv ale curentului consumat.
- Definierea unor clase de semnături care să permită gruparea dispozitivelor în funcție de anumite caracteristici.

Ținând cont de aceste aspecte, teza propune algoritmi ce folosesc date achiziționate de un contor inteligent la frecvența de cca. 20 Hz și ilustrează aplicarea acestora pe mai multe studii de caz. Semnăturile consumatorilor simpli sunt generate ca funcții de regresie ce aproximează traiectoriile tensiune-curent obținute experimental sub formă de șir de perechi de valori tensiune-curent. Parametri funcțiilor de regresie sunt determinați în cadrul tezei folosind două tipuri de algoritmi de optimizare: algoritmi genetici și algoritmi de tip PSO.

Tema folosirii algoritmilor genetici pentru parametrizarea funcțiilor de regresie este dezvoltată în lucrarea [50]. Cu toate că folosirea algoritmilor genetici pentru parametrizarea funcțiilor de regresie utilizate în modelarea matematică are natura unei metode clasice, procedeul de calcul nu s-a răspândit în domeniul tehnic, fiind

întâlnit accidental în aplicații din mecanică [51] și din domeniul energetic [52], în speță pentru modelarea necesarului de energie în sectorul rezidențial folosind regresii liniare. Dacă ne raportăm însă la aplicarea algoritmilor genetici în domeniul tehnic, fără limitarea la parametrizarea funcțiilor de regresie, aria de acoperire este mare. Astfel, oprindu-ne doar la investigații cu aplicabilitate în domeniul electro-energetic putem menționa: proiectarea unor regulatoare (ex. PID) ce să stabilizeze comportamentul unui proces în condițiile de descărcare ale sursei de alimentare - baterie- [53], eliminarea armonicelor tensiunii de ieșire în cazul invertorelor [54], estimarea duratei de viață rămasă a supercapacitoarelor [55]. Aplicarea regresiei neliniare în domeniul tehnic poate fi susținută și de lucrări destinate optimizării unor procese industriale complexe având ca scop diminuarea consumului de energie, respectiv managementul optimal al resurselor [56], sau modelării interdependenței neliniare între creșterea componentei „verzi” a energiei și creșterea economică [57].

În domeniul energetic algoritmi de tip PSO s-au folosit în sisteme de tip NILM la identificarea dispozitivelor electrice din zona rezidențială. Ideea apare în [58] abordarea fiind de tip hibrid, utilizându-se o rețea neuronală în combinație cu algoritmul de tip PSO. Algoritmul este folosit ca instrument de calcul în determinarea parametrilor optimali asociați unei funcții de reducere a costurilor, atât a clientului cât și a utilității, dar și o funcționare optimală a SG [59]. În completare, se cuvine menționat și articolul [60] ce rezumă diferitele aspecte din domeniul energetic ce pot fi formulate ca probleme de optimizare neliniară, rezolvate folosind algoritmul de tip PSO.

Algoritmii și studiile de caz din teză au făcut obiectul a patru articole publicate de autoare. Două au fost susținute la conferințe [61], [62] iar două au fost publicate în reviste [63], [64]. Din punct de vedere cronologic [61], [62] au fost primele două articole ele introducând modul de realizare al măsurătorilor, semnătura privită ca expresia unei funcții analitice ce aproximează prin regresie, folosind algoritmi genetici, traiectoria tensiune-curent, respectiv primele trei clase de semnături: tangentă, tangentă discontinuă, elipsă. Ulterior, în articolul [63] este tratată problema consumatorilor simpli (un singur dispozitiv electric), adăugându-se încă o clasă, clasa hibridă, studiul incluzând în final 4 clase de semnături. În ultimul articolul [64] se prezintă cazul consumatorilor-2. multipli (două dispozitive electrice funcționează concomitent).

3. FUNDAMENTAREA METODOLOGIEI APLICATE ÎN TEZĂ

Scopul acestui capitol este prezentarea cadrului teoretic folosit în cercetarea privind obținerea semnăturilor consumatorilor casnici. Expunerea se concentrează asupra introducerii de termeni (subcapitolul 3.1), prezentării de algoritmi (subcapitolul 3.2 și 3.3) și clase de semnături (subcapitolul 3.4), enunțării obiectului cercetării (subcapitolul 3.5) și detalierii metodei de modelare imaginate (subcapitolele 3.6 și 3.7). În esență, pentru determinarea semnăturilor consumatorilor casnici din valori ale tensiunii de alimentare și ale curentului absorbit, achiziționate cu o frecvență de cca. 20 Hz, s-a folosit regresia neliniară bazată pe utilizarea ca „vehicul de calcul” a algoritmilor genetici. Rezultatele obținute au fost sintetizate sub formă de „metode de determinare a semnăturilor”.

3.1. Terminologie

Acest paragraf este destinat introducerii terminologiei specifice folosite pe parcursul lucrării. Avem în vedere două categorii de termeni: *termeni specifici domeniului de studiu*, respectiv *termeni introduși de către autoare* ca rezultat al dezvoltării unor algoritmi și metode de lucru.

În cazul primei categorii de termeni definițiile preiau sensurile general acceptate în literatura de specialitate, iar după caz, și anumite particularizări în funcție de situație. Această primă categorie cuprinde următorii termeni: *Advance Metering Infrastructure*, *Descriptori electrici*, *Semnătură*, *Smart Grid* și *Smart Meter - Contor inteligent*.

A doua categorie conține termenii: *Algoritm de alocare*, *Clasă de consumatori*, *Consumator multiplu*, *Consumator simplu (ca particularizare a unui consumator multiplu)*, *Funcție suport*, *Semnătură consumator simplu*, *Semnătură consumator multiplu*, *Semnătură consumator echivalent*, *Traietorie tensiune-curent*.

a) *Termeni specifici domeniului de studiu*:

- *Advance Metering Infrastructure¹ — (AMI) — infrastructură de măsurare avansată*. În literatură termenul este folosit adeseori ca sinonim al „contorului inteligent”.
- *Descriptori electrici* — sintagmă utilizată pentru ansamblul mărimilor caracteristice ale unui circuit sau circuitelor electrice ale unui sistem. În contextul lucrării de față termenul desemnează ansamblul mărimilor înregistrate de un contor inteligent ca urmare a măsurării și/sau a prelucrării rezultatelor măsurărilor: tensiune, curent, defazaj, putere activă, putere reactivă, impedanță, armonici, etc.
- *Semnătură* — *formulă sau reprezentare grafică a unuia sau a mai multor parametrii electrici ai unui dispozitiv sau grup de dispozitive electrice, ce permite individualizarea dispozitivului sau grupului de dispozitive*. În cazul unui grup de dispozitive se vorbește despre

semnătură echivalentă, iar în cazul unui singur dispozitiv de *semnătură individuală*.

- *Smart Grid¹* – (SG) – *rețea inteligentă*. Termenul este folosit pentru a fixa imaginea de ansamblu în care se încadrează contorul inteligent, unul din elementele de interes de pe parcursul lucrării. O rețea inteligentă înglobează șapte domenii interconectate: clientul, piața de energie, furnizorul de servicii, gestionarea fluxului de energie, generarea energiei, transportul și distribuția. În acest context contorul inteligent al unui consumator casnic se situează la client, oferind posibilități de comunicare cu celelalte domenii.
- *Smart meter¹* – (SM) – *contor de energie inteligent*. În literatura de specialitate se regăsește adesea sub denumirea prescurtată de „contor inteligent”. Un contor de energie este considerat „inteligent” atunci când satisface simultan următoarele condiții minimale:
 - Achiziționarea în timp real sau aproape real a consumului de energie;
 - Capabilitatea de comutare de la o sursă de energie la alta;
 - Posibilitatea de a „citi” consumul atât de la distanță cât și local;
 - Controlul/întreruperea de la distanță a livrării de energie;
 - Posibilitatea de a interacționa cu alte tipuri de contoare (apă, gaz);
 - Capacitatea de identificare a stării anumitor dispozitive și de evaluare a calității energiei pe baza măsurărilor efectuate;
 - Posibilitatea de a opera în SG.

b) *Termeni preluați sau introduși în contextul dezvoltării de algoritmi/metode de lucru:*

- *Algoritm de alocare* — algoritm ce generează din mulțimea M a punctelor achiziționate ale traiectoriei tensiune-curent un set de puncte $\{(v(t), i(t))\}$, notat cu M_a , pentru ramura ascendentă a semnăturii și un set de puncte $\{(v(t), i(t))\}$, notat cu M_d , pentru ramura descendentă a semnăturii.
- *Clasă de consumatori* — consumatori cu aceeași funcție suport.
- *Consumator multiplu* — ansamblu de dispozitive electrice, fiecare cu rol de consumator. Pentru a evidenția numărul de dispozitive electrice componente, spre exemplu n , vorbim de *consumator n multiplu* notat *$c-n.m.$* . În cazul $n = 1$ avem *consumatorul simplu* (*$c-1.m.$*).
- *Consumator simplu echivalent* — consumator simplu fictiv ce corespunde din punctul de vedere al dependenței dintre tensiunea de alimentare și curentul consumat unui consumator *$c-n.m.$* , aproximând foarte bine traiectoria tensiune-curent a acestuia. Notăția folosită va fi *$c.s-e.$*
- *Funcție suport* — funcție analitică parametrizabilă, folosită pentru determinarea semnăturii unui consumator. În cadrul tezei funcția suport are forma generală $i = f(v, II)$, unde i este curentul momentan consumat, v tensiunea momentană de alimentare, iar II un set de

parametri. Funcția suport reprezintă forma generală a unui model matematic de tip „funcție caracteristică”² asociat consumatorului.

- *Traietorie tensiune-curent* — mulțimea punctelor $M = \{(v(t), i(t))\}$ obținute prin măsurare pentru un consumator, reprezentată în planul tensiune-curent.
- *Semnătura unui consumator simplu* — expresie analitică de forma $i = f(v, I)$ ce aproximează dependența tensiune-curent pentru un $c-1.m.$
- *Semnătura unui consumator multiplu* — ansamblu de expresii analitice de forma $i = f(v, I)$ ce aproximează dependența tensiune-curent pentru un $c-n.m.$
- *Semnătura unui consumator echivalent* — expresie analitică de forma $i = f(v, I)$ asociată unui consumator simplu echivalent sau unui consumator $c-n.m.$

Începând cu subcapitolul următor se procedează la prezentarea aspectelor teoretice referitoare la algoritmi folosiți și la metodele dezvoltate pe parcursul tezei în vederea determinării de semnături. Algoritmii cu care se începe expunerea sunt algoritmi de optimizare folosiți pentru parametrizarea funcțiilor suport. Ei au un rol cheie, de vehicul de calcul a valorilor parametrilor funcțiilor suport și astfel de obținere de semnături.

3.2. Algoritmi de optimizare folosiți pentru calcularea valorilor parametrilor funcțiilor suport

În cadrul tezei ca algoritmi de optimizare pentru calcularea valorilor parametrilor funcțiilor suport s-au folosit algoritmi genetici și algoritmi de tip PSO (particle swarm optimization = optimizarea roiului de particule). Primul algoritm face parte din categoria algoritmilor evoluționiști, iar al doilea se inspiră din modele existente în natură, asimilate în acest caz cu metode de tip „swarm intelligence” ce descriu comportamentul stolurilor de păsări, bancurilor de pești, roiurilor de insecte. Ambii sunt folosiți pentru soluționarea unor probleme de optimizare [65], [66], [60]. În cadrul lucrării ei sunt utilizați ca instrument de minimizare a funcției fitness neliniare folosită pentru determinarea prin regresie a parametrilor semnăturii. Optimizarea cu algoritmi menționați, inclusiv în cazul parametrizărilor prin regresie, este cvasi optimală, dar satisfăcătoare din punct de vedere practic.

Contextul în care se folosesc algoritmi de optimizare este următorul:

Odată achiziționate de la un consumator simplu sau de la un $c-n.m$ puncte ale traiectoriilor tensiune-curent, acestea sunt asociate unei clase de consumatori, consumatorului atribuindu-i-se implicit o *funcție suport* $i=f(v, I)$ parametrizabilă. Atribuirea este echivalentă cu *adoptarea formei unui model matematic de tip funcție*

² În cazul de față prin funcție caracteristică a unui sistem este denumită dependența $x_1(x_2)$ care corelează pentru un regim de funcționare dat a unui sistem dinamic variațiile $x_1(t)$ și $x_2(t)$ a două mărimi, prin eliminarea timpului.

caracteristică a c-n.m. Algoritmii genetici sau algoritmii de tip PSO se utilizează pentru determinarea parametrilor Π ai funcției suport atribuite astfel consumatorului.

În cazul unui consumator simplu algoritmi de optimizare determină valorile parametrilor Π prin minimizarea cu aproximație, prin iterații succesive, a unei funcții criteriu, denumită funcție fitness, $F(|f(v(t), \Pi) - i(t)|)$. Aceasta raportează mulțimea punctelor măsurate ($i(t)$, $v(t)$) la mulțimea punctelor calculate cu ajutorul funcției suport ($i(t)$, $f(v(t))$). Ca urmare, cu ajutorul algoritmilor de optimizare se determină valorile parametrilor Π de așa manieră încât funcția suport f parametrizată, reprezentând semnătura, să urmărească prin puncte discrete cât mai fidel punctele discrete ale traiectoriei tensiune-curent măsurate. Punctele calculate corespund aceluiași valori ale curenților ca și punctele măsurate.

În cazul consumatorului multiplu lucrurile se desfășoară similar cu precizarea că pot intra în discuție una sau mai multe funcții suport după cum se dorește identificarea *c-n.m.* sub forma unui consumator simplu echivalent sau a mai multor consumatori.

3.2.1. Algoritmi genetici

În terminologia specifică algoritmilor genetici, elementele cu care se operează sunt: i) *individul sau genomul* — reprezentat de setul de parametri Π ; ii) *genele* — reprezentate de parametri incluși în setul Π ; iii) *generația* — reprezentând mulțimea de indivizi evaluați simultan într-o iterație; iv) *populația unei generații* — dată de numărul de indivizi incluși într-o generație. Algoritmii genetici furnizează după evaluarea succesivă a mai multor generații „un cel mai potrivit individ”.

Pentru aplicarea algoritmilor genetici pot fi folosite diferite medii de modelare și simulare care conțin funcții sau librării dedicate. Câteva din librăriile dedicate și limbajele de programare folosite sunt:

Matlab	— GEATbx — [67];
Java	— Jenetics — [68], — ECJ (Java-based Evolutionary Computation Research System) — [69];
C++	— OpenGA — [70].

Pentru exemplificare menționăm funcția Matlab *ga* care va fi folosită în partea experimentală a lucrării. Ea implementează algoritmul genetic referit în teză în secțiunea 3.6.2. Funcția *-ga-* oferă implicit un scenariu de lucru care include: funcții de generare a populației, inclusiv a celei inițiale, impunerea dimensiunii populației (numărul de indivizi), funcția de selectare a indivizilor părinți, stabilirea numărului de generații, funcția de încrucișare a doi părinți, procentul din populație ce se transmite ca elite, funcția ce realizează mutația, condițiile de oprire, toleranțe etc. Pe lângă caracteristicile de mai sus, funcția permite, dependent de condițiile de lucru, o gamă largă de ajustări și modificări. Cu privire la scenariul implicit al funcției *-ga-* sunt importante următoarele detalieri [71]:

- Funcțiile implicite de generare a populației inițiale depind de condițiile impuse genelor, cum sunt limitările la anumite intervale de valori și alte restricții de tip egalitate, liniare sau neliniare.

- Numărul de indivizi dintr-o generație se adaptează în funcție de numărul de gene k din individ. Astfel, pentru un individ cu $k \leq 5$ gene populația va conține 50 de indivizi, iar dacă $k > 5$ se generează 200 indivizi.
- În cazul în care soluția nu este convergentă numărul maxim de generații se limitează la $100 \cdot k$.
- Selectarea indivizilor „părinți” din generația curentă, adică a indivizilor care participă la generarea indivizilor din următoarea generație, se face folosind funcția de selecție *Stochastic uniform*.
- Încrucișarea a doi părinți dintr-o generație, pentru obținerea de „indivizi copil” din următoarea generație, se realizează folosind funcția de încrucișare *Crossoverscattered*; 0.8% din indivizii noii populații sunt generați prin încrucișare, (un individ poate fi părinte mai mult de o singură dată).
- O cantitate de 0.05% din populația unei generații se transmite ca elite (indivizi nemodificați) în generația următoare.
- Mutația se realizează folosind funcția *Mutationadaptfeasible* pentru cazul când parametrilor li se impun restricții și funcția *Mutationgaussian* pentru cazul când nu există restricții. Tipurile de restricții avute în vedere sunt: domenii de variație, inegalități, egalități neliniare etc..

3.2.2. Algoritmi de tip PSO

În terminologia algoritmilor de tip PSO elementele cu care se operează sunt: i) *particulele* - reprezentate de puncte în spațiul soluțiilor definite de setul de parametri Π ; ii) *roiul* - mulțimea particulelor considerate în soluționarea unei probleme; iii) „*experiența particulei*” - în contextul dat definește minimumul „local” găsit de particulă; iv) „*experiența roiului*” - în contextul dat definește minimumul „global” rezultat din experiența roiului. Inițializarea presupune generarea roiului și asocierea de viteze fiecărei particule. La fiecare iterație algoritmul calculează o nouă viteză pentru fiecare particulă în funcție de factorul inerție (viteza în iterația anterioară), minimumul „local” asociat particulei în discuție și cel „global” al roiului. Algoritmul reactualizează astfel funcție de cele două tipuri de experiențe, pe de o parte direcția de deplasare a fiecărei particule în spațiul soluțiilor, iar pe de altă parte „cea mai bună experiență”, atât cea raportată la particulă cât și la roi. Acest mod de raportare în luarea deciziilor, atât la experiența individuală cât și la cea colectivă, a „roiului”, definește termenul de „swarm intelligence” (inteligenta roiului).

În categoria medii și librării ce implementează metoda de tip PSO putem enumera:

- | | |
|--------|--|
| Matlab | — PSOT (Particle Swarm Optimization Toolbox) — [72] |
| Java | — ECJ (Java-based Evolutionary Computation Research System)— [69]; |
| Python | — PySwarms — [73]. |

Pentru exemplificare considerăm funcția matlab *particleswarm*, funcție ce implementează această metodă. Am optat pentru detalierea acestei funcții deoarece ea este folosită în partea experimentală a tezei. Funcția implementează operații cum

sunt: generarea roiului, impunerea dimensiunii roiului, stabilirea direcției de deplasare a particulelor, aplicarea de condiții de oprire, toleranță etc. Cu privire la scenariul implicit sunt necesare următoarele detalieri [74]:

- Funcțiile implicite de generare a „roiului” depind de condițiile impuse particulelor cum sunt limitări la anumite intervale de valori. Dacă intervalul de variație a parametrilor nu este specificat, intervalul considerat implicit este $[-1000, 1000]$.
- Numărul de particule dintr-un roi se stabilește în funcție de numărul de parametri k asociați unei particule. Astfel, pentru o particulă cu $k \geq 10$ parametri roiul va conține 100 de particule, iar dacă $k < 10$ se generează $10*k$ particule.
- În cazul în care soluția nu converge, numărul maxim de iterații considerat este $200*k$.

Elementele prezentate mai sus clarifică parțial contextul utilizării algoritmilor de optimizare pentru obținerea de semnături asociate unor consumatori. Conturarea unei imagini complete a contextului presupune și abordarea unor aspecte legate de regresia neliniară pentru care algoritmi de optimizare furnizează în fapt suportul de calcul.

3.3. Regresie neliniară

Fie

$$i=f(v,II) , \quad (3.1)$$

expresia funcției suport a unei semnături, II reprezentând mulțimea parametrilor lui f . În vederea determinării unui set de valori pentru mulțimea II , astfel încât expresia f să aproximeze cât mai bine în raport cu un criteriu dat o dependența experimentală $\{(v(t), i(t))\}$ dată, obținută prin măsurători directe, se recurge la calculul parametrilor II prin regresie. Implementarea unei metode de regresie în vederea obținerii unei semnături conduce la soluționarea cu aproximație a sistemului de ecuații care rezultă impunând modelului (3.1) al consumatorului setul de măsurători $\{(v(t), i(t))\}$.

Dacă expresia lui f este liniară în raport cu parametrii II se vorbește despre *regresie liniară*. Altfel, se vorbește despre *regresie neliniară*. Datorită diversității și complexității traiectoriilor tensiune-curent autoarea tezei a recurs la folosirea regresiei nelinare.

Ca termeni specifici regresiei neliniare se menționează:

f — funcția de *regresie neliniară* sau *estimatorul*;

i — variabila dependentă sau *regresorul* (variația ei fiind obiectul de studiu al regresiei);



v — variabila independentă sau *predictorul*.

Estimatorul în cazul de față îl constituie funcția suport ai cărei parametri II sunt obținuți cu un algoritm de optimizare.

Din perspectiva obținerii unei semnături dintr-o mulțime $\{(v(t), i(t))\}$ de puncte măsurate calculul se desfășoară în condițiile de mai jos:

Punctele măsurate $\{(v(t), i(t))\}$ se achiziționează cu o frecvență mică, de cca. 20 Hz. Din acest motiv informațiile agregate referitoare la traiectoria tensiune-curent alcătuiesc o mulțime M de puncte $\{(v(t), i(t))\}$ ce prezintă o dispersie accentuată.

Aspectul este evidențiat în Fig.3.1.a. Denumim imaginea din figură „nor de puncte”. Corespunzător traiectoriilor reale norul de puncte trebuie parcurs în sens anti orar (trigonometric): ramura inferioară în sens ascendent, iar ramura superioară în sens descendent. Ca urmare, punctele agregate trebuie grupate în lungul celor două ramuri, ramura ascendentă, respectiv ramura descendentă situată deasupra celei ascendente. Gruparea punctelor corespunzător celor două ramuri, în două mulțimi M_a și M_d , se face prin alocare, punct cu punct. Rezultatul aplicării algoritmului de alocare apare în Fig.3.1.b și Fig.3.1.c: submulțimea de puncte M_a — albastru —, iar submulțimea M_d — roșu —. Curbele de regresie obținute sunt ilustrate în Fig.3.1.c — negru —.






Fig.3.1. Mulțimile M , M_a , M_d și curbele de regresie: a) Mulțimea M de puncte măsurate; b) Mulțimile M_a și M_d obținute prin alocare; c) curbele de regresie S_a , S_d .

Contextul de grupare prezentat impune folosirea a două funcții de regresie pentru obținerea unei semnături:

- i) funcția $i_a = S_a(v_a, I_a)$, asociată mulțimii M_a numită și „ramură ascendentă a semnăturii”;
- ii) funcția $i_d = S_d(v_d, I_d)$ asociată mulțimii M_d numită și „ramură descendentă a semnăturii”.

Graficele celor două funcții sunt reprezentate cu negru în Fig.3.1.c.

Așa cum se va arăta, asignarea funcțiilor de regresie, a estimatorului, se realizează în principal asociind consumatorul unei anumite clase.

3.4. Clase de semnături

Alura reprezentărilor grafice $\{(i(t), v(t))\}$ din Fig.3.1, precum și alurile care apar în secțiunile următoare în cadrul studiilor de caz asociate diferitelor dispozitive electrice sugerează gruparea consumatorilor după semnături în patru clase. Fiecărei clase îi corespunde o formă generală de model matematic definit de o funcție $i = S_k(v, I_k)$, unde $k \in K$ reprezintă clasa; $K = \{1, 2, 3, 4\}$ — mulțimea claselor, S_k — funcția suport asociată clasei k . Cele 4 clase, sunt:

- clasa tangentă continuă ($k = 1$),
- clasa tangentă discontinuă ($k = 2$),
- clasa elipsă ($k = 3$) și
- clasa hibridă ($k = 4$)³.

³ Exemple de consumatori care se încadrează în cele 4 clase: laptop ($k=1$), televizor ($k=2$), frigider ($k=3$), aspirator ($k=4$).

Denumirile primelor trei clase au fost date pe baza aspectului caracteristicii tensiune-curent. Denumirea celei de a patra clase are în vedere faptul că sunt posibili nori de puncte al căror aspect îmbină trăsături ale primelor trei clase cu particularități ce nu pot fi redade de acestea sau au aluri complet diferite care nu pot fi descrise prin funcții analitice elementare. Este important de subliniat că încadrarea unui consumator în una dintre cele 4 clase nu este unică, ea depinzând de „gradul de potrivire cu norul de puncte” obținut cu algoritmul de optimizare asociat operației de regresie neliniară folosite pentru obținerea semnăturii.

Cu privire la cele 4 clase de consumatori sunt importante următoarele notații și aspecte specifice referitoare la construcția funcțiilor suport:

- Indicele r identifică ramura semnăturii: $r = a$ pentru ramura ascendentă, respectiv $r = d$ pentru ramura descendentă.
- Pentru introducerea de discontinuități pe ramurile semnăturii în puncte $V \in [V_{min}, V_{max}]$ se folosește funcția semn $sgn(x)$:

$$sgn(x) = \begin{cases} -1, & x < V \\ 0, & x = V \\ 1, & x > V \end{cases} \quad (3.2)$$

Ea face posibilă generarea a două arce cu aceeași expresie analitică însă cu parametri diferiți, primul arc definit pe intervalul $[V_{min}, V]$ iar al doilea pe intervalul $(V, V_{max}]$. Rezultatul permite o mai bună corelare între semnătură și punctele obținute din măsurători. Parametrii arcului definit pe intervalul $[V_{min}, V]$ se vor identifica prin indicele „S” ($S =$ stânga), iar cei ai arcului definit pe intervalul $(V, V_{max}]$ prin indicele „D” ($D =$ dreapta).

- Pentru generarea unor puncte de inflexiune, respectiv a unor puncte de extrem local în cadrul funcțiilor suport corespunzătoare clasei hibride ($k = 4$) se folosește funcția

$$g: R \rightarrow R; g(x) = \begin{cases} a \cdot sgn(x) \cdot |x|^n, & \alpha = 1 \\ a \cdot |x|^n, & \alpha = 2 \end{cases}; a \in R, n \in Q. \quad (3.3)$$

Pentru $\alpha = 1$ se obțin puncte de inflexiune, iar pentru $\alpha = 2$ puncte de extrem local.

Cele 4 clase de semnături se prezintă în secțiunile 3.4.1, 3.4.2, 3.4.3, 3.4.4, informațiile fiind redade în următoarea succesiune:

- expresia analitică a funcției suport: $S_{k,r}(v, \Pi_{k,r})$;
- domeniul de definiție al funcției suport: $[V_{min}, V_{max}]$, valabil pentru toate cele 4 clase;
- codomeniul funcției suport: R , valabil pentru toate cele 4 clase;
- precizarea setului de parametri $\Pi_{k,r}$ asociați funcției suport;
- reprezentări grafice care includ: i) norii de puncte M_a , respectiv M_d ; ii) graficul funcției suport $S_{k,r}(v, \Pi_{k,r})$ pentru consumator simplu asociat clasei k , unde $k \in K$;
- precizarea unor elemente specifice funcției suport, cum sunt:
 - condițiile de adecvare — precizări legate de modul în care s-a realizat alegerea expresiei analitice asociate funcției suport;
 - diferențele impuse între funcția asociată ramurii ascendente respectiv celei descendente.

Modelele matematice asociate celor 4 clase sunt prezentate grupat în Anexa A.

3.4.1. Clasa tangentă discontinuă

Clasa tangentă discontinuă conține consumatori pentru care norul de puncte obținut prin măsurări este dispus ca în Fig.3.2. Atât imaginea ramurii ascendente, cât și imaginea ramurii descendente sugerează existența unui punct de discontinuitate în graficul unei funcții de tip tangentă trigonometrică în care graficul se întrerupe și unul dintre arcele create prin întrerupere (arcul stâng sau arcul drept) este traslatat pe verticală în raport cu celălalt. Denumirea dată clasei, de „tangentă discontinuă”, ține cont tocmai de acest aspect. S-a notat cu v_b abscisa punctului de discontinuitate.

Expresia funcției suport asociată distribuției de puncte ce definește clasa tangentă discontinuă este:

$$S_{2,r}: [V_{min}, V_{max}] \rightarrow R$$

$$S_{2,r}(v) = \left[\frac{1}{a_s} \operatorname{tg} \left(\frac{v+d_s}{c_s} \right) + b_s \right] \cdot \frac{1-\operatorname{sgn}(v-v_{b,r})}{2} + \left[\frac{1}{a_d} \operatorname{tg} \left(\frac{v+d_d}{c_d} \right) + b_d \right] \cdot \frac{1+\operatorname{sgn}(v-v_{b,r})}{2}, \quad (3.4)$$

unde $r \in \{a, d\}$. Ca urmare expresia funcției suport se utilizează în mod independent pentru fiecare dintre cele două ramuri ale semnăturii, ascendentă și descendentă. De asemenea, setul de parametrii $I_{2,r}$ și abscisa $v_{b,r}$ sunt distincte pentru fiecare ramură. Funcția $\operatorname{sgn}(x)$ are expresia (3.2). Domeniul de definiție al funcției suport, $[V_{min}, V_{max}]$, comun celor două ramuri, provine din examinarea măsurărilor efectuate.

Fig.3.2 exemplifică poziționarea graficului funcției suport — roșu — în raport cu norul de puncte M — albastru — pentru un consumator din această clasă. Cele două ramuri, cea ascendentă respectiv cea descendentă, sunt descrise de același tip de expresie analitică, însă cu parametrizări diferite $I_{2,a} \neq I_{2,d}$, respectiv $v_{b,a} = -100V$ pentru ramura ascendentă și $v_{b,d} = 100V$ pentru ramura descendentă.




Fig.3.2. Norul de puncte M — albastru — vs. funcție suport — roșu — pentru un consumator din-clasa tangentă discontinuă

Potrivit formulei (3.4), funcția suport a fiecărei ramuri a semnăturii operează în primă instanță cu 8 parametri agregați în mulțimile Π_{2-r} , $r = \{a, d\}$ (a – ascendentă, d – descendentă):

$$\Pi_{2-r} = \{a_{S-r}, b_{S-r}, c_{S-r}, d_{S-r}, a_{D-r}, b_{D-r}, c_{D-r}, d_{D-r}\}.$$

Ei reprezintă grade de libertate ce permit adecvarea funcției suport la datele experimentale. Se observă că apar parametri distincți pentru intervalul stâng „S” — $[V_{min}, v_b)$, respectiv drept „D” — $[v_b, V_{max}]$ ale fiecărei ramuri. Prin considerarea ca parametru și a lui v_b numărul gradelor de libertate este augmentat la 9.

Pentru adaptarea cât mai bună a semnăturii la particularitățile datelor experimentale este necesară impunerea unor restricții. Le denumim *condiții de adecvare*. Prin introducerea lor se reduce numărul gradelor de libertate ale funcției suport, adică numărul parametrilor efectiv independenți din mulțimea Π_{2-r} . Condițiile de adecvare luate în considerare în cazul clasei tangentă discontinuă sunt următoarele:

- *Limitarea valorilor funcției la capetele domeniului de definiție V_{min} și V_{max} prin impunerea unei „rezerve de argument” ε sub forma:*

$$\frac{V_{min}+d_S}{c_S} = -\frac{\pi}{2} + \varepsilon, \frac{V_{max}+d_D}{c_D} = \frac{\pi}{2} - \varepsilon. \quad (3.5)$$

Condițiile (3.5) conduc la eliminarea parametrilor d_S și d_D potrivit relațiilor:

$$d_S = -c_S \cdot \frac{\pi}{2} + c_S \cdot \varepsilon - V_{min}, \quad d_D = c_D \cdot \frac{\pi}{2} - c_D \cdot \varepsilon - V_{max}. \quad (3.6)$$

- *Impunerea caracterului de funcție monoton crescătoare funcției suport pe fiecare ramură în parte:*

$$\frac{\delta S_{2,r}(v)}{\delta v} > 0. \quad (3.7)$$

În final, din această condiție rezultă restricțiile de tip inegalitate

$$a_S \cdot c_S - \varepsilon > 0, \quad a_D \cdot c_D - \varepsilon > 0, \quad (3.8)$$

pentru intervalele de continuitate din domeniul de definiție, respectiv restricția de tip inegalitate:

$$\left[\frac{1}{a_S} \operatorname{tg} \left(\frac{v_b+d_S}{c_S} \right) + b_S \right] - \left[\frac{1}{a_D} \operatorname{tg} \left(\frac{v_b+d_D}{c_D} \right) + b_D \right] < 0. \quad (3.9)$$

în punctul de discontinuitate $v = v_b$.

- *Impunerea condiției ca funcțiile tangentă din (3.4) să fie continue pe subintervalele $[V_{min}, v_b)$ și $(v_b, V_{max}]$ (i.e. argumentele să nu ia valori de forma $(2j+1) \cdot (\pi/2)$).*

În raport cu un interval (A, B) această condiție conduce la cerința ca dubla inecuație în j :

$$A < (2j+1) \cdot \frac{\pi}{2} < B, \quad j \in Z,$$

să nu aibă soluție. Dubla inecuație se poate rescrie în forma:

$$\frac{A}{\pi} - \frac{1}{2} < j < \frac{B}{\pi} - \frac{1}{2}. \quad (3.10)$$

Pentru a fi îndeplinită condiția de incompatibilitate menționată este necesar ca diferența dintre *părțile întregi* ale celor două margini din (3.10) să fie 0. Substituind în diferențe pe A și B cu argumentele funcției tangentă diferențele devin:

$$\left[\frac{v_{min} + d_S}{c_S \cdot \pi} - \frac{1}{2} \right] - \left[\frac{v_b + d_S}{c_S \cdot \pi} - \frac{1}{2} \right] = 0, \quad \left[\frac{v_b + d_D}{c_D \cdot \pi} - \frac{1}{2} \right] - \left[\frac{v_{max} + d_D}{c_D \cdot \pi} - \frac{1}{2} \right] = 0 \quad (3.11)$$

Ținând cont de cele precizate mai sus, rezultă că, după impunerea condițiilor de adecvare pentru fiecare ramură a semnăturii, numărul parametrilor funcției $S_{2,r}(v)$ se reduce la 6:

$$\Pi_{2,r} = \{a_S, b_S, c_S, a_D, b_D, c_D\}. \quad (3.12)$$

Adoptarea lui v_b trebuie să îndeplinească condițiile (3.11) care, ținând seama de (3.6), devin:

$$\left[\frac{v_b + d_S}{c_S \cdot \pi} - \frac{1}{2} \right] = -1, \quad \left[\frac{v_b + d_D}{c_D \cdot \pi} - \frac{1}{2} \right] = 0 \quad (3.13)$$

În Fig. 3.3 se prezintă graficele câtorva parametrizări posibile obținute în acest context. Variantele a) și b) corespund clasei tangentă discontinuă, pe când c) și d) unui caz particular al clasei tangentă discontinuă — tangentă continuă, clasă ce va fi detaliată în secțiunea următoare. Diversitatea variantelor explică încadrarea unui număr important de consumatori în această clasă.




Fig.3.3. Parametrizări ale funcției tangentă discontinuă: a), b) Clasa tangentă discontinuă; c), d) clasa tangentă continuă.

3.4.2. Clasa tangentă continuă

În Fig.3.4 este reprezentată corelația dintre graficul funcției suport (roșu —) și mulțimea M (albastru —) asociate unui consumator din clasa tangentă continuă.




Fig.3.4. Norul de puncte M vs. graficul funcției suport pentru un consumator din clasa tangentă continuă

Expresia funcției suport ce definește clasa tangentă continuă, este:

$$S_{1,r}: [V_{min}, V_{max}] \rightarrow R$$

$$S_{1,r}(v) = \left[\frac{1}{a_S} \operatorname{tg} \left(\frac{v + d_S}{c_S} \right) + b_S \right] \cdot \frac{1 - \operatorname{sgn}(v)}{2} + \left[\frac{1}{a_D} \operatorname{tg} \left(\frac{v + d_D}{c_D} \right) + b_D \right] \cdot \frac{1 + \operatorname{sgn}(v)}{2} \quad (3.14)$$

Dacă comparăm cele două expresii ale funcțiilor suport, cea asociată clasei tangentă discontinuă (3.4) cu cea asociată clasei tangentă continuă (3.14), se poate observa că (3.14) este o particularizare a expresiei (3.4) rezultată prin substituirea lui v_b cu 0.

Similar clasei tangentă discontinuă, funcția suport (3.14) operează cu 8 parametri a , b , c și d reprezentând 8 grade de libertate. Condițiile de adecvare în acest caz sunt următoarele:

- Limitarea valorilor funcției suport la capetele domeniului de definiție, V_{min} respectiv V_{max} , prin adoptarea unei „rezerve de argument” ε în forma:

$$\frac{V_{min} + d_S}{c_S} = -\frac{\pi}{2} + \varepsilon, \quad \frac{V_{max} + d_D}{c_D} = \frac{\pi}{2} - \varepsilon \quad (3.15)$$

Condiția conduce la eliminarea a doi parametri, d_S , d_D , potrivit relațiilor:

$$d_S = -c_S \cdot \frac{\pi}{2} + c_S \cdot \varepsilon - V_{min}, \quad d_D = -c_D \cdot \frac{\pi}{2} + c_D \cdot \varepsilon - V_{max}. \quad (3.16)$$

- Impunerea continuității funcției suport în punctul $v=0$:

$$\frac{1}{a_S} \operatorname{tg} \left(\frac{d_S}{c_S} \right) + b_S = \frac{1}{a_D} \operatorname{tg} \left(\frac{d_D}{c_D} \right) + b_D.$$

Egalitatea de mai sus permite exprimarea parametrului b_S funcție de b_D

$$b_S = \frac{1}{a_D} \operatorname{tg} \left(\frac{d_D}{c_D} \right) - \frac{1}{a_S} \operatorname{tg} \left(\frac{d_S}{c_S} \right) + b_D. \quad (3.17)$$

- *Impunerea caracterului de funcție monoton crescătoare pentru intervalele de continuitate din domeniul de definiție:*

$$\frac{\delta S_{1,r}(v)}{\delta v} > 0 \quad (3.18)$$

În final, din această condiție rezultă restricțiile de tip inegalitate

$$a_S \cdot c_S - \varepsilon > 0, \quad a_D \cdot c_D - \varepsilon > 0. \quad (3.19)$$

- *Impunerea condiției ca argumentele semnăturilor tangentă continuă din expresia (3.14) să nu ia valori de forma $(2 \cdot j + 1) \cdot (\pi/2)$ pe subintervalele $[V_{min}, 0]$ și $(0, V_{max}]$. Condiția se regăsește în expresiile (3.20), prima corespunzând intervalului $[V_{min}, 0]$, iar a doua intervalului $(0, V_{max}]$. Ambele expresii impun ca diferența între părțile întregi asociate celor două margini să fie 0. Același rezultat se poate obține înlocuind în expresiile (3.11) pe v_b cu 0:*

$$\left[\frac{V_{min} + d_S}{c_S \cdot \pi} - \frac{1}{2} \right] - \left[\frac{d_S}{c_S \cdot \pi} - \frac{1}{2} \right] = 0, \quad \left[\frac{d_D}{c_D \cdot \pi} - \frac{1}{2} \right] - \left[\frac{V_{max} + d_D}{c_D \cdot \pi} - \frac{1}{2} \right] = 0 \quad (3.20)$$

Ținând seama de (3.16), condițiile (3.20) devin:

$$\left[\frac{d_S}{c_S \cdot \pi} - \frac{1}{2} \right] = -1, \quad \left[\frac{d_D}{c_D \cdot \pi} - \frac{1}{2} \right] = 0 \quad (3.21)$$

În consecință, în urma impunerii condițiilor de adecvare numărul parametrilor independenți (gradelor de libertate) asociați fiecărei ramuri $S_{1,r}$ se reduce de la 8 la 5:

$$\Pi_{1,r} = \{a_S, c_S, a_D, c_D, b\}. \quad (3.21)$$

Ei trebuie să satisfacă condițiile (3.21).

În urma celor prezentate putem concluziona că de fapt clasa tangentă continuă poate fi privită ca o particularizare a clasei tangente pentru condițiile:

- valoarea lui v_b este egală cu 0;
- funcția suport este continuă în acest punct.

Astfel expresia (3.14) devine:

$$S_{1,r} = \left(\frac{1}{a_S} \operatorname{tg} \frac{v + d_S}{c_S} - \frac{1}{a_S} \operatorname{tg} \frac{d_S}{c_S} + \frac{1}{a_D} \operatorname{tg} \frac{d_D}{c_D} \right) \cdot \frac{1 - \operatorname{sgn}(v)}{2} + \frac{1}{a_D} \operatorname{tg} \frac{v + d_D}{c_D} \cdot \frac{1 + \operatorname{sgn}(v)}{2} + b \quad (3.22)$$

unde d_S respectiv d_D iau valorile din expresiile (3.16), iar b_S a fost înlocuit de expresia (3.17).

3.4.3. Clasa elipsă

În Fig.3.5 este reprezentată grafic cu roșu — o funcție suport corespunzătoare clasei elipsă. Funcția este corelată cu norul de puncte M rezultat din măsurători, reprezentat cu albastru — , asociat acestui tip de consumator.




Fig.3.5. Norul de puncte M vs. funcție suport pentru un consumator din clasa elipsă.

Expresia funcției suport este:

$$S_{3,r}(v): [V_{min}, V_{max}] \rightarrow R$$

$$S_{3,r}(v) = \left[\left(\frac{a^2}{V_{max}^2} - 1 \right) \cdot v \cdot \sqrt{\frac{V_{max}^2 - b^2}{a^2 - V_{max}^2}} \mp \frac{a \cdot b}{V_{max}} \sqrt{1 - \frac{v^2}{V_{max}^2}} \right] \cdot f_{cor_1}(v) \cdot f_{cor_2}(v) \quad (3.23)$$

$$f_{cor_1}(v) = \left(1 + A \cdot \sin \left(3\pi \cdot \frac{v - V_{min}}{v - V_{max}} \right) \right)$$

$$f_{cor_2}(v) = e^{\frac{|v|}{B \cdot V_{max}}}$$

unde $a > V_{max}$ și $|b| < V_{max}$.

Expresia (3.24) a fost obținută pornind de la forma generală a ecuației unei elipse amplasată într-un sistem de axe cartezian iOv :

$$\frac{v^2}{a^2} + \frac{i^2}{b^2} = 1,$$

$a > 0$ și $b > 0$ fiind lungimile semiaxelor elipsei. Prin rotirea acestei elipse în jurul centrului ei cu unghiul β și explicitarea lui i în funcție de v se obține forma explicită (3.25) a elipsei rotite:

$$S_{3,r} = \frac{\left(1 - \frac{b^2}{a^2} \sin^2(\beta) \right) \cdot v \cdot \text{ctg}(\beta) \mp \sqrt{\Delta(v)}}{1 - \frac{b^2}{a^2}}, \quad (3.24)$$

$$\Delta(v) = \left(1 - \frac{v^2}{a^2} \right) - \left(1 - \frac{b^2}{a^2} \right) \cdot \sin^2(\beta). \quad (3.25)$$

Relația (3.24) se obține din (3.25) după impunerea a două condiții de adecvare și efectuarea unei corecții. Operațiile sunt detaliate mai jos.

- *Prima condiție de adecvare constă în impunerea cerinței ca graficele funcțiilor suport asociate celor două ramuri, ascendentă/ descendentă, ale elipsei să genereze o curbă închisă în planul (v, i) . Aceasta înseamnă:*

$$\Delta(V_{max}) = 0, \Delta(V_{min}) = 0. \quad (3.26)$$

Considerând că $V_{max} = -V_{min}$, din (3.25) deducem:

$$\sin^2(\beta) = \frac{a^2 - V_{max}^2}{a^2 - b^2} \quad (3.27)$$

În (3.24) se înlocuiesc $\sin^2(\beta)$ și $\text{ctg}(\beta)$ conform expresiei (3.27).

- *A doua condiție de adecvare constă în limitarea valorilor funcției suport la planul real. Aceasta înseamnă:*

$$\Delta(v) \geq 0, \text{ unde } v \in [V_{min}, V_{max}] . \quad (3.28)$$

Prelucrând expresia (3.28) se obține restricția de tip dublă inegalitate:

$$0 < \frac{a^2 - V_{max}^2}{a^2 - b^2}. \quad (3.29)$$

- Corecția se bazează pe observația că norul de puncte din Fig.3.5 are imaginea unei elipse ușor turtite (forma de arahidă) în zona centrală a celor două ramuri ascendentă/descendentă. Pentru o aproximare cât mai corectă a norului rezultat din măsurători, expresiei (3.24) i se aplică o dublă corecție ce include folosirea unei sinusoidale și a unei exponențiale. Corecția este dată de factorul:

$$f_{cor1}(v) \cdot f_{cor2}(v) = \left(1 + A \cdot \sin\left(3\pi \cdot \frac{v - V_{min}}{V_{max} - V_{min}}\right)\right) \cdot \left(e^{\frac{|v|}{B \cdot V_{max}}}\right)$$

Astfel, setul de parametri se completează cu A și B .

Numărul gradelor de libertate în cazul expresiei (3.24) este de 3: $\{a, b, \beta\}$. Ca urmare, prin eliminarea unghiului β și adăugarea parametrilor A și B specifici produsului funcțiilor de corecție⁴ $f_{cor1}(v)$ și $f_{cor2}(v)$ se ajunge în final la un număr de 4 grade de libertate:

$$\Pi_{3,r} = \{a, b, B, A\}. \quad (3.30)$$

⁴ Corecțiile conținute de funcția suport a clasei elipsă nu se întâlnesc la funcțiile suport ce definesc clasa tangentă, respectiv clasa tangentă discontinuă.

În Fig.3.6 sunt reprezentate grafic cu albastru — elipsa rotită fără aplicarea corecțiilor, respectiv graficele celor doi factori de corecție $f_{cor1}(v)$ cu linie întreruptă roșie ---, și $f_{cor2}(v)$ cu linie continuă roșie —.

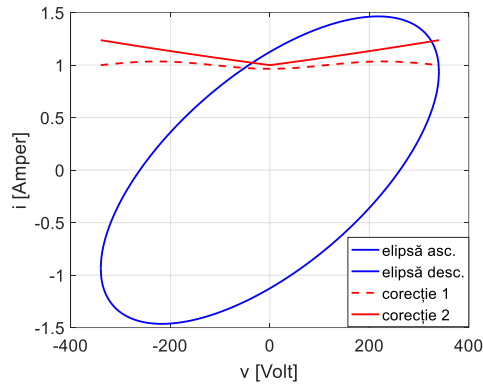


Fig.3.6. Elipsa rotită și graficele factorilor de corecție 1 și 2.

În Fig.3.7 sunt reprezentate 4 parametrizări posibile ale funcției suport $S_{3,r}$ care corespund la diferite valori ale parametrilor A, B din funcțiile de corecție $f_{cor1}(v)$, respectiv $f_{cor2}(v)$.




Fig.3.7. Parametrizări asociate funcției suport $S_{3,r}$.

În final este util de precizat că, spre deosebire de clasele prezentate anterior, în cazul clasei elipsă expresiile analitice asociate celor două funcții suport $S_{3_a}(v)$ respectiv $S_{3_d}(v)$ diferă:

$$S_{3_a}(v) = \left[\left(\frac{a^2}{V_{max}^2} - 1 \right) \cdot v \cdot \sqrt{\frac{V_{max}^2 - b^2}{a^2 - V_{max}^2}} - \frac{a \cdot b}{V_{max}} \sqrt{1 - \frac{v^2}{V_{max}^2}} \right] \cdot f_{cor_1}(v) \cdot f_{cor_2}(v)$$

$$S_{3_d}(v) = \left[\left(\frac{a^2}{V_{max}^2} - 1 \right) \cdot v \cdot \sqrt{\frac{V_{max}^2 - b^2}{a^2 - V_{max}^2}} + \frac{a \cdot b}{V_{max}} \sqrt{1 - \frac{v^2}{V_{max}^2}} \right] \cdot f_{cor_1}(v) \cdot f_{cor_2}(v)$$

3.4.4. Clasa hibridă

În Fig.3.8 sunt reprezentate comparativ pentru un consumator aparținând clasei hibride norul de puncte M —albastru — , rezultat din măsurători, și graficul aferent funcției suport asociate — roșu —.




Fig.3.8. Norul de puncte M vs. graficul funcției suport pentru un consumator din clasa hibridă.

Pentru un consumator simplu expresia funcției suport are forma:

$$S_{4,r}: [V_{min}, V_{max}] \rightarrow R$$

$$S_{4,r}(v) = \sum_{j=1}^5 [I_j + a_j \cdot |v - V_j|^{n_j} \cdot (\text{sgn}(v - V_j))^{\alpha_j}] \cdot f_{cor_{1j}}(v) + \mu \cdot f_{cor_2}(v) \quad (3.31)$$

$$f_{cor_{1j}}(v) = e^{b_{Sj} \cdot (v - V_j) \cdot \frac{1 - \text{sgn}(v - V_j)}{2} + b_{Dj} \cdot (v - V_j) \cdot \frac{1 + \text{sgn}(v - V_j)}{2}}$$

$$f_{cor_2}(v) = e^{-[\mu_1(1 - \text{sgn}(v - V_x)) + \mu_2(1 + \text{sgn}(v - V_x))] \cdot |v - V_x|}$$

iar pentru un $c-n.m$ are forma:

$$S_{4,r}(v) = \sum_{j=1}^3 I_j + a_{Sj} \cdot |v - V_j|^{n_{Sj}} \cdot (\operatorname{sgn}(v - V_j))^{\alpha_{Sj}} \cdot e^{b_{Sj} \cdot (v - V_j) \frac{1 - \operatorname{sgn}(v - V_j)}{2}} + \\ + \sum_{j=1}^3 a_{Dj} \cdot |v - V_j|^{n_{Dj}} \cdot (\operatorname{sgn}(v - V_j))^{\alpha_{Dj}} \cdot e^{b_{Dj} \cdot (v - V_j) \frac{1 + \operatorname{sgn}(v - V_j)}{2}} + \mu \cdot f_{cor2}(v), \quad (3.32)$$

în care

$$f_{cor2}(v) = e^{-[\mu_1(1 - \operatorname{sgn}(v - V_x)) + \mu_2(1 + \operatorname{sgn}(v - V_x))] \cdot |v - V_x|}.$$

Funcția de corecție f_{cor2} este comună celor două expresii (3.31), (3.32).

Expresia (3.31) conține 5 termeni definiți în raport cu parametrii V_j cu $|v - V_j|^{n_j}$, iar expresia (3.32) conține 3 termeni similari definiți în raport cu $|v - V_j|^{n_{Sj}}$, sau $|v - V_j|^{n_{Dj}}$. La aceștia se adaugă ultimul termen f_{cor2} comun celor două expresii ce corespunde înlocuirii lui $|v - V_j|$ cu 1. Acest ultim termen permite redarea de puncte unghiulare.

Parametrul α_j din (3.31), respectiv parametrii α_{S_j} , și α_{D_j} din (3.32) pot lua valorile 1 sau 2 rezultând expresii de forma :

$$r(x) = \begin{cases} a \cdot \operatorname{sgn}(x) \cdot |x|^n, & \alpha = 1 \\ a \cdot |x|^n, & \alpha = 2 \end{cases}, a \in R, n > 1$$

Forma cu $\alpha=1$ permite redarea zonelor cu puncte de inflexiune, iar forma cu $\alpha=2$ redarea zonelor cu puncte de extrem local.

Un alt aspect luat în considerare este continuitatea și derivabilitatea funcției $|x|^n$ pe R . Pentru a putea fi îndeplinite aceste condiții se consideră $n > 1$.

Parametrul I_j are dimensiunea fizică „curent electric” iar parametrii V_j și V_x au dimensiunea fizică „tensiune electrică”. Toți termenii conțin factori de corecție (amortizare/amplificare) cu variație exponențială asimetrică în raport cu diferența $v - V_j$.

În stabilirea relațiilor (3.31), (3.32) s-au avut în vedere două constatări:

- ramurile semnăturii au o alură de funcții impare în raport cu verticalele $v = 50$ V (pentru ramura ascendentă), respectiv $v = -50$ V (pentru ramura descendentă);
- ramurile semnăturii se compun din arce cu aspect parabolic în vecinătatea unor niveluri de tensiune $v = V_j$.

Din considerente legate de alura dependenței tensiune-curent, numărul termenilor incluși în sumă se impune a fi impar {(3.31)—5, (3.32)—3}.

Parametrii care apar în expresia (3.31), în număr de 39, sunt:

$$\Pi_{4,r} = \{V_1, \dots, V_5; \\ n_1, \dots, n_5; \alpha_1, \dots, \alpha_5; b_{S_1}, \dots, b_{S_5}; \\ b_{D_1}, \dots, b_{D_5}; I_1, \dots, I_5; V_x; \mu_1, \mu_2, \mu, a_1, \dots, a_5\} \quad (3.33)$$

iar parametrii care apar în expresia (3.32), în număr de 34, sunt:

$$\Pi_{4,r} = \{V_1, \dots, V_3; n_{S_1}, \dots, n_{S_3}; n_{D_1}, \dots, n_{D_3}; \alpha_{S_1}, \dots, \alpha_{S_3}; \\ \alpha_{D_1}, \dots, \alpha_{D_3}; b_{S_1}, \dots, b_{S_3}; b_{D_1}, \dots, b_{D_3}; I_1, \dots, I_3; V_x; \mu_1, \mu_2, \mu \\ a_{S_1}, \dots, a_{S_3}; a_{D_1}, \dots, a_{D_3}\} \quad (3.34)$$

Condițiile de adecvare asociate fiecăreia din cele două expresii sunt următoarele:

- Pentru expresia (3.31):

Parametrii I_1 și I_5 rezultă impunând la extremitățile intervalului $[V_{min}, V_{max}]$ condițiile: $i_{min} = S_{4_r}(V_{min})$ și $i_{max} = S_{4_r}(V_{max})$, unde i_{min} și i_{max} sunt valori de aproximare ale curentului i în punctele extreme. Pentru valorile de aproximare se consideră formulele:

$$i_{min} = i_{min_a} + \beta_{min} \cdot i_{min_d}, \quad i_{max} = \beta_{max} \cdot i_{max_a} + i_{max_d}. \quad (3.35)$$

Aici i_{min_a} și i_{min_d} sunt valorile curentului corespunzătoare punctelor din extremitatea stângă a mulțimilor M_a și M_d , iar i_{max_a} și i_{max_d} valorile curentului corespunzătoare punctelor de extremitate dreapta a aceluiași mulțimi. Valorile coeficienților de ponderare β_{min} și β_{max} se adoptă în prealabil.

- Pentru expresia (3.32):

I_1 și I_3 se inițializează la valoarea minimă respectiv maximă de curent măsurată pe ramura ascendentă:

$$I_1 = \min(i_a(t)), \quad I_3 = \max(i_a(t)), \quad (3.36)$$

unde $i_a(t)$ reprezintă vectorul de curenți mășurați asociați ramurii ascendente.

În urma aplicării condițiilor de adecvare numărul parametrilor din expresia (3.33) scade la 37 prin excluderea lui I_1 și I_5 , iar numărul celor din expresia (3.34) scade la 32 prin excluderea lui I_1 și I_3 .

Cele două variante ale funcției suport asociate clasei hibride s-au adoptat în urma unor teste. Inițial s-a lucrat cu expresia (3.31) atât în cazul $c-1.m$ cât și în cazul $c-n.m$. Ulterior s-a constatat însă că în cazul $c-n.m$ performanțele obținute sunt mai bune dacă se folosește expresia (3.32).

3.5. Delimitarea obiectului cercetării

Cercetarea de față are ca scop propunerea de metode și instrumente de calcul pentru identificarea dispozitivelor electrice cu rol de consumatori casnici de tip $c-n.m$, aflate în modul de funcționare pornit, pe bază de semnături determinate din seturi de măsurători $\{(v(t), i(t))\}$ furnizate de un contor inteligent pe intervale de timp de cca 51 s (1024 eșantioane la o frecvență de cca. 20Hz).

Demersul se bazează pe ipoteza admisă în literatură conform căreia *semnăturile consumatorilor de tip traiectorii V-I*, exprimabile prin dependențe $i(v)$ dintre tensiunea v de la borne și curentul i absorbit, sunt acceptate ca identificatori ai consumatorilor. Pentru un consumator dependența $i(v)$ leagă valori ale curentului i și ale tensiunii v de la momentul curent t . Tensiunea v ia valori continue în intervalul $[V_{min}, V_{max}]$.

Pentru obținerea semnăturii considerăm că dispozitivele electrice pentru care se determină semnătura se grupează într-un singur proces (P) și că din datele obținute de la acest proces, cu un contor inteligent, un generator de semnături asociază procesului o semnătură $f(v, I)$ de consumator simplu sau multiplu, după caz.

Abordarea este redată în Fig.3.9 în care apare un *c-n.m* pentru care un contor inteligent măsoară tensiunea v și curentul total i , iar generatorul de semnături asociază ansamblului un model tip semnătură.

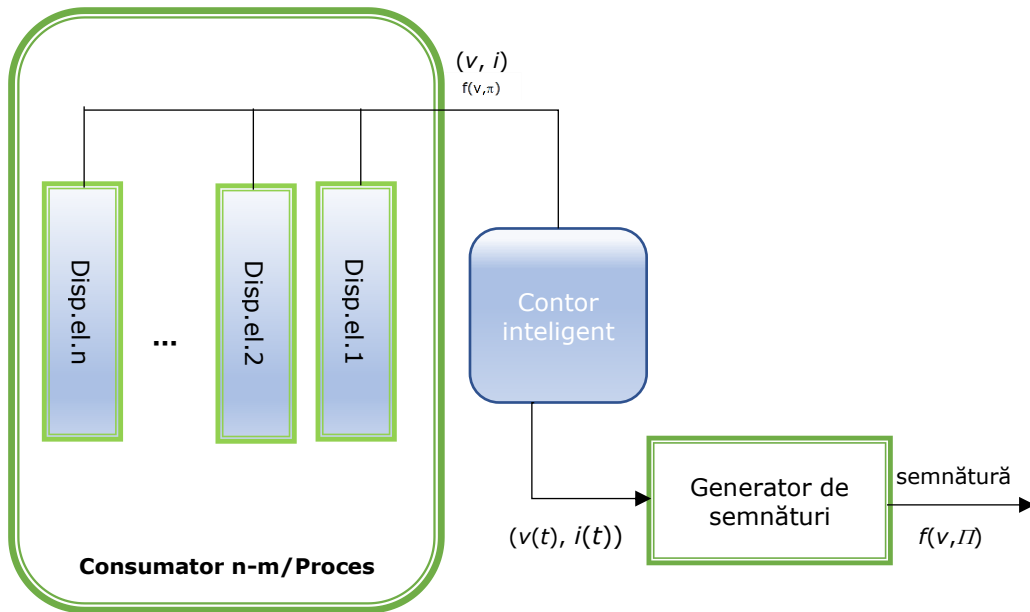


Fig.3.9. Consumatorul *c-n.m* în contextul obținerii semnăturii sale.

Se consideră că acest *model matematic* reprezintă o dependență $i(v)$ capabilă să aproximeze punctele măsurate de la procesul P.

În vederea generării semnăturii unui consumator simplu acestuia i se atribuie inițial o funcție suport $S_k(v, \Pi_k)$ corespunzătoare unei clase $k \in K$.

În cazul unui *c-n.m* forma inițială a semnăturii rezultă prin însumarea mai multor funcții suport, de diferite clase, sub forma:

$$f(v, \Pi) = \sum_{k=1}^4 \sum_{i=1}^{n_k} l_m \cdot S_k(v, \Pi_k^i), \text{ unde } m = \overline{1:4 \cdot n_k}. \tag{3.37}$$

Fiecare termen din sumă este destinat unui consumator simplu, din componența *c-n.m*. În (3.38) n_k reprezintă numărul de consumatori simpli de clasă k , iar l_m este un coeficient care poate lua valorile 0 sau 1, având rolul de a activa sau de dezactiva o anumită componentă a sumei.

Determinarea semnăturii, implică, indiferent de tipul consumatorului următoarele etape:

1. aplicarea algoritmului de alocare în vederea obținerii submulțimilor de puncte M_a , respectiv M_d prin trierea datelor obținute din măsurătorile $\{(i(t), v(t))\}$;
2. atribuirea unei funcții suport sau a unei sume de funcții suport de forma (3.38) din rândul celor 4 clase de consumatori;

3. determinarea valorilor parametrilor funcției suport sau a sumei de funcții suport de forma (3.38) de la punctul 2, și prin aceasta determinarea semnăturii.

Instrumentul de calcul utilizat în ultima etapă în vederea determinării prin regresie a valorilor parametrilor funcției suport sunt algoritmi de optimizare.

3.6. Gestionarea datelor achiziționate de contor și algoritmi de optimizare folosiți pentru parametrizarea funcției suport prin regresie

Pentru obținerea unei semnături se impune gestionarea mulțimii punctelor tensiune-curent măsurate cu contorul inteligent în sensul extragerii selective din aceasta a unor submulțimi de puncte din care apoi se determină în mod separat, prin regresie, folosind algoritmi de optimizare, părțile de semnătura pentru ramura ascendentă și ramura descendentă. După cum s-a menționat operația de extragere selectivă este denumită „alocare”. În secțiunea 3.6.1. se discută procedeul de alocare, iar în secțiunea 3.6.2. se detaliază aspecte referitoare la algoritmi de optimizare folosiți pentru parametrizarea prin regresie.

3.6.1. Alocarea punctelor folosite pentru determinarea semnăturii

În cazul ideal, tensiunea din rețeaua de alimentare a consumatorilor casnici are o variație sinusoidală cu o frecvență de 50 Hz. Ca urmare, pentru consumatorii cu o comportare invariantă în timp, traiectoriile $i(v)$ sunt, datorită periodicității tensiunii și curentului, curbe închise. Traiectoriile sunt decompozabile în două ramuri: o ramură „ascendentă” corespunzătoare intervalelor de timp în care $v(t)$ crește de la V_{min} la V_{max} , respectiv o ramură „descendentă” corespunzătoare intervalelor de timp în care $v(t)$ scade de la V_{max} la V_{min} .⁵

În practică ipotezele de mai sus nu sunt respectate întrucât tensiunea de alimentare nu variază pur sinusoidal iar consumatorii nu sunt efectiv invariabili în timp. Traiectoriile reale $i(v)$ prezintă din acest motiv abateri dispersate în vecinătatea traiectoriilor ideale. Conștientizând această situație, în cercetarea întreprinsă autoarea a adoptat ca ipoteză de lucru generarea de semnături corespunzătoare unor traiectorii $i(v)$ închise sau deschise, după caz, de aproximare a fascicului de traiectorii reale dispersate în vecinătatea celor ideale. Ca urmare, semnăturile determinate surprind, în parte, și anomaliile din rețea și variația comportării consumatorilor. Totodată, s-a avut în vedere tot ca ipoteză de lucru faptul că pentru consumatorii casnici au fost întâlnite, atât din situațiile discutate în literatură cât și din experimentările făcute, doar traiectorii $i(v)$ la care cele două ramuri nu se intersectează.

⁵ După cum s-a menționat în paragrafele anterioare indicele $r \in \{a, d\}$, asociat funcției suport $f_r(v, \Pi_r)$ sau setului de parametri Π_r , indică tipul ramurii: $r = a$ pentru ramura ascendentă, iar $r = d$ pentru ramura descendentă.

În contextul de mai sus, Fig.3.10.a exemplifică un nor de puncte măsurate ce cuprinde cca. 1024 puncte $\{(v(t), i(t))\}$. Norul evidențiază o traiectorie $i(v)$ cu două ramuri care nu se intersectează, una ascendentă (arcul inferior) și una descendentă (arcul superior), cu puncte comune la extremități. În Fig.3.10.b apare o imagine a aceluiași nor de puncte unite cu segmente de dreaptă în succesiunea în care au fost extrase punctele. Datorită faptului că două puncte succesive se achiziționează la un interval de timp de 2.5 perioade ale tensiunii de rețea, de cele mai multe ori unul pe o ramură ascendentă, iar celălalt pe o ramură descendentă, figura rezultată are aspectul unui continuu. Această reprezentare sugerează însă și posibilitatea ca cele două ramuri să se intersecteze. În cazul consumatorilor simpli analizați pe parcursul tezei ramurile semnăturilor nu s-au intersectat.





Fig.3.10. Imagini ale unui nor de puncte rezultat din măsurători: a) puncte $\{(v(t), i(t))\}$ discrete; b) puncte $\{(v(t), i(t))\}$ unite în ordinea succesiunii.

Selectarea submulțimilor de puncte folosite pentru asocierea de semnături reprezintă ansamblul de operații prin care din norul de puncte măsurate se extrag două submulțimi de puncte, M_a și M_d , folosite apoi pentru identificarea în parte a ramurilor semnăturilor. Metoda de selectare utilizată în cazul de față, *algoritmul de alocare*, este în esență un proces de filtrare care, la rândul lui, introduce abateri față de situația ideală.

În Fig.3.11 este reprezentată organigrama algoritmului de alocare. Punctul de plecare al operației de alocare îl constituie dispunerea punctelor măsurate $\{(v(t), i(t))\}$ pe zone ale norului de puncte. Apoi, în cadrul fiecărei zone punctele se distribuie pe ramuri. Se disting două tipuri de zone în raport cu axa tensiunii: verticale și orizontale. Indicii S, m, D marchează – zona stângă, de mijloc, dreaptă, pe când a, d – ramura ascendentă, descendentă.

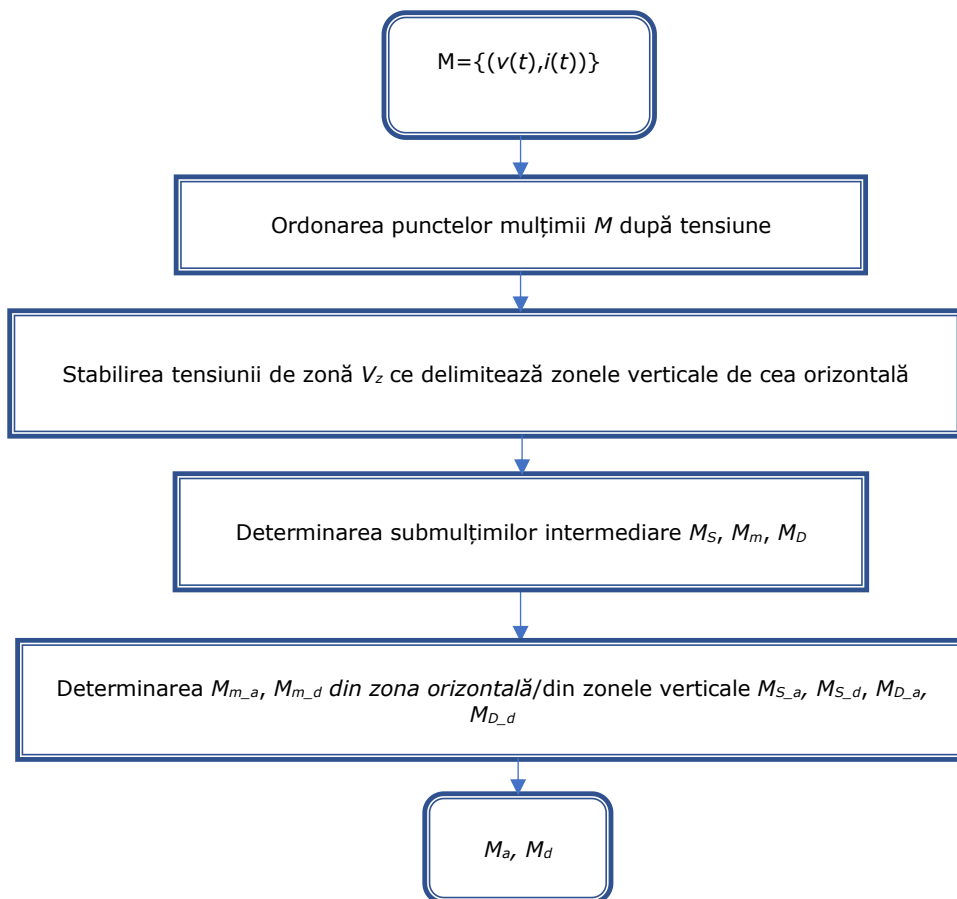


Fig.3.11. Organigrama algoritmului de alocare

În Fig.3.12 - a. sunt indicate, raportat la norul de puncte rezultat din măsurători, mulțimea de puncte M_a ce definește curba ascendentă, respectiv mulțimea de puncte M_d ce definește curba descendentă precum și zonele stânga (M_{S-r}), dreapta (M_{D-r}) și mijloc (M_{m-r}). În Fig.3.12 - b. au fost semnalate zonele verticale respectiv zona orizontală.





Fig.3.12. Reprezentare grafică: a) mulțimile M_a , M_d , M_{S-r} , M_{D-r} , M_m ; b) zone verticale, respectiv zona orizontală.

În zonele orizontale variația curentului consumat este foarte mică, curentul fiind aproape constant, pe când în zonele verticale, pe un interval de tensiuni îngust, variația curentului consumat este mare, punctele fiind dispuse aproape vertical asimptotic.

Împărțirea pe zone se face în principiu în funcție de valorile unor tensiuni de zonă $-V_z$ și V_z ce delimitează zonele verticale de cele orizontale. Din Fig.3.2, Fig.3.4, Fig.3.5 și Fig.3.8 rezultă că practic există o zonă orizontală și două zone verticale. Determinarea tensiunilor de zonă $-V_z$ și V_z se realizează contorizând pe intervale de tensiune de 10V numărul de puncte $\{(v(t), i(t))\}$ măsurate. Atunci când numărul de puncte din interval crește semnificativ, se consideră că tensiunea atinge una dintre valorile V_z sau $-V_z$. Odată determinate valorile tensiunilor de zonă se delimitează, potrivit relațiilor de mai jos, submulțimile: M_m - zona orizontală (mediană) și M_S - zona verticală stânga, respectiv M_D - zona verticală dreapta:

$$\begin{aligned} M_m &= \{(v(t), i(t)) | (v(t), i(t)) \in M, -V_z \leq v(t) < V_z\} \\ M_S &= \{(v(t), i(t)) | (v(t), i(t)) \in M, V_{min} \leq v(t) < -V_z, i(t) < -I_{ref}\} \\ M_D &= \{(v(t), i(t)) | (v(t), i(t)) \in M, V_z \leq v(t) \leq V_{max}, i(t) > I_{ref}\} \\ M \setminus (M_S \cup M_m \cup M_D) &\neq \emptyset \end{aligned}$$

Condițiile $i(t) > I_{ref}$ și $i(t) < -I_{ref}$ servesc pentru eliminarea punctelor din zonele de curbură, zone în care este greu de stabilit apartenența punctelor măsurate la ramura ascendentă sau descendentă. O valoare acceptabilă pentru I_{ref} , obținută empiric pentru consumatorii casnici, este 0.1 A.

După delimitarea celor trei zone, mulțimile punctelor lor sunt divizate între o submulțime alocată ramurii ascendente și o submulțime alocată ramurii descendente. Divizarea se obține în felul următor:

- Pentru zona orizontală:
 - Se calculează curentul mediu I_{avg} pe subintervale de 10V. Fie N numărul intervalelor și n numărul de ordine al intervalului.
 - Punctele pentru care $i(t) < I_{avg}$ se alocă ramurii ascendente, iar cele pentru care $i(t) > I_{avg}$ ramurii descendente. Rezultă mulțimile:

$$\begin{aligned} M_{m_a}^n &= \{(v^n(t), i^n(t)) | (v^n(t), i^n(t)) \in M_m^n, i^n(t) \leq I_{avg}^n\}, \\ M_{m_a} &= \bigcup_n M_{m_a}^n, n = \overline{1 \dots N} \\ M_{m_d}^n &= \{(v^n(t), i^n(t)) | (v^n(t), i^n(t)) \in M_m^n, i^n(t) > I_{avg}^n\}, \\ M_{m_d} &= \bigcup_n M_{m_d}^n, n = \overline{1 \dots N} \end{aligned} \quad (3.38)$$

- Pentru zona verticală se consideră două variante de alocare în funcție de extensia domeniului de valori ale curentului:
 - Prima variantă corespunde situației în care în zona verticală variația curentului este relativ redusă. În acest caz:
 - Se calculează tensiunea medie V_{avg_D} pentru punctele din întreaga zonă.
 - Pentru zona verticală dreapta, punctele din zonă cu $v(t) < V_{avg_D}$ se alocă ramurii descendente, iar cele cu $v(t) \geq V_{avg_D}$ ramurii ascendente. Rezultă submulțimile:

$$M_{D_a} = \{(v(t), i(t)) | (v(t), i(t)) \in M_D, v(t) \geq V_{avg_D}\}, \quad (3.39)$$

$$M_{D,d} = \left\{ \left((v(t), i(t)) \mid (v(t), i(t)) \in M_D, v(t) < V_{avg,D} \right) \right\}$$

- Similar se tratează zona verticală stânga obținând-se mulțimile $M_{S,a}$ și $M_{S,d}$.

$$\begin{aligned} M_{S,a} &= \left\{ (v(t), i(t)) \mid (v(t), i(t)) \in M_S, v(t) \geq V_{avg,S} \right\}, \\ M_{S,d} &= \left\{ \left((v(t), i(t)) \mid (v(t), i(t)) \in M_S, v(t) < V_{avg,S} \right) \right\} \end{aligned} \quad (3.40)$$

- A două variantă de alocare corespunde situației când în zona verticală variația curentului este semnificativă. În acest caz mulțimile $M_{D,a}$, $M_{D,d}$ și $M_{S,a}$, $M_{S,d}$ se reconstituie fără a mai utiliza condițiile $i(t) > I_{ref}$ și $i(t) < -I_{ref}$ și se procedează la o reîmpărțire a intervalelor $[V_z, V_{max}]$ și $[-V_{min}, -V_z]$ în mai multe subintervale cu lățimi de 0.5V - 3V, în ordine descrescătoare înspre extremități. Toate subintervalele se consideră ca zone orizontale. Mulțimile $M_{D,a}$ și $M_{D,d}$, respectiv $M_{S,a}$ și $M_{S,d}$ se constituie prin relații de alocare similar celor prin care se compun mulțimile $M_{m,a}$ și $M_{m,d}$.

$$M_{D,a}^n = \left\{ (v^n(t), i^n(t)) \mid (v^n(t), i^n(t)) \in M_D^n, i^n(t) \leq I_{avg}^n \right\},$$

$$M_{D,d} = \bigcup_n M_{D,a}^n, n = \overline{1 \dots N} \quad (3.41)$$

$$M_{D,d}^n = \left\{ (v^n(t), i^n(t)) \mid (v^n(t), i^n(t)) \in M_D^n, i^n(t) > I_{avg}^n \right\},$$

$$M_{D,d} = \bigcup_n M_{D,d}^n, n = \overline{1 \dots N}$$

Asemănător, rezultă cele două mulțimi $M_{S,a}$ și $M_{S,d}$:

$$M_{S,a}^n = \left\{ (v^n(t), i^n(t)) \mid (v^n(t), i^n(t)) \in M_S^n, i^n(t) \leq I_{avg}^n \right\},$$

$$M_{S,a} = \bigcup_n M_{S,a}^n, n = \overline{1 \dots N} \quad (3.42)$$

$$M_{S,d}^n = \left\{ (v^n(t), i^n(t)) \mid (v^n(t), i^n(t)) \in M_S^n, i^n(t) > I_{avg}^n \right\},$$

$$M_{S,d} = \bigcup_n M_{S,d}^n, n = \overline{1 \dots N}$$

Trebuie menționat faptul că variabila N utilizată în expresia (3.38) nu coincide cu parametrul N utilizat în expresiile (3.42) și (3.44), având semnificația de număr de intervale de lucru. Pe de altă parte, dacă în cazul zonei orizontale dimensiunea intervalului de calcul este fixă, fiind egală cu 10V, în cazul celei de a doua variante, în zona verticală exprimată de (3.42) și (3.44), dimensiunea intervalului de calcul scade progresiv, de la 3V, până la 0.5V, atât în zona verticală stângă (extrem — V_{min}) cât și în zona verticală dreaptă (extrem — V_{max}).

În final se constituie mulțimile M_a și M_d ca reuniune a mulțimilor disjuncte menționate:

$$M_a = M_{S,a} \cup M_{m,a} \cup M_{D,a}, M_d = M_{S,d} \cup M_{m,d} \cup M_{D,d}. \quad (3.43)$$

3.6.2. Algoritmi de optimizare și funcția fitness

Având cele două submulțimi M_a și M_d , expresiile funcțiilor f_a și f_d ($i_a = f_a(v(t))$, $i_d = f_d(v(t))$) precum și intervalele $I_{n,a}$, $I_{n,d}$ admise pentru parametri I_{a} și I_{d} , o semnătură se obține calculând în mod independent valorile parametrilor fiecărei ramuri prin regresie, folosind un algoritm de optimizare.

În cazul unui $c-1.m$ funcțiile f_a și f_d se reduc la expresiile funcțiilor suport S_{k_a} , S_{k_d} , iar seturile de parametrii Π_a , Π_d la seturile Π_{k_a} , Π_{k_d} unde $k \in K$ (Anexa A). În situația unui consumator multiplu cele două funcții f_a , f_d au expresiile de forma (3.37), iar parametrii Π_a , Π_d reprezintă reuniunea seturilor de parametri asociați funcțiilor suport incluse în suma (3.37).

Atunci când algoritmul de optimizare este un algoritm genetic, setul de parametrii Π_a sau Π_d este considerat un individ. Expresia funcției fitness adoptată pentru determinarea valorilor acestor parametri este dată de (3.44), în care $i(v)$ este estimatorul (funcția de regresie):

$$F_{fitness} = \frac{1}{N_r} \cdot \sum_{j=1}^{N_r} \left[|i_j - i(v_j)|^{n_j} \cdot (1 + 0.2 \cdot e^{-|v_j/V|}) \right]. \quad (3.44)$$

În expresia (3.45) i_j este valoarea măsurată a curentului corespunzătoare valorii măsurate v_j a tensiunii, $i(v_j)$ este valoarea estimată cu funcția suport aleasă (cu estimatorul ales), iar N_r , unde $r \in \{a, d\}$, reprezintă numărul de puncte din mulțimea M_a sau M_d .

În Fig.3.4, Fig.3.5 și Fig.3.8 se observă că în zonele orizontale valorile curenților sunt mai mici decât în zonele verticale. Totodată, vor fi mai mici și valorile $|i_j - i(v_j)|$ din zona orizontală. În acest context, în (3.44) exponențiala are rolul de a spori ponderea zonei orizontale în fitness. Întrucât consumatorul casnic se alimentează la o tensiune efectivă de 230 V, s-a considerat $V = 300$ V. Exponentul n_j are rolul de a pondera participarea valorilor $|i_j - i(v_j)|$ la formarea fitnessului. În studiile de caz avute în vedere valoare lui a fost considerată de cele mai multe ori egală cu 1.

Algoritmul genetic folosește funcția Matlab:

$$[x, f_{val}] = \text{ga}(_),$$

unde x reprezintă soluția, adică valorile setului de parametri, iar f_{val} valoarea fitnessului. Conform [71], pentru rulare s-au folosit următoarele parametrizări și operatori predefiniți asociați algoritmului genetic:

- „dimensiunea populației = 50 atunci când numărul parametrilor este mai mic decât 5 și 200 în rest;
- numărul de generații = 100 x numărul parametrilor;
- numărul elitelor=0.05;
- fracțiunea de încrucișare=0.8;
- fracțiunea de migrații între subpopulații = 0.02 (la fiecare a 20-a generație)”, respectiv următorii operatori:
 - generarea populației inițiale se realizează folosind funcția de generare aleatorie cu distribuție de probabilitate uniformă;
 - scalarea funcției fitness folosește ‘scalarea bazată pe rang’;
 - selecția se efectuează folosind un ‘algoritm stocastic uniform’;
 - încrucișarea se realizează folosind funcția de împrăștiere;
 - mutația se implementează printr-o funcție fezabil adaptivă.”

Alte detalii legate de setările și operatorii enumerați mai sus se găsesc în [71].

Atunci când algoritmul de optimizare este de tip PSO setul de parametrii Π_a sau Π_d reprezintă o particulă, iar funcția fitness considerată are tot expresia (3.44). Toate precizările referitoare la această funcție în cazul algoritmilor genetici sunt valabile și în cazul algoritmilor de tip PSO.

Pentru implementare a fost folosită funcția Matlab:

$$[x, f_{val}] = \text{particleswarm}(_)$$

unde x reprezintă soluția, adică vectorul cu valorile parametrilor funcției suport, iar f_{val} valoarea fitnessului.

Conform [74], pentru rulare s-au folosit următoarele parametrizări și operatori predefiniți asociați algoritmului genetic:

- dimensiunea roiului = $\min(100, 10 \cdot \text{numărul variabilelor})$ particule;
- numărul de generații = $200 \times \text{numărul parametrilor}$;
- ponderea minimumului „local” asociat unei particule în calcularea vitezei, de valoare 1.49;
- ponderea minimumului „global” asociat roiului în calcularea vitezei, de valoare 1.49;
- intervalul de variație al factorului de inerție [0.1, 1.1],

respectiv operatorul:

- 'pswcreationuniform' –funcția generează roiul inițial

Alte detalii legate de setările și operatorii enumerați mai sus se găsesc în [74].

După cum s-a precizat, setul de parametri Π_a, Π_d este restricționat la intervalele de variație I_{Π_a}, I_{Π_d} . Acolo unde parametrii au dimensiunea fizică de tensiune sau curent intervalele au fost stabilite în funcție de domeniul de variație al tensiunii, respectiv al curentului. Restul intervalelor s-au stabilit empiric în funcție de disponerea și distribuția punctelor în submulțimile M_a, M_d și de funcțiile f_a, f_d asociate. În mod firesc, în final valorile tuturor parametrilor Π_a, Π_d s-au încadrat în aceste intervale.

Expresia (3.44) a funcției fitness a fost folosită, fără a fi modificată, în toate cazurile de studiu prezentate în teză.

3.7. Determinarea semnăturii

În cazurile prezentate în teză pentru determinarea semnăturii se utilizează două abordări în funcție de tipul de consumator. Prima abordare, prezentată în secțiunea 3.7.1., se referă la algoritmul ce se aplică atunci când se determină semnătura unui consumator simplu. A doua abordare, expusă în secțiunea 3.7.2., integrează acest algoritm în trei variante de determinare a semnăturii unui consumator $c-n.m$ cu detaliere pentru consumatorul $c-2.m$.

3.7.1. Determinarea semnăturii pentru un consumator simplu

Algoritmul de determinare a semnăturii unui consumator simplu parcurge 2 etape:

- Etapa 1: selectarea submulțimilor de puncte M_a și M_d prin aplicarea algoritmului de alocare;
- Etapa 2: obținerea semnăturii prin calcularea prin regresie, folosind un algoritm de optimizare de tip AG sau PSO, pentru fiecare dintre submulțimile M_a și M_d , a valorilor parametrilor specifici funcției suport aferente clasei selectate pentru consumator.

În contextul prezentat clasa este a priori aleasă după inspectarea vizuală a aspectului norului de puncte $M = \{(v(t), i(t))\}$. În situația în care nu se procedează la

o inspectare vizuală se impune reluarea calculului prin regresie prin aplicarea succesivă a algoritmului de optimizare pentru fiecare dintre funcțiile suport $S_{k,r}$ de parametrii $\Pi_{k,r}$ asociate celor patru clase $k \in K$ și $r \in \{a, d\}$ (Anexa A) și compararea soluțiilor parțiale pe baza fitnessurilor rezultate. Fitnessul minim va indica semnătura sub forma de funcție suport parametrizată. În cadrul studiilor de caz expuse în capitolul 4 se prezintă rezultatele obținute pe baze experimentale pentru ambele moduri de abordare.

3.7.2. Determinarea semnăturii pentru un consumator 2-multiplu

Pentru un $c-n.m$, datorită conectării în paralel a celor n consumatori simpli componenți, curentul total consumat este suma algebrică a curenților momentani $i^j(t)$, $j = 1, 2, \dots, n$, absorbiți de dispozitivele componente, iar perechile de valori măsurate $\{v(t), i(t)\}$ sunt formate din valorile momentane ale tensiunii comune de alimentare v și curentului total consumat i :

$$i(t) = i^1(t) + i^2(t) + \dots + i^n(t). \quad (3.45)$$

Aceasta face ca, spre deosebire de consumatorul simplu, unui $c-n.m$ să i se poată atribui semnături în următoarele variante de interes practic:

- Varianta 1: asocierea unei singure dependențe $i(v)$, adică a unui consumator simplu echivalent $c.s-e$;
- Varianta 2: asocierea unui număr de s dependențe $i(v)$, ($1 < s < n$), adică a unui ansamblu de semnături $i^1 = f_1(v)$, $i^2 = f_2(v)$, ..., $i^s = f_s(v)$, fără corespondent fizic individualizat, dar care prin însumarea curenților să echivaleze întregul consumator multiplu;
- Varianta 3: asocierea unui număr de n dependențe $i(v)$, $i^\lambda = f_\lambda(v)$, $\lambda = 1, \dots, n$, în ideea că fiecare dependență corespunde unuia din cei n consumatori simpli din componența $c-n.m$.

Fiecare dintre funcțiile $f_i(v)$ menționate în cele 3 variante de mai sus (unde valoarea maximă a lui i variază în funcție de variantă) se va identifica cu una din funcțiile suport asociate celor patru clase $S_k(v)$, unde $k \in K$. Expresiile $S_k(v)$ sunt rezumate în (Anexa A), prezentarea lor detaliată regăsindu-se în subcapitolul 3.5.

În cazul unui $c-2.m$ varianta 2 se confundă cu varianta 3, astfel că variantele ce prezintă interes sunt variantele 1 și 3, adică asocierea unei singure dependențe $i(v)$ cu rol de semnătură a unui $c.s-e$, respectiv asocierea unei perechi de dependențe $\{i^1 = f_1(v), i^2 = f_2(v)\}$.

- În cazul variantei 1 modul de abordare este echivalent cu cel utilizat în situația consumatorului simplu, procesul de asociere a semnăturii parcurgând următoarele etape:
 - Etapa I: Selectarea submulțimilor de puncte M_a, M_d folosite pentru asocierea semnăturii;
 - Etapa II: Selectarea setului de funcții suport propuse pentru $c.s-e$, în particular chiar a tuturor celor patru funcții corespunzătoare celor patru clase K și adoptarea funcției fitness;
 - Etapa III: Determinarea valorilor parametrilor funcțiilor suport folosind regresia neliniară;
 - Etapa IV: Stabilirea semnăturii $c.s-e$ pe baza fitness-ului minim.

- Procesul de asociere de semnăturii pentru *varianta* 3 parcurge următoarele etapele:
 - Etapa I: Selectarea submulțimilor de puncte M_a, M_d folosite pentru asocierea semnăturilor consumatorilor simpli din componența $c-n.m$;
 - Etapa II: Adoptarea mulțimii de perechi de funcții suport $C_{\alpha\beta} = \{S_\alpha(v), S_\beta(v)\}$, $\alpha, \beta \in K$, precum și a ponderilor aplicate funcțiilor suport și a funcției fitness asociate;
 - Etapa III: Determinarea prin regresie neliniară a valorilor parametrilor perechilor de funcții suport pentru diferitele valori ale parametrului de ponderare p selectate în etapa II;
 - Etapa IV: Stabilirea semnăturilor celor n consumatori simpli din componența $c-n.m$.

În cazul variantei 3 este natural să urmărim dacă cele două dependențe asociate $c-2.m$ corespund semnăturilor consumatorilor simpli reali sau doar unor consumatori echivalenți matematic. Acest aspect este discutat în capitolul 4 în care pentru consumatorii de tipul $c-2.m$ semnăturile se determină folosind atât *varianta* 1, cât și *varianta* 3.

Cu privire la etapele mai sus menționate se fac următoarele precizări:

Etapa I, având ca rezultat generarea submulțimilor M_a și M_d asociate ramurii ascendente și respectiv ramurii descendente prin selectare de puncte din mulțimea M , este comună variantelor 1 și 3. Selectarea se realizează folosind algoritmul de alocare prezentat în secțiunea 3.6.1.

Îndeplinirea obiectivelor etapei II (*varianta* 3) se bazează pe raționamentului prezentat în continuare.

- Se consideră că pentru fiecare ramură r sunt admise toate perechile de consumatori simpli, $C_{\alpha\beta}$, indicii α și β luând toate cele 4 valori $k \in K$. Rezultă astfel un număr de 16 perechi $C_{\alpha\beta}$ de funcții suport: $\{C_{11}, C_{12}, C_{13}, C_{14}, C_{21}, C_{22}, C_{23}, C_{24}, C_{31}, C_{32}, C_{33}, C_{34}, C_{41}, C_{42}, C_{43}, C_{44}\}$.
- Funcția fitness adoptată pentru determinarea prin regresie a valorilor parametrilor fiecărei perechi $C_{\alpha\beta}$ aferentă unei ramuri r , folosind AG sau algoritmi de tip PSO, este:

$$F_{\alpha\beta,r,p} = \frac{1}{N_r} \cdot \sum_{j=1}^{N_r} \left[|i_j - i_{\alpha\beta,r,p}(v_j)| \cdot \left(1 + 0.2 \cdot e^{-|v_j/V|} \right) \right], \quad (3.46)$$

unde

$$i_{\alpha\beta,r,p}(v_j) = i_r^1(v_j) + i_r^2(v_j), \quad (3.47)$$

$$i_r^1(v_j) = p \cdot S_\alpha(v_j), \quad i_r^2(v_j) = (1 - p) \cdot S_\beta(v_j). \quad (3.48)$$

- În aceste formule N_r reprezintă numărul de puncte din mulțimea M_r , i_j — valoarea măsurată a curentului total absorbit corespunzătoare valorii v_j a tensiunii la borne la momentul t_j , adică $i_j = i(v(t_j))$, p — parametrul de ponderare a componentelor perechii $\{\alpha, \beta\}$ folosit pentru calcularea valorii $i_{\alpha\beta,r,p}$ a curentului total absorbit, iar V o constantă de atenuare a valorilor de tensiune măsurate. S-a adoptat valoarea $V = 300V$.

- Ponderarea a fost introdusă datorită faptului că fitnessul $F_{\alpha\beta_r_p}$ operează cu curentul total absorbit pe fiecare ramură în timp ce puterile consumatorilor simpli reali care compun consumatorul $c-2.m$ pot avea ordine de mărime diferite iar. Prin ponderare se creează posibilitatea ca valorile ambelor funcții suport $S_{\alpha}(v_j)$ și $S_{\beta}(v_j)$ să aibă influențe comparabile pe întreg domeniul de variație al tensiunii la borne.
- Pentru cazul general am considerat că p ia valori în mulțimea \mathcal{P} :

$$\mathcal{P} = \{0.2, 0.4, 0.5, 0.6, 0.8\}. \quad (3.49)$$

Ca urmare, curenții totali absorbiți pe ramurile a și d se obțin cu formulele:

$$\begin{aligned} i_{\alpha\beta_a_p}(v_j) &= p \cdot S_{\alpha_a}(v_j) + (1-p) \cdot S_{\beta_a}(v_j), \\ i_{\alpha\beta_d_p}(v_j) &= p \cdot S_{\alpha_d}(v_j) + (1-p) \cdot S_{\beta_d}(v_j), \quad p \in \mathcal{P}. \end{aligned} \quad (3.50)$$

În (3.50) valorile $S_{\alpha_r}(v_j)$ și $S_{\beta_r}(v_j)$ se calculează cu expresiile funcțiilor suport din (Anexa A).

- În final observăm că prin adoptarea mulțimii \mathcal{P} sub forma (3.49) aplicarea relației (3.50) pentru perechea $C_{\alpha\beta}$ de parametrul p și perechea $C_{\beta\alpha}$ de parametrul $1-p$ conduce la același rezultat. Aceasta face ca numărul combinațiilor care trebuie analizate să se reducă la $q = 10$, reținându-se combinațiile: $\{C_{11}, C_{12}, C_{13}, C_{14}, C_{22}, C_{23}, C_{24}, C_{33}, C_{34}, C_{44}\}$.

Etapa III este practic etapa de calcul a metodei de obținere a semnăturilor. În organizarea calculului se are în vedere că pentru fiecare pereche $C_{\alpha\beta}$ funcțiile suport aferente ramurilor ascendente, $S_{\alpha_a}(v)$ și $S_{\beta_a}(v)$, respectiv descendente, $S_{\alpha_d}(v)$ și $S_{\beta_d}(v)$, introduc implicit seturile de parametri Π_{α_a} și Π_{β_a} , respectiv Π_{α_d} și Π_{β_d} . Identificarea perechii de semnături corespunzătoare ramurii r se consideră încheiată odată terminat calculul perechii $\{\Pi_{\alpha_r}, \Pi_{\beta_r}\}$ folosind AG sau algoritmi PSO, punctele din mulțimea M_r și fitnessul $F_{\alpha\beta_r_p}$.

- Având în vedere modul de operare al algoritmilor de optimizare folosiți, fiecare nouă utilizarea a lor pentru un nor de puncte M_r , o combinație $C_{\alpha\beta}$, o pondere p și o ramură r date se soldează, după un număr de n_G generații, suficient de mare, cu stabilizarea seturilor de parametri $\{\Pi_{\alpha_r}, \Pi_{\beta_r}\}$, respectiv a fitnessului $F_{\alpha\beta_r_p}$, la alte valori. Experimental am constatat că stabilizarea valorii $F_{\alpha\beta_r_p}$ se produce în majoritatea cazurilor după un număr $n_G = 200$ generații.
- Denumim „rulare independentă” ansamblul operațiilor prin care se determină simultan, dar independent, pentru toate cele $q = 10$ perechi $C_{\alpha\beta}$, mulțimea valorilor $F_{\alpha\beta_r_p}$ și mulțimile valorilor parametrilor setului $\{\Pi_{\alpha_r}, \Pi_{\beta_r}\}$. Notăm cu θ , $\theta = 1, 2, \dots, m$ numărul de ordine al rulării independente.
- Datorită dispersiei punctelor măsurate din norul de puncte M_r și datorită minimelor locale ale funcțiilor suport, șirul de fitnessuri corespunzător unei combinații $C_{\alpha\beta}$ obținut pe parcursul mai multor rulări independente, adică șirul $\{F_{\alpha\beta_r_p_\theta}\}_{\theta=1, 2, \dots, m}$, nu este constant, valorile $F_{\alpha\beta_r_p_\theta}$ diferind de la o rulare independentă la alta. Investigarea experimentală a convergenței a condus la concluzia că șirurile de valori $\{F_{\alpha\beta_r_p_\theta}\}_{\alpha\beta=C_{\alpha\beta}}$,

- $r \in \{a, d\}$, $p \in \{0.2, 0.4, 0.5, 0.6, 0.8\}$, $\theta = 1, 2, \dots, m$ se stabilizează după un număr de $m = 50$ rulări independente.
- În acest context, pentru finalizarea determinării parametrilor funcțiilor suport folosind regresia neliniară presupunem că, într-o primă etapă, am efectuat pentru fiecare pondere p , ramură r și pentru toate cele $q = 10$ combinații un număr de m rulări independente, fiecare cu extensia de n_G generații. Apoi, într-o a doua etapă, finalizăm etapa III procedând la sistematizarea celor 500 de rezultate (fitnessurile și parametrii combinațiilor participante la o rulare independentă) ca în Tabel 3.1 (mai puțin ultima linie și ultima coloană). În total se obțin 5 tabele pentru $r = a$ și 5 tabele pentru $r = d$.

Tabel 3.1: Fitnessuri și parametri de semnături pentru rulările independente corespunzătoare unui p și unui r date.

θ	C_{11}	C_{12}	...	C_{44}	$C_{\alpha\beta}^\theta$
1	$F_{11_r_p_1},$ $\Pi_{1_r_p_1}, \Pi_{1_r_1-p_1}$	$F_{12_r_p_1},$ $\Pi_{1_r_p_1}, \Pi_{2_r_1-p_1}$...	$F_{44_r_p_1},$ $\Pi_{4_r_p_1}, \Pi_{4_r_1-p_1}$	$C_{\alpha\beta}^1$
...
50	$F_{11_r_p_50},$ $\Pi_{1_r_p_50}, \Pi_{1_r_1-p_50}$	$F_{12_r_p_50},$ $\Pi_{1_r_p_50}, \Pi_{2_r_1-p_50}$...	$F_{44_r_p_50},$ $\Pi_{4_r_p_50}, \Pi_{4_r_1-p_50}$	$C_{\alpha\beta}^{50}$
$f_{p,r}$	$f_{p,r,11}$	$f_{p,r,12}$		$f_{p,r,44}$	f_{pr}

În *etapa IV* datorită mulțimii datelor de analizat sunt posibile mai multe procedee de obținere a semnăturilor consumatorilor simpli din componența *c-n.m.* În toate studiile de caz prezentate în capitolul IV validarea finală a soluțiilor s-a făcut din perspectiva corespondenței cu consumatorii fizici.

- Procedeele cel mai simplu constă în identificarea pentru fiecare ramură r a fitnessului minim notat cu $F_{r,min}$ în ansamblul celor 2500 de valori ale fitnessului din cele 5 tabele de tipul 3.1. Rezultatul se supune validării finale.
- De cele mai multe ori procedeul cel mai simplu nu furnizează însă soluția finală întrucât operațiile care au condus la valoarea $F_{r,min}$ pot eluda anumite abateri ale semnăturii aferente în raport cu mulțimea M_r . Ținând seama de acest aspect s-a adoptat următorul procedeu:
 - Se înscrie în Tabel 3.1 pe fiecare linie θ , în ultima coloană, simbolul perechii cu fitnessul cel mai mic $C_{\alpha\beta}^\theta$. Astfel: $C_{\alpha\beta}^1$ este simbolul din mulțimea $C_{\alpha\beta}$ din rularea independentă $\theta = 1$ care corespunde lui $\min\{F_{\alpha\beta_r_p_1}\}_{\alpha\beta \in \{11,12, \dots, 44\}}$, iar $C_{\alpha\beta}^{50}$ simbol din mulțimea $C_{\alpha\beta}$ care corespunde celui mai mic fitness din rularea $\theta = 50$, $\min\{F_{\alpha\beta_r_p_50}\}_{\alpha\beta \in \{11,12, \dots, 44\}}$.
 - Se calculează cu formula (3.51) frecvențele tuturor combinațiilor din Tabel 3.1 ($f_{p,r,11}, \dots, f_{p,r,44}$) și cu formula (3.52) scorul maxim $f_{p,r,max}$:

$$f_{p,r,\alpha\beta} = (\text{numărul de apariții a combinației } C_{\alpha\beta} \text{ în ultima coloană din Tabel 3.1-p, r})/m. \quad (3.51)$$

$$f_{p,r_max} = \max\{f_{p,r,\alpha\beta}\}, \alpha, \beta \in K \quad (3.52)$$

Rezultatele se înscriu în prima linie din Tabelul 3.2. Pe a doua linie a tabelului apare valoarea minimă a fitnessurilor care au contribuit la stabilirea valorii frecvenței din prima linie. Potrivit exemplului din Tabelul 3.2 lui $p = 0.6$ îi corespunde frecvența maximă $f_{0.6,r_max} = 0.66$ care apare pentru combinația C_{24} și căreia îi corespunde un fitness minim $F_{0.6,r} = 0.12345678$. Notăm cu $\{F_{p,r}\}$ mulțimea tuturor valorilor $F_{p,r}$ din Tabelul 3.2.

Tabelul 3.2: Frecvențele maxime ale combinațiilor analizate pentru ramura r și fitnessurile minime asociate.

$f_{0.2,r,\#\#} = \dots$	$f_{0.4,r,\#\#} = \dots$	$f_{0.5,r,\#\#} = \dots$	$f_{0.6,r,24} = 0.66$	$f_{0.2,r,\#\#} = \dots$
$F_{0.2,r} = \dots$	$F_{0.4,r} = \dots$	$F_{0.5,r} = \dots$	$F_{0.6,r} = 0.12345678$	$F_{0.8,r} = \dots$

- Determinăm soluția corespunzătoare ramurii r efectuând succesiv următoarele operații:
 - a) Se alege ca primă soluție combinația $C_{\alpha\beta}$ corespunzătoare celui mai mic fitness $F_{p,r}$ conform expresiei (3.53):

$$F_r = \min_{p \in P} \{F_{p,r}\}. \quad (3.53)$$

Dacă semnăturile parțiale $i_r^1(v_j)$ și $i_r^2(v_j)$ au sens fizic, atunci se adoptă această primă soluție. Altfel, se trece la o nouă alegere în ordinea crescătoare a fitnessurilor din mulțimea $\{F_{p,r}\}$.

- b) Se determină semnăturile celor doi consumatori componenți prin combinarea semnăturilor parțiale ale celor două ramuri $i_a^1(v_j)$ și $i_a^2(v_j)$ respectiv $i_d^1(v_j)$ și $i_d^2(v_j)$ cu formule de forma (3.54) și (3.55):

Consumator 1:

$$i^1(v) = \begin{cases} p \cdot S_{\alpha,a} & \text{cu parametrii } \Pi_{\alpha,a} \text{ pentru ramura ascendentă} \\ p \cdot S_{\alpha,d} & \text{cu parametrii } \Pi_{\alpha,d} \text{ pentru ramura descendentă} \end{cases} \quad (3.54)$$

Consumator 2:

$$i^2(v) = \begin{cases} (p-1) \cdot S_{\beta,a} & \text{cu parametrii } \Pi_{\beta,a} \text{ pentru ramura ascendentă} \\ (p-1) \cdot S_{\beta,d} & \text{cu parametrii } \Pi_{\beta,d} \text{ pentru ramura descendentă} \end{cases} \quad (3.55)$$

3.7.3. Organigrama metodei de generare a semnăturilor

În Fig.3.13 este reprezentată organigrama metodei de generare a semnăturilor în conformitate cu cele prezentate în secțiunile 3.7.1 și 3.7.2 referitor la consumatorul simplu, respectiv multiplu.

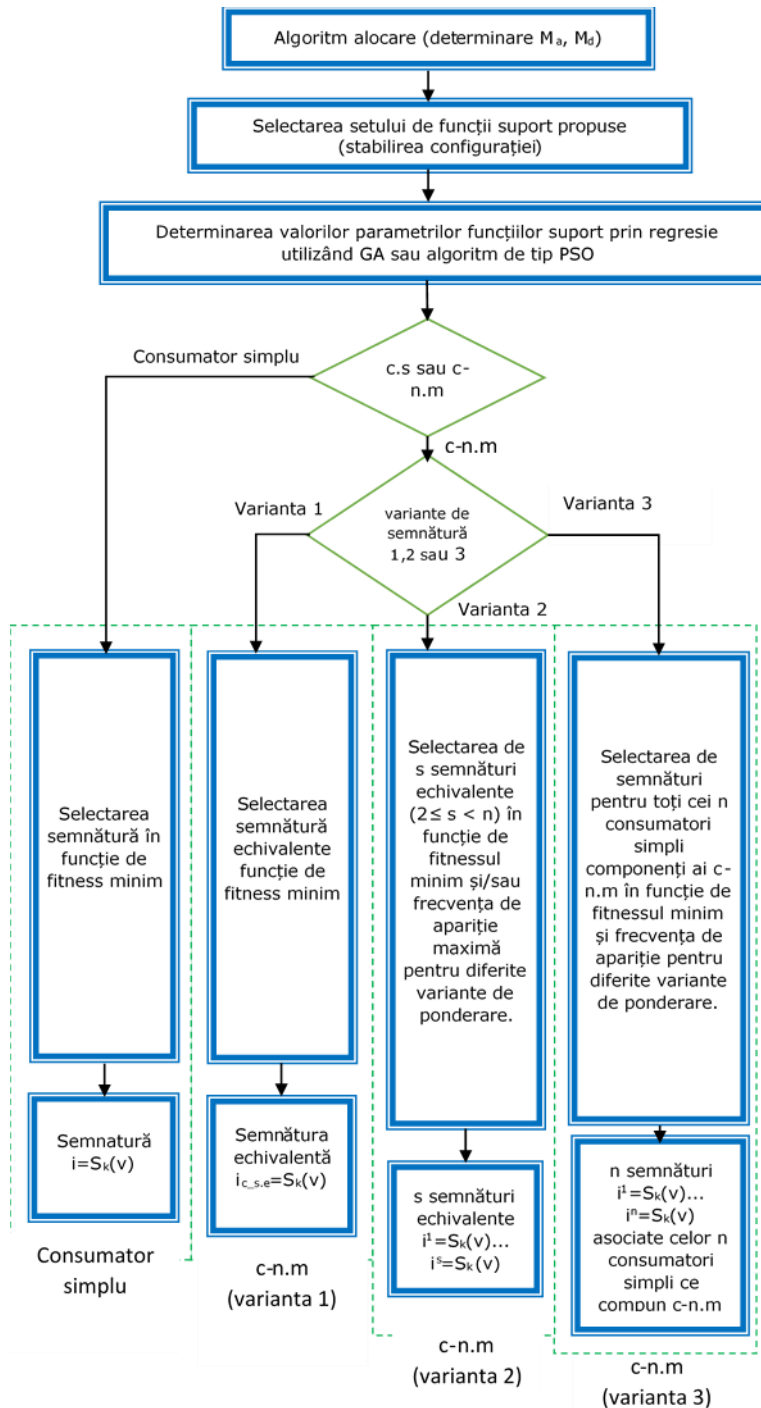


Fig.3.13 Organigrama metodei de determinare de semnătură

În cazul consumatorilor simpli operațiile ce se impun sunt:

- determinarea mulțimilor M_a, M_d ;
- alegerea claselor de lucru k ;
- calcularea fitnessului $F_{k,r}$ parametrilor asociați claselor alese $\Pi_{k,r}$ unde $r \in \{a, d\}$, plecând de la funcțiile suport asociate acestora, prin regresie neliniară folosind algoritmi de optimizare;
- alegerea fitnessului minim ce definește semnătura.

În cazul consumatorilor multipli s-au propus 3 variante de semnături. Pentru varianta 1, generarea unei semnături echivalente parcurge aceleași operații ca și în cazul unui consumator simplu.

În cazul variantei 3, pentru generarea a n semnături asociate celor n consumatori simpli incluși în $c-n.m$ operațiile care se impun sunt:

- determinarea mulțimilor M_a, M_d ;
- alegerea combinațiilor claselor de lucru;
- alegerea ponderilor de lucru;
- calcularea
 - fitnessului asociat unei combinații,
 - frecvenței de apariție a unei combinații,
 - parametrilor asociați unei combinații, prin regresie neliniară folosind algoritmi de optimizare, plecând de la funcțiile suport asociate combinațiilor alese;
- stabilirea celor n semnăturii funcție de elementele calculate mai sus.

În cazul variantei 2 sunt generate un set de s semnături echivalente, unde $2 \leq s < n$ pentru un consumator n multiplu. Cele s semnături nu au un corespondent fizic vizavi de cei n consumatori simpli incluși în consumatorul n -multiplu. Operațiile efectuate sunt:

- determinarea mulțimilor M_a, M_d ;
- alegerea combinațiilor claselor de lucru;
- alegerea ponderilor de lucru;
- calcularea
 - fitnessului asociat unei combinații,
 - frecvenței de apariție a unei combinații,
 - parametrilor asociați unei combinații, prin regresie neliniară folosind algoritmi de optimizare, plecând de la funcțiile suport asociate combinațiilor alese;
- stabilirea celor s semnăturii funcție de elementele calculate mai sus sau funcție doar de fitnessul minim.

Se observă că varianta 2 permite alegerea soluției folosind fie criteriul de la varianta 1, fie cel de la varianta 3.

4. STUDII DE CAZ

Pe parcursul capitolului vor fi analizate o serie de studii de caz asociate unor scenarii considerate de autoare relevante pentru ilustrarea aplicării metodelor propuse pentru determinarea de semnături. Conform celor prezentate în capitolul anterior, consumatorii aflați la un moment dat în starea pornit constituie procesul studiat, observat prin intermediul tensiunii la borne și a curentului total absorbit. În acest sens, indiferent de tipul scenariului, scopul cercetării îl constituie identificarea consumatorului/consumatorilor simpli sau echivalenți implicați în proces prin stabilirea semnăturilor aferente acestor consumatori.

Din punctul de vedere al tipului de investigație scenariile alese se diferențiază în funcție de:

- tipul consumatorului (simplu sau multiplu);
- algoritmul de determinare a semnăturii aplicat în cazul unui consumator multiplu (s-au expus 3 variante în subcapitolul 3.7.2);
- clasa k căreia îi aparține consumatorul;
- procentul reprezentat de puterea activă a unui consumator simplu din puterea activă totală P consumată de $c-n.m$ întrucât în cazul unui $c-n.m$. acesta poate fi constituit din consumatori cu ponderi procentuale apropiate sau mult diferite.

În contextul de mai sus au fost studiate 6 cazuri:

- 4 studii de caz de tip consumator simplu:
 - CS1: clasa tangentă discontinuă $k = 2$ — televizor LCD, $P_{LCD} = 92.78$ W;
 - CS2: clasa tangentă $k = 1$ — laptop1 $P_{laptop1} = 18.6$ W, laptop2 $P_{laptop2} = 39.96$ W;
 - CS3: clasa elipsă $k = 3$ — frigider $P_{frigider} = 148.5$ W;
 - CS4: clasa hibridă $k = 4$ — aspirator $P_{aspirator} = 1729.34$ W.
- 2 studii de caz de tip consumator- n multiplu, ambele investigând combinația între doi consumatori cu puteri active de ordin de mărime diferite:
 - CS5: televizor LCD + laptop, combinație $k = 2$ și $k = 1$, cu $P = 131.51$ W, respectiv un raport de putere egal cu $P_{laptop}/P_{LCD} = 0.43$;
 - CS6: aspirator + laptop combinație $k = 4$ și $k = 1$ cu $P = 1761.49$ W, respectiv un raport de putere egal cu $P_{laptop1}/P_{aspirator} = 0.01$.

În subcapitolul 4.1 se prezintă condițiile de efectuare a măsurărilor. Subcapitolul 4.2 abordează conceptul de semnătură, iar subcapitolele 4.3 și 4.4 detaliază studiile de caz referitoare la identificarea semnăturilor unor consumatori simpli, respectiv a semnăturilor unor consumatori-2 multipli prin două moduri de calcul a semnăturilor.

Un aspect important este faptul că pentru toate studiile de caz semnătura se raportează la punctele măsurate.

4.1. Condițiile de măsurare și schema de măsurare

În cadrul acestui subcapitol se detaliază schema de măsurare, se enumeră condițiile în care s-au efectuat măsurătorile și a consecințelor impuse de aceste condiții.

4.1.1. Schema de măsurare

Fig.4.1 prezintă schema de măsurare folosită pentru achiziționarea perechilor de valori tensiune-curent cu care operează algoritmul de determinare a semnăturilor. Schema include o placă EVaISTPM32 [75] și utilizează un software dedicat [76]. S-a ales acest tip de placă deoarece lucrează cu microcontrolerul SPTM32, microcontroler regăsit în diferite tipuri de contoare inteligente. Placa este înseriată printr-un sistem de prize în circuitul de alimentare de la rețea a unui consumator. De asemenea, ea este conectată la un PC folosind un port USB, identificat de STPM32 ca un port serial virtual. În cazul în care se lucrează cu un consumator simplu, în schema de măsurare apare un singur consumator — 1, ($n = 1$). Atunci când se lucrează cu un consumator- n multiplu, în schema de măsurare apar — Consumator 1 Consumator n conectați în paralel.

Software-ul aferent plăcii permite achiziția valorilor momentane ale tensiunii și ale curentului total absorbit de consumatorii conectați la sursa de alimentare. Rezultă astfel perechi de puncte tensiune-curent ($i(t), v(t)$) achiziționate la momente de timp diferite. Tensiunea $v(t)$ reprezintă tensiunea de la borne la un moment de timp t , iar curentul $i(t)$ reprezintă curentul consumat de consumator la același moment. Același software permite transmiterea în timp real a datelor achiziționate către PC. Identificarea semnăturii se realizează offline.




Fig.4.1. Schema de măsurare.

4.1.2. Condiții de măsurare

Achiziția datelor se realizează la intervale de timp de aproximativ 2.5 perioade ale tensiunii de alimentare. Un set de achiziție conține 1024 de perechi de eșantioane, respectiv 1024 puncte ($i(t), v(t)$) înregistrate la 1024 momente diferite.

Cu privire la condițiile de măsurare sunt de reținut următoarele aspecte:

- i) achiziția se realizează la o frecvență joasă;
- ii) tensiunea de alimentare nu este nici strict periodică și nici strict sinusoidală, prezentând fluctuații.

Ca urmare a acestor condiții rezultă o disperare a valorilor de tensiune în intervalul $[-230\sqrt{2}V, 230\sqrt{2}V] \approx [-320V, 320V]$, dispersie vizibilă în exemplul din Fig.4.2 a. care ilustrează grafic tensiunile măsurate succesiv în cazul unui televizor LCD începând cu eșantionul 20 și până la eșantionul 90 (71 de eșantioane). Reprezentarea din Fig .4.2 b. „întregește” imaginea dispersiei redând toate cele 71 de perechi de valori tensiune-curent măsurate.




Fig.4.2. a) Succesiune de valori măsurate ale tensiunii de la bornele unui televizor LCD (eșantioanele 20-90). b) Punctele măsurate cărora le corespunde succesiunea de la punctul a.

4.2. Semnătura

Potrivit celor prezentate în capitolul 3, determinarea semnăturii unui consumator se realizează în două etape (Fig.4.3):

- alocarea de puncte;
- identificarea funcției suport și calcularea valorilor parametrilor acesteia.

Rezultatul alocării este generarea celor două submulțimi M_r , $r \in \{a, d\}$ pe baza punctelor măsurate $\{(v(t), i(t))\}$.

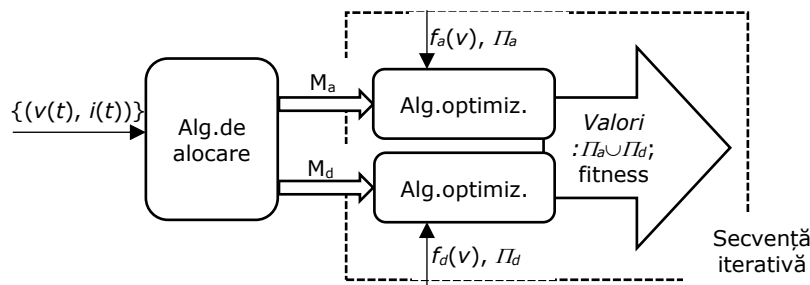


Fig.4.3. Algoritm de determinare a semnăturii.

Calcularea valorilor parametrilor funcțiilor suport se efectuează prin regresie, printr-un proces de optimizare iterativă bazat pe algoritmi genetici sau pe algoritmi de tip PSO.

După parcurgerea celei de a doua etape, semnătura va fi reprezentată de două expresii analitice (funcții) și de valorile setului de parametri asociați lor. Fiecare expresie este asociată unei ramuri: ascendentă, respectiv descendentă. Matematic, semnătura este o aplicație de forma:

$$\{f_r: [V_{min}, V_{max}] \subset \mathbb{R} \rightarrow \mathbb{R}, f_r(v, \Pi_r)\}, \text{ unde } r \in \{a, d\}, \text{ de parametri } \Pi_r - \text{ set de valori} \quad (4.1)$$

Expresia f_r se poate identifica după caz fie cu funcția suport asociată unei clase $k \in K$, fie cu o combinație liniară a funcțiilor suport asociate claselor $k \in K$.

Algoritmul de optimizare impune pe lângă cele două expresii analitice $f_r(v, \Pi_r)$, ce corespund curentului consumat i_r pe ramura ascendentă, respectiv descendentă și anumite intervale de variație ale parametrilor Π_r , în funcție de clasa/clasele cărora le

corespund. În consecință, pentru fiecare studiu de caz, fie el asociat unui consumator simplu sau unui consumator- $n.m$, ca date de intrare vor fi precizate:

- expresiile funcțiilor suport împreună cu parametrii aferenți,
- domeniul de variație asociat setului de parametri,
- restricțiile impuse parametrilor sub forma unor ecuații sau inecuații neliniare abordate pe parcursul capitolului sub forma condițiilor de adecvare, iar ca rezultat se consideră expresia (4.1) cu valorile calculate ale parametrilor la care se va adăuga valoarea fitnessului.

În ceea ce privește notațiile menționăm faptul că în cadrul setului de parametri Π_r , notațiile I și V reprezintă parametrii cu dimensiunea fizică „curent”, respectiv „tensiune”.

4.3. Studii de caz de obținere a semnăturilor unor consumatori simpli folosind algoritmi genetici

Pentru exemplificarea obținerii semnăturii pentru consumatori simpli s-au avut în vedere dispozitive electrocasnice specifice celor patru clase. Primul caz studiat (CS1) se referă la un televizor LCD — consumator din clasa tangentă discontinuă ($k = 2$), al doilea (CS2) la un laptop — consumator din clasa tangentă ($k = 1$), al treilea (CS3) la un frigider — pentru clasa elipsă ($k = 3$) și al patrulea (CS4) la un aspirator — pentru clasa hibridă ($k = 4$). Raportat la gama de puteri a consumatorilor casnici uzuali putem considera aspiratorul ca un consumator de putere activă mare, frigiderul și LCD-ul drept consumatori de putere medie, iar laptopul consumator de putere mică.

Datele experimentale au fost prelucrat de următoarea manieră:

- i) Pentru fiecare consumator s-au efectuat simultan, pentru fiecare ramură, un număr de 50 de rulări corespunzătoare asocierii consumatorului cu fiecare clasă k , rezultând astfel un număr de 200 de rulări independente per ramură.
- ii) Pentru determinarea semnăturii s-a aplicat metodologia de lucru prezentată în capitolul 3, secțiunea 3.7.1, calculul de regresie folosind algoritmi genetici.

În expunerea studiilor de caz din secțiunile 4.3.1, 4.3.2, 4.3.3, 3.3.4 se prezintă de fiecare dată următoarele elemente:

- graficul punctelor de măsură M , respectiv al submulțimilor M_a — albastru, M_d — roșu;
- tabelul ce conține frecvențele $f_{a,k}$ și $f_{d,k}$ de apariție ale claselor $k \in K$ pentru ramurile a și d ; în tabel frecvența $f_{r,k}$ contorizează numărul de rulări în care fitnessul corespunzător ramurii r și încadrării consumatorului în clasa k a fost cel mai mic;
- graficele fitnessurilor pentru ramura ascendentă, descendentă;
- semnătura.

Parametrii diferitelor clase de consumatori și intervalele de variație ale acestora rezultate empiric, în urma analizării mai multor cazuri, sunt:

- Clasa tangentă $k = 1$ cu setul de parametri:

$$\Pi_r = [a_s, b, c_s, a_d, c_d], \text{ unde } r = \{a, d\} \quad (4.2)$$

și intervalele de încadrare:

$$I_{\Pi_r} = \{[-50, 700], [-0.2, 0.2], [50, 850], [104, 400], [50, 850]\}; \quad (4.3)$$

- Clasa tangentă discontinuă $k = 2$ cu setul de parametri:

$$\Pi_r = [a_s, b_s, c_s, a_d, b_d, c_d], \text{ unde } r = \{a, d\}; \quad (4.4)$$

și intervalele de încadrare:

$$I_{\Pi_r} = \{[-50, 700], [-0.6, 0.6], [50, 850], [50, 400], [-0.6, 0.6], [50, 900]\}; \quad (4.5)$$

- Clasa elipsă $k = 3$, cu setul de parametri:

$$\Pi_r = [a, b, A, B], \text{ unde } r = \{a, d\} \quad (4.6)$$

și intervalele de încadrare:

$$I_{\Pi_r} = \{[340, 700], [1, 10], [0, 8], [1, 50]\} \quad (4.7)$$

- Clasa hibridă $k = 4$ cu setul de parametri (cazul consumatorilor simpli)

$$\Pi_r = [V_1, V_2, V_3, V_4, V_5, n_1, n_2, n_3, n_4, n_5, b_{S_1}, b_{S_2}, b_{S_3}, b_{S_4}, b_{S_5}, b_{D_1}, b_{D_2}, b_{D_3}, b_{D_4}, b_{D_5}, s_1, s_2, s_3, s_4, s_5, I_2, I_3, I_4, a_1, a_2, a_3, a_4, a_5, V_x, \mu_1, \mu_2, \mu] \quad (4.8)$$

și intervalele de încadrare:

$$I_{\Pi_a} = \{[-600, 600], [-600, 600], [-600, 600], [-600, 600], [-600, 600], [-100, 100], [-100, 100], [-100, 100], [-100, 100], [-100, 100], [-100, 100], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [1, 2], [1, 2], [1, 2], [1, 2], [1, 2], [-25, 25], [-25, 25], [-25, 25], [*], [*], [*], [*], [*], [50, 120], [-0.001, 1], [-0.001, 1], [-5, 0.1]\} \quad (4.9)$$

$$I_{\Pi_d} = \{[-600, 600], [-600, 600], [-600, 600], [-600, 600], [-600, 600], [-100, 100], [-100, 100], [-100, 100], [-100, 100], [-100, 100], [-100, 100], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [-50, 50], [1, 2], [1, 2], [1, 2], [1, 2], [1, 2], [-25, 25], [-25, 25], [-25, 25], [-25, 25], [*], [*], [*], [*], [*], [-120, -50], [-0.001, 1], [-0.001, 1], [-5, 5]\}$$

Cu privire la intervalele de mai sus se impun două mențiuni:

- Pentru clasele $k = 1, 2, 3$ intervalele de valori sunt comune ambelor ramuri r .
- După cum se va vedea ulterior, pentru clasa $k = 4$ expresia analitică a funcției suport se modifică în cazul consumatorului multiplu, iar modificarea implică alt set de parametri.

4.3.1. Studiul de caz 1 (CS1)

Ca prim caz de studiu s-a considerat un televizor LCD pentru care s-a obținut experimental norul de puncte din Fig.4.4.a. Inspectând vizual imaginea, concluzionăm că acest dispozitiv electric aparține clasei tangentă discontinuă ($k = 2$). În urma aplicării algoritmului de alocare din punctele din Fig.4.4.a au rezultat submulțimile M_a și M_d din Fig.4.4.b.




Fig.4.4. a) Nor rezultat din măsurători; b) Submulțimile M_a și M_d

După efectuarea celor 50 x 4 rulări independente pe baza punctelor alocate au rezultat valorile rezumate în Tabelul 4.1. Prima linie corespunde frecvențelor $f_{r,k}$ de apariție ale celor 4 clase iar a doua linie conține fitnessurile minime ale celor 4 clase apărute în cele 50 de rulări independente/clasă. Tabelul include atât ramura ascendentă (zona stângă) cât și pe cea descendentă (zona dreaptă).

Tabelul 4.1: CS1 - Frecvențele de apariție ale claselor k pentru ramurile a și d și fitnessurile minime asociate.

$f_{a,1} = 0$	$\frac{f_{a,2}}{0.84}$	$f_{a,3} = 0$	$f_{a,4} = 0.16$	$f_{d,1} = 0$	$\frac{f_{d,2}}{0.62}$	$f_{d,3} = 0$	$f_{d,4} = 0.38$
$F_a = 0.20182$	$F_a = 0.057955$	$F_a = 0.604385$	$F_a = 0.060251$	$F_d = 0.19574$	$F_d = 0.055972$	$F_d = 0.626938$	$F_d = 0.053790$

Fig.4.5. redă pentru ramura ascendentă, respectiv descendentă variațiile fitnessurilor în funcție de numărul de ordine al rulării. Din cele două figuri se observă, pe de o parte, că fitnessul asociat clasei $k = 2$ este mai mic decât restul fitnessurilor, iar pe de altă parte faptul că în cazul clasei hibride ($k = 4$) valorile fitnessului sunt distribuite pe un interval mult mai larg decât în cazul celorlalte trei clase.




Fig.4.5. Variația fitnessului pe clase specifice k . a.) Ramura ascendentă. b.) Ramura descendentă. ($k=1$ rosu, $k=2$ negru, $k=3$ albastru, $k=4$ roz)

Fitnessul minim rezultat pentru ramura ascendentă $F_a = 0.0579$ corespunde clasei tangentă discontinuă. În același timp și frecvența de apariție este maximă de 0.84. În aceste condiții ramura ascendentă este asociată clasei tangentă discontinuă. Fitnessul minim rezultat pentru ramura descendentă, $F_d = 0.0537$, corespunde clasei hibride însă frecvența de apariție a acestei clase este mică, de 0.38 (raportat la frecvența de apariție a clasei tangentă discontinuă). În consecință, în această situație va fi considerat ca valid următorul fitness (în ordine crescătoare), cel asociat clasei tangentă discontinuă $F_d = 0.0559$, clasă pentru care frecvența de apariție este de 0.62. Cele două fitnessuri ce au intrat în discuție pentru ramura descendentă sunt apropiate, diferența fiind de 0.0021 evitând pierderea de fidelitate a semnăturii și validând alegerea făcută. În concluzie consumatorului îi corespunde o semnătură cu arce din aceeași clasă, $k = 2$. Rezultatul obținut confirmă identificarea vizuală inițială conform căreia consumatorul „televizor LCD” corespunde acestei clase.

Pentru semnătura corespunzătoare televizorului LCD a rezultat funcția suport de clasă $k = 2$:

$$S_{2,r}(v) = \left[\frac{1}{a_S} \operatorname{tg} \left(\frac{v + d_S}{c_S} \right) + b_S \right] \cdot \frac{1 - \operatorname{sgn}(v - v_b)}{2} + \left[\frac{1}{a_D} \operatorname{tg} \left(\frac{v + d_D}{c_D} \right) + b_D \right] \cdot \frac{1 + \operatorname{sgn}(v - v_b)}{2}$$

cu parametri din (4.4) având valorile:

$$\Pi_a = [59.2425, -0.42416, 210.095, 50.0014, -0.07150, 444.9],$$

$$\Pi_d = [22.1449, 0.04149, 210.099, 59.574, 0.43584, 210.101].$$

Seturilor de parametrii ale celor două ramuri cărora le corespund fitnessurile $F_a = 0.0579$ și $F_d = 0.0559$.

În fine, trebuie menționat că valoarea lui v_b este -100V pentru ramura ascendentă, respectiv 100V pentru ramura descendentă, iar parametrii d_s și d_D au fost calculați conform formulelor din Anexa A — expresia (A.6).

În Fig.4.6.a. este redată grafic semnătura pentru ramura ascendentă raportată la submulțimea M_a , în Fig.4.6.b. semnătura pentru ramura descendentă raportată la submulțimea M_d iar în Fig.4.6.c. semnătura completă a dispozitivului electrocasnic — televizor. Se observă că atât pentru ramura ascendentă cât și pentru cea descendentă semnătura urmărește cele două submulțimi de puncte M_a și M_d .




Fig.4.6. Semnătura unui televizor LCD: a) Ramura ascendentă a semnăturii vs. M_a ; b) Ramura descendentă a semnăturii vs. M_d ; c) Semnătura consumatorului.

4.3.2. Studiul de caz 2 (CS2)

Al doilea caz studiat consideră drept consumator simplu un laptop, consumator din categoria celor de putere activă mică.

În vederea stabilirii semnăturii, primul pas îl constituie alocarea de puncte măsurate $(v(t), i(t))$ la cele două ramuri (ascendentă respectiv descendentă) rezultând astfel cele două submulțimi M_a și M_d . În Fig.4.7.a. este reprezentată grafic mulțimea $M = \{(v(t), i(t))\}$ de puncte rezultată din măsurători, iar în Fig.4.7.b. cele două submulțimi M_a și M_d . Interpretarea vizuală a Fig.4.7. încadrează consumatorul — laptop în clasa tangentă. Ulterior se va constata că identificarea certifică interpretarea vizuală.




Fig.4.7. CS2: a) Nor rezultat din măsurători; b) Submulțimile M_a și M_d .

Tabelul 4.2 redă în prima linie frecvențele de apariție $f_{r,k}$ corespunzătoare celor 4 clase k și unui set de 50 x 4 rulări, iar în a doua linie fitnessurile minime asociate fiecărei clase. Se observă că frecvența de apariție maximă corespunde, atât în cazul ramurii ascendente cât și în cazul ramurii descendente, clasei $k = 1$, tangentă. Considerând cele 50 x 4 rulări independente, fitnessul minim în cazul ramurii ascendente aparține clasei tangentă în 62% din cele 50 de seturi și tot aceiași clase în cazul ramurii descendente în 44% din cele 50 de seturi. Se vor considera ca parametri ai semnăturii cei din cazul fitnessului $F_a = 0.077949$ pentru ramura ascendentă, respectiv din cazul $F_d = 0.033684$ pentru cea descendentă.

Considerând fitnessurile în ordine crescătoare, fitnessul asociat soluției propuse se situează pe poziția 2. Fitnessurile minime sunt asociate clasei hibride atât pentru ramura ascendentă cât și pentru ramura descendentă. Diferența între fitnessul soluție și fitnessul minim este 0.004747 pentru ramura ascendentă, respectiv 0.005565 pentru ramura descendentă, valori mici ce validează soluția propusă.

Tabelul 4.2: CS2 - Frecvențele de apariție a claselor k pentru ramura r și fitnessurile minime asociate.

$f_{a,1} \equiv$	$f_{a,2} \equiv$	$f_{a,3} \equiv$	$f_{a,4} \equiv$	$f_{d,1} \equiv$	$f_{d,2} \equiv$	$f_{d,3} \equiv$	$f_{d,4} \equiv$
<u>0.62</u>	0.32	0	0.06	<u>0.44</u>	0.18	0	0.38
$F_a =$	$F_a =$	$F_a =$	$F_a =$	$F_d =$	$F_d =$	$F_d =$	$F_d =$
0.077949	0.078823	0.638616	<u>0.073202</u>	0.033684	0.033818	0.8000	<u>0.028119</u>

În Fig.4.8. este redată variația fitnessului asociat fiecărei clase pe parcursul celor 50 x 4 rulări independente. Fig.4.8.a. se referă la ramura ascendentă. De menționat este faptul că fitnessul în cazul $k = 3$ depășește valoarea 0.6. De asemenea, se poate observa că în cazul clasei $k = 1$, respectiv $k = 2$ valorile fitnessurilor sunt apropiate, respectiv pentru clasa hibridă plaja de variație a fitnessului este mult mai mare. Concluzii similare rezultă și din fig. Fig.4.8.b., figură ce prezintă grafic situația ramurii descendente.

Conform rezultatelor obținute, pentru semnătura corespunzătoare laptop-ului rezultă funcția suport de clasă $k = 1$:

$$S_{1,r}(v) = \left[\frac{1}{a_s} \operatorname{tg} \left(\frac{v + d_s}{c_s} \right) - \frac{1}{a_s} \operatorname{tg} \frac{d_s}{c_s} + \frac{1}{a_d} \operatorname{tg} \frac{d_d}{c_d} \right] \cdot \frac{1 - \operatorname{sgn}(v)}{2} + \frac{1}{a_d} \operatorname{tg} \left(\frac{v + d_d}{c_d} \right) \cdot \frac{1 + \operatorname{sgn}(v)}{2} + b$$

cu parametrii din (4.2) având valorile:

$$I_{I_a} = [78.2137, -0.03578, 210.094, 165.591, 210.097]$$

$$I_{I_d} = [522.09, 0.02143, 209.846, 399.975, 262.859].$$

În plus, trebuie menționat că parametrii d_s și d_d se calculează conform formulelor din Anexa A — expresia (A.6)




Fig.4.8. Variația fitnessului pe clase k : a.) Ramura ascendentă. b.) Ramura descendentă. ($k=1$ rosu, $k=2$ negru, $k=3$ albastru, $k=4$ roz)

În Fig.4.9.a. este reprezentată grafic semnătura pentru ramura ascendentă vs norul de puncte M_a . Lucrurile se petrec similar în cazul Fig.4.9.b. pentru ramura descendentă, respectiv în Fig.4.9.c. unde este reprezentată semnătura completă a consumatorului simplu laptop.




Fig.4.9. Semnătură laptop1: a) Ramura ascendentă a semnăturii vs. M_a ; b) Ramura descendentă a semnăturii vs. M_d ; c) Semnătura consumatorului.

4.3.3. Studiul de caz 3 (CS3)

Cel de-al treilea caz studiat tratează consumatorul simplu „frigider”. El se consideră ca aparținând consumatorilor casnici de putere activă medie. Similar cazurilor anterioare, prezentarea începe cu graficul mulțimii de puncte M — Fig.4.10.a., respectiv a submulțimilor M_a , M_d — Fig.4.10.b. Interpretarea vizuală a Fig.4.10. încadrează consumatorul simplu frigider în clasa elipsă $k = 3$.

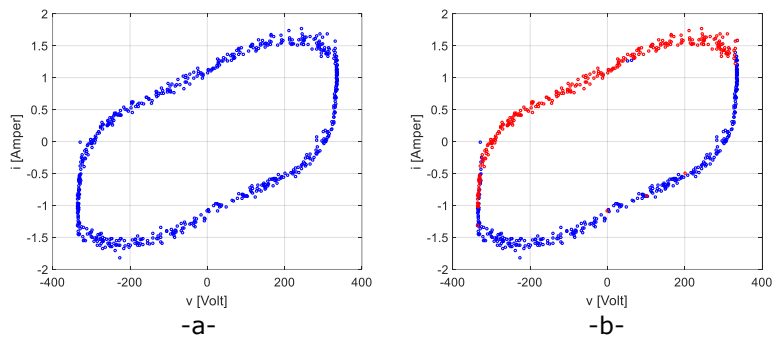


Fig.4.10. a) Nor rezultat din măsurători, b) Submulțimile M_a și M_d . Tabelul 4.3, al frecvențelor de apariție, confirmă interpretarea vizuală. Frecvența de apariție a clasei elipsă este de 98% pe ramura ascendentă, respectiv de 100% în cazul ramurii descendente. Tot acestei clase îi corespund și fitnessurile minime. Rezultatele s-au raportat la un număr de 4×50 rulări independente. Ca urmare, se consideră soluție fitnessurile minime obținute pentru clasa $k = 3$ (subliniate în Tabelul 4.3).

Tabelul 4.3: CS3 - Frecvențele de apariție ale claselor k pentru ramura r și fitnessurile minime asociate.

$f_{a,1} =$ 0	$f_{a,2} =$ 0	<u>$f_{a,3} =$</u> <u>0.98</u>	$f_{a,4} =$ 0.02	$f_{d,1} =$ 0	$f_{d,2} =$ 0	<u>$f_{d,3} =$</u> <u>1</u>	$f_{d,4} =$ 0
$F_a =$ 1.0057	$F_a =$ 0.864760	<u>$F_a =$</u> <u>0.170746</u>	$F_a =$ 0.178255	$F_d =$ 0.962293	$F_d =$ 0.778256	<u>$F_d =$</u> <u>0.113920</u>	$F_d =$ 0.133695

Fig.4.11.a.-b. redau variațiile fitnessurilor corespunzătoare asocierii punctelor măsurate cu cele patru clase. Se poate observa o variație foarte mică în cazul clasei elipsă, mică în cazul claselor tangentă, tangentă continuă, pe când în cazul clasei hibride un interval de dispersie larg raportat la celelalte 3 clase.




Fig.4.11. Variația fitnessului pe clasele k . a.) Ramura ascendentă. b.) Ramura descendentă. ($k=1$ roșu, $k=2$ negru, $k=3$ albastru, $k=4$ roz)

Ca urmare, semnătura frigiderului a dat ca rezultat funcția suport de clasă $k=3$:

$$S_{3r}(v) = \left[\left(\frac{a^2}{V_{max}^2} - 1 \right) \cdot v \cdot \sqrt{\frac{V_{max}^2 - b^2}{a^2 - V_{max}^2}} \mp \frac{a \cdot b}{V_{max}} \sqrt{1 - \frac{v^2}{V_{max}^2}} \right] \cdot f_{cor_1}(v) \cdot f_{cor_2}(v),$$

$$f_{cor_1}(v) = \left(1 + A \cdot \sin \left(3\pi \cdot \frac{v - V_{min}}{v - V_{max}} \right) \right), f_{cor_2}(v) = e^{\frac{|v|}{B \cdot V_{max}}}$$

cu setul de parametri (v. (4.6)) având valorile:

$$II_a = [340.001, 1.12452, 0.03471, 4.63153]$$

$$II_d = [340.001, 1.12452, 0.03471, 4.63153].$$

În Fig.4.12.a. este reprezentată grafic semnătura asociată ramurii ascendente vs. norul de puncte M_a , iar în Fig.4.12.b. semnătura ramurii descendente raportată la norul de puncte M_d . În ambele cazuri semnătura urmărește foarte bine norii de puncte M_a , respectiv M_d . Graficul semnăturii complete asociată consumatorului frigider este reprezentată în Fig.4.12.c.




Fig.4.12. CS3 - Semnătură frigider: a) Ramura ascendentă a semnăturii vs. M_a ; b) Ramura descendentă a semnăturii vs. M_d ; c) Semnătura dispozitivului electric.

4.3.4. Studiul de caz 4 (CS4)

Al patrulea caz studiat include un consumator casnic de putere activă mare — aspiratorul. În Fig.4.13.a este redată mulțimea măsurătorilor M , iar în Fig.4.13.b. submulțimile M_a , M_d . Inspecția vizuală sugerează includerea acestui consumator în clasa hibridă.




Fig.4.13. CS4 - Aspirator: a) Mulțimea M ; b) Mulțimea M_a și M_d .

Valoarea cea mai mare a frecvenței de apariție corespunde clasei elipsă, rezultat ce nu coincide cu inspecția vizuală ce încadra consumatorul în clasa hibridă. Urmărind însă valorile fitnessurilor minime, linia 2 din Tabelul 4.4, asociate clasei hibride și pe cele corespunzătoare clasei elipsă se observă că fitnessul minim (ramura ascendentă), $F_a = 0.300523$, pentru $k = 4$ este mult mai mic decât fitnessul minim (ramura descendentă) $F_a = 0.942396$, pentru $k = 3$. Același lucru se întâmplă și în cazul ramurii descendente, clasa hibridă prezentând un fitness minim $F_d = 0.281488$, pe când fitnessul minim în cazul clasei elipsă este de $F_d = 0.806778$. În acest context se consideră mulțumitoare frecvențele de apariție de 34% — ascendent și 28% — descendent, corespunzătoare clasei hibride. În concluzie, putem încadra aspiratorul în clasa hibridă.

Valorile înscrise între paranteze, în Tabelul 4.1 pentru clasa hibridă, indică fitnessurile după aplicarea corecției f_{cor2} .

Tabelul 4.4: CS4 - Frecvențele de apariție a claselor specifice k pentru ramura r și fitnessurile minime asociate.

$f_{a,1} =$ 0	$f_{a,2} =$ 0	$f_{a,3} =$ <u>0.66</u>	$f_{a,4} =$ 0.34	$f_{d,1} =$ 0	$f_{d,2} =$ 0	$f_{d,3} =$ <u>0.72</u>	$f_{d,4} =$ 0.28
$F_a =$ 6.68346	$F_a =$ 4.48380	$F_a =$ 0.942396	$F_a =$ <u>0.300523</u> (0.2941)	$F_d =$ 6.387834	$F_d =$ 4.217991	$F_d =$ 0.806778	$F_d =$ <u>0.281488</u> (0.2488)

În Fig.4.14 sunt reprezentate variațiile fitnessurilor asociate celor patru clase:




Fig.4.14. CS4 - Variația fitnessului pentru cele 4 clase k . a.) Ramura ascendentă. b.) Ramura descendentă. ($k=1$ roșu, $k=2$ negru, $k=3$ albastru, $k=4$ roz)

Astfel, pentru semnătura corespunzătoare aspiratorului a rezultat funcția suport de clasă $k = 4$:

$$S_{4,r}(v) = \sum_{j=1}^5 [I_j + a_j \cdot |v - V_j|^{n_j} \cdot (\operatorname{sgn}(v - V_j))^{\alpha_j}] \cdot f_{cor_{1j}}(v) + \mu \cdot f_{cor_2}(v), \text{ unde}$$

$$f_{cor_{1j}}(v) = e^{b_{sj} \cdot (v - V_j) \frac{1 - \operatorname{sgn}(v - V_j)}{2} + b_{dj} \cdot (v - V_j) \frac{1 + \operatorname{sgn}(v - V_j)}{2}},$$

$$f_{cor_2}(v) = e^{-[\mu_1(1 - \operatorname{sgn}(v - V_x)) + \mu_2(1 + \operatorname{sgn}(v - V_x))] \cdot |v - V_x|}$$

cu parametrii (4.8), pentru cazul cu corecție $f_{cor_2}(v)$, având valorile:

$$\Pi_a = [423.015, 477.141, 319.015, 566.504, 423.683, 0.11486, -11.2658, 0.34394, 95.8889, -66.6187, 0.00851, 39.8055, 16.2543, 45.2929, -0.00604, -42.9645, -30.8904, 0.95893, 16.078, 5.29437, 1.33683, 1.91159, 1.69288, 1.90483, 1.98157, 24.0396, -1.26171, -12.2273, -24.4031, -3.91345, 3.91903, 4.95629, 9.15424, 69.1299, 0.05168, 0.07532, -0.41355]$$

$$\Pi_d = [369.415, 32.3680, -421.595, 514.280, -324.664, -13.2384, 1.11792, 9.84409, 53.214, 2.06625, 0.01029, 49.7661, 34.498, 45.6737, 7.03688, -9.76205, -0.00146, -19.1961, 6.59569, -0.02284, 1.66644, 1.99623, 1.39193, 1.98498, 1.99635, 1.11449, 21.5681, 12.4970, 11.3099, 0.01295, 5.53797, 10.6085, -0.00275, -68.2498, 0.06930, 0.00862, 0.55068]$$

Relația dintre α_j , din funcția suport asociată clasei hibride, și s_j , din setul de parametrii, este dată de expresia: $\alpha_j = \operatorname{round}(s_j)$, unde $j = 1 \dots 5$.

Parametrii I_1 și I_5 cu dimensiunea fizică „curent” sunt determinați din condițiile $i_{min} = S_{4,r}(V_{min})$, $i_{max} = S_{4,r}(V_{max})$ ținând cont de expresiile (3.36), unde $\beta_{min} = \beta_{max} = 0.1$. Valorile i_{min} și i_{max} sunt valorile algebrice, minimă și maximă, ale curentului măsurat $i(t)$, reținute în mulțimile alocate M_a și M_d . Menționăm că cei doi curenți sunt comuni celor două ramuri ascendente, respectiv descendente. Calcularea celor doi parametri din condițiile menționate decurge astfel:

$$\begin{cases} i_{min} = \sum_{j=1}^5 \left((I_j + \operatorname{sgn}(|V_{min} - V_j|)^{\alpha_j} \cdot a_j \cdot |V_{min} - V_j|^{n_j}) \cdot f_{cor_{1j}}(V_{min}) \right) \\ i_{max} = \sum_{j=1}^5 \left((I_j + \operatorname{sgn}(|V_{max} - V_j|)^{\alpha_j} \cdot a_j \cdot |V_{max} - V_j|^{n_j}) \cdot f_{cor_{1j}}(V_{max}) \right) \end{cases}$$

Pentru a calcula I_1 , respectiv I_5 sistemul de ecuații de mai sus se rescrie sub forma:

$$\begin{cases} i_{min} - \sum_{j=2}^4 (I_j \cdot f_{cor_{1j}}(V_{min})) - \sum_{j=1}^5 \left(\operatorname{sgn}(|V_{min} - V_j|)^{\alpha_j} \cdot a_j \cdot |V_{min} - V_j|^{n_j} \cdot f_{cor_{1j}}(V_{min}) \right) = \\ I_1 \cdot f_{cor_{11}}(V_{min}) + I_5 \cdot f_{cor_{15}}(V_{min}) \\ i_{max} - \sum_{j=2}^4 (I_j \cdot f_{cor_{1j}}(V_{max})) - \sum_{j=1}^5 \left(\operatorname{sgn}(|V_{max} - V_j|)^{\alpha_j} \cdot a_j \cdot |V_{max} - V_j|^{n_j} \cdot f_{cor_{1j}}(V_{max}) \right) = \\ I_1 \cdot f_{cor_{11}}(V_{max}) + I_5 \cdot f_{cor_{15}}(V_{max}) \end{cases}$$

Introducând notațiile:

$$B_1 = i_{min} - \sum_{j=2}^4 (I_j \cdot f_{cor_{1j}}(V_{min})) - \sum_{j=1}^5 \left(\operatorname{sgn}(|V_{min} - V_j|)^{\alpha_j} \cdot a_j \cdot |V_{min} - V_j|^{n_j} \cdot f_{cor_{1j}}(V_{min}) \right)$$

$$B_2 = i_{max} - \sum_{j=2}^4 (I_j \cdot f_{cor_{1j}}(V_{max})) - \sum_{j=1}^5 \left(\operatorname{sgn}(|V_{max} - V_j|)^{\alpha_j} \cdot a_j \cdot |V_{max} - V_j|^{n_j} \cdot f_{cor_{1j}}(V_{max}) \right)$$

$$B_1 = i_{\min} - \sum_{j=2}^4 I_j \cdot e^{-b_j |V_{\min} - V_j|} - \sum_{j=1}^5 \operatorname{sgn}(|V_{\min} - V_j|)^{\alpha_j} \cdot a_j \cdot |V_{\min} - V_j|^{n_j} \cdot e^{-b_j |V_{\min} - V_j|}$$

$$B_2 = i_{\max} - \sum_{j=2}^4 I_j \cdot e^{-b_j |V_{\max} - V_j|} - \sum_{j=1}^5 \operatorname{sgn}(|V_{\max} - V_j|)^{\alpha_j} \cdot a_j \cdot |V_{\max} - V_j|^{n_j} \cdot e^{-b_j |V_{\max} - V_j|}$$

respectiv:

$$A_{11} = f_{cor_{11}}(V_{\min}), A_{12} = f_{cor_{15}}(V_{\min}), A_{21} = f_{cor_{11}}(V_{\max}), A_{22} = f_{cor_{15}}(V_{\max})$$

sistemul de ecuații devine:

$$\begin{cases} B_1 = A_{11} \cdot I_1 + A_{12} \cdot I_5 \\ B_2 = A_{21} \cdot I_1 + A_{22} \cdot I_5 \end{cases}$$

Pentru $\det \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} \neq 0$ sistemul este compatibil determinat având soluțiile:

$$I_1 = \frac{B_1 \cdot A_{22} - B_2 \cdot A_{12}}{A_{11} \cdot A_{22} - A_{21} \cdot A_{12}},$$

$$I_2 = \frac{B_2 \cdot A_{11} - B_1 \cdot A_{21}}{A_{11} \cdot A_{22} - A_{21} \cdot A_{12}}$$

În urma experimentelor repetate s-a ajuns la concluzia că fitnessul cel mai mic rezultă prin segmentarea operației de regresie în două etape. În prima etapă se omite corecția 2 și se determină toți parametrii mai puțin μ_1, μ_2, V_x . În a doua etapă se aplică și corecția 2 păstrând parametrii determinați în prima etapă la valorile calculate și se determină parametrii rămași V_x, μ_1, μ_2, μ .

Fig.4.15.a. reprezintă grafic semnătura asociată ramurii ascendente raportată la mulțimea M_a . În Fig.4.15.b. avem semnătura asociată ramurii descendente raportată la M_d . În final, în Fig.4.15.c, este redată semnătura completă a consumatorului aspirator.




Fig.4.15. CS4 - Semnătură aspirator: a) Ramura ascendentă a semnăturii vs. M_a ; b) Ramura descendentă a semnăturii vs. M_d ; c) Semnătura dispozitivului electric fără corecție f_{cor2} ; d) Semnătura consumatorului cu corecție f_{cor2}

Numărul de 50 de rulări independente a fost ales din observația că el este suficient pentru a stabili pe bază de frecvență de apariție clasa k în care se încadrează un consumator. De asemenea, se reamintește că în cadrul fiecărei rulări independente soluția se stabilizează iar operația de regresie poate fi considerată finalizată. Totuși, acest mod de abordare nu s-a dovedit robust în raport cu soluțiile singulare. Un exemplu în acest sens apare în Fig.4.16 în care este prezentată cea mai bună soluție găsită pentru consumatorul aspirator. Soluția prezentată în [63] a rezultat pe parcursul testelor făcute pentru a stabili numărul de rulări independente necesar la identificarea unui consumator.

Ea nu se regăsește în setul celor 50 de rulări consecutive și independente considerate care au generat soluția din Fig.4.15.




Fig.4.16. CS4 - Semnătură aspirator: $k = 4$, $F_a = 0.16990$; $F_d = 0.13963$;

Parametrii semnăturii sunt:

$\Pi_a = [271.929, 0.55308, 342.173, 461.323, -401.940, -0.81514, -1.15754, 11.8683, 1.6519, -48.7428, 0.00672, 37.9354, 14.2404, 16.9547, 1.24658, 0.0081, -0.56084, 1.87461, 7.02196, -0.00563, 1.99, 1.27587, 1.8633, 1.0697, 1.54814, 4.96387, -6.31971, 6.63704, 71.8425, 0.03634, 0.04242, -0.64859, 0.86177, 4.89705, -0.40721, 23.1971, 10.2171]$

$\Pi_d = [395.829, 396.853, 184.563, -418.157, -298.311, -56.6115, 1.26166, 2.69162, 94.6958, -0.5373, 0.00537, 8.03327, 2.56554, 6.52264, -0.01129, -34.104, 4.86565, -27.1788, -8.999, -0.00626, 1.99, 1.70432, 1.32552, 1.733, 1.94702, -0.1711, -1.56876, 2.11527, -63.7398, 0.04253, 0.06125, 0.76516, 5.18326, 5.44233, 0.06283, 2.55326, 0.15908]$

4.3.5. Concluzii la studiile de caz CS1, CS2, CS3 și CS4 bazate pe folosirea algoritmilor genetici

În toate cele patru cazuri semnăturile obținute urmăresc cu fidelitate sau suficient de aproape mulțimile de puncte M_a , în cazul ramurii ascendente (Fig.4.6, Fig.4.9, Fig.4.12, Fig.4.15-a.), respectiv mulțimile de puncte M_d în cazul ramurilor descendente (Fig.4.6, Fig.4.9, Fig.4.12, Fig.4.15-b.). Rezultatele sunt confirmate și de valorile fitnessurilor.

În cazurile CS1 și CS2 ce corespund clasei tangentă discontinuă, respectiv tangentă, fitnessurile rezultate aparțin intervalului (0.02, 0.08). În cazul CS3, CS4 intervalul de variație este (0.1, 0.4).

Din punctul de vedere al frecvenței de apariție a unei anumite clase în raport cu un tip cunoscut de consumator cele mai bune rezultate s-au obținut în cazul CS3 — frigider (clasa elipsă: 0.98 — ascendentă, 1 — descendentă). S-au obținut rezultate

concludente și în cazul CS1 (clasa tangentă discontinuă: 0.90 — ascendent, 0.82 — descendent), respectiv în cazul CS2 (clasa tangentă: 0.62 — ascendent, 0.44 — descendent). În cazul CS4 (clasa hibridă: 0.34 — ascendent, 0.40 — descendent) însă, rezultatul nu este robust față de punctele singulare din spațiul parametrilor și ca urmare investigația de obținere a semnăturii prin regresie trebuie continuată.

4.4. Extinderea studiilor de caz pentru consumatori simpli folosind un algoritm PSO

Studiul prezentat în acest subcapitol extinde studiile de caz din subcapitolul 4.3 prin folosirea ca algoritm de optimizare, în vederea determinării semnăturii unui consumator simplu, algoritmul de tip PSO. Se lucrează cu cele patru clase și funcții suport prezentate în subcapitolul 3.4, iar consumatorii considerați sunt cei din cazurile de studiu CS1-CS4: televizor, laptop, frigider și aspirator. Extinderile de studii de caz sunt identificate prin acronimele CS1* — CS4*.

Cu toate că studii comparative referitoare la utilizarea AG și algoritmi de tip PSO recomandă ca intervalele de variație ale parametrilor din cazul folosirii algoritmilor de tip PSO să fie mai restrânse decât în cazul folosirii AG, s-a constatat, că se impune modificarea intervalelor de variație ale parametrilor asociați funcțiilor suport doar pentru clasa hibridă. Pentru a obține valori valide ale fitnessului și pentru această clasă spațiul de căutare al soluțiilor considerat pentru algoritmul de tip PSO a fost restrâns. Astfel, pentru ramura ascendentă parametrilor:

$$\Pi_r = [V_1, V_2, V_3, V_4, V_5, n_1, n_2, n_3, n_4, n_5, b_{S1}, b_{S2}, b_{S3}, b_{S4}, b_{S5}, b_{D1}, b_{D2}, b_{D3}, b_{D4}, b_{D5}, s_1, s_2, s_3, s_4, s_5, I_2, I_3, I_4, a_1, a_2, a_3, a_4, a_5, V_x, \mu_1, \mu_2, \mu]$$

le-au fost asociate intervalele de variație:

$$I_{\Pi_a} = \{[-350, 350], [-350, 350], [-350, 350], [-350, 350], [-350, 350], [2, 100], [2, 100], [2, 100], [2, 100], [2, 100], [-0.01, 100], [-0.01, 100], [-0.01, 100], [-0.01, 100], [-0.01, 100], [-100, 0.01], [-100, 0.01], [-100, 0.01], [-100, 0.01], [1, 2], [1, 2], [1, 2], [1, 2], [1, 2], [1, 2], [-25, 25], [-25, 25], [-25, 25], [50, 120], [*, *], [*, *], [*, *], [*, *], [-0.001, 1], [-0.001, 1], [-5, 0.1]\}$$

Intervalele I_{Π_d} asociate parametrilor ramurii descendente sunt identice cu intervalele I_{Π_a} , excepție făcând parametrul V_x al cărui interval de variație este $[-120, -50]$ și parametrul μ cu intervalul $[-5, 5]$.

Intervalele de valori atribuite parametrilor verifică următoarele condiții:

- încadrarea valorilor parametrilor V_i în intervalul $[-350 \text{ V}, 350 \text{ V}]$ de variație a tensiunii de alimentare;
- asigurarea continuității și derivabilității termenilor de forma $f(v) = (I + a_j \cdot \text{sign}(v - V_j)^{\alpha_j} \cdot |v - V_j|^{n_j}) \cdot f_{cor1}(v)$, pe intervalul de variație al tensiunii de alimentare prin satisfacerea cerinței $n_j > 1$;
- adoptarea de valori pozitive pentru b_S și negative pentru b_D în factorul de corecție $f_{cor1j}(v) = e^{b_{Sj} \cdot (v - V_j) \cdot \frac{1 - \text{sgn}(v - V_j)}{2} + b_{Dj} \cdot (v - V_j) \cdot \frac{1 + \text{sgn}(v - V_j)}{2}}$ pentru atenuarea funcției putere $|v - V_j|^{n_j}$;
- încadrarea valorilor parametrilor I_i în intervalul $[-25 \text{ A}, 25 \text{ A}]$ de variație a curentului consumat de dispozitivele electro-casnice.

După efectuarea pentru fiecare caz a celor 50 x 4 rulări independente⁶ au rezultat valorile înscrise în Tabelul 4.5. Notația $f_{r,k}$ corespunde frecvențelor de apariție

⁶ Se reamintește că o rulare include 4 rulări independente ce asociază consumatorul cu fiecare dintre cele 4 clase k .

ale fiecăreia din cele 4 clase în cursul celor 50 de rulări, în timp ce notația F_r , $r \in \{a, d\}$, se referă la fitnessurile minime care apar în șirul de rulări independente corespunzător unei clase $k \in \{1, 2, 3, 4\}$. Tabelul include atât ramura ascendentă (zona stângă) cât și pe cea descendentă (zona dreaptă).

Tabelul 4.5: Frecvențele de apariție ale claselor k pentru ramurile r și fitnessurile minime corespunzătoare claselor.

	Tg ($k = 1$)	Tg_dis ($k = 2$)	Elipsă ($k = 3$)	Hibridă ($k = 4$)	Tg ($k = 1$)	Tg_dis ($k = 2$)	Elipsă ($k = 3$)	Hibridă ($k = 4$)
CS1* LCD	$f_{a,1} = 0$ $F_a =$ 0.084682	$f_{a,2} = 1$ $F_a =$ 0.052947	$f_{a,3} = 0$ $F_a =$ 0.604382	$f_{a,4} = 0$ $F_a =$ 0.07784	$f_{d,1} = 0$ $F_d =$ 0.126833	$f_{d,2} = 0.98$ $F_d =$ 0.055374	$f_{d,3} = 0$ $F_d =$ 0.626928	$f_{d,4} = 0.2$ $F_d =$ 0.04084
CS2* laptop	$f_{a,1} = 0$ $F_a =$ 0.0767 1	$f_{a,2} = 1$ $F_a =$ 0.0743 4	$f_{a,3} = 0$ $F_a =$ 0.6385 8	$f_{a,4} = 0$ $F_a =$ 0.0822	$f_{d,1} = 0$ $F_d =$ 0.0336 3	$f_{d,2} = 1$ $F_d =$ 0.03278	$f_{d,3} = 0$ $F_d =$ 0.8000 1	$f_{d,4} = 0$ $F_d =$ 0.0335 4
CS3* Frigide r	$f_{a,1} = 0$ $F_a =$ 0.5005 2	$f_{a,1} = 0$ $F_a =$ 0.8346 8	$f_{a,1} = 1$ $F_a =$ 0.1707 3	$f_{a,1} = 0$ $F_a =$ 0.3139 7	$f_{d,1} = 0$ $F_d =$ 0.9265 4	$f_{d,1} = 0$ $F_d =$ 0.74411	$f_{d,1} = 1$ $F_d =$ 0.1138 7	$f_{d,1} = 0$ $F_d =$ 0.9767 9
CS4* Aspir.	$f_{a,1} = 0$ $F_a =$ 3.7596 5	$f_{a,1} = 0$ $F_a =$ 4.3199 3	$f_{a,1} = 0.9$ $F_a =$ 0.9423 9	$f_{a,1} = 0.1$ $F_a =$ 0.1912 0 0.1734 2	$f_{d,1} = 0$ $F_d =$ 3.9171 4	$f_{d,1} = 0$ $F_d =$ 3.92313	$f_{d,1} = 0.9$ $F_d =$ 0.8067 7	$f_{d,1} = 0.1$ $F_d =$ 0.1691 9 0.1556 8

Analizând rezultatele obținute se observă că soluțiile admise în cele patru cazuri sunt date de fitnessurile minime. Astfel:

- CS1* - televizorul LCD:
 - Pentru ramura ascendentă soluția este $k = 2$. Acestei clase îi corespund atât frecvența maximă cât și fitnessul minim.
 - Pentru ramura descendentă fitnessul minim apare pentru clasa hibridă, dar frecvența pentru această clasă este 0.2. Deoarece această frecvență este destul de mică inspectăm și următorul fitness în ordine crescătoare. El corespunde clasei $k = 2$ ce are o frecvență de apariție de 0.98. Datorită valorii mari a frecvenței și diferenței mici de 0.014534 față de fitnessul minim, pentru ramura descendentă se validează tot clasa $k = 2$.
 - Concluzie: consumatorul aparține clasei tangentă discontinuă ($k = 2$) având semnătura de expresie (3.4), cu parametrii:
 $\Pi_{a,2} = [24.6352, -0.45946, 76.8777, 50, -0.07665, 477.271]$,
 $\Pi_{d,2} = [41.4553, 0.06126, 415.526, 50, 0.43232, 180.912]$.
 obținuți pentru fitnessurile $F_a = 0.052947$, $F_d = 0.055374$.
- CS2* — laptopul:
 - Soluția corespunde clasei $k = 2$ pentru care frecvența este 1 atât pentru ramura ascendentă cât și pentru cea descendentă. Aceleași clase îi corespund și fitnessurile minime. Fitnessurile rezultate sunt $F_a = 0.074349$, $F_d = 0.03278$, soluția încadrând consumatorul în clasa

- tangentă discontinuă. Semnătura are expresia (3.4), iar parametrii au valorile:
- $$\Pi_{a,2} = [267.381, -0.00114, 849.931, 399.981, -0.04821, 619.913],$$
- $$\Pi_{d,2} = [697.260, 0.02737, 319.861, 399.954, 0.010711, 388.647].$$
- Se observă că metoda de optimizare nu activează clasa tangentă, clasă în care s-ar înscrie laptopul conform inspecției vizuale. În sine, aceasta nu este o problemă majoră deoarece clasa tangentă reprezintă un caz particular al clasei tangentă discontinuă.
- CS3* — frigider:
 - Soluția corespunde clasei $k = 3$ pentru care frecvența este 1 pe ambele ramuri. Aceleași clase îi corespund și fitnessurile minime $F_a = 0.170734$, $F_d = 0.113876$. Semnătura este dată de expresia (3.23) și valorile parametrilor:

$$\Pi_{a,3} = [340, 1.12486, 0.03493, 4.64311],$$

$$\Pi_{d,3} = [340, 1.08125, 0, 2.81867].$$
 - CS4* — aspirator:
 - Fitnessurile minime asociate celor două ramuri, $F_a = 0.191207$, $F_d = 0.169192$, calculate fără aplicarea funcției de corecție $f_{cor2}(v)$, corespund clasei hibride, $k = 4$. Clasa are frecvența de apariție de 0.1 în ambele cazuri.
 - Datorită valorii mici a acestei frecvențe de apariție se inspectează și următoarele fitnessuri în ordine crescătoare, $F_a = 0.94239$ și $F_d = 0.80677$, ce corespund clasei elipsă ($k = 3$) ce are o frecvență de apariție de 0.9. Deși această frecvență de apariție este foarte mare, sunt mari și diferențele celor două fitnessuri față de fitnessurile minime: 0.751183 pentru ramura ascendentă și 0.637578 pentru ramura descendentă. În consecință încadrarea consumatorului în clasa $k = 4$ este justificată.
 - Pentru a consolida această concluzie s-a reluat calculul bazat pe algoritmul de tip PSO incluzând și cea de-a doua corecție $f_{cor2}(v)$ ce intervine prin parametrii V_x, μ_1, μ_2, μ . Fitnessurile rezultate pentru ramura ascendentă și cea descendentă au rezultat mai mici: $F_a = 0.17342$, $F_d = 0.15568$.
 - Semnătura este dată de expresia (3.21), având parametrii:

$$\Pi_{a,4} = [350, -349.172, 319.174, -349.9, 343.464, 2.18035, 2.06403, 99.9893, 2, 2, 34.4591, -0.00297, 99.0533, -0.01, 0.01731, -12.1837, -29.8420, -75.7285, -0.01537, -99.9604, 1, 1, 1.9, 1.9, 1.9, 15.6082, 15.2255, -16.6469, -54482500000000, 580133000000000, -201310000000, -0.001971, 0.00176, 75.1046, 0.02990, 0.05268, -0.88904],$$

$$\Pi_{d,4} = [-350, -319.625, 349.168, 349.99, 319.044, 2.05895, 3.89752, 99.8948, 2, 31.0751, 10.6047, 0.13893, 98.944, 0.0153, 99.5031, -0.01684, -4.26904, -94.8229, -89.2905, -72.6215, 1, 1.98962, 1.97405, 1, 1.26830, -23.8947, -24.9790, 16.5593, -0.00122, -73.9475, 108791000000, -0.00197, 697239093.9, -63.7811, 0.04047, 0.04848, 0.78694]$$

În Fig. 4.17 a. – e. sunt redată pentru cei 4 consumatori variațiile fitnessurilor în funcție de numărul de ordine al rularii independente atât pentru ramura ascendentă cât și pentru ramura descendentă. Fitnessul minim pentru fiecare clasă este indicat pe reprezentările grafice prin „markerul” pătrat. Legenda de culori folosită în reprezentare este: clasa tangentă – roșu ($k = 1$), clasa tangentă discontinua – negru ($k = 2$); clasa elipsa – albastru ($k = 3$), clasa hibridă – roz ($k = 4$). Inspectând variațiile fitnessului pe parcursul celor 50 de rulări independente concluzionăm că pentru clasele tangentă, tangentă discontinuă și elipsă variațiile sunt foarte mici. În cazul clasei hibride variații foarte mici apar doar în cazul laptopului (Fig. 4.17 a., b.).

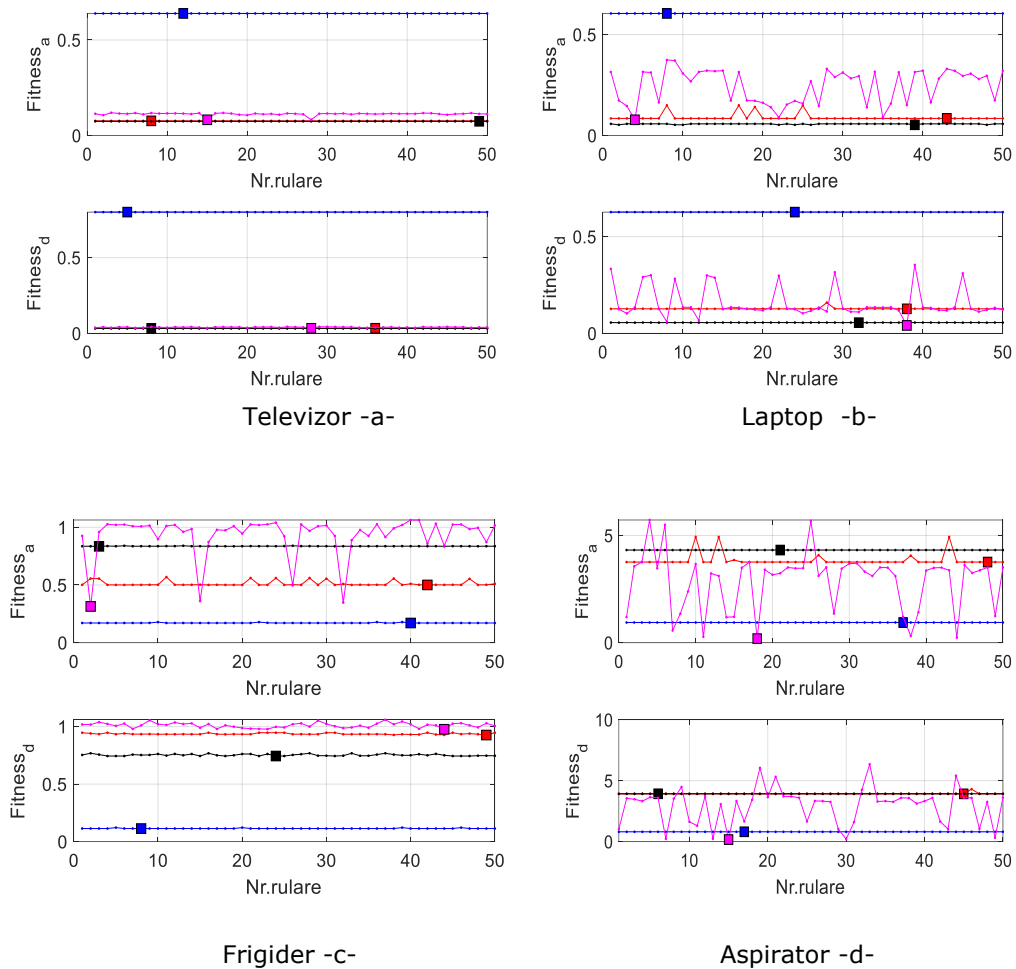


Fig. 4.17 CS1* - CS4*: Variațiile fitnessului pe clase k . Ramura ascendentă - $Fitness_a$, ramura descendentă $Fitness_d$.

În Fig. 4.18 sunt reprezentate grafic semnăturile versus submulțimile M_a , M_d . F Fig. 4.18 a., b. corespund laptopului, c., d. televizorului LCD, e., f. frigiderului, g., h. aspiratorului (funcție suport fără corecție $f_{cor_2}(x)$). Reprezentările au fost realizate pe intervalul $[V_{r_min}, V_{r_max}]$.

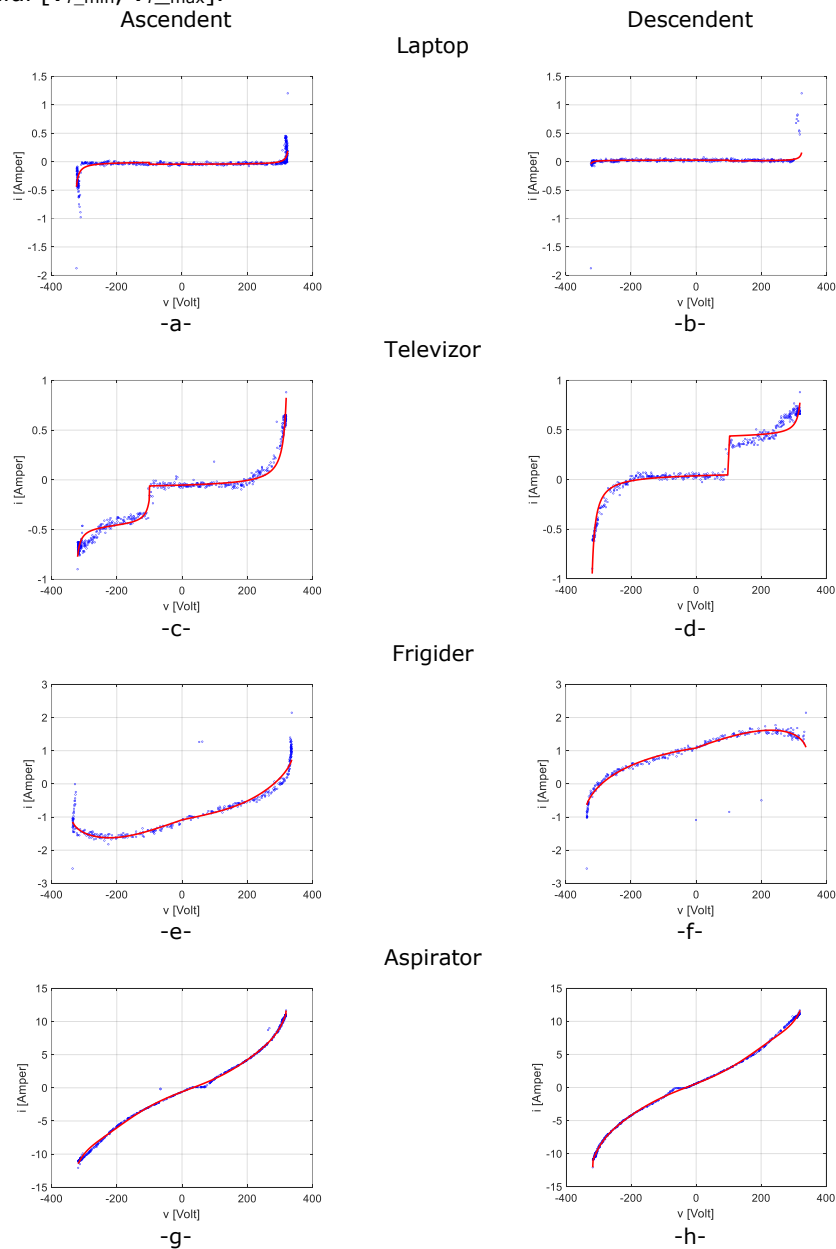


Fig. 4.18 CS1* - CS4*: Reprezentare grafică a semnăturilor asociate clasei hibride pentru cei 4 consumatori; stânga ramura ascendentă, semnătură (roșu) versus M_a , (albastru) dreapta ramura descendentă, semnătură (roșu) versus M_d (albastru).

În Fig. 4.19 sunt reprezentate semnăturile celor 4 consumatori.

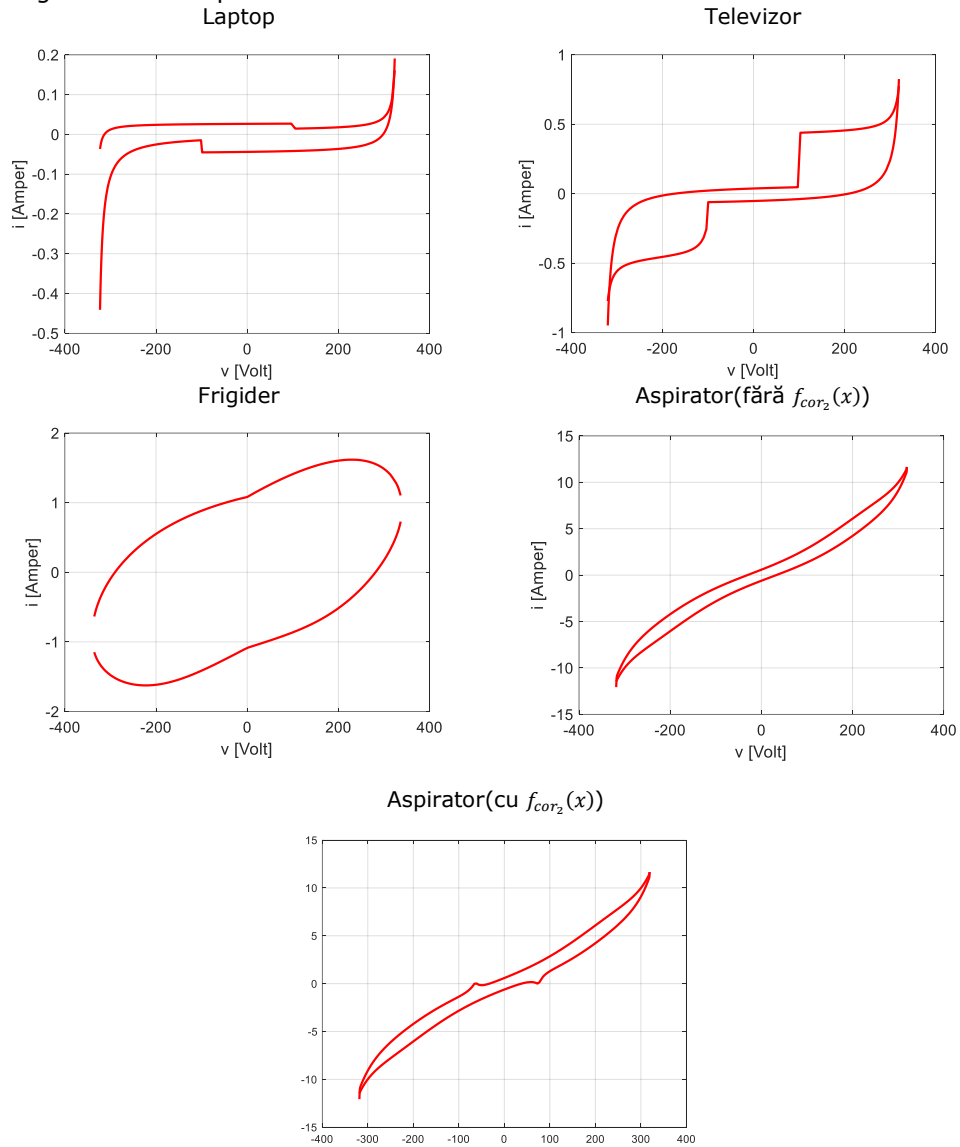


Fig. 4.19 CS1* - CS4*: Semnăturile celor 4 consumatori

Valorile parametrilor ce definesc semnătura în cazul celor 4 consumatori sunt sistematizate în Anexa B.

În toate cele patru cazuri de consumatori semnătura urmărește, uneori cu fidelitate destul de mare, mulțimea M a punctelor rezultate din măsurători.

4.5. Compararea rezultatelor din cazurile CS1 – CS4 cu cele din cazurile CS1* – CS4*

După cum s-a menționat, în cazul folosirii algoritmilor de tip PSO literatura recomandă, spre deosebire de cazul folosirii AG, adoptarea de intervale restrânse pentru parametrii funcțiilor de regresie. Concret, așa cum s-a precizat la începutul secțiunii 4.4, restrângerea domeniului de variație al parametrilor s-a impus doar în cazul CS4. Așa cum era de așteptat, după restrângerea spațiului de căutare algoritmul de tip PSO a generat soluții mai bune într-un interval de timp mai scurt. Observația este în corelație cu faptul că algoritmul de tip PSO comportă operații mai puține și mai simple decât AG.

Funcțiile suport din studiile de caz prezentate diferă în cea ce privește numărul de parametri: 5 în cazul CS1, 6 în cazul CS2, 4 în cazul CS3, 32 în cazul CS4. Studiul efectuat a condus la o concluzie metodologică suplimentară: *importanța restrângerii intervalelor de variație a parametrilor crește odată cu dimensiunea spațiului de căutare a soluției*. Aceasta se explică prin faptul că pe parcursul operării cu algoritmul genetic populația inițială „evoluează” prin excluderea de indivizi, prin operații de selecție, mutație, încrucișare și transmitere de elite, pe când în cazul operării cu algoritmul de tip PSO roiul inițial nu se modifică pe parcurs.

Pentru a compara rezultatele obținute prin folosirea AG și PSO adoptăm următorii indicatori de performanță: clasa k în care a fost încadrat consumatorul, fitnessul corespunzător soluției (F_r), timpul de execuție asociat rulării independente ce generează soluția (T_r).

Valorile indicatorilor sunt rezumate în tabelul Tabel 4.6. pentru ambii algoritmi de optimizare și cei 4 consumatori studiați.

Tabel 4.6 Indicatori de performanță AG/PSO

	AG				PSO			
	LCD (CS1)	Laptop (CS2)	Frigider (CS3)	Aspirator (CS4)	LCD (CS1*)	Laptop (CS2*)	Frigider (CS3*)	Aspirator (CS4*)
<i>Ramura ascendentă</i>								
k	2	1	3	4	2	2	3	4
F_a	0.05795	0.07794	0.17074	0.2941	0.05294	0.07434	0.17073	0.17342
T_{Fa}	16.8428	0.7826	1.4606	48.0220	0.5045	0.4107	0.3265	41.0582
<i>Ramura descendentă</i>								
k	2	1	3	4	2	2	3	4
F_d	0.05597	0.03368	0.11392	0.2488	0.05537	0.03278	0.11387	0.15568
T_{Fd}	16.9287	2.1012	1.6908	206.8907	0.3643	0.2290	0.2353	74.8003

Consultând valorile trecute în tabelul de mai sus se desprind următoarele concluzii:

- Pentru ambii algoritmi de optimizare clasele k în care sunt încadrați consumatorii corespund alurii sugerate de punctele de măsură, cu excepția cazului laptop, când algoritmi de tip PSO îl încadrează în clasa $k = 1$, iar AG în clasa $k = 2$. Cu privire la acest caz, pentru care clasa de încadrare este 2 și nu 1, se reamintește faptul că funcția suport din cazul $k = 1$ este un caz particular al funcției suport din cazul $k = 2$.
- Fitnessurile pentru consumatorii LCD, laptop, frigider sunt sensibil mai mici în cazul aplicării metodei de tip PSO și ele confirmă rezultatul obținut în cazul aplicării algoritmilor genetici. În cazul aspiratorului raportul între fitnessurile obținute aplicând algoritmul de tip PSO și cel de tip AG sunt doar „mai mici”, de 0.59 pe ramura ascendentă și de 0.62 pe ramura descendentă.

- Timpii de execuție sunt mai mici în cazul algoritmilor de tip PSO. Raportul între timpul de execuție în cazul PSO și AG variază în intervalul $[1/46.4, 1/1.17]$. Astfel putem concluziona că în condițiile date algoritmul de tip PSO are, în ceea ce privește valorile fitnessului, performanțe mai bune decât cel de tip AG.

4.6. Studii de caz pentru consumatori de tip $c-2.m$ folosind AG

În contextul determinării semnăturilor consumatorilor de tip $c-n.m$ în această secțiune se tratează doi consumatori de tip $c-2.m$. Cele două cazuri studiate vor fi denumite pe parcursul subcapitolului CS5 — studiul de caz 5, respectiv CS6 — studiul de caz 6. Relevanța lor este dată de faptul că în primul studiu de caz (CS5) consumatorul $c-2.m$ este compus din doi consumatori cu puteri de același ordin de mărime, pe când în al doilea studiu de caz (CS6) din doi consumatori ce au puteri de ordin de mărime diferit. Astfel, CS5 include un laptop DELL și un televizor LCD, iar CS6 un laptop HP și un aspirator.

Într-o primă fază, în secțiunile 4.6.1 și 4.6.2 pentru cele 2 cazuri regresia folosește AG. Rezultatele se analizează în secțiunea 4.6.3. Apoi, într-o a doua fază, în secțiunea 4.6.4, se consideră aceiași consumatori, dar folosind un algoritm de optimizare de tip PSO. Aspectele evidențiate pe parcursul prezentării sunt următoarele:

- reprezentarea grafică a punctelor măsurate - mulțimea M , respectiv a submulțimilor M_a — albastru, M_d — roșu;
- semnătura $c.s-e$ — varianta 1;
- descompunerea $c-2.m$ în 2 consumatori simpli — varianta 3.

Metodele de determinare a semnăturilor în variantele 1 și 3 au fost detaliate în secțiunea 3.7.2.

Intervalele de variație ale parametrilor pentru clasele tangentă, tangentă discontinuă, elipsă s-au adoptat, fiind identice cu cele din cazul consumatorului simplu ((4.5), (4.6), (4.7)). Pentru clasa hibridă expresia (3.31) a funcției suport și implicit setul de parametri a fost simplificată sub forma (3.32). Modificarea a avut ca scop obținerea pentru cei doi consumatori care au alcătuit $c-2.m$ a unor semnături cât mai apropiate de cele individuale. În acest sens s-a avut în vedere:

- mai buna urmărire a punctelor de măsură pe porțiuni prin activarea unor seturi diferite de parametri în stânga, respectiv în dreapta valorilor de tensiune V_j , de ex.: $n_{S_1} \dots, n_{D_1} \dots$;
- scăderea numărului de parametri prin scăderea numărului de valori V_j de la 5 la 3.

Setul de parametri folosit în expresia (3.32) este:

$$\Pi_r = [V_1, V_2, V_3, n_{S_1}, n_{S_2}, n_{S_3}, n_{D_1}, n_{D_2}, n_{D_3}, b_{S_1}, b_{S_2}, b_{S_3}, b_{D_1}, b_{D_2}, b_{D_3},$$

$$s_{S_1}, s_{S_2}, s_{S_3}, s_{D_1}, s_{D_2}, s_{D_3}, I_2, a_{S_1}, a_{S_2}, a_{S_3}, a_{D_1}, a_{D_2}, a_{D_3}, V_x, k_1, k_2, k], \text{ unde } r \in \{a, d\} \quad (4.10)$$

respectiv I_1 - fixat, I_3 - fixat, $s_{S_j} = \text{round}(\alpha_{S_j})$, $s_{D_j} = \text{round}(\alpha_{D_j})$.

Intervalele de variație asociate parametrilor sunt:

$$I_{\Pi_a} = \{[-330,350], [-290,350], [330,350], [-3,0.001], [-3,3], [-3,0.001], [-3,0.001], [-3,3],$$

$$[-3,0.001], [-0.2,2], [-0.2,2], [-0.2,2], [-0.2,2], [-0.2,2], [-0.2,2], [1,2], [2,2], [2,2], [1,2], [2,2],$$

$$[2,2], [-25,25], *, *, *, *, *, *, [50,120], [-0.001,1], [-0.001,1], [-5,0.1]\}$$

$$I_{\Pi_d} = \{[-330,350], [-290,350], [330,350], [-3,0.001], [-3,3], [-3,0.001], [-3,0.001],$$

$$[-3,3], [-3,0.001], [-0.2,2], [-0.2,2], [-0.2,2], [-0.2,2], [-0.2,2], [-0.2,2], [-0.2,2], [1,2], [2,2], [2,2], [1,2], [2,2],$$

$$[2,2], [-25,25], *, *, *, *, *, *, [-120,50], [-0.001,1], [-0.001,1], [0,5]\}$$

4.6.1. Studiul de caz 5 (CS5)

În CS5 consumatorul c-2.m este compus dintr-un laptop DELL și un televizor LCD cu puterile active într-un raport de cca. 1 / 2.3. Laptopul DELL reprezintă un consumator de clasă $k = 1$ iar televizorul LCD un consumator de clasă $k = 2$. Norul de puncte obținut prin măsurări și mulțimile de puncte selectate pentru stabilirea semnăturilor (M_a albastru și M_d roșu) au aspectele din Fig.4.20.




Fig.4.20. CS5: a) Norul de puncte măsurate; b) Mulțimile de puncte M_a și M_d .

În varianta 1 (v. secțiunea 3.7.2), în care c-2.m i se asociază un singur consumator simplu echivalent de clasă k , celor 4 funcții suport din Anexa A le corespund fitnessurile din Tabelul 4.7. Sunt subliniate rezultatele optime cu frecvența de apariție maximă. Ele recomandă adoptarea unui model de consumator simplu echivalent de clasă $k = 2$. Semnătura are funcția suport dată de expresia (3.4) cu parametrii (B.3.1) pentru ramura ascendentă și (B.3.2) pentru ramura descendentă (Anexa B).

Tabelul 4.7: Valorile fitnessurilor c.s-e (varianta 1) pentru CS5.

r	$k = 1$	$k = 2$	$k = 3$	$k = 4$
	0	<u>0.8</u>	0	0.2
a	0.420278	<u>0.301889</u>	0.714876	0.274029
	0	<u>0.78</u>	0	0.22
d	0.278012	<u>0.13152</u>	0.649752	0.129297

Cele două ramuri ale semnăturii sunt reprezentate atât separat cât și în ansamblu în Fig.4.21. Mulțimile de puncte M_a și M_d apar cu culoare albastră, iar semnăturile c.s-e cu culoare roșie.




Fig.4.21. Semnătura unui c.s-e de clasă $k = 4$ pentru CS5: a) Ramura ascendentă; b) Ramura descendentă; c) Ansamblul.

În continuare abordăm problema obținerii semnăturilor consumatorilor simpli din componența $c-2.m$ în varianta 3 (vezi secțiunea 3.7.2). Frecvențele maxime — scorurile maxime — pentru cele $q = 10$ combinații corespunzătoare rulărilor independente au distribuțiile prezentate în Tabelul 4.8. Valorile subliniate indică fitnessurile minime $F_{a,min}$, respectiv $F_{d,min}$.

Tabelul 4.8: CS5 - Frecvențele maxime ale combinațiilor analizate pentru ramurile a și d și fitnessurile minime asociate.

$f_{0.2,a,44} = 0.78$	$f_{0.4,a,44} = 0.64$	$f_{0.5,a,44} = 0.56$	$f_{0.6,a,44} = 0.46$	$f_{0.8,a,24} = 0.56$
$F_{0.2,a} =$ 0.2409420	$F_{0.4,a} =$ 0.239268202	$F_{0.5,a} =$ 0.238015452	$F_{0.6,a} =$ 0.237630446	$F_{0.8,a} =$ <u>0.219822977</u>
$f_{0.2,d,44} = 0.82$	$f_{0.4,d,44} = 0.58$	$f_{0.5,d,24} = 0.56$	$f_{0.6,d,24} = 0.54$	$f_{0.8,a,24} = 0.56$
$F_{0.2,d} =$ 0.099602776	$F_{0.4,d} =$ 0.10052771	$F_{0.5,d} =$ 0.094081329	$F_{0.6,d} =$ 0.102157999	$F_{0.8,d} =$ <u>0.09077883</u>

În cazul ramurii ascendente alegem pentru început ca soluție combinația cu fitnessul $F_a = 0.219822977$. Aceasta este perechea C_{24} pentru $p = 0.8$, identică cu perechea C_{42} pentru $p = 0.2$. Vom observa că din mulțimea de valori $\{p/(1-p)\}_{p \in P}$ ale ponderilor, raportul $0.2/0.8 = 1/4$ are cea mai apropiată valoare față de raportul de puteri $1/2.3$ precizat inițial. Alegerea corespunde unui consumator 2-multiplu format din doi consumatori simpli, unul cu $k = 2$ (clasa tangentă discontinuă), celălalt cu $k = 4$ (clasa hibridă).

Semnăturile componente rezultate pentru ramura ascendentă sunt redată în Fig.4.22.a. Parametrii semnăturilor celor doi consumatori simpli asociați perechii C_{24} au valorile din relațiile (B.3.5) și (B.3.6) din Anexa B. În Fig.4.22.b este reprezentată cu linie roșie suma celor două semnături. Se observă o poziționare foarte bună a sumei celor două semnături în raport cu mulțimea de puncte M_a . Cu excepția zonei valorilor foarte mari ale tensiunii la borne v , semnăturile validează calculul făcut. Abaterea menționată, din zonele verticale, se explică prin trunchierea numărului de puncte care formează mulțimea M_a .




Fig.4.22. CS5 - soluția pentru ramura ascendentă în varianta 3: a) Componentele semnăturii; b) Suma componentelor raportată la M_a .

În cadrul studiului s-a avut în vedere faptul că folosirea AG poate conduce la soluții care converg spre minime locale. Conștientizăm existența lor prin faptul că semnăturile aferente nu au sens fizic, deci nu pot fi atribuite unor consumatori simpli. Ilustrăm acest lucru considerând a doua valoare, în ordine crescătoare, din linia a doua din Tabelul 4.8: $F_{0.6,a} = 0.237630446$. Ea corespunde perechii C_{44} . Semnăturile apar în Fig.4.23. Cu toate că per ansamblu lucrurile stau bine (Fig.4.23.a.), soluția nu

este validată deoarece semnătura unuia din consumatori are numai valori strict pozitive, ceea ce nu are sens fizic în circuite de curent alternativ (Fig.4.23.b.).




Fig.4.23. O alegere nevalidată pentru ramura ascendentă din CS5, varianta 3: a) Suma componentelor raportată la M_a ; b) Componentele semnături

Pentru ramura descendentă reținem, potrivit aceluiași raționament, fitnessul $F_{0.8,d} = 0.09077883$ (rândul 3 din Tabelul 4.8)-corespunzător perechii C_{24} . Rezultatul este validat de semnăturile redată în Fig.4.24. Valorile parametrilor semnăturilor consumatorilor simpli asociați perechii C_{24} sunt cele (din Anexa B) notate în (B.3.7) și (B.3.8).




Fig.4.24. CS5 - soluția pentru ramura descendentă în varianta 3: a) Semnătura descendentă descompusă pe componente, b) Semnătura descendentă raportată la M_d .

Spre deosebire de ramura ascendentă, de data aceasta și următoarele două valori din ultima linie din Tabelul 4.8 conduc la rezultate validabile fizic. De exemplu lui $F_{0.5,d} = 0.094081329$ îi corespund semnăturile din Fig.4.25.




Fig.4.25. CS5 - Soluție potențială pentru ramura descendentă: a) Semnătura descendentă descompusă în componente; b) Semnătura descendentă raportată la M_d .

După cum s-a precizat la începutul acestei secțiuni, laptopul DELL reprezintă un consumator de clasă $k = 1$ iar televizorul LCD un consumator de clasă $k = 2$. Rezultatul cel mai bun corespunde însă unei perechi de consumatori simpli de clasă $k = 2$ și $k = 4$. Situația se explică prin faptul că semnăturile de clasă $k = 4$ pot substitui adeseori, cu erori ne semnificative, semnăturile de tip tangentă sau tangentă discontinuă.

Combinând rezultatele parțiale obținute reținem următorul rezultat final: $c-2.m$ îi corespunde perechea de semnături $i^1(v)$ și $i^2(v)$ calculate cu formulele (4.11) și (4.12). Graficele celor două semnături sunt date în Fig.4.26.

Consumator 1:

$$i^1(v) = \begin{cases} 0.8 \cdot S_{2,a}(v) \text{ cu parametrii (B.3.3) - ramura ascendentă} \\ 0.8 \cdot S_{2,d}(v) \text{ cu parametrii (B.3.5) - ramura descendentă} \end{cases} \quad (4.11)$$

Consumator 2:

$$i^2(v) = \begin{cases} 0.2 \cdot S_{4,a}(v) \text{ cu parametrii (B.3.4) - ramura ascendentă} \\ 0.2 \cdot S_{4,d}(v) \text{ cu parametrii (B.3.6) - ramura descendentă} \end{cases} \quad (4.12)$$




Fig.4.26. Soluția „pereche de consumatori simpli” pentru $c-2.m.$ -ul din CS5: a) Semnătură consumator simplu 1; b) Semnătură consumator simplu 2.

4.6.2. Studiul de caz 6 (CS6)

De data aceasta consumatorul $c-2.m$ este format dintr-un aspirator și un laptop HP cu puterile active aflate într-un raport disproporționat de cca. $1/92$. Aspiratorul reprezintă un consumator de clasă $k = 4$ iar laptopul HP un consumator de clasă $k = 1$. Norul de puncte obținut prin măsurări și mulțimile de puncte selectate pentru stabilirea semnăturilor (M_a albastru și M_d roșu) au aspectele din Fig.4.27.




Fig.4.27. CS6: a) Norul de puncte măsurate; b) Mulțimile de puncte M_a și M_d .

La prelucrarea datelor din perspectiva variantei 1, celor 4 funcții suport din Anexa A le corespund fitnessurile din Tabelul 4.9. Rezultatele subliniate recomandă și de data aceasta adoptarea unui model de consumator simplu echivalent de clasă $k = 4$.

Tabelul 4.9: Valorile fitnessurilor consumatorilor simpli echivalenți (varianta 1) pentru CS6.

r	$k = 1$	$k = 2$	$k = 3$	$k = 4$
	0	0	0.46	<u>0.54</u>
a	6.922604	4.16259	1.026761	<u>0.202195</u>
	0	0	0.46	<u>0.54</u>
d	7.082493	4.224756	1.08494	<u>0.239039</u>

Semnătura are parametrii indicați în (B.3.7) pentru ramura ascendentă și în (B.3.8) pentru ramura descendentă. Ramurile și semnătura c.s-e în ansamblu sunt prezentate în Fig.4.28. Mulțimile de puncte M_a și M_d apar cu culoare albastră, iar semnăturile cu culoare roșie.




Fig.4.28. Semnătura unui c.s-e de clasă $k = 4$ pentru CS6: a) Ramura ascendentă, b) Ramura descendentă; c) Ansamblul.

În cazul variantei 3 rezultatele obținute pentru cele 10 combinații $C_{\alpha\beta}$ și cele 5 valori $p \in P$ din (3.47) nu au fost validate din considerente fizice. Punem acest fapt pe seama diferenței dintre puterile celor doi consumatori. Ca urmare, am extins șirul (3.47) al valorilor lui p cu valorile 0.015, 0.025, 0.05 și 0.95, 0.975, 0.985, apropiate calitativ de valorile rapoartelor de puteri de 1/20, respectiv 19/20.

În Tabelul 4.10 sunt redată doar acele părți din rezultate care sunt considerate relevante pentru stabilirea soluției.

Tabelul 4.10: CS6 - Frecvențele maxime ale combinațiilor analizate pentru ramurile a și d și fitnessurile minime asociate acestora.

$\hat{f}_{0.05,a,34} = 0.88$	$\hat{f}_{0.6,a,34} = 0.44$	$\hat{f}_{0.985,a,44} = 0.4$	$(\hat{f}_{0.6,a,44} = 0.42)$
$F_{0.05,a} = 0.12095$...	$F_{0.985,a} = \underline{0.172632228}$	$(F_{0.6,a,44} = 0.100406146)$
$\hat{f}_{0.015,d,34} = 0.88$	$\hat{f}_{0.05,d,34} = 0.82$	$\hat{f}_{0.5,d,24} = 0.56$	$\hat{f}_{0.95,d,44} = 0.39$
$F_{0.015,d} = 0.132942854$...	$F_{0.5,d} = 0.094081329$	$F_{0.95,d} = 0.251224$

Analizând semnăturile din punctul de vedere al tipului fizic de consumator și în ordinea crescătoare a fitnessurilor din prima linie din Tabelul 4.10 reținem ca soluție viabilă pentru ramura ascendentă cea cu fitnessul $F_{0.985,a} = 0.172632228$ din cazul combinației C_{44} .

Semnăturile aferente sunt date în Fig.4.29. Figura din stânga evidențiază ordinele de mărime diferite ale curenților absorbiți de cei doi consumatori componenți. Potrivit figurii din dreapta curentul sumă (curba roșie) urmărește suficient de bine valorile măsurate, exceptând oscilația de curent calculat din vecinătatea tensiunii de -100 V. Ea se datorează aproximării semnăturii laptopului, consumator de clasă $k = 1$, printr-o semnătură de clasă $k = 4$. Valorile parametrilor semnăturilor consumatorilor simpli asociați perechii C_{44} sunt date în relațiile (B.3.9.1) și (B.3.10.1) din anexa B.




Fig.4.29. CS6 - soluția pentru ramura ascendentă în varianta 3: a) Descompunere pe ramura ascendentă; b). Semnătura ramurii ascendentă raportată la M_a .

Fitnessul minim pe ansamblul ramurilor ascendente are valoarea $F_{0.6,a,44} = 0.100406146$ și apare pentru combinația C_{44} câștigătoare cu o frecvență $f_{p,a,44} = 0.42$. Cazul este notat în Tabelul 4.10 între paranteze. Semnăturile sunt date în Fig.4.30. Ele invalidează soluția matematică care a convers spre un minim local pentru care curenții corespunzătorii celor doi consumatori simpli componenți au același ordin de mărime dar sunt de polarități diferite.




Fig.4.30. Semnăturile corespunzătoare fitnessului minim pentru CS6, ramura ascendentă, versiunea 3: a) Descompunere pe ramura ascendentă; b) Semnătura ramurii ascendente raportată la M_a .

Pentru ramura descendentă soluția reținută este cea cu fitnessul $F_{0.015,d} = 0.132942854$. Ea corespunde lui $p = 0.015$ și combinației C_{34} . Semnăturile aferente sunt date în Fig.4.31. În Fig.4.31.a. consumatorul de clasă $k = 3$ apare printr-o elipsă degenerată, redusă practic la o axă, iar consumatorul de clasă $k = 4$ printr-o curbă sub formă de arc, specifică acestei clase. Valorile parametrilor semnăturilor consumatorilor simpli asociați perechii C_{34} sunt date în (B.3.11.1) și (B.3.12.1). Din punctul de vedere al polarității curenților, soluția are sens fizic. Practic însă, soluția nu corespunde situației reale. Pe de-o parte curentul consumat de consumatorul de clasă $k = 4$ ar trebui să fie mult mai mare decât al celui alt consumator, pe de altă parte segmentul de dreapta ar trebui să fie foarte puțin înclinat pentru a corespunde

consumatorului real de clasă $k = 1$. Fig.4.31.b. ilustrează însă o potrivire foarte bună a rezultatului matematic cu rezultatele experimentale. Această situație conduce la concluzia că practic consumatorii simpli calculați sunt relevanți în acest caz numai prin consumul comun.




Fig.4.31. Soluția pentru CS6, ramura descendentă, versiunea 3: a) Descompunere pe ramura descendentă; b) Semnătura ramurii descendente raportată la Md.
 Fitnessul minim pentru ramura descendentă, $F_{0.05,d} = 0.124737$, nu are relevanță fizică.

Combinând rezultatele parțiale obținute reținem următorul rezultat final: consumatorului-2 multiplu îi corespunde perechea de semnături $i^1(v)$ și $i^2(v)$ calculate cu formulele (4.13) și (4.14):

Consumator 1:

$$i^1(v) = \begin{cases} 0.985 \cdot S_{4,a}(v) \text{ cu parametrii (B.3.9.1) - ramura ascendentă} \\ 0.985 \cdot S_{4,d}(v) \text{ cu parametrii (B.3.11.1) - ramura descendentă} \end{cases} \quad (4.13)$$

Consumator 2:

$$i^2(v) = \begin{cases} 0.015 \cdot S_{4,a}(v) \text{ cu parametrii (B.3.10.1) - ramura ascendentă} \\ 0.015 \cdot S_{3,d}(v) \text{ cu parametrii (B.3.12.1) - ramura descendentă} \end{cases} \quad (4.14)$$

Graficele celor două semnături sunt date în Fig.4.32.




Fig.4.32. Soluția „pereche de consumatori simpli” pentru consumatorul 2-multiplu în CS6: a) Semnătură consumator 1; b) Semnătură consumator 2.

Având în vedere caracterul matematic al soluției (4.13) - (4.14), denumită „soluția 1” extindem investigarea pentru identificarea în mulțimea de semnături calculate a unei soluții ce să satisfacă atât din punctul de vedere al tipului fizic de consumator, adică al alurii semnăturilor componentelor rezultate din descompunere, cât și din punct de vedere matematic, de urmărire cât mai fidelă a punctelor de măsură. În acest sens extindem setul de combinații considerate selectând pentru interpretare (în ordine crescătoare a fitnessului v. 3.7.2) nu doar frecvența maximă

(scorul maxim) corespunzătoare fiecări ponderi ci toate frecvențele diferite de 0 asociate fiecărei ponderi. Fără a intra în detalii, precizăm că soluția identificată, denumită „soluția 2” este cea redată în Fig. 4.33. Soluția, cu caracter de optim local, apare pentru combinația C_{14} pe ambele ramuri și o pondere $p = 0.8$. Frecvențele de apariție sunt $f_{0.8,a,14} = 0.1$, $f_{0.8,d,14} = 0.1$, iar fitnessurile sunt $F_{a,0.8} = 0.169383548$, $F_{d,0.8} = 0.217786952$. Valorile parametrilor asociați celor 2 consumatori simpli ce intră în componența $c-2.m$ sunt date în Anexa B de expresiile (B.3.9.2, B.3.11.2), (B.3.10.2, B.3.12.2).




Fig. 4.33 Soluția 2 pentru CS6: a) Descompunere pe ramura ascendentă. b) Descompunere pe ramura descendentă. c.) Semnătură consumator 2-multiplu versus $M_a \cup M_d$. d.) Consumator simplu 1. e.) Consumator simplu 2..

Semnăturile celor 2 consumatori simpli redade în Fig. 4.33, a) și b) sunt:

Consumator 1:

$$i^1(v) = \begin{cases} 0.8 \cdot S_{1-a}(v) \text{ cu parametrii (B.3.9.2) - ramura ascendentă} \\ 0.8 \cdot S_{1-d}(v) \text{ cu parametrii (B.3.11.2) - ramura descendentă} \end{cases}$$

Consumator 2:

$$i^2(v) = \begin{cases} 0.2 \cdot S_{4-a}(v) \text{ cu parametrii (B.3.10.2) - ramura ascendentă} \\ 0.2 \cdot S_{4-d}(v) \text{ cu parametrii (B.3.12.2) - ramura descendentă} \end{cases}$$

4.6.3. Concluzii la studiile de caz CS5 și CS6.

Studiile de caz CS5 și CS6 ilustrează că aplicarea variantei 1, de asociere a unui consumator simplu echivalent unui consumator 2-multiplu, a avut de fiecare dată o soluție. Pentru cazurile studiate soluția a fost de fiecare dată un consumator de clasă $k = 4$. Întrucât, în fiecare caz semnătura s-a mulat foarte bine pe norul de puncte $M_a \cup M_d$ (Fig.4.20. și Fig.4.27.) soluția a fost acceptată. Totodată, varianta 1 este favorabilă și din punctul de vedere al volumului de calcule care trebuie efectuat.

Aplicarea varaintei 3 ridică câteva probleme.

În primul rând, soluțiile obținute nu au cu certitudine un echivalent fizic din punctul de vedere al asocierii rezultatului la o clasă. Astfel, la semnătura din Fig.4.26.a. ramurile se intersectează, situație neîntâlnită la consumatorii simpli din clasele K ; la semnătura din Fig.4.26.b semnătura are un echivalent fizic cu excepția

unei linii parazite la tensiuni pozitive mari; la semnăturile din Fig.4.32. ramurile se intersectează și nu au un echivalent fizic așteptat. Totuși, ansamblul celor două semnături se mulează foarte bine pe norul de puncte $M_a \cup M_d$ (Fig.4.22., Fig.4.24., Fig.4.25., și Fig.4.29., Fig.4.31. – b). Această constatare sugerează că pentru consumatorii componenți aferenți unui consumator 2-multiplu ar trebui acceptate semnături simple care să aparțină doar matematic claselor K .

În al doilea rând, metoda de obținere a semnăturilor nu elimină posibilitatea apariției unor soluții asociate unor extreme locale datorate optimizării cu AG.

În al treilea rând, trebuie observat că procesul de validare a deciziilor pentru obținerea semnăturilor consumatorilor simpli componenți este destul de complex, iar procesul de determinare necesită timp și, implicit, capacitate de procesare. Importanța acestui aspect crește odată cu valoarea lui n .

4.7. Extinderea studiilor de caz pentru $c-2.m$ folosind un algoritm de tip PSO (CS5*, CS6*)

Studiile de caz se referă la situațiile analizate în CS5 și CS6, în locul AG folosindu-se un algoritm de tip PSO. Noile cazuri sunt notate cu CS5*, respectiv CS6*.

Rezultatele obținute în varianta 1 – consumator simplu echivalent asociabil celor 4 clase (v. subcapitolul 4.3) sunt rezumatate în tabelul de mai jos:

Tabel 4.11 Valorile fitnessurilor consumatorilor simpli echivalenți (varianta 1) pentru CS5*, CS6*.

Consumator	r	$k = 1$	$k = 2$	$k = 3$	$k = 4$
LCD+DELL (CS5*)	a	0	<u>0.98</u>	0	0.02
		0.318674	<u>0.297182</u>	0.714875	0.263875
	d	0	<u>0.98</u>	0	0.02
		0.209206	<u>0.127422</u>	0.649732	0.114033
Aspirator+HP (CS6*)	a	0	0	0.74	<u>0.26</u>
		3.429158	4.047648	1.02676	<u>0.1808343</u>
	d	0	0	0.94	<u>0.06</u>
		3.98327	3.921596	1.084939	<u>0.593438823</u>

Consultând tabelul de mai sus, pentru $c-2.m$. LCD+DELL se observă că frecvenței maxime de 0.98 ($k=2$) îi corespund atât pe ramura ascendentă cât și pe cea descendentă fitnessuri foarte apropiate de fitnessurile minime. În consecință semnătura consumatorului simplu echivalent asociat primului consumator 2-multiplu este de clasă $k=2$.

Pentru $c-2.m$ Aspirator+HP frecvențelor maxime le corespund valori mari ale fitnessului în raport cu valorile minime, astfel că soluția adoptată va fi cea cu fitness minim. În cazul consumatorului Aspirator+HP semnătura consumatorului simplu echivalent se încadrează în clasa $k = 4$.

Pentru CS5*, în care $c-2.m$ este compus dintr-un consumator de clasă $k = 2$ (LCD), respectiv un consumator de clasă $k = 1$ (DELL), încadrarea consumatorului compus în clasa $k = 2$ este de așteptat. Pentru CS6* $c-2.m$. este încadrat în clasa $k = 4$, clasă ce corespunde aspiratorului, consumator dominant în combinația Aspirator+HP.

Parametrii asociați celor două semnături sunt înscrși în Anexa B (B.4.1), (B.4.2) – CS5* – varianta 1; (B.4.3), (B.4.4) – CS6* – varianta 1

În figura Fig. 4.34 sunt reprezentate semnăturile c.s-e raportate la punctele de măsură pentru cele două cazuri: LCD+DELL (Fig. 4.34.a) respectiv Aspirator+HP (Fig. 4.34.b).




Fig. 4.34 Semnătură c.s-e adoptat. a.) LCD+DELL. b.) Aspirator+HP

Comparând rezultatele — fitnessurile din Tabelul 4.9 și Tabel 4.11, respectiv reprezentările grafice din Fig.4.21 Fig.4.28, Fig. 4.34 — se poate concluziona că indiferent de metoda de optimizare folosită, AG sau algoritm de tip PSO, rezultatele raportate la fitnessuri și semnături sunt similare.

Pentru CS5* — varianta 3, deși fitnessurile obținute au valori valide, rezultatele nu sunt relevante din punctul de vedere al descompunerii consumului cumulat în consumatori simpli. Combinațiile pot fi interpretate din punct de vedere matematic, nu și fizic. Acest lucru nu exclude eventuale soluții de extrem local validate sub aspect fizic.

Pentru CS6* -varianta 3, în scopul obținerii unor rezultate ce corespund realității fizice, numărul combinațiilor interpretate grafic a fost extins, pentru fiecare pondere p considerându-se nu numai combinația corespunzătoare frecvenței maxime — scorului maxim —, ci toate combinațiile pentru care frecvențele sunt diferite de 0. Ca rezultat s-a obținut semnătura ilustrată în Fig. 4.35, o soluție de extrem local corespunzătoare atât pe ramura ascendentă cât și pe cea descendentă combinației C_{14} și ponderii $p = 0.975$. Frecvențele de apariție au fost: $f_{0.975,a,14}=0.22$, $f_{0.975,d,14}=0.20$, iar fitnessurile $F_{a,0.975} = 0.103267157$, respectiv $F_{d,0.975} = 0.107305626$.




Fig. 4.35. CS6*: a) și b) Semnăturile consumatorilor simpli componenți ai c-2.m (a-Semnătură consumatorul 1, b-semnătură consumatorul 2), c) Suma semnăturilor consumatorilor simpli (roșu) vs. setul de măsurători (albastru).

Potrivit acestui rezultat consumatorului-2 multiplu îi corespunde perechea de semnături $i^1(v)$ și $i^2(v)$:
Consumator1

4.8 - Compararea rezultatelor din cazurile CS5 – CS6 cu cele din cazurile CS5* – CS6* 99

$$i^1(v) = \begin{cases} 0.975 \cdot S_{1,a}(v) \text{ cu parametrii (B.4.5) – ramura ascendentă} \\ 0.975 \cdot S_{1,d}(v) \text{ cu parametrii (B.4.7) – ramura descendentă} \end{cases}$$

Consumator2

$$i^1(v) = \begin{cases} 0.025 \cdot S_{4,a}(v) \text{ cu parametrii (B.4.6) – ramura ascendentă} \\ 0.025 \cdot S_{4,d}(v) \text{ cu parametrii (B.4.8) – ramura descendentă} \end{cases}$$

Valorile parametrilor asociați celor 2 consumatori simpli ce intră în componența c-2.m sunt date în Anexa B de expresiile (B.4.5, B.4.7), (B.4.6, B.4.8).

4.8. Compararea rezultatelor din cazurile CS5 – CS6 cu cele din cazurile CS5* – CS6*

Tabel 4.12 rezumă rezultatele obținute în secțiunile 4.6, respectiv 4.7. Pentru cazul variantei 1 – c-s.e, din punct de vedere al fitnessului și al claselor de apartenență k, rezultatele obținute folosind AG sunt similare cu cele obținute folosind algoritmul de tip PSO. Timpii de execuție au valori mai bune în cazul algoritmului de tip PSO

Tabel 4.12 Rezultate c.2-m varianta 1, varianta 3

c.s-e (var.1)	AG			PSO	
	LCD+DELL (CS5)	Aspirator+HP (CS6)		LCD+DELL (CS5*)	Aspirator+HP (CS6*)
<i>Ramura ascendentă</i>					
k	2	4		2	4
F _a	0.301889	0.202195		0.297182	0.180834328
T _{Fa}	15.421108	50.176602		0.481764	78.1305131
<i>Ramura descendentă</i>					
k	2	4		2	4
F _d	0.13152	0.239039		0.127422	0.593438823
T _{Fd}	15.239440	110.4550231		0.922765	27.7351442
(var.3)					
Tip soluție	Minim global - cu coresp. fizic	Sol1- Minim global - fără coresp. fizic	Sol2 – Minim local cu corespondent fizic	-	Minim local cu corespondent fizic
<i>Ramura ascendentă</i>					
k	24(p=0.8)	44(p=0.985)	14(p=0.8)	-	14(p=0.975)
F _d	0.21982297	0.172632228	0.169383548	-	0.103267157
T _{Fd}	211.212577	419.1156149	430.673807	-	59.1618065
<i>Ramura descendentă</i>					
k	24(p=0.8)	34(p=0.015)	14(p=0.8)	-	14(p=0.975)
F _d	0.09077883	0.132942854	0.217786952	-	0.107305626
T _{Fd}	711.274813	85.2769387	554.8627733	-	31.1543172

În cazul variantei 3 pentru primul c-2.m (LCD+DELL) AG furnizează o soluție de tip minim global cu corespondent fizic, pe când algoritmul de tip PSO nu furnizează o astfel de soluție. Menționăm însă că acest lucru nu exclude soluții de tip minim local.

Pentru al doilea consumator c-2.m (Aspirator+HP) dacă impunem ca soluția să aibă corespondent fizic discutăm atât pentru AG cât și pentru PSO de identificarea

unor minime locale cu o frecvență mică de apariție. Fitnessurile și timpii de execuție sunt mai mici în acest caz pentru algoritmul de tip PSO.

4.9. Implementarea MATLAB

Pentru a estima semnătura unui consumator s-a folosit mediul MATLAB. Alegerea acestui mediu de programare este susținută de existența unui set de funcții de optimizare printre care se numără atât algoritmul genetic cât și algoritmul de tip PSO. Utilizarea funcțiilor Matlab permite adaptarea la condițiile impuse de problema ce se cere a fi rezolvată. În acest sens se pot menționa, pe de o parte, modificarea unor parametri (numărul de generații, toleranțe, etc.), pe de altă parte definirea unor funcții de către utilizator (funcția de generare a populației/roiul inițial, etc.) dacă nu se dorește folosirea celor implicite. Setările folosite pentru cei doi algoritmi de optimizare au fost detaliate în subcapitolul 3.9.

Un alt aspect ce se cere a fi menționat este faptul că teza este o lucrare care și-a propus investigarea posibilității de determinare a semnăturii unui consumator în diverse situații și nu furnizarea unui produs soft. În acest sens în Anexa C a tezei se prezintă câteva segmente de program considerate relevante de autoare. Acestea sunt grupate în funcții și scripturi.

Anexa C conține:

- Implementarea funcțiilor suport pentru cele patru clase, condiții de adecvare — secțiunea C.1;
- Implementarea algoritmului de alocare — secțiunea C.2;
- Implementarea calculării parametrilor semnăturilor și fitnessului — secțiunea C.3.

5. Concluzii

Acest capitol final este destinat prezentării în sinteză a obiectivelor tezei, actualității temei abordate, a conținutului capitolelor 2, 3, 4, respectiv a contribuțiilor aduse în domeniul de studiu și sugerării unor direcții de dezvoltare ulterioară a cercetărilor în domeniu.

Obiectivul general al tezei a fost studierea posibilității de a determina semnături pentru consumatori casnici folosind înregistrările de tensiune și curent efectuate la o frecvență de achiziție redusă cu contoarele inteligente existente în prezent pe piață.

Ca *obiective specifice* ale tezei enumerăm: realizarea de investigații experimentale noninvazive, folosirea unor descriptori electrici purtători de semnătură obținabili din datele măsurabile brute, definirea unor clase de semnături care să permită gruparea consumatorilor funcție de aspectul traiectoriei tensiune-curent.

Actualitatea temei determinării semnăturilor consumatorilor este confirmată de numeroasele cercetări de dată recentă. În acest sens studiul prezentat în secțiunea 2.1.4 analizează cercetările din literatura de specialitate ce au ca subiect generarea de semnături folosind ca și descriptor electric traiectoria tensiune-curent. Această perspectivă de lucru a fost adoptată și în prezenta teză. Perioada în care sunt raportate majoritatea articolelor este 2017 - 2021, certificându-se astfel actualitatea temei.

Tematica de cercetare a fost dezvoltată pe parcursul capitolelor 2, 3 și 4. În capitolul 2 este abordată problematica semnăturii consumatorilor casnici. Aspectele avute în vedere sunt: descriptorii electrici și instrumentele de calcul folosite pentru identificarea semnăturii, bazele de date existente (rezultate din măsurători) folosite la testarea diferitelor metode de generare de semnături, analizarea cercetărilor raportate în literatura de specialitate, respectiv încadrarea temei tezei în preocupările existente în domeniu. În capitolul 3 se fundamentează metodologia aplicată în teză. Se prezintă terminologia specifică utilizată pe parcursul tezei, se discută problema estimării parametrilor semnăturilor prin regresie neliniară folosind ca algoritm de optimizare algoritmul genetic respectiv algoritmul de tip PSO și se delimitează obiectul cercetării. Capitolul se încheie cu prezentarea metodologiei de lucru adoptate bazată pe definirea claselor de semnături, gestionarea datelor achiziționate și a algoritmilor de optimizare folosiți, respectiv determinarea semnăturii. Capitolul 4 include 6 studii de caz dintre care patru se referă la consumatori simpli, iar două la perechi de consumatori (*c-2.m*). Studiile de caz sunt însoțite de discuții comparative realizate în mai multe planuri referitoare la tipurile de consumatori, raporturile de puteri absorbite de consumatori, efectele algoritmilor de optimizare folosiți în regresie asupra operației de estimare și rezultatelor ei, valabilitatea fenomenologică sau doar matematică a semnăturilor. Capitolul se încheie cu o scurtă referire la principalele coduri Matlab folosite pentru implementarea calculului aferent procedurilor de calcul propuse. Capitolele tezei sunt însoțite de 3 anexe și o bibliografie care cuprinde 83 de titluri (65 lucrări și 11 materiale disponibile pe internet).

Contribuția globală adusă prin teză constă în demonstrarea posibilității de a determina semnături ale consumatorilor casnici folosind înregistrările contoarelor inteligente efectuate cu o frecvență de achiziție redusă. Practic demonstrația este dată de rezultatele raportate în capitolul 4 referitoare la determinarea semnăturilor pentru 4 consumatori simpli și doi *c-2.m*.

Abordarea din teză este complet diferită de abordările existente în literatură. Ea se bazează pe definirea a patru clase de consumatori simpli caracterizate prin funcții suport distincte. Contribuția globală este concretizată printr-o metodologie și aplicarea ei în șase studii de caz. Rezultatele au fost publicate în cadrul a 4 articole, 2 de jurnal și 2 de conferințe, toate indexate WoS (Clarivate Alalitics). Ele se găsesc în bibliografia tezei sub numerele de ordine [63], [61], [62] și [64].

Metodologia de lucru, sintetizată în Fig.3.13 reunește mai multe procedee originale având ca obiect:

- a. *Selectarea* din mulțimea punctelor măsurate a punctelor folosite pentru determinarea semnăturii, punctele măsurate reprezentând perechi de forma (tensiune, curent) care, după aplicarea selectării, sunt considerate ca traiectorie tensiune-curent care constituie de fapt descriptorul electric ales pentru determinarea ulterioară a semnăturilor.
- b. *Asocierea* de semnături prin estimarea valorilor parametrilor funcțiilor suport prin regresie neliniară folosind ca algoritmi de optimizare AG și algoritmi PSO pentru situațiile de mai jos:
 - i. *Semnături pentru consumatori simpli*: s-au determinat pe baza traiectoriei tensiune-curent semnăturile a patru consumatori de clase diferite (CS1-CS4, CS1*-CS4*);
 - ii. *Semnături echivalente pentru consumatori 2-multipli*: s-au determinat pe baza traiectoria tensiune-curent comune pentru două cazuri de $c-2.m$ (CS5-CS6, CS5*-CS6*);
 - iii. *Semnături asociate consumatorilor componenți*: s-au determinat pe baza traiectoria tensiune-curent comune de la subpunctul ii;
- c. *Validarea* semnăturilor în cazurile de la punctul b. de mai sus.

Performanțele folosirii celor doi algoritmi de optimizare utilizați în cadrul estimării parametrilor semnăturilor prin regresie au fost evaluate în funcție de două criterii: valoarea fitnessului și timpul de execuție. S-a constatat că pe baza primului criteriu rezultatele obținute nu pot diferenția cei doi algoritmi de optimizare, pe când din punctul de vedere al celui de al doilea criteriu rezultatele sunt în favoarea algoritmului de tip PSO.

În timp, din diferite cauze, în principal datorită îmbătrânirii, semnătura unui consumator casnic se modifică. În acest context facem observația că, în mod natural, după generarea unui set de semnături asociate dispozitivelor electrocasnice orice identificare ulterioară poate avea ca și punct de plecare ultimul set de semnături determinat.

Cercetarea prezentată în teză deschide mai multe nișe de cercetare, cum sunt:

- a. valorificarea potențialului metodologiei folosite în teză prin extensia numărului de clase de consumatori casnici și, corespunzător, a tipului de funcții suport;
- b. studierea influenței măririi numărului de puncte de măsurare asupra calității semnăturii prin extinderea duratei de achiziție a punctelor tensiune-curent;
- c. aplicarea metodologiei folosite în teză la consumatori de putere superioară celor casnici uzuali.

Bibliografie

- [1] U.S. Energy Information Administration, „U.S. Energy facts explained,” U.S. Energy Information Administration, 07 Martie 2020. [Interactiv]. Available: <https://www.eia.gov/energyexplained/us-energy-facts/>. [Accesat 09 Martie 2021].
- [2] European Environment Agency, „Household energy consumption,” European Environment Agency, 26 Noiembrie 2019. [Interactiv]. Available: <https://www.eea.europa.eu/airs/2018/resource-efficiency-and-low-carbon-economy/household-energy-consumption>. [Accesat 09 Martie 2021].
- [3] Institutul Național de Statistică, „Balanța energetică și structura utilajului energetic,” Institutul Național de Statistică, 11 Noiembrie 2020. [Interactiv]. Available: <https://insse.ro/cms/ro/content/balan%C5%A3a-energetic%C4%83-%C5%9Fi-structura-utilajului-energetic-cd-rom-3>. [Accesat 09 Martie 2021].
- [4] K. Carrie Armel, A. Gupta, G. Shrimali și A. Albert, „Is disaggregation the holy grail of energy efficiency? The case of electricity,” *Energy Policy*, vol. 52, pp. 213-234, 1, 2013.
- [5] H. Rashid, V. Stankovic, L. Stankovic și P. Singh, „Evaluation of Non-intrusive Load Monitoring Algorithms for Appliance-level Anomaly Detection,” *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, Vol. 1 din 2019-May, pp. 8325-8329, 5, 2019.
- [6] G. W. Hart, „Nonintrusive Appliance Load Monitoring,” *Proceedings of the IEEE*, vol. 80, nr. 12, pp. 1870-1871, 1992.
- [7] N. Sadeghianpourhamami, J. Ruyssinck, D. Deschrijver, T. Dhaene și C. Davelder, „Comprehensive feature selection for appliance classification in NILM,” *Energy and Buildings*, vol. 151, pp. 98-106, 9, 2017.
- [8] Jian Liang, S. Ng, G. Kendall și J. Cheng, „Load signature study - part I: Basic concept, structure and methodology,” *IEEE Transactions on Power Delivery*, vol. 25, nr. 2, pp. 551-560, 10, 2010.
- [9] M. Zhuang, M. Shahidehpour și Z. Li, „An Overview of Non-Intrusive Load Monitoring: Approaches, Business Applications, and Challenges,” *2018 International Conference on Power System Technology, POWERCON 2018 - Proceedings*, pp. 4291-4299, 1, 2018.
- [10] H. K. Iqbal, F. H. Malik, A. Muhammad, M. A. Qureshi, M. N. Abbasi și A. R. Chishti, „A critical review of state-of-the-art non-intrusive load monitoring datasets,” *Electric Power Systems Research*, vol. 192, p. 106921, 3, 2021.
- [11] H. C. Ancelmo, B. M. Mulinari, F. Pottker, A. E. Lazzaretti, T. D. P. Bazzo, E. Oroski, D. P. Renaux, C. R. Lima, R. R. Linhares și A. R. De Gamba, „A New Simulated Database for Classification Comparison in Power Signature Analysis,” *2019 20th International Conference on Intelligent System Application to Power Systems, ISAP 2019*, 12, 2019.

- [12] H. Y. Lam, G. S. Fung și W. K. Lee, „A novel method to construct taxonomy electrical appliances based on load signatures,” *IEEE Transactions on Consumer Electronics*, vol. 53, nr. 2, pp. 653-660, 5, 2007.
- [13] T. Hassan, F. Javed și N. Arshad, „An empirical investigation of V-I trajectory based load signatures for non-intrusive load monitoring,” *IEEE Transactions on Smart Grid*, vol. 5, nr. 2, pp. 870-878, 3, 2014.
- [14] C. Miller, Z. Nagy și A. Schlueter, „Automated daily pattern filtering of measured building performance data,” *Automation in Construction*, vol. 49, nr. PA, pp. 1-17, 1, 2015.
- [15] N. Iksan, J. Sembiring, N. Haryanto și S. H. Supangkat, „Appliances identification method of non-intrusive load monitoring based on load signature of V-I trajectory,” *2015 International Conference on Information Technology Systems and Innovation, ICITSI 2015 - Proceedings*, pp. 1-6, 3, 2016.
- [16] D. Teshome, T. D. Huang și K.-L. Lian, „A Distinctive Load Feature Extraction Based on Fryze's Time-domain Power Theory,” *IEEE Power and Energy Technology Systems Journal*, vol. 3, nr. 2, pp. 60-70, 4, 2016.
- [17] L. Du, D. He, R. G. Harley și T. G. Habetler, „Electric load classification by binary voltage-current trajectory mapping,” *IEEE Transactions on Smart Grid*, vol. 7, nr. 1, pp. 358-365, 1, 2016.
- [18] S. Welikala, C. Dinesh, R. I. Godaliyadda, M. P. B. Ekanayake și J. Ekanayake, „Robust Non-Intrusive Load Monitoring (NILM) with unknown loads,” *2016 IEEE International Conference on Information and Automation for Sustainability: Interoperable Sustainable Smart Systems for Next Generation, ICIAfS 2016*, 7, 2016.
- [19] P. Held, F. Laasch, D. O. Abdeslam și D. Benyoucef, „Frequency invariant transformation of periodic signals (FIT-PS) for signal representation in NILM,” *IECON Proceedings (Industrial Electronics Conference)*, pp. 5149-5154, 12, 2016.
- [20] D. Weibhaar, P. Held, S. Mauch și D. Benyoucef, „Device classification for NILM using FIT-PS compared with standard signal forms,” *CANDO-EPE 2018 - Proceedings IEEE International Conference and Workshop in Obuda on Electrical and Power Engineering*, pp. 79-84, 1, 2019.
- [21] M. Azaza și F. Wallin, „Evaluation of classification methodologies and Features selection from smart meter data,” *Energy Procedial*, vol. 142, pp. 2250-2256, 12, 2017.
- [22] A. Bouhouras, P. Gkaidatzis, K. Chatzisavvas, E. Panagiotou, N. Poulakis și G. Christoforidis, „Load Signature Formulation for Non-Intrusive Load Monitoring Based on Current Measurements,” *Energies*, vol. 10, nr. 4, p. 538, 4, 2017.
- [23] B. Huang, M. Knox, K. Bradbury, L. M. Collins și R. G. Newell, „Non-intrusive load monitoring system performance over a range of low frequency sampling rates,” *2017 6th International Conference on Renewable Energy Research and Applications, ICRERA 2017*, Vol. 1 din 2017-January, pp. 505-509, 12, 2017.
- [24] A. L. Wang, B. X. Chen, C. G. Wang și D. D. Hua, „Non-intrusive load monitoring algorithm based on features of V-I trajectory,” *Electric Power Systems Research*, vol. 157, pp. 134-144, 4, 2018.

- [25] L. De Baets, T. Dhaene, D. Deschrijver, M. Berges și C. Develder, „VI-based appliance classification using aggregated power consumption data,” *Proceedings - 2018 IEEE International Conference on Smart Computing, SMARTCOMP 2018*, pp. 179-186, 7, 2018.
- [26] L. De Baets, J. Ruyssinck, C. Develder, T. Dhaene și D. Deschrijver, „Appliance classification using VI trajectories and convolutional neural networks,” *Energy and Buildings*, vol. 158, pp. 32-36, 1, 2018.
- [27] L. De Baets, C. Develder, T. Dhaene și D. Deschrijver, „Automated classification of appliances using elliptical fourier descriptors,” *2017 IEEE International Conference on Smart Grid Communications, SmartGridComm 2017*, Vol. 1 din 2018-Janua, pp. 153-158, 4, 2018.
- [28] Y. Liu, X. Wang și W. You, „Non-intrusive Load Monitoring by Voltage-Current Trajectory Enabled Transfer Learning,” *IEEE Transactions on Smart Grid*, vol. 10, nr. 5, pp. 5609-5619, 2018.
- [29] K. S. Barsim, L. Mauch și B. Yang, „Neural Network Ensembles to Real-time Identification of Plug-level Appliance Measurements,” *arXiv*, 2, 2018.
- [30] S. Ghorbanpour și R. Mallipeddi, „Significance of Classifier and Feature Selection in Automatic Identification of Electrical Appliances,” *Proceedings - 2018 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2018*, pp. 4184-4189, 1, 2018.
- [31] S. Khan, A. F. Latif și S. Sohaib, „Low-cost real-time non-intrusive appliance identification and controlling through machine learning algorithm,” *2018 International Symposium on Consumer Technologies, ISCT 2018*, pp. 32-36, 7, 2018.
- [32] P. Dash și K. Naik, „A Very Deep One Dimensional Convolutional Neural Network (VDOCNN) for Appliance Power Signature Classification,” *2018 IEEE Electrical Power and Energy Conference, EPEC 2018*, pp. 1-6, 12, 2018.
- [33] M. Kahl, A. U. Haq, T. Kriechbaumer și H. A. Jacobsen, „A comprehensive feature study for appliance recognition on high frequency energy data,” *e-Energy 2017 - Proceedings of the 8th International Conference on Future Energy Systems*, pp. 121-131, 5, 2017.
- [34] C. C. Yang, C. S. Soh și V. V. Yap, „A systematic approach in load disaggregation utilizing a multi-stage classification algorithm for consumer electrical appliances classification,” *Frontiers in Energy*, vol. 13, nr. 2, pp. 386-398, 6, 2019.
- [35] L. De Baets, C. Develder, T. Dhaene și D. Deschrijver, „Detection of unidentified appliances in non-intrusive load monitoring using siamese neural networks,” *International Journal of Electrical Power and Energy Systems*, vol. 104, pp. 645-653, 1, 2019.
- [36] A. S. Bouhouras, P. A. Gkaidatzis, E. Panagiotou, N. Poulakis și G. C. Christoforidis, „A NILM algorithm with enhanced disaggregation scheme under harmonic current vectors,” *Energy and Buildings*, vol. 183, pp. 392-407, 1, 2019.
- [37] D. Yan, Y. Jin, H. Sun, B. Dong, Z. Ye, Z. Li și Y. Yuan, „Household appliance recognition through a Bayes classification model,” *Sustainable Cities and Society*, vol. 46, p. 101393, 4, 2019.

- [38] H. C. Ancelmo, F. L. Grando, B. M. Mulinari, C. H. Da Costa, A. E. Lazzaretti, E. Oroski, D. P. Renaux, F. Pottker, C. R. Lima și R. R. Linhares, „A Transient and Steady-State Power Signature Feature Extraction Using Different Prony's Methods,” *2019 20th International Conference on Intelligent System Application to Power Systems, ISAP 2019*, 12, 2019.
- [39] A. Faustine și L. Pereira, Improved Appliance Classification in Non-Intrusive Load Monitoring Using Weighted Recurrence Graph and Convolutional Neural Networks, vol. 13, Multidisciplinary Digital Publishing Institute, 2020, p. 3374.
- [40] Y. Han, Y. Xu, Y. Huo și Q. Zhao, Non-intrusive load monitoring by voltage-current trajectory enabled asymmetric deep supervised hashing, The Institution of Engineering and Technology, 2021.
- [41] S. Wang, H. Chen, L. Guo și D. Xu, Non-intrusive load identification based on the improved voltage-current trajectory with discrete color encoding background and deep-forest classifier, vol. 244, Elsevier, 2021, p. 111043.
- [42] R. de Paula Rodrigues și P. M. da Silveira, Curvature scale space-based signatures for electrical load classification in NILM, vol. 103, Springer, 2021, pp. 1239-1252.
- [43] A. A. Kholeif, H. A. El-Ghany și A. M. Azmy, „Impact of supply voltage variation on V-I trajectory identification method,” *2017 19th International Middle-East Power Systems Conference, MEPCON 2017 - Proceedings*, Vol. %1 din %22018-Febru, pp. 839-844, 2, 2018.
- [44] P. Held, S. Mauch, A. Saleh, D. O. Abdeslam și D. Benyoucef, „Frequency Invariant Transformation of Periodic Signals (FIT-PS) for Classification in NILM,” *IEEE Transactions on Smart Grid*, vol. 10, nr. 5, pp. 5556-5563, 2018.
- [45] L. Y. Hui, T. Logenthiran și W. L. Woo, „Non-Intrusive Appliance Load Monitoring and Identification for smart home,” *2016 IEEE 6th International Conference on Power Systems, ICPS 2016*, pp. 1-6, 10, 2016.
- [46] M. Shakeri, M. Shayestegan, H. Abunima, S. M. Reza, M. Akhtaruzzaman, A. R. Alamoud, K. Sopian și N. Amin, „An intelligent system architecture in home energy management systems (HEMS) for efficient demand response in smart grid,” *Energy and Buildings*, vol. 138, pp. 154-164, 3, 2017.
- [47] C. M. Lin și M. T. Chen, „Design and implementation of a smart home energy saving system with active loading feature identification and power management,” *2017 IEEE 3rd International Future Energy Electronics Conference and ECCE Asia, IFEEEC - ECCE Asia 2017*, pp. 739-742, 7, 2017.
- [48] M. S. Ahmed, A. Mohamed, T. Khatib, H. Shareef, R. Z. Homod și J. A. Ali, „Real time optimal schedule controller for home energy management system using new binary backtracking search algorithm,” *Energy and Buildings*, vol. 138, pp. 215-227, 3, 2017.
- [49] B. Kalluri, S. Kondepudi, T. K. Wai, K. H. Wei și A. Kamilaris, „SMELs: A data-driven middleware for smart miscellaneous electrical load management in buildings,” *Proceedings - IEEE 16th International Conference on Dependable, Autonomic and Secure Computing*, pp. 159-165, 10, 2018.
- [50] S. Minghua, X. Qingxian, Z. Benda și Y. Feng, „Regression modeling based on improved genetic algorithm,” *Tehnicki Vjesnik*, vol. 24, nr. 1, pp. 63-70, 2, 2017.

- [51] M. Vlada, „Modele neliniare. Teorie și aplicații.” în *Conerința Națională de Învățământ Virtual, ediția a X-a*, 2012.
- [52] A. Kialashaki și J. R. Reisel, „Modeling of the energy demand of the residential sector in the United States using regression models and artificial neural networks,” *Applied Energy*, vol. 108, pp. 271-280, 8, 2013.
- [53] O. Saleem, M. Rizwan, P. S. Shiokolas și B. Ali, „Genetically Optimized ANFIS-based PID Controller Design for Posture-Stabilization of Self-Balancing-Robots under Depleting Battery Conditions,” 2019.
- [54] S. Urgun și H. Yigit, „Selective Harmonic Eliminated Pulse Width Modulation (SHE-PWM) Method using Genetic Algorithm in Single-Phase Multilevel Inverters,” *International Journal on Electrical Engineering and Informatics*, vol. 13, nr. 1, 2021.
- [55] Y. Zhou, Y. Wang, K. Wang, L. Kang, F. Peng, L. Wang și J. Pang, „Hybrid genetic algorithm method for efficient and robust evaluation of remaining useful life of supercapacitors,” *Applied Energy*, vol. 260, p. 114169, 2, 2020.
- [56] K. Zhang, W. Li, Y. Han, Z. Geng și C. Chu, „Production capacity identification and analysis using novel multivariate nonlinear regression: Application to resource optimization of industrial processes,” *Journal of Cleaner Production*, vol. 282, p. 124469, 2, 2021.
- [57] Q. Wang și L. Wang, „Renewable energy consumption and economic growth in OECD countries: A nonlinear panel data analysis,” *Energy*, vol. 207, p. 118200, 9, 2020.
- [58] Y.-H. Lin și Y.-C. Hu, *Electrical Energy Management Based on a Hybrid Artificial Neural Network-Particle Swarm Optimization-Integrated Two-Stage Non-Intrusive Load Monitoring Process in Smart Homes*, vol. 6, Multidisciplinary Digital Publishing Institute, 2018, p. 236.
- [59] A. Faza și A. Al-Mousa, *PSO-based optimization toward intelligent dynamic pricing schemes parameterization*, vol. 51, Elsevier, 2019, p. 101776.
- [60] Y. del Valle, G. K. Venayagamoorthy, S. Mohagheghi, J. C. Hernandez și R. G. Harley, *Particle swarm optimization: Basic concepts, variants and applications in power systems*, vol. 12, 2008, pp. 171-195.
- [61] **D. V. Caiman** și T. L. Dragomir, „Non intrusive load monitoring: Analytic expressions as load signature,” *SACI 2018 - IEEE 12th International Symposium on Applied Computational Intelligence and Informatics, Proceedings*, pp. 15-20, 8, 2018.
- [62] **D. V. Caiman** și T. L. Dragomir, „Two voltage-current load signature classes for residential consumers,” *2018 22nd International Conference on System Theory, Control and Computing, ICSTCC 2018 - Proceedings*, pp. 176-181, 11, 2018.
- [63] **D. V. Caiman** și T. L. Dragomir, „Empirical voltage-current signatures for individual household consumers obtained by non-linear regression,” *Studies in Informatics and Control*, vol. 28, nr. 2, pp. 201-212, 2019.
- [64] **D. V. Caiman** și T.-L. Dragomir, „A Novel Method for Obtaining the Signature of Household Consumer Pairs,” *Energies*, vol. 13, nr. 22, p. 6030, 11, 2020.
- [65] D. T. Pham și D. Karaboga, „Genetic Algorithms,” *Intelligent Optimisation Techniques*, pp. 51-147, 2000.

- [66] D. T. Pham și D. Karaboga, *Intelligent Optimisation Techniques*, Springer London, 2000.
- [67] H. Pohlheim, „GEATbx.com - Evolutionary Algorithms for MATLAB,” 2006. [Interactiv]. Available: http://www.geatbx.com/ea_matlab.html. [Accesat 28 04 2021].
- [68] F. Wilhelmstötter, „Jenetics,” 09 02 2021. [Interactiv]. Available: <https://jenetics.io/>. [Accesat 28 04 2021].
- [69] E. O. S. L. P. e. Sean Luke, „ECJ 27-A Java-based Evolutionary Computation Research System,” 2019. [Interactiv]. Available: <https://cs.gmu.edu/~eclab/projects/ecj/>. [Accesat 28 04 2021].
- [70] A. Mohammadi, H. Asadi, S. Mohamed, K. Nelson și S. Nahavandi, „Openga, a C++ genetic algorithm library,” *2017 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2017*, pp. 2051-2056, 11, 2017.
- [71] MathWorks, „Mathworks - Help -ga,” [Interactiv]. Available: <https://www.mathworks.com/help/gads/ga.html>. [Accesat 09 Martie 2021].
- [72] Birge și Brian, „Particle Swarm Optimization Toolbox - File Exchange - MATLAB Central,” *MATLAB Central File Exchange*, 2021. [Interactiv]. Available: <https://www.mathworks.com/matlabcentral/fileexchange/7506-particle-swarm-optimization-toolbox>. [Accesat 10 05 2021].
- [73] L. James V. Miranda, „PySwarms: a research toolkit for Particle Swarm Optimization in Python,” *The Journal of Open Source Software*, vol. 3, nr. 21, p. 433, 1, 2018.
- [74] MathWorks, „Particle swarm optimization - MATLAB particleswarm,” MathWorks, [Interactiv]. Available: <https://www.mathworks.com/help/gads/particleswarm.html>. [Accesat 10 05 2021].
- [75] STMicroelectronics, „EVALSTPM32 - Single-phase energy metering evaluation board with shunt current sensor based on the STPM32,” STMicroelectronics, [Interactiv]. Available: https://www.st.com/content/st_com/en/products/evaluation-tools/solution-evaluation-tools/energy-and-smartgrid-solution-eval-boards/evalstpm32.html/. [Accesat 12 03 2021].
- [76] STMicroelectronics, „STM32 Embedded Software,” STMicroelectronics, [Interactiv]. Available: <https://www.st.com/en/embedded-software/stm32-embedded-software.html>. [Accesat 12 03 2021].

Anexa A. Funcții suport asociate claselor k .

Mai jos sunt date expresiile funcțiilor suport $S_{k,r}$ pentru cele 4 clase $k \in K$. Ele sunt urmate de câteva precizări privind parametrii acestor funcții.

- $k=1$ (clasa tangentă):

$$S_{1,r}: [V_{min}, V_{max}] \rightarrow R$$

$$S_{1,r}(v) = \left[\frac{1}{a_s} tg \left(\frac{v+d_s}{c_s} \right) - \frac{1}{a_s} tg \frac{d_s}{c_s} + \frac{1}{a_d} tg \frac{d_d}{c_d} \right] \cdot \frac{1-sgn(v)}{2} + \frac{1}{a_d} tg \left(\frac{v+d_d}{c_d} \right) \cdot \frac{1+sgn(v)}{2} + b \quad (A.1)$$

- $k=2$ (clasa tangentă discontinuă):

$$S_{2,r}: [V_{min}, V_{max}] \rightarrow R$$

$$S_{2,r}(v) = \left[\frac{1}{a_s} tg \left(\frac{v+d_s}{c_s} \right) + b_s \right] \cdot \frac{1-sgn(v-v_b)}{2} + \left[\frac{1}{a_d} tg \left(\frac{v+d_d}{c_d} \right) + b_d \right] \cdot \frac{1+sgn(v-v_b)}{2} \quad (A.2)$$

- $k=3$ (clasa elipsă):

$$S_{3,r}: [V_{min}, V_{max}] \rightarrow R$$

$$S_{3,r}(v) = \left[\left(\frac{a^2}{V_{max}^2} - 1 \right) \cdot v \cdot \sqrt{\frac{V_{max}^2 - b^2}{a^2 - V_{max}^2}} \mp \frac{a \cdot b}{V_{max}} \sqrt{1 - \frac{v^2}{V_{max}^2}} \right] \cdot f_{cor_1}(v) \cdot f_{cor_2}(v),$$

$$f_{cor_1}(v) = \left(1 + A \cdot \sin \left(3\pi \cdot \frac{v-V_{min}}{v-V_{max}} \right) \right), f_{cor_2}(v) = e^{\frac{|v|}{B \cdot V_{max}}} \quad (A.3)$$

- $k=4$ (clasa hibridă):

$$S_{4,r}: [V_{min}, V_{max}] \rightarrow R$$

- varianta 1

$$S_{4,r}(v) = \sum_{j=1}^5 \left[I_j + a_j \cdot |v - V_j|^{n_j} \cdot (sgn(v - V_j))^{\alpha_j} \right] \cdot f_{cor_{1j}}(v) + \mu \cdot f_{cor_2}(v)$$

$$f_{cor_{1j}}(v) = e^{b_{sj} \cdot (v-V_j) \cdot \frac{1-sgn(v-V_j)}{2} + b_{dj} \cdot (v-V_j) \cdot \frac{1+sgn(v-V_j)}{2}},$$

$$f_{cor_2}(v) = e^{-[\mu_1(1-sgn(v-V_x)) + \mu_2(1+sgn(v-V_x))] \cdot |v-V_x|}. \quad (A.4)$$

- varianta 2

$$S_{4,r}(v) = \sum_{j=1}^3 I_j + a_{sj} \cdot |v - V_j|^{n_{sj}} \cdot (sgn(v - V_j))^{\alpha_{sj}} \cdot e^{b_{sj} \cdot (v-V_j) \cdot \frac{1-sgn(v-V_j)}{2}} +$$

$$+ \sum_{j=1}^3 a_{dj} \cdot |v - V_j|^{n_{dj}} \cdot (sgn(v - V_j))^{\alpha_{dj}} \cdot e^{b_{dj} \cdot (v-V_j) \cdot \frac{1+sgn(v-V_j)}{2}} + \mu \cdot f_{cor_2}(v),$$

$$f_{cor_2}(v) = e^{-[\mu_1(1-sgn(v-V_x)) + \mu_2(1+sgn(v-V_x))] \cdot |v-V_x|}. \quad (A.5)$$

Caracterele S , D , utilizate ca indici ai parametrilor, se referă la partea „stângă”, respectiv „dreaptă” a ramurii r a semnăturii, $r \in \{a, d\}$.

Funcția $sgn(x) = \begin{cases} -1, x < V \\ 0, x = V \\ 1, x > V \end{cases}$ permite raportarea stânga/dreapta la norul de puncte

M_r necesară pentru determinarea parametrilor asociați celor două părți ale unei ramuri $r \in \{a, d\}$. Raportarea se realizează față de valoarea $v = 0$ (punct de continuitate) pentru S_{1_r} , față de v_{b_r} fixat — punct de discontinuitate pentru S_{2_r} , respectiv $v = V_j$ pentru S_{4_r} . În ultimul caz partea „stângă” este separată de partea „dreaptă” printr-o zonă „centrală”.

Pentru $k = 1$ și $k = 2$ satisfacerea cerinței ca funcția $tg(x)$ să fie definită pe întreg intervalul $[V_{min}, V_{max}]$ impune relațiile de legătură (A.6) și drept urmare eliminarea parametrilor d_S și d_D .

$$d_S = -c_S \cdot \frac{\pi}{2} + c_S \cdot \varepsilon - V_{min}, \quad d_D = c_D \cdot \frac{\pi}{2} - c_D \cdot \varepsilon - V_{max} \quad (\text{A.6})$$

În cazul $k = 3$ radicalii impun condițiile $a > V_{max}$, $b < V_{max}$, iar paranteza cu funcție sinusoidală asigură forma de arahidă a elipsei.

Anexa B. Valorile parametrilor soluțiilor din studiile de caz din capitolul 4

1. Consumatori simpli - AG		
CS1 – LCD	<i>k</i>	
$\Pi_a = [56.4149059490743, -0.415957267370672, 210.099589492196, 50.0142024755726, -0.0625777477871177, 428.426364331765]$	2	(B.1.1)
$\Pi_d = [21.9323380813181, 0.0457852624449561, 210.569557659973, 64.3502583313587, 0.458213094431142, 210.119739702183]$	2	(B.1.2)
CS2 – laptop	<i>k</i>	
$\Pi_a = [581.028347448698, -0.0437285436460968, 849.999624417095, 226.791360755119, 333.593530065276]$	1	(B.1.3)
$\Pi_d = [616.319334715818, 0.0246655445168449, 264.48152324589, 399.999957587483, 196.563781154081]$	1	(B.1.4)
CS3 – frigider	<i>k</i>	
$\Pi_a = [340.001281738281, 1.1138883456248, 0.0271885287834639, 4.13968808047162]$	3	(B.1.5)
$\Pi_d = [340.001178553439, 1.08088833077722, 0.000121546628319535, 2.81291284811141]$	3	(B.1.6)
CS4 – Aspirator	<i>k</i>	
$\Pi_a = [577.8596, -3.2891, 5.2673, -153.9212, 289.8818, -87.0775, 3.4353, -10.9097, -9.331, 0.0395, 0.0599, 1.6257, 0.0016, 3.0964, -0.0043, -0.0302, -1.5718, 0.0057, -11.5309, -17.0486, 1.8883, 1.786, 1.5888, 1.7508, 1.7694, -0.9057, 1.5073, 4.0771, 65.2409218547914, 0.0480945256579872, 0.0198855386985386, -0.809154758491877, -8.1992, 4.5426, 2.9869, 1.8856, 5.8482]$	4	(B.1.7)
$\Pi_d = [-365.3262, -26.279, 524.3904, -504.5321, -318.4183, -46.681, -29.347, -66.1377, 17.1111, 0.1642, 2.1596, 0.0176, 5.28, -37.0919, 1.8556, 0.4427, 0.0057, -11.7895, -1.4143, -0.0069, 2, 1.9968, 1.625, 1.3496, 1.8056, 1.6721, 2.737, 2.1405, -63.6939159460682, 0.0234186290661995, 0.0635533627287685, 0.855256179576457, 1.2528, 9.3844, 2.7107, 0.6983, 1.9099]$	4	(B.1.8)
2. Consumatori simpli – algoritm de tip PSO		
CS1* – LCD	<i>k</i>	
$\Pi_a = [24.6352264512093, -0.459467958553743, 76.8777834214771, 50, -0.0766513651717538, 477.271531328175]$	2	(B.2.1)
$\Pi_d = [41.455319373869, 0.0612671864156738, 415.526520120843, 50, 0.432329310768815, 180.912181623888]$	2	(B.2.2)

CS2* – Laptop	k	
$I_{I_a} = [267.381970841887, -0.00114708474037109, 849.93128761897, 399.981798482973, -0.048212195710405, 619.913697873717]$	2	(B.2.3)
$I_{I_d} = [697.260330620509, 0.0273707447870813, 319.86128126094, 399.954786796045, 0.0107118298495593, 388.647175029793]$	2	(B.2.4)
CS3* – Frigider	k	
$I_{I_a} = [340.001285436733, 1.12486688784924, 0.0349365158344447, 4.64311981336065]$	3	(B.2.5)
$I_{I_d} = [340.001177970937, 1.08125780204672, 0, 2.81867640584178]$	3	(B.2.6)
CS4* – Aspirator – cu corecția $f_{cor2}(v)$	k	
$I_{I_a} = [350, -349.1727283, 319.1747856, -349.999988, 343.4647954, 2.180355129, 2.064035099, 99.98932193, 2.000000418, 2.000000538, 34.45915045, -0.002978273, 99.05335748, -0.01, 0.017318959, -12.18373382, -29.84205223, -75.72858221, -0.015370488, -99.96043414, 1.00003777, 1.000133257, 1.999981438, 1.9997608, 1.999999427, 15.6082258, 15.22558399, -16.64696403, -54482500000000, 58013300000000, -201310000000, -0.001971095, 0.001760123, 75.1046324843749, 0.029902063713858, 0.0526879813528334, -0.889048479839695]$	4	(B.2.7)
$I_{I_d} = [-350, -319.6257101, 349.1687905, 349.9996025, 319.0445957, 2.058954027, 3.89752444, 99.89482587, 2, 31.07511895, 10.60472362, 0.138938343, 98.94400904, 0.015308066, 99.50312455, -0.016846802, -4.269049019, -94.82294254, -89.29052471, -72.6215539, 1, 1.989629213, 1.974057224, 1, 1.268306098, -23.89479311, -24.97905469, 16.55932881, -0.001225803, -73.9475951, 108791000000, -0.001973014, 697239093.9, -63.7811997936079, 0.0404731390523191, 0.0484850045771089, 0.786949403393077]$	4	(B.2.8)
3. Consumatori 2 multipli -AG		
CS5 – varianta 1	k	
$I_{I_{2,a}} = [23.9810137307397, -0.422945103938825, 210.098167868941, 50.0054712945244, -0.127935082261758, 381.379511619863]$	2	(B.3.1)
$I_{I_{2,d}} = [52.4393268958068, 0.112392683774571, 354.191975810474, 50.0003643044887, 0.422217612585275, 430.292755758633]$	2	(B.3.2)
CS6 – varianta 1	k	
$I_{I_{4,a}} = [-526.623656925563, -105.731901842488, 537.44670607972, 475.446282487041, 178.638210702301, -29.0153903911796, 1.30691295215106, -13.2226949571077, 9.09321256510226, -0.137038373564356, 13.2247203855357, 0.00731706712727692, 35.4053425425584, 7.79623220707127, 0.0126674300763483, -0.00657226298694924, -0.00140239853217772, 8.47213941920348, 16.1583513806619, 0.0308974528264109, 1.97605746833198, 1.49069046147626, 1.37970738008968, 1.99280748020868, 1.445068359375, -0.0919199259565708, -2.44491526107674, -0.21346228486985,$	4	(B.3.3)

14.8837193910023, 0.00412558594013035, 8.58070650334716, -1.78583301256016, 0.543082093933521, 99.1714453887278, 0.00591176809895044, 0.0389636015486463, -1.85411682128906]		
$\Pi_{4,d} = [403.170291577901, -312.051378602522, -377.911701430299, 12.3902400512224, -467.764365307662, -52.7956148078173, 3.86979063588326, 0.798118948967034, 0.798694581626659, -70.6041166978689, 0.0134552408579286, 25.856779041709, 49.9698073478918, 49.9999931499069, 6.58751986219757, 3.91482826543743, -0.734595800524648, -27.7113743753913, -0.00119620025134337, -0.00835665554632214, 1.9658461853101, 1.90578027072179, 1.8662109375, 1.96926189933176, 1.897822388428, -1.53003133911076, 0.519866848032189, -0.728370383046442, 11.6482581216659, -0.0770750132149196, 9.13574874336712, 0.109327307144663, -4.39204588721655, -77.5389842126472, 0.0282440185546875, 0.00449244415601413, 1.40489380951861]$	4	(B.3.4)
CS5 – varianta 3 – ramura ascendentă	k	
$\Pi_{2,a,0.8} = [556.03, -0.47, 534.11, 50.03, -0.02, 585.43]$	2	(B.3.5)
$\Pi_{4,a,0.2} = [-330.00, -172.97, 330.00, -0.56, -2.82, -1.91, -0.28, 0.33, -0.10, -0.12, -0.09, 0.20, -0.18, -0.18, 0.19, 1.00, 1.83, 2.00, 1.00, 1.94, 2.00, 0.58, 119.96, 0.01, 0.01, -0.42, 0.20, -11.59, -188.84, 31.90, 0.22, 16.14]$	4	(B.3.6)
CS5 – varianta 3 – ramura descendentă	k	
$\Pi_{2,d,0.8} = [227.51, -0.20, 742.48, 73.12, 0.20, 229.12]$	2	(B.3.7)
$\Pi_{4,d,0.2} = [-330.00, 196.48, 330.00, -2.86, 0.30, -0.50, -0.18, -2.71, -0.02, 0.15, 0.01, 0.18, -0.02, 0.11, -0.18, 1.00, 1.99, 2.00, 1.00, 1.86, 2.00, 2.45, -82.91, 0.73, 0.98, 2.04, 3.39, -0.08, -36.24, -3.95, 3.72, -6.12]$	4	(B.3.8)
CS6 – varianta 3 – ramura ascendentă -sol 1	k	
$\Pi_{4,a,0.985} = [-330, -88.45682442, 330, -0.886627393, -0.1605959, -0.139920452, -2.961244482, 0.331960325, -0.606538542, -0.126281126, -0.007081717, 0.003747776, -0.193727474, -0.016503071, 0.06101668, 1, 1.495258987, 2, 1, 1.645819353, 2, -1.644319602, 59.60375292, 0.025791006, 0.012781753, -1.18456939, 2.397929641, 5.387719145, 21.4033764, -0.005029314, -1.313289822, 0.949587649]$	4	(B.3.9.1)
$\Pi_{4,a,0.015} = [-330, -214.8841888, 330, -0.187740679, 1.266305623, -0.002663143, -2.988015647, 0.917751051, -0.241920167, -0.004266573, 0.038148773, 0.058082053, -0.191262526, -0.118784223, 0.185899854, 1, 1.272896179, 2, 1.601771352, 2, -13.6482072, 77.98802887, 0.325548382, 0.00302769, -4.998870972, 3.539275922, 2.387108621, 234.9170775, -0.00297658, -8.712786589, -4.671751987]$	4	(B.3.10.1)
CS6 – varianta 3 – ramura descendentă -sol 1	k	
$\Pi_{3,d,0.015} = [617.5344397, 1.001820073, 1.73558E-05, 49.99807013]$	3	(B.3.11.1)
$\Pi_{4,d,0.985} = [-330, -281.0068316, 330, -0.422513103, 1.468095482, -0.621639412, -1.525593683, 0.940312772, -$	4	(B.3.12.1)

0.007492236, 0.08659972, 0.015285928, -0.006155645, 0.013493475, -0.012187864, 0.168646641, 1, 1.597097378, 2, 1, 1.812436858, 2, 0.786945874, -66.86886724, 0.017088726, 0.025757337, 1.149448916, -1.052872026, -0.027335466, - 3.787297011, 17.05746886, 0.056786824, 8.421205757]		
CS6 – varianta 3 – ramura ascendentă – sol 2	k	
$\Pi_{1,a,0.8} = [699.998909318204, -0.179005985776793,$ $412.977568055416, 274.998502471456, 228.4032278838]$	1	(B.3.9.2)
$\Pi_{4,a,0.8} = [342.107914602809, 268.220632815737,$ $347.54702313869, -0.109531801245887, 1.71325877688563, -$ $0.130898116893685, -1.12348336083117, 0.22845644084029, -$ $2.25881054541029, 0.0101511122480373, 0.0583720977120426,$ $-0.00432972234474605, 0.0869579625042019,$ $0.0298157256384725, 0.1220002457993, 1, 1.98924972681165,$ $2, 1, 1.53430647376904, 2, 17.6486405571567, -$ $97.2394531350089, 0.0575785635587032, -10.4824528737349,$ $12.812910542291, 0.17340065576655, 9.01218388200002, -$ $0.248143079428116, 19.6261170588167, 3.15126710310171,$ $6.39890920286169]$	4	(B.3.10.2)
CS6 – varianta 3 – ramura descendentă – sol 2	k	
$\Pi_{1,a,0.8} = [660.928044461764, 0.0896784520424267,$ $339.60647212933, 326.892958177487, 522.922421416142]$	1	(B.3.11.2)
$\Pi_{4,a,0.8} = [284.122867720846, -283.234835745807,$ $330.012614199795, -0.364302621398811, 0.729901820484153,$ $0.000951745358505285, -0.703058113414256, -$ $0.240215133893103, -1.03201994862408, -$ $0.00879262380706289, 0.120903930260473,$ $0.147814299114008, 0.107920623107056,$ $0.00810117427605467, 0.173731303917773, 1.8879346597708,$ $1.06638644189283, 2, 1.78230436053549, 1.84780694244607,$ $2, 3.86529971246875, -3.56484431885107, -2.99575726989026,$ $118.673344873166, -11.8084578260853, 2.54103726989433,$ $8.89006138121967, 2.37058327080581, 0.00346656416742874,$ $8.11575588081861, -2.87053137246058]$	4	(B.3.12.2)
4. Consumatori 2 multipli - PSO		
CS5* – varianta 1	k	
$\Pi_{2,a} = [11.3330880530237, -0.475065632126083,$ $93.3090802854651, 100.584248598455, -0.141567246708934,$ $899.928592407306]$	2	(B.4.1)
$\Pi_{2,d} = [26.0352907741588, 0.0838726227010311,$ $168.727173793192, 73.5325467860045, 0.376566292481871,$ $900]$	2	(B.4.2)
CS6* – varianta 1	k	
$\Pi_{4,a} = [313.023060157691, 300.203579100977,$ $340.27152792292, -294.793003358737, 350, 59.9399317050121,$ $100, 60.1330129023309, 2.0000124999653, 2,$ $26.9411398969154, 99.9942461528783, 21.360295707487, -$ $0.00984585826412312, 0.0121443498712429, 0.01, -$ $78.8106978349374, -100, -0.0241996952137589, -$ $99.9543148962278, 1.70292990114498, 1.86632923142503,$ $1.98703767806638, 1, 1.18204454087899, -24.999962957737, -$ $14.5641202382254, -8.2262496747109, 163890.851836305, -$ $66003110679720.7, -220001955509994, -0.00350290112445616,$	4	(B.4.3)

-0.000499111336055059, 50.0108001667906, - 0.000999999993023722, 0.00605279355393223, - 1.66423361429587]		
$\Pi_{4,d} = [-349.987215404255, -305.227170732367, -$ 349.999922536497, -350, 348.700678717648, 5.27349473721419, 10.6371505560307, 2, 2, 2.00013013157439, 99.9653927082407, 90.5776268064597, 99.9796811347077, 25.3829353782124, 0.0165762634636333, - 99.999927959241, -40.2433223004594, -67.4693676441702, - 0.0209546288964384, -0.212480680190962, 1.08915962718111, 1.0000060463589, 1.0431270191024, 1.66637145964725, 1.82621766859823, 3.3893894675437, -24.9985612860601, - 19.0642347523259, -52871221.8133487, 10152.1696060672, 8438550509.45244, -0.00150665129412882, 0.00264424534477458, -119.998189675242, -0.001, 0.0114596946159386, -1.84546215166005]	4	(B.4.4)
CS6* – varianta 3 - ramura ascendenta	k	
$\Pi_{1,a,0.975} = [699.99607056333, 0.0696774025831044,$ 117.12645005676, 104.000000016293, 268.69964820306]	1	(B.4.5)
$\Pi_{4,a,0.975} = [-303.079666815086, 28.6898383929624,$ 330.000083297318, -0.0874348877795156, 0.192695681845924, 0.000999959587919252, -0.139577595584099, 1.00457878260129, -2.99760078588273, -0.0594608027698807, -0.00536408055312401, 0.0480424662223139, 0.00750029425025269, -0.0435817638253352, - 0.199986340677953, 1, 1.99990824318091, 2, 1, 1.83577914157062, 2, -16.125709527158, -21.7520267534481, - 26.1887494185556, 99.999221336665, 10.4901765382543, - 6.53770489388779, -99.999999949014, 60.3602591550017, 0.00152700808585359, 0.990218756273806, 0.0999990961861584]	4	(B.4.6)
CS6* – varianta 3 - ramura descendenta	k	
$\Pi_{1,d,0.975} = [173.366231099761, -0.199772151824137,$ 849.944897956825, 399.900162488422, 72.4324587224394]	1	(B.4.7)
$\Pi_{4,d,0.975} = [37.0455038835253, -67.4233894744399,$ 330.0023866421, -0.316554566110823, 0.0396161768884655, 0.00099867571318703, -0.040192023468584, 0.0996383393720681, -0.000001982802949662, - 0.0102629515044093, 0.0265786547794379, 0.0450384713289231, -0.0024551606244637, 0.00515866118240255, 0.199997175339333, 1.95584625396921, 1.3361628762303, 2, 1.25865484272117, 1.99976990977736, 2, -24.9996570978965, -72.8539665903627, -74.6467230396364, - 99.9994596058462, -27.7709066850005, 44.4687462769286, 99.2136082517549, -50.0000551819639, 0.00563606761754018, 0.136244546654736, 4.99998073893915]	4	(B.4.8)

Anexa C. Implementarea Matlab

C.1 Funcții MATLAB de implementare a funcțiilor suport și condiții de adecvare

În această secțiune se prezintă implementarea MATLAB a celor 5 funcții suport asociate celor patru clase k , condițiile de adecvare și funcții suport asociate $c-2.m$. Claselor $k = 1...3$ le corespund subsecțiunile (C.1.1 – C.1.3). Clasei hibride i-au fost asociate două funcții suport: prima folosită în identificarea unui consumator simplu (C.1.4-a), a doua folosită în identificarea unui consumator $c-2.m$ (C.1.4-b). Subsecțiunea C.1.5 prezintă implementarea condițiilor de adecvare. Secțiunea se finalizează cu subsecțiunea C.1.6 ce conține implementarea MATLAB a generării funcțiilor suport aferente unui combinații de tip C_{ij} specifică identificării componenței unui $c-2.m$.

Considerentele teoretice aferente implementărilor MATLAB enumerate mai sus apar în secțiunile 3.4 și 3.7.

C.1.1. Implementarea funcției suport pentru clasa tangentă ($k=1$)

Funcția suport clasa tangentă $k = 1$ cu referire (3.22)

```
function Y=Class_tg(par,X)
%{
-----
Funcție suport clasa tangenta k=1
Intrari :par    — vector parametri asociati expresiei analitice aferente clasei
                tangenta k = 4,
            X    — marimi masurate [tensiune curent]
Iesire : Y     — vector curent momentan estimat
-----
}%
global Value_a Value_d CurveType dl dr
fun=[];Y=[];fun1=[];fun2=[];
Vmin=-330; Vmax=330;

%conditii de adecvare (3.16)
dl=(-pi/2)*par(3)+par(3)*0.0001-Vmin;
dr=(pi/2)*par(5)-par(5)*0.0001-Vmax;

fun1=1/par(1)*tan( (X(:,1)+dl )*(1/par(3)) )+( 1/par(4)*tan(dr/par(5))-
1/a(1)*tan(dl/par(3)));
fun2=1/par(4)*tan( (X(:,1)+dr )*(1/par(5)) );
fun=fun1.*(1-sign(X(:,1)))/2 +par(2)+ fun2.*(1+sign(X(:,1)))/2;
Y=fun;
end
```

C.1.2. Implementarea funcției suport pentru clasa tangentă discontinuă ($k = 2$)

Funcția suport clasa tangentă discontinuă $k = 2$ cu referire la (3.4)

```
function Y=Class_tg_disc(par,X)
%{
-----
Funcție suport clasa tangenta discontinua k=2
Intrari :par    — vector parametri asociati expresiei analitice aferente clasei
                tangenta discontinua k = 2,
           X    — marimi masurate [tensiune curent]
Iesire  : Y    — vector curent momentan estimat
-----
}%
..global Value_a Value_d CurveType dl dr;
fun=[];Y=[];fun1=[];fun2=[];
Vmin=-330;Vmax=330;

%conditii de adecvare (3.6)
dl=(-pi/2)*par(3)+par(3)*0.0001-Vmin;
dr=(pi/2)*par(6)-par(6)*0.0001-Vmax;

if CurveType=='a'
    va=-100;
else
    va=100;
end
fun1=1/par(1)*tan( X(:,1)+dl )*1/par(3) +par(2);
fun2=1/par(4)*tan( X(:,1)+dr )*(1/par(6)) +par(5);
fun=fun1.*(1-sign(X(:,1)-va))/2+ fun2.*(1+sign(X(:,1)-va))/2;
Y=fun;
end
```

C.1.3. Implementarea funcției suport pentru clasa elipsă ($k = 3$)

Funcția suport clasa elipsă $k = 3$ cu referire la (3.23)

```
function Y=Class_ell(par,X)
%{
-----
Funcția suport clasa elipsa k=3
Intrari :par — vector parametri asociati expresiei analitice aferente clasei elipsa k
                = 3,
           X  — marimi masurate [tensiune curent]
Iesire  :Y   — vector curent momentan estimat
-----
}%
global CurveType
Y=[]; Y1=[]; Y2=[];
Vmax=340; Vmin=-340;a=par(1);b=par(2);A=par(3);K=par(4);

Y1=((a/Vmax)^2-1)*X(:,1).*sqrt((Vmax^2-b^2)/(a^2-Vmax^2))...
```

```

-a*b/Vmax*sqrt(1-(X(:,1)/Vmax).^2).*(1+A*sin(3*pi*(X(:,1)...
-Vmin)/(Vmax-Vmin))).*exp(abs(X(:,1))/(K*Vmax));
Y2=((a/Vmax)^2-1)*X(:,1).*sqrt((Vmax^2-b^2)/(a^2...
-Vmax^2))+a*b/Vmax*sqrt(1-(X(:,1)/Vmax).^2)...
.*(1+A*sin(3*pi*(X(:,1)-Vmin)/(Vmax-Vmin))).*exp(abs(X(:,1))...
/(K*Vmax));
if CurveType=='a'
    Y=Y1;
else
    Y=Y2;
end
end
end

```

C.1.4. Implementarea funcției suport pentru clasa hibridă ($k = 4$)

Sunt menționate cele două funcții suport aferente clasei hibride atât cea folosită în cazul consumatorului simplu, cât și cea folosită în cazul $c-2.m$.

a) Funcția suport clasa hibridă $k = 4$ cu referire la (3.31) — consumator simplu

```

function Y=Class_hib(par,voltage)
%{
-----
Funcția suport clasa hibrida k=4 (aplicabila in cazul determinarii semnaturii
consumatorului simplu)
Intrari :par — vector parametri asociati expresiei analitice aferente clasei hibride
k = 4,
        X   — marimi masurate [tensiune curent]
Iesire  :Y   — vector curent momentan estimat
-----
}%
global I1 I5
Y=0;
V=par(1,1:5);
n= par(1,6:10);
bl= par(1,11:15);
br= par(1,16:20);
s= par(1,21:25);
Vx= par(1,34);
k= par(1,35:37);
a= par(1,29:33);
% determinarea celor 2 curentii I1 si I5 conform conditiilor de adecvare (3.35)
[I1,I5]=determinareI1I5(n,bl,br,s,a,V, par(26:28),k,Vx);
Current=[I1, par(1,26:28),I5];
for j=1:5
    Y= Y+( Current(j)+(sign(X(:,1)-V(j))).^round(s(j)).*a(j)...
    .*abs(X(:,1)-V(j))).^n(j)).*exponent(X(:,1),bl,br,V,j);
end
Y=Y+k(3)*exp(-(k(1)*(1-sign(X(:,1)-Vx))+k(2)*(1+sign(X(:,1)...
-Vx))).*abs(X(:,1)-Vx));
end
end

```

a) Funcția suport clasa hibridă $k = 4$ cu referire la (3.32) — $c-2.m$

```

function Y=Class_hib(par,X)
%{
-----
expresie analitica clasa hibrida k=4 (aplicabila in determinarea semnaturii
consumatorului 2 multiplu)
Intrari :par — vector parametri asociati expresiei analitice aferente clasei hibride
          k = 4,
          X  — marimi masurate [tensiune curent]
Iesire  :Y   — vector curent momentan estimat
-----
}%
global I1 I3
Y=0;
V=par(1,1:3);
nl=par(1,4:6);
nr= par (1,7:9);
bl= par (1,10:12);
br= par (1,13:15);
sl= par (1,16:18);
sr= par (1,19:21);
al= par (1,23:25);
ar= par (1,26:28);
Vx= par (1,29);
k= par (1,30:32);
% determinarea celor 2 curentii I1 si I3 conform conditiilor de adecvare (3.36)
I1=Value_a(1,2);
I3=Value_a(end,2);
Current=[I1,par(1,22),I3];

for j=1:3
    Y= Y+ Current(j)+...
        +((sign(X(:,1)-V(j))).^round(sl(j)).*al(j).*(abs(X(:,1)-V(j))).^nl(j))...
        .*exp( bl(j).*(X(:,1)-V(j))).*( 1-sign(X(:,1)-V(j)) )/2...
        .*((sign(X(:,1)-V(j))).^round(sr(j)).*ar(j).*(abs(X(:,1)-V(j))).^nr(j))...
        .*exp( br(j).*(X(:,1)-V(j))).*( 1+sign(X(:,1)-V(j)) )/2;
end
Y=Y+k(3)*exp(-(k(1)*(1-sign(X(:,1)-Vx))+k(2)*(1+sign(X(:,1)...
-Vx))).*abs(X(:,1)-Vx));
end

```

C.1.5. Condiții de adecvare

- Condiții de adecvare — Restricții neliniare aplicabile clasei tangentă $k = 1$ cu referire la (3.16), (3.19), (3.20)

```

function [c, ceq]=nonlconstrain_Tg(par)
%{
-----
Implementare conditii de adecvare pentru clasa k=1.
Intrari :par — vector parametri asociati expresiei analitice aferente clasei
          tangente sau clasei tangente discontinue;
Iesire  :c   — matricea de inegalitati neliniare;

```

```

ceq.— matrice d eecuatii neliniare;
-----
}%
global dl dr;
Vmin=-330; Vmax=330;

dl=(-pi/2)*par(3)+par(3)*0.0001-Vmin;
dr=(pi/2)*par(5)-par(5)*0.0001-Vmax;

%conditiile de adecvare (3.19)
c(1)=-a(1)*a(3);
c(2)=-a(4)*a(5);
c(3)=abs(dr/par(5))-pi/2+0.0001;
c(4)=abs(dl/par(3))-pi/2+0.0001;

fun1=1/par(1)*tan( (-5+dl )*(1/par(3)) )+( 1/par(4)*tan(dr/par(5))...
-1/par(1)*tan(dl/par(3)));
fun2=1/par(4)*tan( (5+dr )*(1/par(5)) );

%diferenta functiilor apropape 0 in vecinatatea lui V = 0 (tensiunea a fost
considerata V=5V)
c(5)=fun2-fun1-0.001;

ceq=[];
end

```

- Condiții de adecvare — Restricții neliniare aplicabile clasei tangentă discontinuă $k = 2$ cu referire la (3.6), (3.8), (3.11)

```

function [c, ceq]=nonlconstrain_TgD(par)
%{
-----
Implementare conditii de adecvare pentru clasa k=2.
Intrari :par — vector parametri asociati expresiei analitice aferente clasei
tangente sau clasei tangente discontinue
Iesire :c — matricea de inegalitati neliniare
ceq.— matricea de ecuatii neliniare
-----
}%

global CurveType dl dr Value_a Value_d;
Vmin=-330;Vmax=330;c=[];ceq=[];

dl=(-pi/2)*par(3)+par(3)*0.0001-Vmin;
dr=(pi/2)*par(6)-par(6)*0.0001-Vmax;

if CurveType=='a'
Vmin=min(Value_a(:,1));
Vmax=max(Value_a(:,1));
va=-100;
else
Vmin=min(Value_d(:,1));

```



```

    Vmax=max(Value_d(:,1));
    va=100;
    end
    fun1=1/par(1)*tan( (va+dl )*(1/par(3) )+par(2);
    fun2=1/par(4)*tan( (va+dr )*(1/par(6)) )+par(5);
    c(1)=fun1-fun2+0.0001;

    c(2)=-par(1)*par(3)+0.0001;
    c(3)=-par(4)*par(6)+0.0001;
    c(4)=abs(dr/par(6))-pi/2+0.0001;
    c(5)=abs(dl/par(3))-pi/2+0.0001;

    Al=fix((Vmin+dl )*(1/(par(3)*pi)-1/2);
    Bl=fix((va+dl )*(1/(par(3)*pi)-1/2);
    Ar=fix((Vmax+dr )*(1/(par(6)*pi)-1/2);
    Br=fix((va+dr )*(1/(par(6)*pi)-1/2);
    ceq=[Al-Bl,Ar-Br];

    end

```

C.1.6. Generarea funcțiilor suport asociate unei combinații

Determinarea expresiei analitice, funcției suport, asociate unei combinații de tip $\{C_{ij} \mid i \leq j, i, j \in \{1, 2, 3, 4\}\} / \{C_i \mid i \in \{1, 2, 3, 4\}\} \rightarrow (p \cdot S_{i,r}(v) + (1-p) \cdot S_{j,r}(v)) / S_{i,r}(v)$; impunerea intervalelor de variație parametrilor funcției suport determinate.

```

function [nr_parameters, lb_a, ub_a, lb_d, ub_d]=ConstructHandler(k, p)
%{
-----
Generare functie suport asociate unei combinatii (Si,r(v)+Sj,r(v)) cazul a doi
consumatori, sau cazul unui consumator simplu Si,r(v)
Intrari: k                — tipul consumatorului (1/2 → consumator simlu/
                        c-2.m
          p                — ponderea
Iesire : nr_parameters    — nr. parametri asociati functiei suport
          lb_a, ub_a, lb_d, ub_d — vectorul limitelelor inferioara, respectiv
                        superioara de variatie pentru cele doua ramuri
                        ascendenta, respectiv descendenta
-----
%}
global sol CurveType functionHandle;

%initializare intervale parametrui
[parameters, classes]=init_matrix_of_classes();
lb_a=[]; ub_a=[]; lb_d=[]; ub_d=[];

for i=1:k
    if(CurveType=='a')
        o=2*sol(i)-1 ;
    else
        o=2*sol(i);

```

```

end
lb_a =[lb_a parameters(o, 3:parameters(o,2)+2) ];
ub_a =[ub_a parameters(o, parameters(o,2)+3:2*parameters(o,2)+2 )];
lb_d =[lb_d parameters(o, 3:parameters(o,2)+2) ];
ub_d =[ub_d parameters(o, parameters(o,2)+3:2*parameters(o,2)+2 )];
end
limit_inf=1;
store = cell(2,k);

for i=1:k
    if(CurveType=='a')
        o=2*sol(i)-1 ;
    else
        o=2*sol(i);
    end
    limit_sup=parameters(o,2)+limit_inf-1;
    store{1,i}=...
    sprintf('%s(a(%d:%d),x)',char(classes(o,1)),limit_inf,limit_sup);
    store{2,i}=['+',num2str(1-p),'*'];
    limit_inf=limit_sup+1 ;
end

nr_parameters=limit_sup;

funStr=['@(a,x)',num2str(p),'*', store{1:end-1}];
functionHandle=str2func(funStr);
if sol(1)==4 && k==1
    lb_a(29:33)= -Inf ;
    ub_a(29:33)= Inf ;
    lb_d(29:33)=-Inf ;
    ub_d(29:33)=Inf;
    return
end
if sol(1)==4
    lb_a(23:28)=-Inf;
    ub_a(23:28)=Inf;
    lb_d(23:28)=-Inf;
    ub_d(23:28)=Inf;
end
if sol(2)==4
    lb_a(end-9:end-4)=-Inf;
    ub_a(end-9:end-4)=Inf;
    lb_d(end-9:end-4)=-Inf;
    ub_d(end-9:end-4)=Inf;
end
end

```

C.2 Implementarea MATLAB a algoritmului de alocare

În secțiunea curentă se prezintă cele două variante ale algoritmului de alocare ce au ca rezultat generarea celor două submulțimi M_a și M_d . Prima variantă se aplică

claselor tangentă, tangentă discontinuă, elipsă (c) a doua clasei hibride (d). Cele două variante sunt precedate de calcularea lui V_z (a), parametru ce delimitează cele trei zone două verticale și una orizontală necesare generării celor două submulțimi.

- a. Delimitarea zonelor orizontale, respectiv verticale prin calcularea tensiunii de referință V_z cu referire la subsecțiunea 3.6.1

```
function [Vz, VALUE]=determine_V(path,sheets_name)
%{
-----
Determinarea valorii tensiunii Vz ce delimiteaza zonele verticale de cele orizontale
Intrari : path          — calea asociata fisierului de masuratori (...//date.xlsx)
          sheets_name   — numele shhetului ce contine masuratorile
                        consumatorului studiat
Iesire  : Vz            — valoarea tensiunii de referinta
          VALUE         — matricea valorile de tensiune, curent masurate
                        ([tensiune curent])
-----
}%

pas=10; VALUE=[]; intervale=[]; Voltage_Value=[];
TypeOfZone=[];nr_points=[];
VALUE=xlsread(strcat(path,'date.xlsx'),sheets_name);
VALUE=sortrows(VALUE);
l=1;
Vmin=min(VALUE(:,1));
Vmax=max(VALUE(:,1));
V=Vmin;
k=1;
nr_points_max=0;

while(V<=Vmax)
    if(Vmax-(V+pas)<pas)
        nr_points(l)=sum((VALUE(:,1)>=V )& (VALUE(:,1)<Vmax));
        V=Vmax;
        Voltage_Value(k)=V;
    else
        nr_points(l)=sum((VALUE(:,1)>=V )& (VALUE(:,1)<V+pas));
        Voltage_Value(k)=V+pas;
    end
    if(nr_points_max<nr_points(l))
        nr_points_max=nr_points(l);
    end
    l=l+1;
    V=V+pas;
    k=k+1;
end
nr_points=1/nr_points_max*nr_points;

%se determina tipul zonei
for i=1:length(nr_points)
    if nr_points(i)>0.3
        TypeOfZone(i)=1;
    end
end
```

```

else
    TypeOfZone(i)=0;
end
end
end
i=1;k=1;test=0;
while (i<=length(TypeOfZone) )
    while(i<=length(TypeOfZone)&&TypeOfZone(i)==0)
        if(i==1 && test==0)
            intervale(k,1)=Vmin;
        else
            if(i~=1 && test==0)
                intervale(k,1)=Voltage_Value(i-1);
            end
        end
        intervale(k,2)=Voltage_Value(i);
        intervale(k,3)=TypeOfZone(i);
        i=i+1;
        test=1;
    end
    if(test==1)
        k=k+1;
        test=0;
    end
    while(i<=length(TypeOfZone)&&TypeOfZone(i)==1)
        if(i==1 && test==0)
            intervale(k,1)=Vmin;
        else
            if(i~=1 && test==0)
                intervale(k,1)=Voltage_Value(i-1);
            end
        end
        intervale(k,2)=Voltage_Value(i);
        intervale(k,3)=TypeOfZone(i);
        i=i+1;
        test=1;
    end
    if(test==1)
        k=k+1;
        test=0;
    end
end
end
Vz= min(abs(intervale(1,2)),abs(intervale(3,1)));
end

```

- b. Algoritm de alocare — determinarea celor două submultimi M_a respectiv M_d cu referire la expresiile (3.39), (3.40)

```

function[Ma, Md] =GenerateCDcurve_(FileName, X, CurrentLimit, Vz,
IntervalNumber, SheetsName_A, SheetsName_D)
%{

```

Se determina cele doua submultimi Ma si Md.

```

Intrari : FileName      — numele fisier „.xlsx” in care se salveaza submultimile
                        Ma si Md
                X        — matricea masuratorilor [tensiune curent]
                Vz       — tensiunea de referinta (delimiteaza zona orizontala de
.....cele verticale)
                SheetsName_A — nume sheet in care se salveaza Ma
                SheetsName_D — nume sheet in care se salveaza Md
                IntervalNumber — numarul de intervale considerate pe zona orizontala
                CurrentLimit  — limita de curent ce impune eliminarea unui set de
                        puncte din zona de curbura a celor doua extremitati
                        din stanga si dreapta
Iesiri :  Ma           — submultimea de puncte asociate curbei ascendente
                Md      — submultimea de puncte asociate descendente
-----
%}
Ma=[];Md=[];l=1;r=1;i=1;sum=0; contor=1;
%-----
%se trateaza zona din stanga, intervalul
%din acest interval se exclude perechile de puncte pentru care valorile de curent
%sunt mai mari sau egale -0.1
%-----
while(X(i,1)<=-Vz)
    if(X(i,2)<=-CurrentLimit)
        sum=sum+X(i,1);
        contor=contor+1;
    end
    i=i+1;
end
sum=sum/(contor-1);
i=1;
while(X(i,1)<=-Vz)
    if (X(i,2)<=-CurrentLimit)
        if (X(i,1)<=sum)
            X(i,3)='D';
            Md(l,1)=X(i,1);
            Md(l,2)=X(i,2);
            l=l+1;
        else
            X(i,3)='A';
            Ma(r,1)=X(i,1);
            Ma(r,2)=X(i,2);
            r=r+1;
        end
    end
    i=i+1;
end
end
end
%-----

```

```

% se trateaza zona de mijloc
% se calculeaza media de curent pe intervale de 10 V
%-----
pas=abs(-Vz-Vz)/IntervalNumber;
Step=-Vz;
while (X(i)<=Vz)
    sum=0;
    contor=1;
    k=i;
    while(X(i)<=(Step+pas))
        sum=sum+X(i,2);
        contor=contor+1;
        i=i+1;
    end
    sum=sum/(contor-1);
    j=k;
    while(X(j)<=(Step+pas))
        if (X(j,2)<=sum)
            X(j,3)='A';
            Ma(r,1)=X(j,1);
            Ma(r,2)=X(j,2);
            r=r+1;
        else
            X(j,3)='D';
            Md(l,1)=X(j,1);
            Md(l,2)=X(j,2);
            l=l+1;
        end
        j=j+1;
    end
    Step=Step+pas;
End
end
%-----
%se trateaza zona din stanga, din acest interval se exclud perechile de puncte
%pentru care valorile de curent sunt mai mici sau egale 0.1
%-----
k=i;sum=0;contor=1;
while (i<=length(X(:,1)))&& (X(i,1)>Vz)
    if(X(i,2)> CurrentLimit)
        sum=sum+X(i,1);
        contor=contor+1;
    end
    i=i+1;
end
sum=sum/(contor-1);
i=k;
while (i<=length(X(:,1)))&&(X(i,1)>Vz)
    if (X(i,2)> CurrentLimit)
        if (X(i,1)<=sum)
            X(i,3)='D';
        end
    end
end

```

```

                Md(l,1)=X(i,1);
                Md(l,2)=X(i,2);
                l=l+1;
            else
                X(i,3)='A';
                Ma(r,1)=X(i,1);
                Ma(r,2)=X(i,2);
                r=r+1;
            end
        end
    end
    i=i+1;
end
xlswrite(FileName,Ma,SheetsName_A,'A1')
xlswrite(FileName,Md,SheetsName_D,'A1')
end

```

c. Algoritm de alocare — determinarea celor două submultimi M_a respectiv M_d cu referire la expresiile (3.41), (3.42) — clasă hibridă

```

function[Ma, Md] =GenerateADcurve(FileName, X, Vz, SheetsName_A,
SheetsName_D)
%{
-----
Functia determina cele doua submultimi Ma si Md. — cazul clasei hibride,
consumator 2.m
Intrari : FileName      — nu fisier .xlsx in care se salveaza submultimile Ma si
                        Md
           X             — masuratori [tensiune curent]
           Vz           — tensiunea ce delimiteaza zona orizontala de cele
                        verticale
           SheetsName_A — nume sheet in care se salveaza Ma
           SheetsName_D — nume sheet in care se salveaza Md
Iesiri  : Ma            — submultimea de puncte asociate curbei ascendente
           Md            — submultimea de puncte asociate descendente
-----
%}

Ma=[];Md=[];Suma_dr=[];Suma_st=[];Rezultat_dr=[];
Rezultat_st=[];puncte=[];
l=1;r=1;i=1; sum=0;contor=1;
%-----
%se trateaza zona din stanga
%-----
Step=min(X(:,1));
while (X(i,1)<=-Vz)
    if(X(i,1))>=-315
        pas=1.5;
    else
        pas=0.5;
    end
    sum=0;contor=1; k=i;
    while(X(i,1)<=(Step+pas))
        sum=sum+X(i,2);
    end
end

```

```

        contor=contor+1;
        i=i+1;
    end
    sum=sum/(contor-1);
    Suma_st=[Suma_st;sum];
    if length(Suma_st)~=1 &&
    Suma_st(length(Suma_st))<Suma_st(length(Suma_st)-1)
        Suma_st(length(Suma_st))=Suma_st(length(Suma_st)-1);
        sum=Suma_st(length(Suma_st));
    end
    Rezultat_st=[Rezultat_st;Step+pas/2,sum];
    j=k;
    while(X(j)<=(Step+pas))
        if (X(j,2)<=sum)
            X(j,3)='C';
            Ma(r,1)=X(j,1);
            Ma(r,2)=X(j,2);
            r=r+1;
        else
            X(j,3)='D';
            Md(l,1)=X(j,1);
            Md(l,2)=X(j,2);
            l=l+1;
        end
        j=j+1;
    end
    Step=Step+pas;
end
%-----
% se trateaza zona de mijloc
% se calculeaza media de curent pe intervale de 10 V
%-----
IntervalNumber=62;
pas=abs(-Vz-Vz)/IntervalNumber;
Step=-Vz;
while (X(i)<=Vz)
    sum=0;
    contor=1;
    k=i;
    while(X(i)<=(Step+pas))
        sum=sum+X(i,2);
        contor=contor+1;
        i=i+1;
    end
    sum=sum/(contor-1);
    j=k;
    while(X(j)<=(Step+pas))
        if (X(j,2)<=sum)
            X(j,3)='C';
            Ma(r,1)=X(j,1);
            Ma(r,2)=X(j,2);

```



```

        r=r+1;
    else
        X(j,3)='D';
        Md(l,1)=X(j,1);
        Md(l,2)=X(j,2);
        l=l+1;
    end
    j=j+1;
end
Step=Step+pas;
end
%-----
%se trateaza zona din dreapta
%-----

pas=1.5;Step=Vz;i=j;limit=j;
while (X(i,1)<max(X(:,1)))
    if(X(i,1))>315
        pas=0.5;
    end
    sum=0;
    contor=1;
    k=i;
    while(i<length(X(:,1))&&X(i,1)<=(Step+pas))
        sum=sum+X(i,2);
        contor=contor+1;
        i=i+1;
    end
    sum=sum/(contor-1);
    Suma_dr=[Suma_dr;sum];
    if length(Suma_dr)~=1 &&
    Suma_dr(length(Suma_dr))<Suma_dr(length(Suma_dr)-1)
        Suma_dr(length(Suma_dr))...
        =Suma_dr(length(Suma_dr)-1);
        sum=Suma_dr(length(Suma_dr));
    end
    Rezultat_dr=[Rezultat_dr;Step+pas/2,sum];

j=k;
while(j<length(X(:,1))&&X(j)<=(Step+pas))
    if (X(j,2)<=sum)
        X(j,3)='C';
        Ma(r,1)=X(j,1);
        Ma(r,2)=X(j,2);
        r=r+1;
    else
        X(j,3)='D';
        Md(l,1)=X(j,1);
        Md(l,2)=X(j,2);
        l=l+1;
    end
end

```

```

        j=j+1;
    end
    Step=Step+pas;
..end
i_dr=2*max(Md(:,2))-max(Ma(:,2));
i_stg=2*min(Ma(:,2))-min(Md(:,2));
st=[min(X(:,1)),i_stg];
dr=[max(X(:,1)),i_dr];
Md=[st;Md;dr];
Ma=[st;Ma;dr];
xlswrite(FileName,Ma,SheetsName_A,'A1');
xlswrite(FileName,Md,SheetsName_D,'A1');
end

```

C.3 Implementarea calculării valorii parametrilor semnăturilor folosind algoritmi de optimizare

În secțiunea curentă este prezentată implemetarea funcției MATLAB ce apelează algoritmul de optimizare rezultând un anumit fitness și setul de parametri aferenți, informațiile sunt salvate în fișierul Rezultate.xlsx, funcția ce generează vectorul de fitnessuri asociat unui set de combinații C_{ij} și scriptul ce generează rezultatele pentru cele 50 de rulări independente.

- Funcției MATLAB ce apelează algoritmul de optimizare rezultând un anumit fitness și setul de parametri aferenți, informațiile sunt salvate în fișierul Rezultate.xlsx

```

function [fitness_]=c_fitness(k, name, tit_a, C)
%{
-----
Apeleaza algoritmul genetic generand fitnessul si setul de parametrii aferenti,
rezultatele se salveaza in fisierul Rezultate.xlsx
Intrari :   k           — nr. de consumatori
           name, tit_a, C — construiesc, numele sheetului in care se realizeaz
           salvarea ex.(LCD_DELL, 11, d)→LCD_DELL44_d
Iesire:    fitness_    — valoarea fitnessului
-----
%}
global line_nr CurveType
CurveType=C
clear NVARs lb_a ub_a lb_d ub_d X0 fitness_
[NVARs, lb_a, ub_a, lb_d, ub_d] =ConstructHandler(k);
FITNESSFCN=@fitness;
if char(C)=='a'
    [X0_, fitness_]=...
    ga(FITNESSFCN,NVARs,[],[],[],[],lb_a,ub_a,@nonlconstrain);
..else
    [X0_, fitness_]=...
    ga(FITNESSFCN,NVARs,[],[],[],[],lb_d,ub_d,@nonlconstrain);
..end

```

```

..xlswrite(strcat('...\Rezultate\Rezultate','.xlsx'),[fitness_ X0_]...
..,strcat(char(name), char(tit_a)), strcat('A',int2str(line_nr)));
end

```

- Funcția generează vectorul de fitnessuri asociat unui set de combinații C_{ij} cu referire la Tabel 3.1

```

function calculare_fitness(name, k)
%{
-----
Genereaza vectorul fitness_ pentru setul de combinatii Cij asociat ramurii
ascendente respectiv descendente;
Intrari   name — nume sheet salvare fitness/paramertii
          k    — numarul de consumatori (1 sau 2)
-----
%}
global solutie sol j fitness_a fitness_d q
if(k==1)
%consumator-2.m
    titlu={'11_','12_','13_','14_','22_','23_','24_','33_','34_','44_'};
...else
%consumator simplu
    titlu={'1_','2_','3_','4_'};
end
ramura=['a','d'];
for r=1:length(ramura)
    for q=1:length(titlu)
        sol=solutie(q,:);
        fitness=c_fitness(k, name, strcat(char(titlu(q))
, char(ramura(r))), ramura(r));
        if(r==1)
            fitness_a(j,q)=fitness;
        else
            fitness_d(j,q)=fitness;
        end
    end
end
..end
end

```

- Script generează rezultatele pentru cele 50 de rulări independente.

```

%{
-----
Scriptul genereaza rezultatele asociate celor 50 de rulari independente
-----
%}
clear; clc;
global Value_a Value_d q line_nr solutie fitness_a fitness_d j
path='...\DeterminareV\';
%sheets_name={'HP' 'DELL' 'LCD' 'Frigider' 'Aspirator'};
%sheets_name={'Frigider_HP_1mas'};
sheets_name={'Aspirator_HP'}
%sheets_name={'HP_DELL'};

```

```

%sheets_name={'LCD_DELL'};
len=size(sheets_name);
for i=1:len(:,2)
    fitness_a=[];
    fitness_d=[];
    Vz=0;
    [nr_points, Vz, VALUE]=determine_V(path,char(sheets_name(i)));
    sheet1=strcat(sheets_name(i),'_a');
    sheet2=strcat(sheets_name(i),'_d');
    [Value_a, Value_d]...
    =GenerateCDcurve(strcat(path,'CurbeA_D.xlsx'),VALUE,0.1,Vz,62...
    ,char(sheet1),char(sheet2));
    solutie=combinatie(1:4,2);
    q=1;line_nr=1;
    for j=1:50
        calculare_fitness(sheets_name(i),2);
        line_nr=line_nr+1;
    end
    xlswrite(strcat('...\Rezultate\fitness_.xlsx'),fitness_a,strcat(char(...
    sheets_name(i),'_a'),strcat('A',int2str(1))));
    xlswrite(strcat('...\Rezultate\fitness_.xlsx'),fitness_d,strcat(char...
    (sheets_name(i),'_d'),strcat('A',int2str(1))));
end

```