


Cornel BARNA

# Contribuții la dezvoltarea sistemelor de supraveghere în mediu extern

Teză de doctorat

Conducător științific:  
Prof.dr.ing.Mircea STRATULAT

2006





## Cuprins

<b>PARTEA I. Introducere .....</b>	<b>1</b>
Capitolul I. Introducere.....	2
Capitolul II. Stadiul actual al dezvoltării sistemelor antiefracție .....	7
2.1. Introducere.....	7
2.2. Sisteme antiefracție cu detectori convenționali .....	8
2.2.1. Senzori de detecție.....	9
2.2.2. Elemente de avertizare.....	13
2.2.3. Unități de comandă.....	14
2.3. Sisteme de supraveghere cu camere video .....	16
2.3.1. Camere de supraveghere.....	17
2.3.2. Echipamente de prelucrare a semnalelor video .....	17
2.3.2.1. Switcher.....	18
2.3.2.2. Quad.....	19
2.3.2.3. Multiplexor .....	20
2.3.3. Echipamente de înregistrare video .....	21
2.3.4. Echipamente de achiziție .....	24
2.3.5. Monitoare.....	25
2.4. Concluzii.....	26
<b>PARTEA II. Contribuții la fundamentarea alegerii</b>	
<b>metodelor .....</b>	<b>29</b>
Capitolul III. Mulțimi grosiere .....	31
3.1. Introducere.....	31
3.2. Mulțimi grosiere .....	31
3.3. Mulțimi grosiere generalizate pe bază de similaritate .....	36
3.4. Aplicații ale mulțimilor grosiere.....	38
3.4.1. Reducerea numărului de attribute.....	38
3.4.2. Abordarea statistică a mulțimilor grosiere.....	42

3.4.3. Gruparea obiectelor utilizând mulțimi grosiere.....	43
3.4.4. Stabilirea de reguli folosind mulțimi grosiere .....	44
3.4.5. Fundamentarea deciziilor utilizând mulțimi grosiere .....	46
3.4.6. Metode de clasificare folosind mulțimi grosiere .....	46
3.5. Mulțimi fuzzy grosiere .....	48
3.6. Concluzii.....	52
Capitolul IV. Granularitatea informației .....	55
4.1. Introducere .....	55
4.2. Sisteme cu granularitate multiplă .....	55
4.3. Granularitatea binară .....	58
4.4. Stabilirea conceptelor prin noțiuni de granularitate .....	61
4.5. Granularitatea vagă.....	64
4.6. Concluzii.....	68
Capitolul V. Fuziunea informațiilor .....	69
5.1. Introducere.....	69
5.2. Definierea fuziunii informațiilor .....	70
5.2.1. Clasificări folosite în fuziune .....	71
5.2.2. Aspecte ale incertitudinii și impreciziei informației.....	74
5.3. Fuziunea euristica .....	76
5.3.1. Fuziunea pe bază de medie .....	76
5.3.2 Fuziunea prin vot.....	82
5.4. Fuziunea prin metode probabilistice.....	84
5.4.1. Elemente din teoria probabilităților folosite în fuziune.....	84
5.4.2. Fuziunea informațiilor folosind teoria probabilităților .....	86
5.4.3. Aplicații ale fuziunii folosind probabilități .....	91
5.5. Fuziunea prin metode fuzzy .....	102
5.5.1. Elemente din teoria mulțimilor vagi folosite în fuziune.....	102
5.5.2. Fuziunea informațiilor folosind teoria mulțimilor vagi .....	104
5.5.3 Aplicații ale fuziunii folosind mulțimi vagi .....	106
5.6. Fuziunea prin metode ce folosesc teoria posibilității .....	114



5.6.1. Elemente din teoria posibilității folosite în fuziune.....	114
5.6.2. Fuziunea informațiilor folosind teoria posibilităților .....	116
5.6.3. Aplicații ale fuziunii folosind teoria posibilităților .....	120
5.7. Fuziunea prin metode ce folosesc teoria Dempster-Shafer .....	125
5.7.1. Elemente din teoria Dempster-Shafer folosite în fuziune .....	125
5.7.2. Fuziunea informațiilor folosind teoria Dempster-Shafer.....	127
5.7.3. Aplicații ale fuziunii folosind teoria Dempster-Shafer.....	129
5.8. Metode combinate de fuziune.....	132
5.9. Alte metode folosite în fuziune .....	135
5.10. Concluzii.....	138

### **PARTEA III. Contribuții la proiectarea, realizarea și testarea sistemelor de supraveghere în mediu extern**

..... **141**

Capitolul VI. Arhitectura sistemului de supraveghere .....	142
6.1. Introducere.....	142
6.2. Organizarea sistemului .....	144
6.3. Construcția sistemului .....	146
6.4. Stabilirea scalei pentru detectori conici.....	151
6.5. Concluzii.....	152
Capitolul VII. Sistemul Video .....	155
7.1. Introducere.....	155
7.2. Metode de stereoscopie utilizare .....	156
7.3. Metodele de localizare și stabilire a caracteristicilor.....	160
7.3.1. Extragerea trăsăturilor .....	160
7.3.1.1. Problematika generală.....	160
7.3.1.2. Recunoașterea formelor prin clasare .....	163
7.3.1.3 Extragerea trăsăturilor de tip vag.....	167
7.3.2. Stabilirea marginilor de incertitudine .....	168
7.3.3. Determinarea granularității optime.....	172

---

---

7.4. Urmărirea obiectului.....	176
7.5. Concluzii.....	182
Capitolul VIII. Sistemul bazat pe detectori PIR.....	185
8.1. Introducere.....	185
8.2. Metoda de proiectare a sistemului.....	186
8.3. Metoda de testare.....	189
8.4. Metoda de localizare și estimare a suprafeței radiate.....	196
8.5. Concluzii.....	202
Capitolul IX. Fuziunea rezultatelor.....	203
9.1. Introducere.....	203
9.2. Fuziunea euristică.....	203
9.3. Fuziunea prin metode fuzzy.....	205
9.4. Fuziunea prin confirmare.....	207
9.5. Compararea metodelor.....	209
9.6. Stabilirea deciziei.....	212
9.6.1. Metode hard.....	212
9.6.2. Metode soft.....	213
9.7. Concluzii.....	216
<b>PARTEA IV. Concluzii finale.....</b>	<b>217</b>
Capitolul X. Concluzii finale.....	218
10.1. Structura tezei.....	219
10.2. Clasificarea contribuțiilor pe aspecte.....	221
10.3. Contribuții teoretice și aplicative.....	224
10.3.1. Contribuții teoretice.....	224
10.3.2. Contribuții aplicative.....	225
BIBLIOGRAFIE.....	227
LISTA PUBLICAȚIILOR PERSONALE.....	237

## PARTEA I. Introducere

Primul capitol al acestei teze constituie capitolul introductiv în care se prezintă tema lucrării și principalele domenii abordate.

Capitolul II face o trecere în revistă a stadiului actual din domeniul sistemelor de supraveghere antiefracție.

Mai întâi sunt prezentate sistemele antiefracție ce au în componență detectoare bazate pe sesizarea gradientului de temperatură. Astfel, după prezentarea structurii generale a sistemelor de supraveghere se analizează fiecare grupă de componente ce intră în structura ansamblului. În acest sens sunt prezentate tipurile de detectoare și sunt enumerate principalele caracteristici ale acestora, iar apoi sunt descrise elementele de avertizare și unitățile de comandă.

În continuare se detaliază a doua grupă importantă de sisteme de supraveghere antiefracție, și anume cele bazate pe informația obținută din imagini video. Astfel, sunt reliefate caracteristicile de bază pentru camere video, pentru echipamente de prelucrare și pentru echipamente de stocare.

## Capitolul I. Introducere

Prezenta teză își propune să reliefeze contribuțiile proprii, rezultate din activitatea de cercetare cuprinsă în programul de doctorat cu tema „ Contribuții la dezvoltarea sistemelor de supraveghere în mediu extern”, sub coordonarea științifică a prof.dr.ing. Mircea STRATULAT, de la Facultatea de Automatică și Calculatoare din cadrul Universității „Politehnica” din Timișoara

Sistemele de supraveghere antiefracție și domeniul Teoriei mulțimilor fuzzy, a mulțimilor grosiere și a fuziunii informațiilor din cadrul Inteligenței Artificiale sunt domenii care până în prezent nu au fost abordate împreună, dar fiecare în parte beneficiind de o bogată abordare în literatura de specialitate. Această intersecție relativ restrânsă a celor două domenii nu are o cauză principială, ele fiind perfect compatibile, explicația constând mai mult în limitarea zonelor în care activează persoanele ce se ocupă de aceste domenii. Astfel, sistemele de supraveghere sunt mai mult conectate la o cercetare de tip tehnologic, cu aplicații în partea comercială, respectiv din punct de vedere teoretic, în ultima vreme, la domeniul prelucrării imaginilor. Pe de altă parte aplicațiile din Inteligența Artificială referitoare la Teoria mulțimilor fuzzy, a mulțimilor grosiere și a fuziunii informațiilor sunt în majoritate specifice preocupărilor de tip academic, cum ar fi robotica sau recunoașterea formelor, ori preocupărilor din domeniu militar. De altfel abordarea tematicii acestei teze, care se referă la aplicarea sistemelor de supraveghere în aceste domenii din inteligența artificială, în cazul meu, a fost determinată de preocupări cauzate de o istorie personală, care s-au potrivit pentru a obține aceste abordări.

Din materialele studiate a rezultat că această sinteză, între cele două domenii, este posibilă, și că există chiar o legătură naturală între ele. Astfel cum va rezulta din conținutul acestei teze, teoriile referitoare la incertitudine și granularitatea informațiilor conferă un cadru teoretic adecvat studierii metodelor aplicabile în sistemele de supraveghere antiefracție folosite în medii externe, în care există numeroase fenomene incerte din punct de vedere al informațiilor captate. De altfel tipul de detectoare folosite nici nu au o importanță în cadrul abordării problematicii prezentei lucrări, senzorii de

tip PIR fiind folosiți deoarece au o largă utilizare în sistemele actuale de supraveghere. Dar toate metodele implică un grad de generalitate, care permit utilizarea oricărui senzor de fuziune. Din acest motiv, în Capitolul IX se va face referire la senzorii de fuziune, chiar dacă în experimentele efectuate s-au utilizat detectori PIR, bazați pe sesizarea gradientului de temperatură.

Pe de altă parte unele din domeniile studiate și aplicate din aria de cuprindere a inteligenței artificiale sunt foarte noi și în concluzie nu suficient structurate, existând în prezenta teză o contribuție importantă de ordonare a unor problematici din această zonă. De asemenea, pe parcursul lucrării s-a încercat să se aducă câteva contribuții la o serie de probleme legate de tematica abordată referitoare la :

- Analiza tipurilor de mulțimi grosiere utilizate în cadrul literaturii de specialitate consultată și stabilirea celei care se potrivește cerințelor acestei cercetări (Capitolul III),
- Gruparea categorială a aplicațiilor mulțimilor grosiere, și determinarea celor care au conexiune cu prezenta lucrare (Capitolul III),
- Clasificarea diferitelor abordări ale noțiunii de granularitate a informației și stabilirea celei aplicabile sistemului propus (Capitolul IV),
- Gruparea tehnicilor de fuziune a informației printr-o viziune originală, care are la bază principiul teoretic aplicat (Capitolul V),
- Analiza critică a diferitelor metode folosite în fuziunea informațiilor pentru a stabili avantajele și deficiențele fiecăreia în parte, necesare determinării acelor procedee de fuziune care se potrivesc cel mai bine sistemului propus (Capitolul V),
- Stabilirea unei metode de măsurare a gradului de incertitudine prin coeficienți bazați pe nivelul de disimilitudine (Capitolul VII),
- Demonstrarea utilității folosirii granulației multiple și determinarea granularităților optime pentru obiectele dintr-un sistem video (Capitolul VII),
- Stabilirea și verificarea unor metode de proiectare și testare pentru sisteme cu detectoare PIR (Capitolul VIII),

- Reliefaarea unei metode de localizare a obiectelor folosind sisteme bazate pe detectori în infraroșu (Capitolul VIII),
- Determinarea și fundamentarea unei tehnici de estimare a suprafeței radiante pentru sistemele cu detectori PIR (Capitolul VIII),
- Stabilirea unei metode de determinare a gradului de încredere în sistemele de alarmare (Capitolul VIII),
- Stabilirea unui proces de adaptare a coeficienților de decizie printr-o metodă de învățare (Capitolul IX),
- Realizarea fuziunii informației printr-un sistem ierarhic în două etape (Capitolul IX).

Teza de față sintetizează rezultatele obținute în cadrul activității de doctorat .

Pentru a sistematiza volumul de informație cuprins în cadrul tezei, prezenta lucrare a fost structurată pe patru părți.

Prima parte conține două capitole introductive. Astfel capitolul următor denumit „Stadiul actual în domeniul sistemelor de supraveghere” trece în revistă principalele două categorii de sisteme antiefracție. În prima parte sunt prezentate sistemele bazate pe detectoare cu sesizare a gradientului de temperatură. Se descriu principalele componente și anume : tipurile de detectori, elementele de semnalizare și unitățile de comandă. În partea a doua se prezintă a doua categorie de sisteme, cele bazate pe imagini video. Astfel sunt descrise tipurile și principalele caracteristici de camere video, de unități de prelucrare, de unități de stocare și cele de afișare.

A doua parte, „Contribuții la fundamentarea alegerii metodelor” cuprinde trei capitole cu conținut teoretic, menite să justifice considerentele pentru care s-au ales metodele din sistemul abordat. În acest sens Capitolul III intitulat „Mulțimi grosiere” prezintă noțiunile legate de mulțimile introdus de Pawlak și tradus de mine cu termenul de mulțimi grosiere. De asemenea se face o clasificare a tipurilor de mulțimi grosiere și a aplicațiilor acestora. Se face o analiză a avantajelor și deficiențelor fiecărui tip prezentat. În Capitolul IV denumit „Granularitatea informației”, se face un studiu asupra unei teme tot mai actuale din domeniul „soft computing” și anume, granularitatea unei

informații. În continuare, se prezintă tipurile de granularități și aplicații ale acestora. Capitolul V, având titlul de „Fuziunea informațiilor” prezintă o clasificare originală a metodelor de fuziune a informației, pe baza teoriilor care fundamentează procesul. De asemenea, se fac comentarii referitoare la avantajele și dezavantajele fiecărui tip de fuziune, ceea ce permite justificarea alegerii unora dintre metode.

Partea a treia, „Contribuții la proiectarea, realizarea și testarea sistemului de supraveghere în mediu extern” conține un număr de patru capitole, și prezintă soluția propusă pentru sistemele de supraveghere în mediu extern, împreună cu rezultatele obținute pe baza experimentărilor efectuate. În acest sens în capitolul VI denumit „Arhitectura sistemului de supraveghere” se face o descriere a structurii sistemului propus, evidențiindu-se rolul fiecărei componente. De asemenea se prezintă echipamentele folosite pentru realizarea practică a sistemului, iar în încheiere se fac câteva considerații teoretice referitoare la particularități ale folosirii captoarelor de informații de tip conic, așa cum sunt cele utilizate în acest sistem. Capitolul VII, intitulat „Sistemul video”, prezintă în mod detaliat fundamentul teoretic, precum și rezultatele experimentale, obținute în modulele implicate în captarea și prelucrarea fluxului de informații video. Astfel sunt reliefate metodele stereoscopice folosite, metoda de extragere a trăsăturilor, modul de stabilire a marginilor domeniului de incertitudine, precum și metoda de determinare a granularității optime. În Capitolul VIII, denumit „Sistemul bazat pe detectori PIR”, se descrie suportul teoretic și modul de realizare și testare a componentelor implicate în captarea și prelucrarea informațiilor provenite de la detectoarele de gradient în infraroșu. De asemenea se prezintă în mod detaliat metoda de localizare și estimare a suprafețelor radiante a obiectelor care au cauzat efracția. Ultimul capitol al acestei părți, Capitolul IX, având titlul de „Fuziunea rezultatelor”, prezintă o metodă originală de obținere a deciziei de alarmare, bazată pe o ierarhie formată din trei procese de fuziune și unul de decizie. Pentru fiecare dintre fuziunile utilizate sunt descrise bazele teoretice, precum și rezultatele obținute. De asemenea, se descriu două moduri de luare a deciziei și se face o comparație între ele.

Ultima parte, „Concluzii finale”, conține Capitolul X și conține o sinteză a concluziilor și contribuțiilor desprinse din prezenta lucrare, analizate din diverse puncte de vedere.

Lucrarea de doctorat a fost realizată din finanțare proprie și cu sprijinul firmei Contact Plus S.R.L. din Arad, având suportul colegilor de la secția de Automatizări și Informatică Aplicată din cadrul Facultății de Inginerie a Universității „Aurel Vlaicu” din Arad.



## Capitolul II. Stadiul actual al dezvoltării sistemelor antiefracție

### 2.1. Introducere

În piramida nevoilor umane elaborată de A. Maslow [Kot98] în cadrul studiului de marketing referitor la comportamentul cumpărătorului, pe un nivel de bază, imediat după necesitățile primare fiziologice, apare cerința umană pentru securitatea personală, a familiei și a grupului din care face parte (fig.2.1). Odată cu dezvoltarea societății umane în cadrul civilizațiilor care au dezvoltat o cultură bazată pe proprietatea privată, pe lângă necesitățile amintite a apărut și cea a protejării bunurilor personale, intensitatea



**Figura 2.1.** Ierarhia nevoilor elaborată de MASLOW

acestei cerințe fiind plasată imediat după cea a securității personale. Pentru a răspunde acestor nevoi comunitățile umane și-au organizat instituții specializate sub forma poliției și unităților de pompieri, pentru asigurarea siguranței în interior și a armatelor pentru amenințările externe.

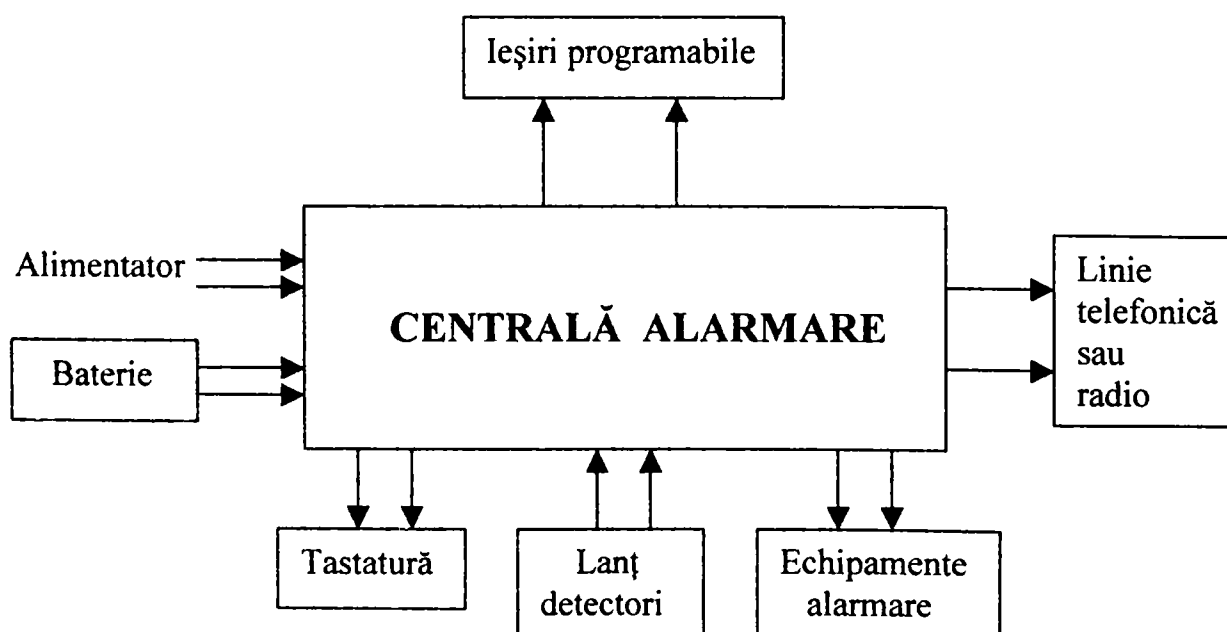
Asigurarea securității persoanelor și protecției bunurilor a ajuns în prezent să fie realizate nu numai de instituțiile statului ci și prin efortul individual al celor care solicită astfel de servicii, dezvoltându-se câteva piețe ce satisfac aceste nevoi. În acest sens s-a dezvoltat piața societăților de asigurate de viață și bunuri care au rolul de a compensa chiar și numai parțial pierderile înregistrate de beneficiarii polițelor de asigurare. De

asemenea au apărut societățile de protecție și pază care folosesc oameni de pază, gărzi de corp, efectuează transporturi de valori și intervin cu personal specializat în caz de alarmare, respectiv, au apărut echipamente de prevenire, supraveghere și alarmare antiincendiu și antiefracție precum și dispozitive de stingere automate a incendiilor. Dintre serviciile prezentate în ultimii ani s-au dezvoltat vertiginos sistemele electronice de prevenire, supraveghere și alarmare antiincendiu și în special cele antiefracție, devenind bunuri de larg consum, de sine stătătoare sau incluse în sisteme mai complexe de tip „building management” denumite, generic și cam limitativ, în română, „case inteligente”.

Ca și principiu de funcționare aceste sisteme se împart actualmente în două categorii: una bazată pe detectori convenționali de tipul senzorilor în infraroșu, ultrasonici, magnetici sau cu analiza de sunet și alta bazată pe supravegherea imaginilor obținute cu ajutorul camerelor video [Mel99].

## 2.2. Sisteme antiefracție cu detectori convenționali

Din prima categorie, cele mai uzuale sisteme de alarmare antiefracție folosite în prezent se compun dintr-o centrală de alarmare la care se conectează tastatura de




**Figura 2.2.** Structura unui sistem de supraveghere cu detectori PIR

comandă sau circuitul de armare-dezarmare, senzorii de detecție, și elementele de avertizare sonoră sau de comunicare a incidentelor (fig.2.2.).

### **2.2.1. Senzori de detecție**


Senzorii de detecție sunt echipamente de o mare diversitate atât din punct de vedere tehnologic cât și al utilității. O primă clasificare a detectorilor antiefracție se poate face după numărul de utilizări posibile. Astfel detectorii se pot diviza în senzori de unică folosință, și senzori de folosință multiplă. În prima categorie se înscriu timbrele cu fir subțire care se aplică prin lipire, în general pe geamuri sau vitrine, și care, la spargerea sau fisurarea suportului pe care se aplică, se rup, întrerupând circuitul de zonă pe care sunt conectați, declanșând alarma. O altă utilizare a aceluiași principiu a ruperii firului din circuit se regăsește la cordoanele perimetrare, care se folosesc la protecția unor zone exterioare. Aceste echipamente nu se mai folosesc în ultimul timp din cauza problemelor de service pe care le implică, fiind necesară schimbarea lor frecventă. Fiind elemente pasive, diferitele tipuri de timbre și cordoane diferă numai prin dimensiuni și impedențe electrice.

Un înlocuitor al timbrelor, care înlătură dezavantajul schimbării frecvențe a senzorilor, îl reprezintă senzorul magnetic. Acest sesizor este format dintr-un magnet și un releu incorporat fiecare într-o bucată de plastic. Când releul se află în apropierea magnetului acesta menține contactele închise iar dacă este îndepărtat de magnet contactele se deschid întrerupând circuitul zonei pe care este inseriat. Astfel de detectori se pot monta pe uși, ferestre sau alte elemente constructive ce pot fi deplasate, semnalizând trecerea unei persoane prin acea zonă. Distanța medie de acționare a releului este între 5 – 10 cm, lungimea senzorului fiind de 3,5 cm, iar valoarea nominală a curentului este de 100 mA la 15 V. Aceste elemente din sistem, deși sunt simple, au dezavantajul cablării destul de dificile, montarea lor putându-se face numai în anumite locuri.




**Figura 2.3.** Detector PIR

Majoritatea senzorilor folosiți astăzi în sistemele de alarmă sunt bazați pe principiul detecției gradientului de emisie în infraroșu și sunt numiți detectori PIR (fig.2.3.). Acești senzori au receptori pasivi ai radiațiilor în infraroșu, unghiul de percepție a acestora putând avea formă conică în cazul detectorilor volumetrici, semisferică în cazul detectorilor de tavan, sau lamear în cazul detectorilor peretea. De obicei volumetrici variază atât în funcție de tipul lentilei montate în fața capului de sesizare, cât și în funcție de numărul de franjuri pe care le recepționează un cap de recepție, și numărul de capete de recepție folosite într-un detector PIR. Din punct de vedere a tipului de lentile, senzorii sunt de tip coridor pentru conuri de percepție alungite, sau de tip încăpere pentru conuri cu unghi de deschidere până la 110 grade (fig.2.4.). În concordanță cu complexitatea detectorului este și prețul acestuia, folosirea unui tip sau a altuia fiind justificată de aplicația în care intervine și de gradul de siguranță cerut. Astfel, în cazul sistemelor mai puțin pretențioase se pot folosi detectori cu un singur cap și cu franjuri mai puține [M 3] iar la sisteme mai sofisticate se utilizează detectori cu capete multiple și franjuri cu interferență, care uneori au incorporate și capete de emisie-recepție cu microunde. Raza



**Figura 2.4.** Amplasarea franjurilor de detecție

de acțiune a PIR-urilor volumetrice obișnuite poate varia între 8 și 15 m pentru recepția în diagonală. Detectori de tavan, care au unghiul de recepție semisferic, au în general raza de acțiune de 4-8 m, iar detectorii perdea care percep mișcarea într-o fâșie de grosime tipică de 15 cm, pot avea profunzimea de 8-10 m pe o lățime de 5-7 m. O problemă importantă a acestui tip de detector este imunitatea la zgomot și prevenirea alarmelor false care pot să apară chiar și din cauza unui curent de aer. Problema este cu atât mai acută la senzorii care se folosesc în mediu exterior unde pot apărea declanșări accidentale și din cauza unor păsări sau animale de casă care pot intra în raza de acțiune a detectorilor. O soluție la aceste probleme este reducerea sensibilității în funcție de mediu sau posibilitatea dublei detecții pentru același eveniment. Fiecare dintre aceste metode au inconveniente legate de rata mică de detecție, dacă se scade sensibilitatea, sau de creșterea numărului de alarme false, dacă se lasă o sensibilitate mărită. Trebuie menționat că aceste inconveniente sunt de natură principială și sunt determinate de modul de funcționare a detectoarelor.



**Figura 2.5.** Detector geam spart

Un alt principiu folosit în detectorii de mișcare este bazat pe un emițător și receptor cu microunde. Acest tip de senzori se folosesc în special în sistemele de alarmare pentru autovehicule, fiind mai greu de utilizat în cazul sistemelor de alarmă pentru imobile deoarece detectează prin sticla obișnuită. Există totuși detectori care încorporează două capete cu infraroșu și unul cu microunde, fiind folosit la supravegherea incintelor ce necesită un grad mare de protecție. Dar și aceste tipuri de detectori au aceleași limitări anivelului de încredere, din cauza numărul mare de efracți neidentificate și alarme false.

Pentru prevenirea efracției prin spargerea geamurilor și a vitrinelor se utilizează detectori speciali numiți detectori de geam spart (glass track ) (fig.2.5.) care sunt formați din analizori de sunet și declanșează la recepționarea unui spectru ce corespunde

celui provocat la spargerea unui geam sau la prăbușirea unei vitrine, acționând mai repede decât senzorii PIR. Detectorul trebuie montat cu microfonul orientat către vitrină sau geam permițând sesizarea efracției în general de la 6-8 m.


În situațiile în care nu se pot folosi detectori PIR din cauza posibilității ridicate de apariție a alarmelor false, de exemplu în medii exterioare, se folosesc dispozitive de pază perimetrală, ca de exemplu bariere cu infraroșu, formate din perechi de dispozitive, unul emițător de fascicol, celălalt receptor. În funcție de putere și de calitatea oglinzilor și a lentilelor de focalizare, barierele se clasifică corespunzător distanțelor maxime la care se pot monta emițători față de receptori în așa fel încât să funcționeze optim și în condiții de ploaie torențială sau ceață. Pentru a evita obturarea fascicolului în mod accidental de exemplu de o găză, barierele se montează în perechi, având grijă să nu apară încrucișări de spoturi, ceea ce ar reduce posibilitățile de alarmare. Deoarece barierele se montează în general în exterior, realizarea cablajelor este mai dificilă, de aceea au și posibilitatea de a fi legate în lanțuri de alarmare în așa fel încât o alarmare apărută la o barieră se propagă prin tot lanțul până la ultima care este conectată la centrală. Tot pentru mediu extern se mai folosesc covoarele de alarmare, care au la bază principii hidraulice sau electrice și care acționează la o presiune peste un anumit prag exercitată asupra lor. Aceste tipuri de senzori au însă un mare dezavantaj, cauzat de caracterul limitativ al razei de acțiune, ceea ce face să poată fi ocolite ușor dacă se cunoaște poziționarea lor.

La sistemele de alarmă auto se folosesc detectori capacitivi care se reglează pentru sesizarea apropierii unei persoane de automobil, declanșând de obicei o prealarmă, iar dacă persoana nu iese din zona sesizorului într-un timp prestabilit se declanșează alarma. Aceste detectoare nu se prea folosesc la imobile deoarece necesită o suprafață metalică extinsă, greu de montat în diferitele situații care pot să apară. Tot la sistemele de alarmă auto dar și în sistemele bancare se folosesc detectori de vibrații bazați în majoritatea cazurilor pe efectul inerțial sau piezoelectric, montați pe carcasa vehiculului sau pe pereții camerelor de valori. O problemă principală a acestor tipuri de detectori este rata mare de alarme false, cauzate de vibrații ce au altă sursă decât o eventuală efracție.

Pentru situațiile care pot apărea în caz de furturi se pot folosi butoane de panică sau pedale de panică. Aceste dispozitive sunt formate dintr-un întrerupător care poate fi cu revenire sau cu cheie. Folosirea cheii se face pentru a se constata care buton sau pedală a fost apăsată în cazul când există un număr mare de astfel de dispozitive montate în sistem.

### 2.2.2. Elemente de avertizare

Elementele de avertizare cele mai des utilizate sunt sirenele sau hupele, care diferă prin puterea pe care o disipă, cuprinsă între 10W și 130W, și prin tonalitatea unică sau selectabilă (fig.2.6.). Tot pentru avertizare se folosesc și becuri stroboscopice sau girofare, având ca parametri puterea, culoarea și dimensiunile incintei în care sunt instalate. Un echipament des folosit este sirena cu flash încorporat



**Figura 2.6.** Sirena de 10W

care pe lângă elementul de generare a sunetului și becul stroboscopic mai include și o alimentare autonomă, astfel permițând funcționarea acestuia și dacă nu este alimentată



de la sistem [M5]. De asemenea, echipamentele de avertizare sunt prevăzute cu elemente de protecție împotriva sabotării, formate din releu și întrerupătoare de protecție.

### 2.2.3. Unități de comandă

Comanda întregului sistem este formată din centrala de alarmare care cuprinde un microcalculator cu o memorie EEPROM la care se conectează tastaturile, elementele de sesizare și dispozitivele de alarmare, eventual modulele de comunicație sau cele auxiliare. Centralele de alarmare se clasifică în funcție de destinația lor, de la cele simple pentru apartamente până la cele mai complexe pentru uz bancar sau centrale de antiincendiu pentru complexe de clădiri. Pentru apartamente, centralele folosite [M12] au posibilitatea de a avea un număr mic de lanțuri de senzori numite zone ( maxim 4 ), nu pot fi partiționate și acceptă puține tastaturi suplimentare. De asemenea nu au posibilitatea de a comunica cu un dispecerat sau de a încărca programarea de pe un calculator și nu acceptă module auxiliare [M14]. Programarea lor este simplă rezumându-se la introducerea codurilor , definirea tipurilor de zone și specificarea timpilor de intrare și ieșire pentru zonele întârziate [M9]. Tastaturile utilizate la aceste centrale nu pot fi decât cu LED-uri. Pentru a extinde sistemele de acest tip cu posibilități de comunicare se pot atașa dispozitive separate numite comunicatoare sau apelatoare care se conectează pe ieșirile programabile numite PGM și care în caz de alarmă primesc comanda de ieșire de la sistem pentru a forma un număr de telefon și a transmite un mesaj preînregistrat de maxim 15 sec. Apelatoarele se programează pentru cel mult 4 numere de telefon în așa fel încât dacă nu se răspunde la primul număr, sună la al doilea și așa mai departe [M4]. Înregistrarea mesajului se face digital prin stocare într-o memorie statică.

Centralele de alarmare de nivel mediu au posibilitatea partiționării zonelor, ceea ce înseamnă gruparea unor zone care deservește același scop și care pot fi armate



respectiv dezarmate împreună. De asemenea se pot conecta mai multe tastaturi, care pot fi de tip global, permițând controlul întregului sistem, sau pot fi asignate câte unei partiții pe care le deservește exclusiv. De asemenea, unele tipuri de centrale permit folosirea conectării cu dublare de zonă [M1], ceea ce înseamnă folosirea a două valori de rezistențe de capăt în cadrul aceleiași bucle, centrala sesizându-le ca zone diferite. Un alt avantaj al acestor sisteme este folosirea unui bus de comunicații care permite conectarea la centrale a diferitelor module de extensie (pentru mărirea numărului de zone), conectarea la o imprimantă, conectarea de module de amplificare a semnalelor, module de comenzi pentru semnale de ieșire sau module de comunicare prin GSM ori cu sinteza vocală. Toate aceste centrale sunt prevăzute cu module de comunicare pe linie telefonică care permit transmiterea unor mesaje la punctele de dispecerizare și intervenție, precum și la un calculator de pe care se pot descărca fișiere cu programările solicitare de utilizatori [M10].

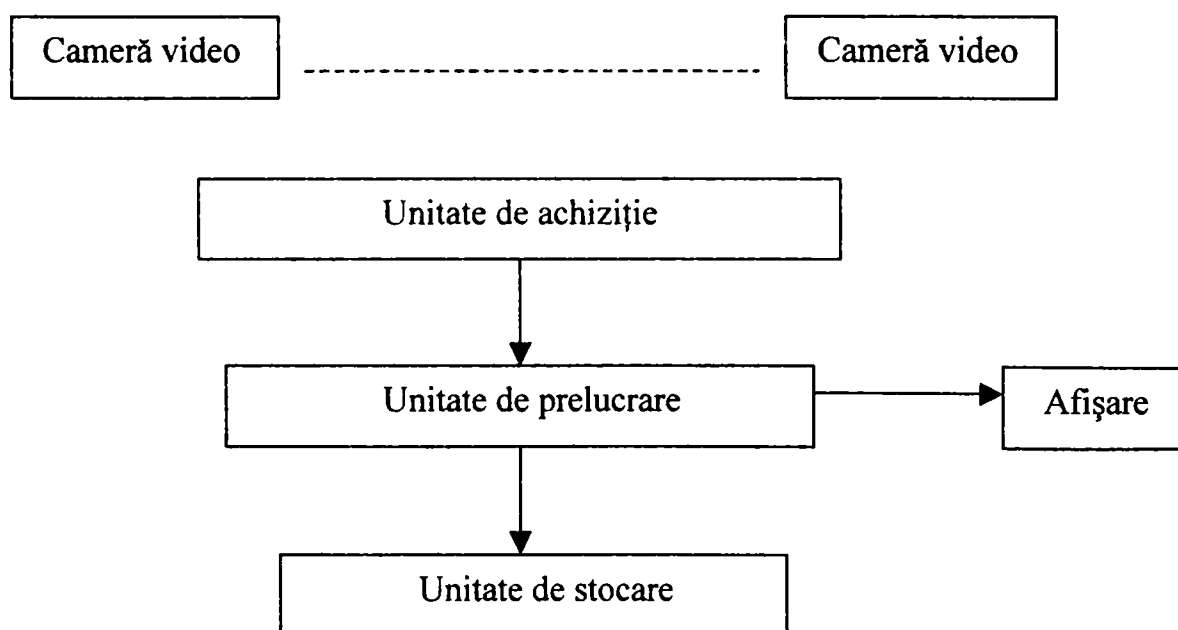
Pentru fiecare tip de centrală există diferite tastaturi cu care sunt compatibile, unele având posibilitatea de a aloca direct zone, fără să mai fie necesară conectarea prin centrală [M11] sau altele având posibilitatea de a comanda un zăvor electromagnetic la introducerea unui cod programat anterior [M2]. O altă îmbunătățire constă în posibilitatea de a folosi senzori cu transmisie radio, ceea ce elimină necesitatea cablării, dar impune folosirea unor interfețe de emisie-recepție între centrală și detectori. Sistemele radio se diferențiază prin puterea de emisie, distanța maximă admisă de recepție, în funcție de mediul de propagare și frecvența de comunicare, care variază între 330 MHz și 900 MHz. Printre modulele auxiliare de extensie se pot regăsi și cele care permit conectarea unor interfoane, sau facilități de control acces .

Sistemele cu grad mare de securitate antiefracție și antiincendiu necesită centrale care permit un număr mare de zone și partiții [M7], pot comanda ieșiri multiple pentru punerea în funcțiune a unor mecanisme de securitate și efectuează transmisii de date pe mai multe canale. La fel ca și centralele prezentate anterior și cele pentru sisteme mari au bus-uri de comunicare permițând conectarea unui număr mare de module auxiliare și de extensie [M15] dar mai permit și interconectarea centralelor între ele realizându-se structuri ierarhice de sisteme [M8]. O parte din acest tip de sisteme sunt dublate de pază

umană, caz în care se pot folosi și sisteme de patrulare care constă dintr-un dispozitiv mobil aflat la paznicul care trebuie să patruleze și un număr de timbre fixate în puncte succesive de pe traseu [M6]. Paznicul este obligat ca în timpul rondului să atingă cu dispozitivul mobil timbrele de traseu, memorându-se timpul în care a ajuns la punctul de rond și numărul atribuit timbrului, iar la revenirea în locul de plecare să introducă dispozitivul mobil într-un soclu al interfeței cu un calculator, care preia datele înregistrate de dispozitivul mobil. Astfel, se poate întocmi o evidență cu numărul și frecvența patruleșilor efectuate în fiecare schimb de fiecare paznic.

### 2.3. Sisteme de supraveghere cu camere video

Un sistem de supraveghere video este format dintr-un lanț compus din: camerele video, echipamente de achiziție, echipamente de prelucrare, unități de stocare și echipamente de afișare, așa cum se prezintă în figura 2.7.




**Figura 2.7.** Structura unei unități de supraveghere video

### 2.3.1. Camere de supraveghere

Sistemele de supraveghere cu camere video s-au răspândit tot mai mult în ultima perioadă [Bar04b]. Majoritatea camerelor video sunt realizate cu matrici de CCD-uri sau CMOS de rezoluție medie, alb-negru sau color, unele având și o cale de sunet incorporate în ele. Semnalul furnizat de camere este de obicei de tip AV (audio-video), transmisia efectuându-se pe cabluri coaxiale dar există și varianta cu transmisie radio, caz în care sunt necesare echipamente suplimentare. Diferențele de preț ale camerelor video se reflectă în calitatea sistemelor, la numărul de pixeli afișați (ex : 500 H, 582 V ), modul de sincronizare, care poate fi intern sau extern, numărul de linii pe cadru (ex : 450 linii), tipul și calitatea lentilelor folosite precum și distanța focală a obiectivelor, raportul semnal-zgomot (ex : 0 dB), iluminarea minimă necesară (ex : 0,4 Lux) nivelul semnalului de ieșire (ex : 1Vpp), tensiunea de alimentare (ex :12 V cc sau 220 V ac), dimensiunile mecanice, greutatea cu sau fără carcasă, consumul mediu (ex : 4 W), temperaturile de funcționare (ex : -40C la 60C) și stocare (ex : -40C la 60C).

### 2.3.2. Echipamente de prelucrare a semnalelor video

În cazul cel mai simplu fiecare cameră video este conectată la un monitor, iar un operator urmărește în permanență toate imaginile afișate. Experiența demonstrează că în astfel de situații intervine rutina și plictiseala în activitatea personalului de supraveghere, monotonia imaginilor îl fac să fie tentat să desfășoare alte activități care îi distrag atenția. La acest neajuns se mai adaugă cel de ordin economic, care cere ca un operator să supravegheze un număr cât mai mare de monitoare, ceea ce intră în contradicție cu performanțele operatorului de a sesiza eventualele mișcări de pe un monitor anume, performanțe care scad cu cât supraveghetorul trebuie să-și distribuie atenția pe cât mai multe imagini. De aceea se folosesc echipamente de prelucrare a



semnalelor video care permit sesizarea mai ușoară a mișcării sau a neregulilor apărute în imaginile provenite de la mai multe camere video.

### **2.3.2.1. Switcher**

Din categoria echipamentelor care se folosesc la urmărirea locală a mai multor camere video cele mai simple sunt switcherele. Aceste echipamente prezintă pe monitorul atașat sistemului, imaginile primite de la fiecare cameră video, prin rotire, un timp preprogramat. Imaginile sunt afișate pe rând pe tot ecranul. De asemenea există posibilitatea de a forța ca o singură imagine să fie menținută un timp nelimitat pe ecran. Deci în tot timpul de funcționare, fiecare cameră este conectată succesiv un timp dat într-o anumită ordine după care ciclul se reia. Există posibilitatea de a programa echipamentul astfel încât să excludă din ciclul de redare camerele care nu au semnal. O altă opțiune este cea de a afișa, odată cu imaginea de la o cameră video, și un număr de identificare a sursei semnalului. De obicei fiecare intrare are alocată și un conector de ieșire pentru a putea înlanțui mai multe echipamente de prelucrare a imaginilor, semnalul de ieșire fiind amplificat față de cel de intrare. Timpul de afișare este pentru fiecare cameră video programabil având valori tipice între 1 și 36 de secunde. Switcherele pot fi cu prelucrare alb-negru sau color, în funcție de tipul semnalului video pe care îl poate comuta. Numărul de canale de intrare poate varia în funcție de model, între 4 și 16, pentru echipamentele comerciale, fiecare imagine putând fi selectată într-unul din modurile de funcționare: bypass, automat sau manual. Caracteristicile tipice ale unui asemenea echipament sunt: semnal de intrare maxim admis 2Vpp, semnal de ieșire calibrat la 1 Vpp, impedanță de intrare 75 ohmi, conectori pentru semnal video de tip BNC. Uneori switcher-ul se încorporează în aceeași carcasă cu monitorul, în care caz are în general 4 până la 8 canale și un număr mai redus de funcții programabile.

### **2.3.2.2. Quad**

Echipamentele care se folosesc cel mai des în perioada actuală, în sistemele de supraveghere video sunt quad-urile. Aceste aparate creează semnale video a căror afișare prezintă simultan mai multe imagini de la camere video, împărțind ecranul monitorului într-un număr de domenii a căror dispunere se poate alege dintr-un meniu. Quad-ul face o prelucrare digitală a semnalelor video, permițând controlul programărilor de la distanță prin intermediul unei interfețe seriale. De asemenea în dreptul fiecărei imagini afișate, se poate înscrie un șir de caractere corespunzătoare denumirii spațiului supravegheat cu camera video de la care provine semnalul. Memoria video a echipamentului este în general de 512 x 512 pixeli sau de 1024 x 1024 pixeli, cu o quantificare pe 8 bit pentru imagini monocrome și de 3 x 8 bit pentru imagini color. Semnalul procesat poate afișa câte o imagine de la o cameră, de la 4 camere, 9 sau 16 camere simultan în domenii egale de imagini, dar există și posibilitatea de a afișa și o imagine pe o suprafață extinsă a ecranului și alte cadre de la camere pe suprafețe mai reduse, realizându-se împărțirea ecranului în 5, 7 sau alt număr de imagini afișate simultan. O altă facilitate este oprirea imaginii la un anumit cadru de la o cameră într-un moment ales de utilizator. La mai multe modele de quad apare posibilitatea de a funcționa și împreună cu un sistem de alarmare care folosește senzori PIR. În acest scop quad-ul are un număr de intrări de alarmare, care se conectează la senzorii de mișcare montați în apropierea camerelor video. Dacă detectorul PIR sesizează mișcare, va declanșa semnalul de alarmă care are ca rezultat afișarea pe tot ecranul de monitorizare a imaginii provenite de la camera video de lângă senzorul care s-a activat, iar cu ajutorul textului ce se afișează în același timp pe ecran se poate determina imediat localizarea alarmei. Tot odată, din interpretarea informațiilor de pe monitor se poate determina dacă este o alarmă falsă sau se necesită intervenție umană. Odată cu declanșarea alarmei se activează o sirenă care avertizează operatorul asupra existenței unui eveniment ce necesită un răspuns. În cadrul sistemului de alarmă din componența unui quad este și o mufă de ieșire care permite prin intermediul unui releu activarea unei comenzi către o unitate de execuție. Prin programare se poate comuta din modul de afișare simultană a

imaginilor în modul de afișare secvențială, existând, de asemenea, posibilitatea de a stabili timpul de afișare a fiecărei camere. Caracteristicile unui echipament quad uzual sunt: semnal de intrare permis, în domeniul 0,7-1,2Vpp având impedanța de 75 ohmi, amplitudinea semnalelor de ieșire de 1Vpp la 75 ohmi, quantizarea pe 8 bit a fiecărui culori de bază, mufele de conectare de intrare-ieșire de tip BNC, carcasă metalică, temperatură de funcționare de la -5C la 40C.

### **2.3.2.3. Multiplexor**

Un echipament mult îmbunătățit în cea ce privește nivelul de prelucrare a semnalelor video este multiplexorul. Acest aparat este conceput să lucreze în combinație cu un înregistrator, oferind funcții de conexiune și permițând schimbarea automată a vitezelor de redare după modificarea vitezelor de înregistrare o recorder-ului. Multiplexorul oferă semnale video de calitate cu posibilitatea de a mări imaginea furnizată de o cameră video de 4 ori ( de 2 ori pentru fiecare dimensiune ), pentru a permite observarea unor detalii. Această facilitate este valabilă atât pentru imaginile în timp real furnizate de camere video, cât și pentru imagini redare de pe înregistratoare. Memoria video are o capacitate de 512 x 512 pixeli sau 1024 x 1024 pixeli cu o quantizare pe 8 bit pentru imagini monocrome sau 3 x 8 bit pentru imagini color. La fel ca echipamentele de tip quad și multiplexoarele pot crea imagini pe monitoare care să prezinte simultan semnale de la 4, 9, 16 camere video în cazul prezentării pe suprafețe egale de ecran sau 3, 5, 7 etc. pentru afișarea cu o imagine centrală și alte câteva imagini prezentate în rezumat pe suprafețe mici. De asemenea aceste echipamente permit afișarea imaginilor în mod secvențial ca și swicher-ele, având timpi de afișare programabili pentru fiecare semnal de intrare video. Programarea unui multiplexor se poate face de la butoanele de pe partea frontală a aparatului sau de la distanță, prin intermediul unui port serial de comunicație având de obicei o conexiune RS 232 sau RS 485. Prin program se pot stabili modurile de funcționare pentru regimul de zi și regimul de noapte, separat pe intervale de o săptămână sau în mod general pentru zile lucrătoare, sărbători legale și duminici. Din programare se pot masca anumite camere



video de la afișare și se poate stabili ordinea de desfășurare spațială și temporală a imaginilor recepționate din sistem. Multiplexoarele au posibilitatea de gestionarea unui număr mai mare de semnale de alarmare decât quad-urile, acordând diferitelor semnale de intrare priorități, operațiile ce se execută în caz de alarmă fiind tratate separat în modul de funcționare de zi și cel de noapte. Caracteristicile unui multiplexor comercial sunt: număr de camere video maxime la intrare poate varia între 9 și 16, modelele de echipamente fiind separate pentru cele ce pot prelucra semnale video monocrome și cele ce pot prelucra semnale video color; două ieșiri pentru semnalele către monitoare și o ieșire-intrare video pentru recorder; toate semnalele video se conectează prin mufe BNC cu impedanțe de 75 ohmi, iar semnalele de alarmă se conectează pe conectori DB25 și porturile seriale pe conectori DB 9; carcasa este metalică; apariția unui semnal de alarmă sau pierderea unui semnal video se semnalizează prin activarea unui buzzer; afișarea a maxim 24 caractere în dreptul fiecărei imagini de la câte o cameră video; posibilitatea de a îngheța o imagine atât pentru cele în timp real, provenite de la camere video cât și a celor provenite din înregistrări.

### **2.3.3. Echipamente de înregistrare video**

Semnalul rezultat este afișat pe unul sau mai multe monitoare, iar în unele cazuri este și stocat în recorder-e numite și înregistratoare. Înregistratoarele pot fi analogice sau digitale având posibilitatea de a înregistra cadre cu frecvențe variabile. Astfel pentru o înregistrare analogică, o casetă obișnuită video VHS, la o înregistrare de un cadru la câteva secunde, poate conține imagini de până la 960 de ore. La înregistratoarele digitale imaginile se stochează după comprimare pe hard discuri, timpul de supraveghere depinzând de rata de eșantionare și de capacitatea hard-ului. Un avantaj major al înregistratoarelor digitale, care compensează prețul, este posibilitatea de stocare a fișierelor și de prelucrare ulterioară cu un calculator, precum și posibilitatea de transmitere a imaginilor compresate prin rețele de calculatoare sau prin modem, la alte calculatoare ale beneficiarului, aproape în timp real. Tot pe acest principiu se pot utiliza

și dispecerate care pe lângă alarmele și informațiile primite de la sisteme de alarmă obișnuite pot primi și imagini de la obiectivele supravegheate.

Înregistratoarele analogice realizează memorarea pe casete video standard VHS, folosind 4 capete de înregistrare, care funcționează cu rotații variabile în trepte, permițând preluarea imaginilor cu o viteză ce se modifică de la cea normală până la preluarea unui cadru tot la câteva secunde [M13]. Redarea se poate face atât în sensul înregistrării, cât și în sens invers, folosind viteza de înregistrare sau una accelerată care permite căutarea mai rapidă a secvenței dorite, iar imaginea, odată găsită, se poate îngheța pe un cadru. Timpul de înregistrare după pornire poate fi de minim 1,5 s, deci de la declanșarea semnalului de înregistrare, când recorder-ul este oprit după acest timp, se pot obține primele imagini memorate. Prin intermediul unei cuple DB15 se pot conecta semnale de intrare de la sistemul de alarmă care pun în funcțiune înregistratorul pentru un timp preprogramat de 15s, 30s, 1min 5min dacă nu se dorește să se facă înregistrări non-stop. Înregistrărilor din timpul alarmelor li se atribuie câte un index pentru a fi regăsite cât mai ușor la redare. Există de asemenea și un semnal de ieșire în caz de alarmă pentru comenzi exterioare. Pe lângă un canal de înregistrare video există și un canal audio, dar care nu se poate folosi la înregistrările setate pe lungimi mai mari de 24 de ore pentru o casetă. Imaginile înregistrate se mixează opțional cu data și ora efectuării înregistrării și cu un text ce poate avea caracterele afișate într-o culoare preselectată. Semnalul de intrare sau ieșire video are 1Vpp la o impedanță de 75 ohmi, cuplarea realizându-se pe mufe BNC, iar mufele de intrare și ieșire audio sunt de tip RCA. La sistemele mai puțin pretențioase există posibilitatea de a conecta pentru înregistrare un video recorder obișnuit, de uz casnic, împreună cu un controler de înregistrare care în cazul în care primește un semnal de alarmă de la sistemul de efracție, comandă începerea înregistrării pentru un timp stabilit în prealabil. În acest caz înregistrarea va avea o singură viteză, cea standard, existând posibilitatea de a se umple caseta relativ repede, caz în care imaginile de la eventuale alarmări ulterioare se vor pierde.

Echipamentele de înregistrare digitale extind posibilitățile sistemelor analogice, prin ușurința cu care se pot prelucra și transmite informațiile înmagazinate și prin



creșterea calității imaginilor stocate. Un exemplu de înregistrator digital conține un hard disc de 32 Gb, care poate fi extins cu maxim încă 7 harduri, un port serial pentru transferul de texte atașate imaginilor, un slot PC Card, la care se poate conecta un card de rețea sau de modem din tipurile listate în meniul de instalare. De asemenea firma furnizează și un soft pentru conectarea aparatului la rețea sau la modem, care se instalează pe calculatoarele cu care urmează să comunice înregistratorul. Semnalele de intrare video sunt eșantionate cu o frecvență de la 50 cadre/s la 0,05 cadre/s, existând și posibilitatea de declanșare a înregistrării de la un semnal extern. Înregistratoarele digitale nu au nevoie de un timp de pornire, astfel încât la momentul declanșării unei alarme înregistrarea poate începe imediat. Pentru a mări capacitatea de înmagazinare a imaginilor în cadrul variantelor de vârf a recorder-elor se folosesc arii de hard discuri, ce se pot conecta în grupe de câte 8. Fiecare hard disc se poate extrage sau reintroduce în echipament chiar și în timpul funcționării crescând astfel fezabilitatea sistemului. Cu toate că există posibilitatea ca, după prezentarea parolelor, să se obțină pe floppy discuri sau discuri Zip secvențe de imagini înregistrate de la oricare camera video în fișiere de diferite format de exemplu: MPG sau MOV, pe hard discuri imaginile sunt codificate într-un format propriu, ceea ce nu permite preluarea neautorizată a informațiilor direct de pe aceste discuri. Setările stabilite se pot păstra în fișiere înregistrate pe floppy discuri pentru a permite restaurarea cât mai rapidă a funcționării recorder-ului după o eventuală resetare a sistemului. La înregistrator se pot conecta atât camere video color cât și camere video monocrome. De asemenea există posibilitatea de a înregistra unele semnale video pe discuri în timp ce pe ecranul monitorului se afișează aceleași sau alte semnale video. Care dintre camerele video se vizualizează într-un moment dat precum și modul de aranjare a imaginilor pe ecran se stabilește prin programare. Tot prin setări de către operator se face ca unele imagini să prezinte cadre luate în direct, iar altele să fie secvențe înregistrate pe discuri la un moment anterior stabilit de operator. Pentru economisirea de spațiu pe hard discuri imaginile sunt automat comprimate la înregistrare și decomprimate la redare în mod MPEG sau JPEG cu o rată a compresiei programabilă. Posibilitatea de a sesiza o mișcare în cadrul imaginilor de pe ecran este mai perfecționată la înregistratoarele digitale prin facilitatea de a programa zone de

dectție a mișcării și a stabili sensibilitatea fiecărei zone. Recorder-ul, în urma unor teste, detectează în mod automat dacă există semnal video la intrările validate, sistemul de codare a cromaticității pentru fiecare cameră video separat, precum și sectoarele defecte din matricile de hard discuri. În caz de întrerupere a sursei de alimentare, există încorporat în echipament o memorie flash care poate prelua imagini un timp după căderea tensiunii. Toate imaginile pot fi procesate pentru evitarea vibrațiilor care pot apărea dacă din cauza suportului camera video intră în balans. Pentru a asigura un grad cât mai mare de securitate a informațiilor se folosesc parole cu diferite nivele de acces, atât în utilizarea locală cât și în cazul conectării în rețea.

#### **2.3.4. Echipamente de achiziție**

Pentru sisteme moderne cu mai puține pretenții de performanță și securitate se pot folosi una sau mai multe plăci de achiziție a imaginilor, care se montează într-un calculator, de obicei pe un slot PCI. Aceste card-uri împreună cu softul aferent permit conectarea a câte 2, 4 sau 8 camere video color sau monocrome, precum și a unui număr de intrări de semnale de alarmare de la un sistem de prevenire antiefracție împreună cu ieșiri de comandă pentru unități de execuție ca de exemplu apelatoare telefonice. Astfel de sisteme permit operarea distinctă în modul de zi și în modul de noapte, având programați parametri diferiți în cele 2 moduri de lucru. Imaginile sunt comprimate în mod JPEG sau H263 cu rată de compresie programabilă, ceea ce permite stocarea unui volum mai mare de informații pe hard discuri. Cu aceste echipamente se pot simula quad-uri și multiplexoare, permițând afișarea a 4, 9 sau 16 imagini simultan, sau se pot simula switchere afișând-se câte o imagine pe tot ecranul la intervale de timp prestabilite. Pentru fiecare imagine în parte se poate regla strălucirea, contrastul și saturația. Există posibilitatea de conectare a mai multor calculatoare în rețea, informațiile transferate fiind protejate printr-un sistem de parole pe diferite nivele de acces. Pentru detecția mișcării care poate declanșa caile de ieșire către un sistem de alarmă, se programează zone de detecție a mișcării, pentru fiecare astfel de zonă

existând posibilitatea de setare a sensibilității. De asemenea sistemul oferă suport pentru comanda unui echipament PAN-TILT-ZOOM.

În afara acestor echipamente în cadrul sistemelor de supraveghere prin camere video se mai folosesc și alte aparate anexe ca de exemplu amplificatoare de semnal video, utilizate în cazul în care distanțele de la camerele video la sistemul de prelucrare sunt mari; distribuitoare de semnale video și audio; sisteme PIP ( imagine în imagine ), care permit afișarea în rezumat a unei imagini de la o cameră video în cadrul altei imagini care se afișează pe tot ecranul monitorului; iluminatoare în infraroșu folosite în zonele supravegheate cu camere video și care au o iluminare slabă; unități de control pentru scanare și dispozitive de scanare, pe care se montează camere video, pentru a se obține o mișcare permanentă în plan orizontal ( PAN ) de la stânga la dreapta și invers, cu un unghi reglabil de maxim 355°. Un alt dispozitiv de mișcare a camerei video este PAN-TILT-ZOOM care permite rotirea sistemului de captarea a imaginilor atât în plan orizontal ( PAN ), cât și în plan vertical ( TILT ), precum și modificarea zoom-ului. Toate aceste mișcări sunt controlate de la unitatea de control care se conectează la un pupitru de comandă prevăzut cu un joy-stick. Există astfel de unități de control pentru coordonarea unei camere video sau unități care comandă un grup de 4, 8 sau 16 camere video pe rând. De asemenea la sistemele care nu au detectoare de mișcare încorporat se pot atașa echipamente speciale pentru detecția mișcării într-un număr de puncte sau în anumite zone stabilite prin reglaje.

### **2.3.5. Monitoare**

Afișarea imaginilor se poate face pe ecrane TV sau pe display-uri de calculator dar majoritatea sistemelor de supraveghere video folosesc monitoare profesionale. Aceste monitoare video pot fi monocrome sau color și se remarcă prin fiabilitate și posibilitatea de a funcționa în condiții severe de mediu. Aproape toate monitoarele de acest tip au carcase metalice, cea ce le permite să suporte o presiune ridicată la apăsare statică cât și la impact. De asemenea au o protecție îmbunătățită la perturbații

electromagnetice și electrostatice. Diagonala tuburilor cinescop din componența monitoarelor variază într-o gamă largă, în uzul comercial având dimensiunile între 12” și 21”. Monitoarele au intrările video sunt prevăzute cu conectori BNC și permit conectarea și a unui canal audio. De asemenea au în configurație câte o ieșire video BNC, pentru a permite conectarea mai multor monitoare sau legarea la alte echipamente din sistem. În mod uzual un monitor profesional are următoarele caracteristici: impedanță de intrare video 75 ohmi, amplitudinea semnalului maxim admis de 2 Vpp, boxe încorporate, rezoluție orizontală de 380 linii TV pentru sistem NTSC și 420 linii TV pentru sistem PAL, temperatură admisă a mediului la funcționare de -10C la 60C.

În finalul acestui subcapitol trebuie menționat faptul că deși informația furnizată de sistemele video este mai cuprinzătoare, totuși există unele dezavantaje care nu pot fi eliminate, deoarece sunt legate de principiul de funcționare a sistemului. Una din aceste limitări se referă la necesitatea existenței unei iluminări a cadrului care trebuie supravegheat, condiție care în mediu extern, uneori este greu de îndeplinit. Un alt impediment al acestui tip de supraveghere se referă la mărimea spațiului cuprins în imagine, respectiv la faptul că dacă se dorește o supraveghere pe o arie extinsă se pierde din detalii, iar dacă se dorește obținerea a mai multor detalii se poate face o urmărire numai pe o arie mai restrânsă. În final, un alt impediment al acestui tip de supraveghere se datorează complexității imaginilor obținute din cauza variației luminii reflectate de obiecte, cum ar fi de exemplu umbrele. Aceste fenomene fac ca recunoașterea obiectelor să fie dificilă și în mare măsură incertă. Din toate aceste motive abordarea prezentată în această teză, folosind granularitatea și fuziunea informației cu sistemele bazate pe gradienti de temperatură, conduce la eliminarea, uneori chiar și numai parțială, a acestor deficiențe, obținându-se rezultate mult îmbunătățite.

## 2.4. Concluzii

Sistemele de supraveghere și alarmare sunt cuprinse într-un domeniu în plină dezvoltare. Dacă acum 20 de ani se foloseau astfel de sisteme numai în unele instituții

bancare, azi se instalează un număr impresionant de astfel de sistem, în aproape toate domeniile, începând de la cel casnic și până la cel militar. În România azi sunt înregistrate în jur de 450 de firme care au ca principal domeniu de activitate această ocupație, iar cifra de afaceri a acestor firme fost evaluat la 200 milioane de euro în 2005 și se estimează că va continua să crească. Trebuie menționat că situația de la noi nu este o particularitate. În toată lumea acest domeniu este în dezvoltare. Cauzele ar putea fi două: o schimbare de mentalitate a societății și o dezvoltare tehnologică, care face posibilă obținerea acestor servicii la prețuri relativ mici.

Din punct de vedere tehnic, azi cele mai multe sisteme se bazează pe detecția pasivă a modificării gradientului de temperatură, dar există în mod cert o trecere spre detecția video, care prezintă unele avantaje nete, din punct de vedere a incidenței alarmelor false. Pe de altă parte a început să aibă o valoare comercială utilizarea echipamentelor biometrice, cea ce face ca varietatea echipamentelor și a metodelor de protecție să fie tot mai largă. Rezultă că cea ce este important pentru proiectarea unui astfel de sistem este obținerea celui mai bun compromis preț-eficiență.

În acest context teza de față aduce o deschidere într-un domeniu nou, cel a utilizării teoriei mulțimilor vagi, a teoriei mulțimilor grosiere, a granularității informației și a fuziunii în acesastă arie de dezvoltare. Prin aplicarea acestor teorii din perspectiva inteligenței artificiale se obține cumularea avantajelor din cele două domenii de dezvoltare a sistemelor de alarmare descrise anterior, obținându-se rezultate superioare fiecăruia în parte. Astfel, dezavantaje ale sistemelor de tipul celor prezentate în paragraful 2.2. referitoare la slabul nivel de localizare și identificare, dar mai ales cel referitor la procentul mare de alarme false, precum și principalele dezavantaje a sistemelor prezentate în paragraful 2.3. referitoare în special la funcționarea noctură și la ambiguitatea etichetării obiectelor apărute în imagini să fie diminuate. Prin folosirea informațiilor din cele două sisteme se obține o rezultantă îmbunătățită datorită complementarității parțiale a datelor, a granularității lor, a stabilirii nivelelor de incertitudine și a faptului că prelucrează caracteristici diferite ale acelorași obiecte.



## **PARTEA II. Contribuții la fundamentarea alegerii metodelor**

Partea a doua prezintă contribuțiile autorului la sistematizarea unor domenii noi din aria de cuprindere a bazei teoretice a tezei, iar prin folosirea acestor studii se fundamentează alegerea metodelor folosite în partea a treia a prezentei lucrări. Această parte a tezei cuprinde trei capitole.

Capitolul III face un studiu a teoriei mulțimilor grosiere, referitor la fundamentele teoretice și la aplicațiile acestora, așa cum este prezentată în articolele din literatura de specialitate. De asemenea se face o grupare a mulțimilor grosiere pe tipuri și se specifică motivația pentru care s-au ales mulțimilor grosiere de tip fuzzy pentru a fi utilizate în partea a treia a lucrării

În Capitolul IV se analizează un domeniu de actualitate din domeniul Inteligenței Artificiale și anume cel al Granularității Informației. În acest sens, după studierea diferitelor interpretări ale acestei noțiuni, se trece la o clasificare a tipurilor de abordări a acestui concept. În acest mod se fundamentează folosirea granularității informației în parte a treia a tezei.

Capitolul V prezintă o clasificare originală a fuziunii informațiilor pe baza unui studiu a lucrărilor din acest domeniu. Se stabilesc tipurile de fuziuni ale informației, precum și avantajele și dezavantajele utilizării lor. Aceste rezultate sunt apoi folosite în capitolul IX.





## Capitolul III. Mulțimi grosiere

### 3.1. Introducere

Acest capitol își propune să realizeze o analiză originală a noțiunilor din teoria mulțimilor grosiere. Denumirea de mulțime grosieră am introdus-o prin traducerea termenului folosit în engleză de „rough”, cea ce în dicționar [Lev74] este tradus ca: „*grosolan; ordinar; aspru; brut; zbârlit; pietros; accidentat; discordant*”. Am considerat că traducerea în limba română prin „grosier” are o semnificație mai aproape de esența noțiunii.

Pe de altă parte clasificarea realizată în cadrul capitolului a fost realizată de mine pe baza lucrărilor studiate din acest domeniu. Asupra corectitudinii sau completitudinii grupării categoriale care este prezentată în acest capitol pot exista eventuale obiecții, pe care le primesc cu mulțumiri anticipate.

Referitor la noțiunea de mulțime grosieră, respectiv la cele conexe, de aproximare superioară și aproximare inferioară, ar trebui subliniată legătura pe care o au cu alte noțiuni din „soft computing”. Astfel, și această teorie își propune să creeze un procedeu de delimitare a incertitudinii, la fel ca în teoria posibilității, unde se definește necesitatea și posibilitatea, sau în teoria Demster-Schaffer, în care se definește credibilitatea sau plauzabilitatea. Avantajul pe care, cred eu, îl are această teorie este modul mai natural de definire. În acest sens am folosit și eu aceste noțiuni, de aproximare inferioară și superioară, în partea a III-a a acestei teze, care se referă la realizarea sistemului.

### 3.2. Mulțimi grosiere

Teoria mulțimilor grosiere a fost introdusă de Pawlak [Paw01] în 1982, ca o metodă de a defini aproximarea unei informații incomplet cunoscute. În acest sens considerăm un set de obiecte  $X$  definite într-un univers  $U$  și caracterizate printr-o serie

de atribute  $A$ . Deoarece cunoștințele noastre despre aceste obiecte se consideră incomplete, nu avem decât o evaluare a unor atribute. Noțiunea de bază introdusă de această teorie este cea de *indistinctibilitate* care subliniază imposibilitatea celui care observă aceste obiecte să le distingă pe fiecare în parte, din cauza informației incomplete. Astfel, între obiectele care nu pot fi deosebite apare o relație de echivalență indusă de clasificarea realizată de observator, care, din cauză că nu le poate deosebi, le consideră identice și le atribuie aceeași etichetă. Cea ce se transpune matematic în următoarea teoremă:

Considerând un univers  $U$  și două elemente  $x, y$  ale universului  $U$ , precum și o relație de echivalență  $R$  definită cu elemente din  $U$ , există o clasă de echivalențe  $[y]_R = [x]_R$  dacă  $y \in [x]_R$ .

De asemenea se definesc următoarele noțiuni:

1. Considerăm un univers  $U$  și o relație de echivalență  $R$  definită cu elemente din  $U$ . Pentru orice submulțime  $X \subseteq U$ , submulțimea

$$\underline{R}(X) = \{x \in U \mid [x]_R \subseteq X\} \quad (3.1.)$$

se numește *aproximarea inferioară* a mulțimii  $X$ .

2. Considerăm un univers  $U$  și o relație de echivalență  $R$  definită cu elemente din  $U$ . Pentru orice submulțime  $X \subseteq U$ , submulțimea

$$\overline{R}(X) = \{x \in U \mid [x]_R \cap X \neq \emptyset\} \quad (3.2.)$$

se numește *aproximarea superioară* a mulțimii  $X$ .


3. Considerăm un univers  $U$  și o relație de echivalență  $R$  definită cu elemente din  $U$ . Fie o submulțime  $X \subseteq U$ ; Mulțimea  $\mathcal{W} = \{R(X) \mid X \subseteq U\}$  se numește *mulțimea mulțimilor grosiere* pe  $U$ .

4. Considerăm un univers  $U$  și o relație de echivalență  $R$  definită cu elemente din  $U$ . Fie submulțimile  $X, Y \subseteq U$ . Mulțimea  $X$  se numește  $R$ -inclusă în  $Y$  dacă  $\underline{R}X \subseteq \underline{R}Y$  și  $\overline{R}X \subseteq \overline{R}Y$ , și se numește  $R$ -echivalentă cu  $Y$  dacă  $\underline{R}X = \underline{R}Y$  și  $\overline{R}X = \overline{R}Y$ .

Din definițiile prezentate anterior rezultă că aproximarea inferioară  $\underline{R}$  reprezintă mulțimea elementelor universului  $U$  care aparțin unor clase de echivalență incluse în mulțimea  $X$  și deci care aparțin în mod *sigur* mulțimii  $X$ .

Aproximarea superioară  $\overline{R}$  reprezintă mulțimea elementelor universului  $U$  care aparțin unor clase de echivalență care au elemente comune cu mulțimea  $X$  dar care conțin și elemente care nu sunt în mod sigur incluse în mulțimea  $X$ . Deci această mulțime conține elementele *posibile* să aparțină mulțimii  $X$ .

Spre exemplu în figura 3.1 se prezintă aproximarea inferioară și aproximarea superioară a unui obiect observat cu o granularitate reprezentată prin pătrate.



**Figura 3.1.** Aproximarea unei mulțimi  $X$ , ce cuprind granule pozitive  $P$  și nu cuprinde granule negative  $N$

Unii autori [Coc03] consideră mai important de subliniat complementul mulțimii  $\overline{R}$  și care reprezintă mulțimea elementelor din universul  $U$  care în mod sigur nu aparțin mulțimii  $X$  și care definește funcția de *distinctibilitate*. Din acest punct de vedere se pot defini 3 tipuri de regiuni [Jen04].

Regiunea pozitivă a mulțimii definită astfel:

$$POS(X) = \bigcup_{X \in I'} \underline{R}X \quad (3.3.)$$

regiunea negativă:

$$NEG(X) = U - \bigcup_{X \in I'} \overline{R}X \quad (3.4.)$$

Între cele două aproximări este o regiune de graniță în care nu putem determina care dintre elemente aparțin mulțimii  $X$  și care nu:

$$BND(X) = \bigcup_{X \in I'} \overline{R}X - \bigcup_{X \in I'} \underline{R}X \quad (3.5.)$$

În cazul datelor spațiale, existând pentru fiecare mulțime robustă câte o regiune pozitivă și una negativă, relațiile topologice reciproce dintre două mulțimi devin mai complexe. Astfel dacă în cazul unor domenii precise pot exista 8 poziții topologice, de tip RCC-8, în cazul mulțimilor robuste relațiile sunt mult mai ample, având 46 de posibile relații topologice [Bea01]. Dintre aceste unele sunt degenerate, deoarece, de exemplu, nu are sens o relație de mulțimi tangente, iar unele cazuri, dacă aproximarea inferioară este egală cu aproximarea superioară, se reduc la cele existente în relațiile dintre mulțimi precise.

Principalele proprietăți ale mulțimilor grosiere sunt [Rod04]:

Pentru orice spațiu de aproximare  $X$  având dată o relație  $R$  avem

P1: 
$$\underline{R}(X) = X, \overline{R}(0) = 0 \quad (3.6.)$$

P2: pentru orice  $A, B \subseteq X$ , (proprietatea de monotonie)

dacă,  $A \subseteq B$ , atunci :

$$\begin{aligned} \underline{R}(A) &\subseteq \underline{R}(B) \\ \overline{R}(A) &\subseteq \overline{R}(B) \end{aligned} \quad (3.7.)$$

P3: pentru oricare  $A \subseteq X$ , (proprietatea de dualitate)

$$\begin{aligned} \overline{R}(A) &= -\underline{R}(-A) \\ \underline{R}(A) &= -\overline{R}(-A) \end{aligned} \quad (3.8.)$$

P4: pentru orice familie indexată de submulțimi  $A_i$  ai mulțimii  $X$  avem:

$$\begin{aligned} \underline{R}(\bigcap_{i \in I} A_i) &= \bigcap_{i \in I} \underline{R}(A_i) \\ \overline{R}(\bigcap_{i \in I} A_i) &\subseteq \bigcap_{i \in I} \overline{R}(A_i) \\ \underline{R}(\bigcup_{i \in I} A_i) &\supseteq \bigcup_{i \in I} \underline{R}(A_i) \\ \overline{R}(\bigcup_{i \in I} A_i) &= \bigcup_{i \in I} \overline{R}(A_i) \end{aligned} \quad (3.9.)$$

P5: pentru orice  $A, B \subseteq X$ , (proprietatea de normalitate)

$$\underline{R}(-A \cup B) \subseteq -\underline{R}(A) \cup \underline{R}(B) \quad (3.10.)$$

Pe baza definiției mulțimilor grosiere se pot da următoarele extensii [Huy04] :

- o mulțime  $X$  se numește definită (sau exactă), dacă și numai dacă  $\underline{R}(X) = \overline{R}(X)$
- o mulțime  $X$  se numește inclusă în mod grosier în mulțimea  $Y$  dacă și numai dacă  $\underline{R}(X) \subset \underline{R}(Y)$  și  $\overline{R}(X) \subset \overline{R}(Y)$
- două mulțimi  $X, Y$  se numesc egale grosier dacă și numai dacă  $\underline{R}(X) = \underline{R}(Y)$  și  $\overline{R}(X) = \overline{R}(Y)$

De asemenea se mai definesc două elemente de caracterizare a impreciziei:

- coeficientul de acuratețe:

$$\alpha_R = \frac{|R(X)|}{|\overline{R(X)}|} \quad (3.11.)$$

- coeficientul de grosiere:

$$\rho_R = 1 - \alpha_R = \frac{|\underline{R(X)}|}{|\overline{R(X)}|} \quad (3.12.)$$

De observat că coeficientul  $\rho_R$  poate fi folosit ca o metrică de tip Marczewski-Steinhaus:

$$D_{MZ}(X, Y) = 1 - \frac{|X \cap Y|}{|X \cup Y|} \quad (3.13.)$$

### 3.3. Mulțimi grosiere generalizate pe bază de similaritate

Relația de echivalență introdusă de Pawlak este în numeroase cazuri practice mult prea restrictivă. Echivalența dintre obiecte implică îndeplinirea simultană a trei proprietăți: reflexivitate, simetrie și tranzitivitate. Dintre acestea doar proprietatea de reflexibilitate este îndeplinită în mod natural, deoarece în mod evident un obiect se află într-o mulțime cu el însăși. De aceea în cazul aproximărilor o relație de similitudine este mai generală și mai des întâlnită. Proprietatea de simetrie este îndeplinită în multe cazuri în care aproximarea are un caracter spațial și este asociată cu vecinătatea obiectelor. Deci o aproximare superioară sau inferioară a unui obiect va lua în considerare elementele vecine acestuia. În aceste cazuri proprietatea de vecinătate induce și proprietatea de simetrie. Dar în cazul aproximărilor temporale nu este sigură simetria. Un atribut ce derivă sau evoluează dintr-un alt atribut nu are proprietatea de simetrie față de ascendentul său, pentru că nu se poate considera că atributul din care a derivat descendentul este în aceeași relație de descendență și deci relația nu este simetrică. Tranzitivitatea este o proprietate și mai puțin întâlnită în relațiile de similitudine. Un caz celebru cel a lui Luce [Slo00], în care se consideră similitudinea dintre o serie de cești

de cafea îndulcite cu cantități de zahăr din ce în ce mai mari, dar între două cești succesive fiind o diferență de zahăr mică. Astfel între două cești există o similitudine, pentru că un om obișnuit nu poate face diferența dintre ele, dar între primul și ultimul există o diferență ce poate fi sesizată. O analiză matematică a implicațiilor ce rezultă din existența sau nu, a acestor proprietăți se face în [Slo00]. Astfel, în cazul în care aplicația permite existența numai a proprietății de reflexibilitate, aproximarea inferioară se poate defini cu relația:

$$\underline{R}X = \{x \in U : R^{-1}(x) \subseteq X\} \quad (3.14.)$$

iar aproximarea superioară prin relația:

$$\overline{R}X = \bigcup_{x \in U} R(x) \quad (3.15.)$$

unde  $R^{-1}$  este inversul relației  $R$ . Dacă pe lângă relația de reflexibilitate se mai poate aplica și proprietatea de simetrie atunci relația inversă este aceeași cu relația directă și se mai poate defini o pereche de relații ce definesc aproximarea inferioară:

$$\underline{R}X = \{x \in U : R(x) \subseteq X\} \quad (3.16.)$$

și aproximarea superioară :

$$\overline{R}X = \{x \in U : R(x) \cap X \neq \emptyset\} \quad (3.17.)$$

Dacă pe lângă proprietățile mai sus amintite relația din cadrul unei aplicații, se admite și proprietatea de tranzitivitate atunci avem toate condițiile necesare definirii unei echivalențe și se pot folosi definițiile introduse de Pawlak pentru aproximațiile inferioare și superioare.

### 3.4. Aplicații ale mulțimilor grosiere

#### 3.4.1. Reducerea numărului de atribute

Algoritmul de reducere a atributelor este una din cele mai utilizate aplicații a teoriei mulțimilor grosiere și constă din compararea relațiilor de echivalență generate pe spațiile de atribute. Reducerea se obține prin determinarea unei submulțimi de cardinalitate minimă, care să aibă același factor de acoperire asupra unui sistem de informații. Un **sistem de informații** este o funcție  $f : U \times A \rightarrow V$ , unde elemente din Universul  $U$  au atribute în mulțimea  $A$  de valori  $V$  [Pal04]. În cele mai multe cazuri sistemele de informații se prezintă sub forma unor tabele de corespondență în care un număr de atribute ce reprezintă condițiile, sunt puse în corespondență cu atribute ce reprezintă concluziile sau deciziile.

Fiecare atribut care definește o condiție definește o clasă de echivalență pe mulțimea obiectelor definite în sistemul de informații. Pentru a determina clasele de echivalență generate de o mulțime de atribute ale condițiilor se determină reuniunea mulțimilor rezultate din toate intersecțiile dintre elementele fiecărei clase de echivalență corespunzătoare atributelor. Astfel folosind notațiile din [Jen03] clasele de echivalență definite de un atribut au expresia:

$$U / IND(a) = \{(x, y) \in U^2 \mid \forall a \in A, a(x) = a(y)\} \quad (3.18.)$$

iar clasa de echivalență generată de o mulțime de atribute  $P$  se determină cu relația:

$$U / IND(P) = \otimes \{a \in P : U / IND(a)\} \quad (3.19.)$$

unde

$$A \otimes B = \{X \cap Y : \forall X \in A, \forall Y \in B, X \cap Y \neq \emptyset\}$$



Folosind relațiile de echivalență induse de mulțimi de atribute, așa cum au fost definite mai sus, se pot determina regiunile pozitive, negative și de graniță folosind relațiile (3.3. ), (3.4), (3.5).

Considerând două mulțimi de atribute  $P$  și  $Q$  se poate defini un nivel de dependență între ele prin calcularea unui coeficient  $k$ , numit și măsură a suportului mulțimii  $Q$ :

$$k_{P,Q} = \frac{|POS_P(Q)|}{|U|} \quad (3.20.)$$

unde  $|U|$  reprezintă cardinalitatea mulțimi  $U$ .

Dacă  $k$  are valoarea 1 există o dependență totală, ceea ce denotă că toate atributele din mulțimea  $Q$  sunt în mod unic determinate de atributele din mulțimea  $P$ , iar o valoare  $k=0$  semnifică o independență între cele două mulțimi de atribute. În acest fel, definind prin  $P$  o mulțime de atribute ce semnifică condiții și prin  $Q$  mulțimea atributelor ce reprezintă concluzii sau decizii, se poate determina influența fiecărui atribut de tip condiție  $a$  asupra mulțimii atributelor de tip decizie folosind diferența între coeficientul de dependență a unei mulțimii de atribute  $P$  raportat la mulțimea  $Q$  și coeficientul de dependență a mulțimii  $P-\{a\}$  raportat la aceeași mulțime  $Q$  :

$$\sigma_{P,Q}(a) = k_{P,Q} - k_{P-\{a\},Q} \quad (3.21.)$$

Dacă diferența nu crește atunci putem considera că atributul  $a$  nu are nici o influență asupra mulțimii de decizie  $Q$  și poate fi redus. Deci un algoritm pentru reducerea atributelor și obținerea unor reguli dintr-o bază de date este determinarea iterativă a influenței fiecărui atribut de condiție [Hu96]. Algoritmul se oprește când nu mai există nici un atribut care poate fi redus, rezultând un set de atribute esențiale.

O metodă des utilizată pentru determinarea mulțimii atributelor esențiale de tip condiție, care nu pot fi reduse fără modificarea semnificației informației, este folosirea matricii de distinctibilitate și a funcției de distinctibilitate.

O matrice de distinctibilitate este o matrice simetrică de dimensiune  $U \times U$  care are ca elemente mulțimea atributelor de tip condiție  $d_{i,j}$ , care diferă între două obiecte ale universului  $U$ :

$$d_{i,j} = \{a \in C \mid a(x_i) \neq a(x_j)\}, i, j = 1, \dots, |U| \quad (3.22.)$$

Dintre elementele matricii se stabilește un nucleu de elemente, sau măcar unul dintre ele care să fie cuprins în fiecare dintre celule.

Funcția de distinctibilitate este o funcție de tip Boolean care are câte o variabilă pentru fiecare atribut și care transformă o dispunere canonic conjunctivă în una disjunctivă. Elementele inițiale sunt atributele din fiecare celulă a matricii de distinctibilitate unite prin operații disjunctive, iar între elementele celulelor se aplică operații conjunctive:

$$f_D = \wedge \{ \vee c_{i,j} \mid 1 \leq j \leq i \leq |U|, c_{i,j} \neq 0 \} \quad (3.23.)$$

În urma transformării în forma disjunctivă rămân numai elementele nucleului, care reprezintă reuniunea atributelor esențiale care nu pot fi reduse. Aceste atribute formează numărul minim de elemente care păstrează informația din sistemul inițial. Deși această metodă garantează determinarea tuturor mulțimilor minimale, totuși are dezavantajul de a necesita un timp de calcul foarte mare pentru situațiile în care se utilizează multe atribute. Din această cauză, pentru unele aplicații în care nu este necesară determinarea decât a unei mulțimi reduse, se poate folosi o metodă de determinare de jos în sus plecând de la un atribut și încercând să se adauge la nucleu câte un element. Ca și criteriu de selecție a atributelor candidate ce urmează să fie incluse în nucleu, poate fi folosit cel al frecvenței de apariție, deci cu cât un atribut are o

frecvență de apariție mai mare în matricea de distinctibilitate cu atât are o șansă mai mare de a aparține nucleului.

Pentru obiectele care au un grad de suprapunere, se poate folosi o metodă de reducere folosind o precizie variabilă [Jen04]. În acest caz se propune modificarea printr-o manieră statistică a caracteristicii de indistinctibilitate prin admiterea unei erori de clasificare. Metrica pentru această eroare are relația:

$$c(X, Y) = 1 - \frac{|X \cap Y|}{|X|} \quad (3.24.)$$

iar obiectele se consideră aparținând aceleiași clase dacă eroarea  $c(X, Y)$  este mai mică decât o constantă  $\beta$  definită de utilizator. În acest fel se poate defini o relație de incluziune:

$$X \subseteq_{\beta} Y \text{ dacă } c(X, Y) \leq \beta \quad (3.25.)$$

iar aproximarea inferioară  $\underline{R}_{\beta}$  și aproximarea superioară  $\overline{R}_{\beta}$  se redefinesc astfel:

$$\begin{aligned} \underline{R}_{\beta} &= \bigcup \{ [x]_R \in U \mid [x]_R \subseteq_{\beta} X \} \\ \overline{R}_{\beta} &= \bigcup \{ [x]_R \in U \mid c([x]_R, X) < 1 - \beta \} \end{aligned} \quad (3.26.)$$

Pe baza acestor relații se pot determina regiuni  $\beta$ -pozitive, regiuni  $\beta$ -negative și regiuni  $\beta$ - de graniță, precum și se poate folosi metodele de reducere prezentate anterior.

### 3.4.2. Abordarea statistică a mulțimilor grosiere

În afară de o abordare algebrică, în unele lucrări [Wan04] se propune și o abordare statistică a mulțimilor grosiere. Astfel peste un sistem de informații putem defini un spațiu de probabilități

$$U / IND(X_p) = \begin{bmatrix} X_1 & X_2 \dots & X_n \\ p(X_1) & p(X_2) & p(X_n) \end{bmatrix} \quad (3.27.)$$

unde  $X_i$  este o combinație de atribute, iar  $p(X_i) = |X_i| / |U|$  este raportul dintre numărul de apariții ale acestei combinații și dimensiunea sistemului de informații.

Folosind probabilitățile astfel definite se poate determina entropia sistemului prin relația:

$$H(X) = - \sum_{i=1, n} p(X_i) \log(p(X_i)) \quad (3.28.)$$

precum și o entropie condiționată dacă se utilizează în relația anterioară o probabilitate condiționată :

$$p(Y_j | X_i) = \frac{|Y_j \cap X_i|}{|X_i|} \quad (3.29.)$$

Se poate stabili următoarea definiție: se spune că un atribut  $a$  poate fi redus dacă entropia condiționată a unei combinații  $B$  de atribute care îl conține, are aceeași valoare cu entropia condiționată a combinației din care a fost scos atributul  $a$ , deci cu  $B-a$  :

$$H(D | B - \{a\}) = H(D | B) \quad (3.30.)$$

unde  $D$  sunt atribute de decizie.

Dacă nici un atribut din mulțimea  $B$  nu mai poate fi redus, atunci acest set este o deducție a mulțimii inițiale de atribute. În [Wan04] se demonstrează că rezultatul obținut prin această metodă este același cu cel obținut prin metode algebrice, dar cu condiția ca sistemul de informații să fie consistent. Dacă această condiție nu este îndeplinită, atunci un rezultat al metodei statistice este o submulțime a celei algebrice și un rezultat statistic este și un rezultat al metodei algebrice, dar reciproca nu este necesară. Consistența se referă la lipsa oricăror contradicții în interiorul sistemului de informații.

Abordarea statistică a unui sistem de informații nu este totdeauna justificată din punct de vedere teoretic, deoarece implică în mod implicit existența unui număr mare de elemente. Însă această premisă nu este îndeplinită întotdeauna, teoria probabilităților fiind aplicată, în aceste cazuri, și unui număr mic de evenimente.

### 3.4.3. Gruparea obiectelor utilizând mulțimi grosiere

Modalitatea de grupare a unor obiecte se poate baza pe similitudinea dintre caracteristicile obiectelor așa cum este exemplificat în [Hir01], ceea ce implică posibilitatea utilizării mulțimilor vagi, așa cum rezultă din cele prezentate anterior.

Astfel, partiționarea în grupe  $P_i$  se face în funcție de un indice de similitudine care este comparat cu un nivel de prag  $T$ :

$$P_i = \{x_j \mid s(x_i, x_j) \geq T\} \quad (3.31.)$$

unde  $s(x_i, x_j)$  este o relație de similitudine.

În unele articole [Hir01] funcția  $s$  din relația 3.31. reprezintă o măsură a similitudinii care se determină ca sumă ponderată între distanțele caracteristicilor

numerice stabilite printr-o distanță euclidiană și distanțele calculate pentru atribute simbolice folosind o metrică Hamming:

$$s(x_i, x_j) = \frac{N_n}{N} \left(1 - \frac{d_E(x_i, x_j)}{\max_{x_u \in U} d_E(x_u, x_i)}\right) + \frac{N_s}{N} \left(1 - \frac{d_H(x_i, x_j)}{\max_{x_u \in U} d_H(x_u, x_i)}\right) \quad (3.32.)$$

iar pragul de separație dintre partiții,  $T$ , se determină ca maxim al variației raportului dintre numărul de elemente similare și numărul total de obiecte.

#### 3.4.4. Stabilirea de reguli folosind mulțimi grosiere

Una din aplicațiile cele mai frecvente a reducerii numărului de atribute și implicit a mulțimilor grosiere este metoda de determinare a unor reguli pe baza informațiilor dintr-o bază de date. Regulile sunt elemente ale cunoașterii de tip intensiv [Car94] și reprezintă o formă de generalizare a cunoștințelor de tip extensiv. Regulile sunt stabilite în urma procesului de reduce a atributelor, prin relații de tip *dacă-atunci*, prin concatenarea atributelor condiționale cu ajutorul operațiilor conjunctive și relaționarea lor cu atributul decizional. Regulile obținute sunt de tipul:

$$atribut_{condi\text{t}ion1} \otimes atribut_{condi\text{t}ion2} \dots \otimes atribut_{condi\text{t}iond} \rightarrow decizie \quad (3.35.)$$

Această procedură permite stabilirea unor reguli care nu sunt în totalitate deterministe, deci nu verifică toate relațiile, ci numai un număr considerat semnificativ dintre ele. Pentru aceasta se stabilește *suportul* și *consistența* unei reguli [Sha96], unde suportul  $\sigma$  este definit ca fiind numărul de exemple care satisfac regula, iar consistența se determină folosind relația:

$$\delta = \frac{\sigma}{N}, N \text{ fiind numărul total de exemple.}$$

Iar o regulă este acceptată ca fiind o aproximare permisă dacă are consistența mai mare decât un prag prestabilit. Astfel, dacă pragul este apropiat de valoarea 1 se vor stabili mai puține reguli, dar mai generale, iar pentru valori mai mici ale pragului zona de acoperire a regulilor asupra exemplurilor va fi mai mică și deci mai puțin semnificativă, dar numărul de reguli va fi mai mare. În acest fel se pot stabili reguli și în condiții de zgomot (respectiv eroare) care pot să afecteze exemplele. În alte articole [Tsu99] se utilizează coeficienții de acuratețe și cei de proiecție, definiți ca raport între numărul de exemple ce satisfac regula  $|A_c \cap D|$  și cele care satisfac numai partea de condiție  $|A_c|$  sau pe cea de decizie  $|D|$  :

$$\alpha = \frac{|A_c \cap D|}{|A_c|} \quad \kappa = \frac{|A_c \cap D|}{|D|} \quad (3.36.)$$

Regulile determinate prin această metodă se clasifică în trei categorii:

- reguli caracteristice, care se aplică la toate exemplele. Acestea sunt de tip determinist și au relația  $d \rightarrow R$ , adică apariția exemplului implică existența regulii,
- reguli discriminatorii, care sunt verificate de majoritatea exemplurilor, respectiv la care acuratețea și proiecția depășesc un anumit prag acceptat ,
- reguli complementare, la care regulile divid mulțimea exemplurilor în partiții unde este valabilă câte o regulă.

### 3.4.5. Fundamentarea deciziilor utilizând mulțimi grosiere

Pentru baze de date ce conțin relaționări între condiții și concluzii, există posibilitatea apariției unor componente eronate, care introduc un zgomot în sistem. În astfel de situații, pentru a stabili reguli fiabile, este nevoie ca aproximarea superioară să nu includă toate informațiile din baza de date. O metodă facilă de a elimina aceste neajunsuri este filtrarea prealabilă a datelor după unele criterii cum ar fi suportul și consistența relației condiție-concluzie. Un exemplu de o astfel de abordare este prezentată în [Sha96]. În acest sens se stabilesc două valori, un număr întreg și pozitiv care va reprezenta suportul, deci numărul minim de apariții necesare unei relații condiție-concluzie pentru a putea fi luată în considerare, și un număr pozitiv și subunitar care reprezintă consistența, deci procentul minim de apariție a unei relații condiție-concluzie. Aceste valori sunt alese de utilizator în funcție de volumul și semnificația datelor. Prin această metodă se face o clasificare în două clase și anume în date semnificative și date ce pot fi ignorate, care probabil reprezintă erori sau cazuri izolate. În continuare se aplică metoda de stabilire a regulilor prezentată în subcapitolul anterior. Prin această filtrare se poate influența numărul de reguli obținute precum și gradul lor de generalitate. Dar trebuie subliniat și neajunsul principal al metodei și anume stabilirea parametrilor care rămâne în sarcina utilizatorului. Alegerea valorilor se face deci în mod subiectiv, iar rezultatul este influențat în mare măsură de acești parametri. Astfel, există riscul ca unele reguli să fie pierdute sau dimpotrivă să se obțină reguli ne semnificative.

### 3.4.6. Metode de clasificare folosind mulțimi grosiere

Clasificarea implică în ultimă instanță atribuirea unui obiect la o anumită clasă deci o etichetare, pe baza unor attribute observabile ale obiectului care este clasificat. Deoarece mulțimile grosiere implică o zonă de incertitudine, rezultă că utilizarea aproximațiilor include același tip de clasificare ca cele de tip soft. Metodele folosite sunt întrucâtva asemănătoare cu cele fuzzy, dar în aceste abordări, pentru domeniile de incertitudine nu se utilizează coeficientul de apartenență, ci un coeficient bazat pe



cardinalitatea zonei pozitive față de întreaga submulțime aflată în discuție. Pentru a putea realiza totuși clasificarea, care este o decizie fermă, trebuie stabilit un prag peste care obiectul se consideră admis. De exemplu, în cazul [Kim00] acest prag se stabilește prin utilizarea unui algoritm genetic aplicat unui set de date de învățare, iar funcția de fitness ține cont atât de cardinalitatea zonei pozitive, cât și de necesitatea de a avea o partiționare cu cât mai puține clase, evitându-se astfel și situația extremă în care fiecare element din mulțimea de învățare generează o partiție separată.

Ca metrică se utilizează de obicei o distanță, așa cum se procedează în majoritatea metodelor de clasificare, dar pentru a avea posibilitatea de a defini o aproximare inferioară și una superioară se folosește o măsură a zonei de graniță, cum ar fi o relație de echivalență, sau mai des una de similitudine. În exemplul amintit anterior relația de similitudine este de forma:

$$S(x, y) = 1 - \frac{d(a(x), a(y))}{d_{\max}} \quad (3.37.)$$

unde

$a(x), a(y)$  sunt atributele obiectelor  $x, y$ , iar  $d_{\max}$  este distanța maximă dintre atribute. Iar măsura incertitudinii se stabilește cu relația:

$$\mu(x) = \frac{\text{card}(\{\forall y \in S(x, y) \mid d(y) \in D\})}{\text{card}(S(x, y))} \quad (3.38.)$$

unde

$D$  este clasa la care se raportează elementul  $x$ .

Ceea ce mai trebuie remarcat, este modul în care se face respingerea unui candidat dacă gradul de incertitudine stabilit pentru o clasă este prea apropiat de gradul de incertitudine a următoarei clase (ordonate descrescător după valorile gradelor de incertitudine). Acest prag se stabilește în funcție de numărul de clase  $N$  definite. Astfel, verificarea se face cu relația:

$$(\mu_{\max 1} - \mu_{\max 2}) / \mu_{\max 1} \leq 1/N \quad (3.39.)$$

De asemenea, este util de remarcat numărul mare de atribute folosite, care sunt stabilite atât pe poziționare (stânga, dreapta, sus, jos), cât și prin proiecțiile acestora pe axele principale.

Aceste două remarci le consider utile și le-am folosit și eu în metoda prezentată în capitolele următoare, dar într-un alt mod de abordare.

### 3.5. Mulțimi fuzzy grosiere

Mulțimile fuzzy grosiere sunt o aplicare a noțiunilor din teoria mulțimilor grosiere adaptate mulțimilor fuzzy. Există mai multe moduri de a generaliza teoria standard la cazul mulțimilor vagi. Două dintre aceste metode sunt mai des folosite [Inu04]. Una este abordarea aproximării inferioare și a celei superioare ca mulțimi fuzzy, deci ștergerea frontierei ferme dintre zonele pozitive, de graniță și negative, prin înlocuirea lor cu treceri gradate, numită și mulțimi robuste fuzzy orientate spre clasificare. Cealaltă își propune determinarea unor aproximări inferioare, respectiv superioare ale unei mulțimi de tip vag (fuzzy).

În primul caz se pleacă de la definiția aproximației inferioare și superioare din teoria mulțimilor grosiere originală și se înlocuiesc operatorii de intersecție și implicație cu variantele generalizate din teoria mulțimilor vagi.

Astfel noile relații devin (Rad04):

- aproximația inferioară fuzzy

$$\underline{R}_F(A)(x) = \inf_{y \in X} (R(x, y) \rightarrow A(y)) \quad (3.40.)$$

- aproximația superioară fuzzy

$$\overline{R}_F(A)(x) = \sup_{y \in X} (R(x, y) \otimes A(y)) \quad (3.41.)$$

unde

$\rightarrow, \otimes$  reprezintă o implicație de tip fuzzy (de exemplu  $a \rightarrow b = \sup\{c \in X : a \otimes c \leq b\}$ ), respectiv o t-normă folosită în cadrul aplicației.

Tot asemănător cu varianta standard se introduce și *mulțimea grosieră fuzzy definită* (care este o singură mulțime), stabilită dacă sunt îndeplinite relațiile:

$$\underline{R}_F(A) = A = \overline{R}_F(A) \quad (3.42.)$$

iar principalele proprietăți sunt:

$$\text{PF1:} \quad \underline{R}_F(X) = X, \overline{R}_F(0) = 0 \quad (3.43.)$$

PF2: pentru orice  $A, B \in F(X)$ , dacă  $A \subseteq B$ , atunci

$$\begin{aligned} \underline{R}_F(A) &\subseteq \underline{R}_F(B) \\ \overline{R}_F(A) &\subseteq \overline{R}_F(B) \end{aligned} \quad (3.44.)$$

PF3: pentru orice  $A \in F(X)$

$$\begin{aligned} \overline{R}_F(A) &\subseteq \neg \underline{R}_F(\neg A) \\ \underline{R}_F(A) &\subseteq \neg \overline{R}_F(\neg A) \end{aligned} \quad (3.45.)$$

PF4: pentru orice familie indexată de submulțimi  $A_i$  ale mulțimii  $X$  avem:

$$\begin{aligned} \underline{R}_F(\bigcap_{i \in I} A_i) &= \bigcap_{i \in I} \underline{R}_F(A_i) \\ \overline{R}_F(\bigcap_{i \in I} A_i) &\subseteq \bigcap_{i \in I} \overline{R}_F(A_i) \end{aligned} \quad (3.46.)$$

$$\begin{aligned} \underline{R}_F(\bigcup_{i \in I} A_i) &\supseteq \bigcup_{i \in I} \underline{R}_F(A_i) \\ \overline{R}_F(\bigcup_{i \in I} A_i) &= \bigcup_{i \in I} \overline{R}_F(A_i) \end{aligned}$$

Se observă că proprietățile PF1, PF2 și PF4 sunt similare cu proprietățile P1, P2 și P4 din cazul mulțimilor grosiere standard, iar proprietatea FP3 este mai slabă decât P3. Este de asemenea de menționat că echivalentul proprietății P5 nu este în general valabil pentru cazul mulțimilor grosiere fuzzy.

O observație interesantă se face în [Inu04], referitor la relațiile de definire a aproximațiilor prezentate anterior. Astfel se arată că relațiile respective implică în mod tacit existența proprietății de reflexibilitate a relației  $R$ . Dacă nu este satisfăcută această proprietate atunci gradul de apartenență devine:

- pentru aproximarea inferioară,:

$$\mu_{\underline{R}(X)}(x) = \min(\mu_X(x), \inf_{y \in X} (\mu_R \rightarrow \mu_X(y))) \quad (3.47.)$$

- iar pentru aproximarea superioară :

$$\mu_{\overline{R}(X)}(x) = \max(\mu_X(x), \sup_{y \in X} (\mu_R \otimes \mu_X(y))) \quad (3.48.)$$

De asemenea este de menționat că aproximațiile fuzzy obținute prin complementare sunt de obicei diferite față de cele directe. Deci vor exista două seturi de aproximații: una obținută prin aproximarea zonei pozitive și alta obținută prin aproximarea complementului zonei negative,  $\mu_{\underline{Q}(X)}, \mu_{\overline{Q}(X)}$  :

$$\mu_{\underline{Q}(X)}(x) = \min(\mu_X(x), \inf_{y \in X} \neg(\mu_Q \otimes \neg\mu_X(y))) \quad (3.49.)$$

și respectiv

$$\mu_{\overline{Q}(X)}(x) = \max(\mu_X(x), \sup_{y \in X} \neg(\mu_Q \rightarrow \neg\mu_X(y))) \quad (3.50.)$$

În ceea ce privește al doilea caz, se consideră aproximarea inferioară, respectiv superioară a unui mulțimi fuzzy [Huy04]. Din acest punct de vedere dacă avem o mulțime fuzzy  $F$  definită pe un univers la cunoașteri  $U$  și o relație  $R$  care induce în universul  $U$  setul de submulțimi  $\{X_1, X_2, \dots, X_m\}$ , atunci funcțiile de aproximare inferioară (funcția de necesitate), respectiv superioară (funcția de posibilitate),  $\underline{F}, \overline{F}$  sunt definite prin următoarele relații de determinare a gradelor de apartenență:

$$\begin{aligned}\mu_{\underline{R(F)}}(X_i) &= \min_{x \in X} (\mu_F(x)) \\ \mu_{\overline{R(F)}}(X_i) &= \max_{x \in X} (\mu_F(x))\end{aligned}\tag{3.51.}$$

iar

$$\begin{aligned}\mu_{\underline{F}}(x) &= \mu_{\underline{R(F)}}(X_i) \\ \mu_{\overline{F}}(x) &= \mu_{\overline{R(F)}}(X_i)\end{aligned}\tag{3.52.}$$

unde  $x \in X_i$ . Deci aproximările sunt mulțimi fuzzy cu valoare constantă pe intervalele claselor de echivalență determinate de relația  $R$ .

În acest mod se poate defini egalitatea din punct de vedere grosier prin îndeplinirea următoarelor relații între două mulțimi fuzzy  $F$  și  $G$ :

$$\underline{R(F)} = \underline{R(G)} \text{ și } \overline{R(F)} = \overline{R(G)}\tag{3.53.}$$

Principalele proprietăți ale acestor mulțimi grosiere fuzzy sunt:

$$\begin{aligned}\underline{R(F)} &\subseteq F \subseteq \overline{R(F)} \\ \overline{R(F \cup G)} &= \overline{R(F)} \cup \overline{R(G)} \\ \underline{R(F \cap G)} &= \underline{R(F)} \cap \underline{R(G)} \\ \underline{R(F \cup G)} &\supseteq \underline{R(F)} \cup \underline{R(G)} \\ \overline{R(F \cap G)} &\subseteq \overline{R(F)} \cap \overline{R(G)} \\ \overline{R(\neg F)} &= \neg \underline{R(F)}, \underline{R(\neg F)} = \neg \overline{R(F)}\end{aligned}\tag{3.54.}$$

unde intersecția este definită de obicei prin funcția minim, reuniunea prin funcția maxim, iar complementul prin negată.

Și în acest caz se poate determina nivelul de grosieritate a unei funcții de tip vag prin calcularea unui coeficient de grosiere  $\rho_R$

$$\rho_R^{\alpha,\beta}(F) = 1 - \frac{|R(F)_\alpha|}{|R(F)_\beta|} \quad (3.55.)$$

dar trebuie observat că așa cum este el definit în relația de mai sus, propusă de Pal și Banerjee [Pal04], implică folosirea a doi coeficienți de tăiere  $\alpha, \beta$  care să transforme mulțimile fuzzy în intervale. Există și alte propuneri mai complexe cum este de exemplu cea din [Huz04], care implică folosirea maselor similare cu cele din teoria Demster-Schaffer.

### 3.6. Concluzii

Teoria mulțimilor grosiere a fost introdusă de Pawlak în 1982, deci are o istorie destul de scurtă. De altfel, denumirea de mulțimi grosiere, a fost făcută de mine din termenul englez de „rough” poate în mod neinspirat, cu toate că mie mi se pare destul de sugestivă prin cea ce exprimă în esență. Chiar dacă teoria mulțimilor grosiere ar putea fi considerată în opoziție cu teoria mulțimilor fuzzy, prin faptul că nu folosește o funcție de reglementare a gradului de incertitudine din interiorul zonei de frontieră, ci doar constată că nu se poate face nici o afirmație referitoare la informațiile din această zonă, personal consider că cele două nu se exclud, doar că este o altă abordare a imperfecțiunii. Pe baza analizei acestei teorii, am decis să folosesc și eu o metodă cu două limite pentru determinarea incertitudinii, care să fie conectată de distanța dintre aceste limite, tot așa cum gradul de incertitudine din teoria mulțimilor grosiere este legat de cardinalitate.

Elemente rezultate din acest capitol le-am folosit și în capitolul de fuziune a părții a 3-a din prezenta teză, în care se stabilește o limită superioară și una inferioară a localizării. În acest caz am aplicat teoria mulțimilor grosiere a unui domeniu nou de aplicare.





## Capitolul IV. Granularitatea informației

### 4.1. Introducere

Granularitatea informației reprezintă o noțiune cuprinzătoare, cu un grad mare de generalizare, a cărei cristalizare taxonomică este încă în curs de realizare. Conceptul este legat de teoria mulțimilor grosiere prin proprietatea de indivizibilitate, respectiv prin faptul că elementele granulei își pierd individualitatea, respectiv noua structură are atribuită o etichetă unică. Prin granularizare informația poate da impresia că pierde din precizie dar așa cum arăta L.Zadeh [Zad05] câștigă în semnificație.

Prezentul capitol descrie principalele tipuri de abordare a granularității informației, pe care le-am studiat din literatura de specialitate. Analizând caracteristicile aplicației, am stabilit să utilizez în sistemul de supraveghere propus în cadrul tezei, granularitatea de tip fuzzy, deoarece informațiile folosite sunt de tip vag.


### 4.2. Sisteme cu granularitate multiplă

Orice percepție a unei informații reale are o anumită granularitate [You04], este o aproximație sau o partiționare a informației care ar mai putea fi detaliată sau formulată mai exact, dar care satisface în forma primită necesitățile concrete de informare. În esență, orice informație este o formă de condiționare generalizată, în sensul că restricționează o variabilă la valoarea pe care o ia prin informarea însăși [Zad04]. Din acest punct de vedere se deosebesc elemente singulare, care au o etichetă individuală, și elemente granulare, în care sunt incluse mai multe elemente singulare și care sunt etichetate printr-o valoare generică. Astfel, în afara unei dualități evidente între precizie, gradul de precizie și mărimea granularității, există și o mărime a utilității nivelului de granulație folosit. O granularitate fină nu implică o utilitate mare, cantitatea

suplimentară de informație obținută poate fi ori nerelevantă pentru aplicație, ori afectată de zgomot și deci inutilizabilă.

Definiția dată de L.Zadeh pentru granularitatea informației este: *”granularitatea informației implică partiționarea unei clase de obiecte (sau puncte) în granule, în care o granulă este un grup de obiecte (sau puncte) care sunt unite prin indistinctibilitate, similaritate sau funcționalitate”*. Granulele de informații nu implică neapărat o partiționare disjunctă, ele se pot și suprapune parțial, așa cum rezultă din unele exemple din biologie, delimitarea partițiilor rezultate în urma unei clasificări având uneori un caracter fuzzy. Rezultă ca granularitatea este un concept cu o arie conceptuală largă, referindu-se atât la dimensiuni spațiale, temporale cât și conceptuale. Din definiția dată anterior se deduce că granularitatea implică un grad de asemănare între caracteristicile elementelor constituate ale granulei de informație și un grad de simetrie care să le permită să fie similare și să poată fi cuprinse într-un obiect generic.

Asupra noțiunilor ce definesc granularitatea informației, încă există dezbateri. Astfel în [Zad05] se face o distincție, care nu este unanim acceptată, între eșantionare și granularizare. Diferența constă în forma ferestrelor prin care se obține informația din mediul observat, eșantionarea având ferestre dreptunghiulare, iar granularizarea ferestre specifice de tip fuzzy, respectiv triunghiulare sau trapezoidale, vezi figura 4.1.



**Figura 4.1.** Exemplificarea diferenței dintre eșantionare și granularizare

În opinia altor autori [Str00] eșantionarea este un caz particular al determinării granularității, care cuprinde toate tipurile de ferestre prin care o mulțime de puncte dintr-un spațiu de analiză sunt etichetate printr-o valoare generică. În cazul în care elementele componente se pot determina prin valori precise, valoarea generică se poate determina prin medie aritmetică, în situația eșantioanelor care folosesc ferestre dreptunghiulare, sau prin sume ponderate cu gradul de apartenență în cazul ferestrelor de tip fuzzy:

$$val(x) = \frac{1}{N} \sum_{i=1}^N x_i \mu_k(x_i) \quad (4.1.)$$

unde  $x_i$  sunt valorile singulare iar  $\mu_k$  sunt coeficienții de apartenență la cele două mulțimi fuzzy care sunt intersectate de elementul  $i$ . Dar în majoritatea situațiilor reale valorile sunt imprecise și cel mult estimate printr-o medie și o eroare presupusă. În aceste cazuri pentru estimarea cu ferestre dreptunghiulare se pot determina cel mult valorile posibile și necesare. Trebuie menționat că metodele probabilistice nu au totdeauna o bază matematică pentru a fi aplicate, în special în cazul unui număr mic de valori. Pentru cazul ferestrelor de tip triunghiulare în [Str00] se demonstrează că valoarea estimată cea mai bună este:

$$\bar{x} = e_{\min} + (x + \bar{\alpha}_m) \Delta / 2 \quad (4.2.)$$

unde:

$$\bar{\alpha}_i = \frac{H_{i-1} - H_{i+1}}{H_{i-1} - H_i - H_{i+1} + H_{i+2}} \quad (4.3.)$$

reprezintă abaterea dintre centrul intervalului considerat și centrul triunghiului de eșantionare. Aici  $\Delta$  este lățimea intervalului considerat, iar  $H_j$  sunt cele 4 intervale de eșantionare posibile care pot fi intersectate de  $\Delta$ .

### 4.3. Granularitatea binară

În acest paragraf se vor prezenta considerații referitoare la granularitatea mulțimilor clasice, urmând ca problemele specifice mulțimilor vagi să fie cuprinse în paragraful următor.

Prin granularitate se stabilește o relație de echivalență, de natura celei prezentate în paragrafele despre mulțimile grosiere. Deci elementele (care în caz particular, pot fi definite ca puncte. ) grupate din cadrul granulei sunt caracterizate de proprietatea de indistinctibilitate [Li03]. Toate primesc o etichetă comună, exprimată printr-un nume sau o valoare. Astfel în cadrul mulțimii de definiție  $U$ , granularitatea determină o partiționare într-un set de granule  $U/R$ , determinate de o relație  $R$  de echivalență, similitudine, proximitate sau utilitate. Relația binară determinată de aceste relații creează indistinctibilitatea. Rezultă că două elemente din aceeași granulă îndeplinesc relația:

$$x, y \in G(R) \Leftrightarrow R(x) = R(y) \quad (4.4.)$$

Din punct de vedere formal granularitatea  $G$  este o proiecție a unui mulțimi de indexi pe mulțimea partițiilor unui domeniu  $N$ ,  $G : IS \rightarrow 2^N$  astfel încât să fie satisfăcute următoarele condiții [Cam02]:

- a. dacă  $i < j$  ; și dacă  $G(i)$  și  $G(j)$  nu sunt vide rezultă că  $G(i) < G(j)$
- b. dacă  $i < k < j$  și  $G(i)$  și  $G(j)$  nu sunt vide atunci și  $G(k)$  nu este vid

Prima proprietate definește o relație de ordine în cadrul mulțimii granularităților, iar a doua reflectă proprietatea de continuitate a cestei mulțimi.

O granularitate  $G$  se spune că este mai fină decât o granularitate  $H$ , dacă pentru orice index  $i$  din  $G$ , există un  $j$  din  $H$  astfel ca :

$$\{G(i) \subseteq H(j), \mid \text{daca } \forall i, \text{ atunci } \exists j\} \quad (4.5.)$$

adică cel puțin o granulă din setul de granularitate mai fină este inclusă într-o granulă a setului de granularitate mai robustă.

Dacă avem două mulțimi de elemente care au granularități diferite se poate defini o funcție de constrângere care să facă uniformizarea granularităților, deci aducerea la aceeași granularitate, astfel încât să se poată aplica operatori între cele două mulțimi [Ber01]. Pentru a nu pierde din informația existentă este indicat să se convertească granularitatea mai grosieră  $H$ , la nivelul celei mai fine  $G$ . În acest caz funcția de constrângere  $C$  se definește prin relația:

$$C : [i, j] \rightarrow \{[h, k]^c \mid \cup_{h < p < k} G(p) \subseteq \cup_{i \leq p \leq j} H(p)\} \quad (4.6.)$$

și nu există un interval  $[h', k']$  pentru care este îndeplinită relația:

$$\cup_{h \leq p \leq k} G(p) \subseteq \cup_{h' \leq p \leq k'} G(p) \subseteq \cup_{i \leq p \leq j} H(p) \quad (4.7.)$$

Totuși trebuie menționat că procedeul de mai sus nu reprezintă o regulă generală, granularitatea comună fiind stabilită și în funcție de aplicație. De exemplu, în cazurile în care granularitatea grosieră are o semnificație mai evidentă decât cea fină, se poate alege o transformare inversă. De asemenea există și situații când cele două granularități sunt incompatibile din punct de vedere a divizării. De exemplu în domeniul temporal o informație prezentată la nivel de săptămâni nu este compatibilă cu o transformare dintr-o alta prezentată la nivel de luni (nu se divid perfect). În acest caz este necesară determinarea unei granularități comune care să fie cel mai mic divizor comun (zile, în cazul exemplului anterior) și aplicarea funcției de constrângere fiecărei granularități inițiale pentru aducerea la granularitatea comună.

Dintr-un punct de vedere se poate considera o identitate între discretizare și formarea granularității. Din această cauză trebuie subliniat că discretizarea are o altă

bază de fundamentare în cea ce privește reprezentarea unui domeniu pe care sunt definite elementele constituente (care sunt în general de tip continuu). Astfel, dacă granularitatea este definită ca o relație de indistinctibilitate între unele elemente ale domeniului de definiție, aproximarea prin discretizare este bazată pe eroarea de reprezentare [Mor97]. Alegerea erorii admisibile reprezintă o alegere ce se poate dovedi problematică, în măsura în care o eroare prea mică poate duce la un timp de calcul nejustificat, iar una prea mare poate determina ulterior concluzionări greșite. Pe de altă parte, folosirea granularității implică un proces de mapare în care stabilirea mărimii granulelor să se facă astfel încât în fiecare granulă să fie incluse elemente care pot fi reprezentate de reprezentantul generic al granulei. Pentru a îndeplini acest deziderat este nevoie uneori de divizarea unor granule prea mari în mai multe granule fine, care să reprezinte mai fidel fiecare element constitutiv, sau dimpotrivă gruparea mai multor granule în una mai grosieră, dacă aceasta poate reprezenta toate elementele constitutive. Un exemplu de astfel de construcție este cea bazată pe criteriul de heterogenități [Liu05]. Criteriul își propune să păstreze maximul de informație, folosind un număr cât mai mic de intervale pentru cazul în care orice clasificare are densități de probabilitate cât mai apropiate pentru fiecare interval. Deci se încearcă să se minimizeze distanța dintre densitățile de probabilitate și cazul ideal, în care toate clasele sunt distribuite în mod egal, având probabilitate  $1/s$ . Rezultă relația :

$$d_h(p) = \sqrt{\sum_{j=1}^s (p_j - 1/s)^2} \quad (4.8.)$$

Algoritmul de determinare a soluției suboptimale pentru minimul stabilit cu acest criteriu implică operații de divizare și concatenare a intervalelor, prin încercări succesive. Metoda implică un timp de calcul mare, dar rezultatul este mai bun decât cel obținut folosind alte criterii, cum ar fi cel al entropiei.

În cadrul prezentării noțiunilor legate de granularitate, trebuie menționată și relația dintre viteza unui obiect aflat în mișcare și mărimea granulelor care caracterizează spațiul prin care se face mișcarea [Xu04]. Această corelație are o valoare practică, permițând luarea în considerare a unei constrângeri atunci când se stabilește granularitatea unui spațiu de observare, constrângere determinată de așa numitul *efect de granularitate*. Efectul de granularitate constă în imposibilitatea de detecție a unor obiecte ce se deplasează lent în interiorul unei granularități grosiere, deci evidențierea obiectului de către senzorii care au caracteristici de localizare inferioare. Dar odată cu creșterea vitezei obiectului, acest efect de granularitate se estompează, deci nivelul de localizare crește. Rezultă posibilitatea de compensare a unei granularități scăzute prin creșterea vitezei de deplasare a obiectului ce trebuie localizat. De asemenea pe baza experimentărilor prezentate în [Xu04], s-a evidențiat că datele obținute de la senzori pe perioade lungi sunt neadecvate schemelor de predicție a mișcării bazate pe granularitate mare, dar îmbunătățesc acuratețea predicției pentru modelele bazate pe granularitate mică, prin eliminarea efectului de granularitate. În situații concrete, alegerea granularității trebuie să țină cont de considerente contrare, respectiv că prin folosirea unei granularități mari, pe lângă creșterea efortului de calcul, informația este supusă unui zgomot mai mare, iar pe de altă parte, o granularitate prea mică, determină apariția efectului de granularitate.

O altă concluzie este determinată de funcția de mediere a informațiilor provenite prin granularizare, respectiv că dinamica unui obiect aflat în mișcare are o influență mai mică asupra modelelor cu granularitate redusă, decât asupra modelelor care utilizează o granularitate mai fină.

#### **4.4. Stabilirea conceptelor prin noțiuni de granularitate**

De noțiunile prezentate în paragraful anterior este legată stabilirea noțiunii de concept. Menționez că, deoarece granularitatea a fost definită pe domeniul mulțimii de tip ferm ( deci nu de tip fuzzy) și prezentarea ce urmează presupune utilizarea acestui

tip de mulțime. Conceptul ca generalizare a unor exemple izolate, are caracteristicile unei partiționări granulare, în sensul în care mai multe elemente (exemple) sunt definite într-o granulă (care este conceptul) și care primește o denumire generică. Din acest punct de vedere o informație poate avea o formă extensivă, când reprezintă o mulțime de date concrete aflate într-o relație de asociere, ca de exemplu în cazul bazelor de date, sau o formă intensivă când este prezentată în mod generalizat ca în cazul conceptelor sau a regulilor [Yao01]. Rezultă faptul că un domeniu al cunoașterii se poate partiționa în granule, care cuprind elemente asemănătoare din perspectiva unui atribut sau a unei caracteristici. Aceste granule sunt asimilate conceptelor.

Într-o descriere formală forma extensivă este un quadruplu  $S$  definit astfel:

$$S = (U, A, V_A; I_a) \quad (4.9.)$$

unde

$U$  este mulțimea elementelor pe care se definește partiționarea,

$A$  este atributul luat în considerare,

$V_A$  este mulțimea valorilor pe care le poate lua atributul  $A$ ,  $\{V_A \in A\}$

și  $I_a$  este relația de asociere  $I_a : u \rightarrow V_A \mid a \in A$

iar granula  $m(a, v)$  se definește prin:

$$m(a, v) = \{x \in U \mid I_a(x) = v\} \quad (4.10.)$$

Principalele proprietăți ale granulelor, în raport cu operatorii din logica formală sunt:

$$\begin{aligned} m(\neg\phi) &= -m(\phi) \\ m(\phi \wedge \varphi) &= m(\phi) \cap m(\varphi) \\ m(\phi \vee \varphi) &= m(\phi) \cup m(\varphi) \\ m(\phi \rightarrow \varphi) &= -m(\phi) \cup m(\varphi) \\ m(\phi \equiv \varphi) &= (m(\phi) \cap m(\varphi)) \cup (-m(\phi) \cap -m(\varphi)) \end{aligned} \quad (4.11.)$$



unde  $m(\phi), m(\varphi)$  reprezintă granule pentru care elementele componente au aceeași proprietate. Din relațiile prezentate rezultă că proprietățile din logica formală sunt valabile și în cazul conceptelor, așa cum au fost definite anterior. Concluzia nu este de fapt surprinzătoare, pentru că modul de abordare păstrează structura bivalentă a relațiilor.

Trebuie menționat că această abordare a conceptelor este doar una din cele posibile. Astfel există și alte abordări cum ar fi cea filozofică sau cea bazată pe aplicația concretă la care se referă conceptul [Yao04].

Deoarece între noțiunea de granularitate și teoria mulțimilor grosiere există o legătură strânsă, modelul de concept prezentat poate fi abordat și dintr-o perspectivă a mulțimilor grosiere. Astfel se poate defini în mod similar cu teoria mulțimilor grosiere, o mărime a suportului unui concept  $k(\phi)$  și un coeficient al acurateței (sau a încrederii) în acel concept  $\alpha(\phi)$  :

$$k(\phi) = \frac{|m(\phi)|}{|U|} \quad \text{respectiv} \quad \alpha(\phi) = \frac{|m(\phi) \cap m(\varphi)|}{|m(\varphi)|} \quad (4.12.)$$

unde

$U$  este mulțimea tuturor elementelor din domeniu de definiție, iar  $m(\phi), m(\varphi)$  sunt granule ce definesc concepte.

O concluzie interesantă, din punct de vedere teoretic este prezentată în [You02] referitor la atributele sau caracteristicile care nu pot fi observate direct din exemplele disponibile și cele care sunt ascunse în structura datelor. Astfel în cazul în care se pot obține concepte sau reguli din date ce reprezintă distanțelor în coordonate polare, în urma transformării datelor în reprezentare prin coordonate carteziene există posibilitatea de a nu mai putea pune în evidență conceptele sau regulile. Pentru a determina și mulțimea corelațiilor ascunse de structura datelor ar trebui studiate toate izomorfismele care pot fi obținute prin transformări ale structurii datelor. O astfel de transformare  $S$

leagă domeniul de definiție a unui atribut  $A_i$  de un domeniul de definiție a unui alt atribut  $A_j$ :

$$Dom(A_i) \rightarrow Dom(A_j), \text{unde, } A_j = S(A_i) \quad (4.13.)$$

Ceea ce este de remarcă este că și trăsăturile sau conceptele rezultate dintr-un domeniu sunt într-o relație de izomorfism cu cele corespunzătoare domeniului în care se face transformarea. Rezultă că prin izomorfism, dacă pentru o granularitate a unui trăsături se poate stabili o caracteristică sau o regulă, atunci și în domeniul obținut prin transformare există o caracteristică sau o regulă. Dar mai trebuie menționat că semnificația primei caracteristici (sau reguli), nu are nici o legătură cu semnificația celei de a doua. De fapt interpretarea unei granule care determină o caracteristică se face prin etichetare, respectiv prin atribuirea unui nume [You04]. În acest fel granula devine un element care, eventual, poate să participe la o altă granularizare, pentru obținerea unui concept de ordin superior.

#### 4.5. Granularitatea vagă

Elementele ce compun granulele, din acest paragraf, nu mai reprezintă entități bine definite, fiind descrise prin mulțimi de tip fuzzy. Rezultă că și definirea marginilor granulelor nu mai are un caracter bine definit, fiind caracterizate prin coeficienți de apartenență, iar unele elemente pot să aparțină, în grade diferite, la mai multe granule. Granulele pot avea atașate valori lingvistice, iar operațiile să fie specifice mulțimilor fuzzy. De exemplu în [Con02] se prezintă un sistem de extragere a regulilor dintr-o bază de date și care stabilesc granularități diferite utilizate la extragerea de reguli, prin folosirea unor indicatori de potrivire stabiliți printr-un algoritm genetic. Astfel, dacă regula obținută acoperă un număr considerat suficient de cazuri, granularitatea este păstrată, dar în caz contrar regula se împarte în alte două reguli și se mărește finețea

granularității prin expandarea unei variabile lingvistice într-un set cu granularitate mai fină. Deci vor fi reguli care vor acoperi o suprafață mai mare din domeniul de definiție, iar altele una mai mică. Această construcție ierarhică a granularității este foarte utilă, dar practic ridică probleme legate de stabilirea criteriilor de potrivire acceptație.

Un caz asemănător, dar plecând invers este cel în care avem valori lingvistice de granularități diferite și se impune o procesare sau stabilirea unei decizii pe baza acestor informații multigranulare. În [Her05] se propune folosirea unei relații de transformare din informația cu granularitate mai grosieră  $A = \{l_0, \dots, l_p\}$ , la cea cu granularitate mai fină  $S = \{c_0, \dots, c_g\} \mid g \leq p$  folosind relația de transformare  $\tau_{A,S}$  :

$$\tau_{A,S} : A \rightarrow F(S) \text{ unde } \tau_{A,S}(l_i) = \{(c_h, \alpha_{ih}) \mid h \in \{0, \dots, g\}\}, \forall l_i \in A \quad (4.14.)$$

unde  $F(S)$  este mulțimea fuzzy definită pe  $S$ ,  $\mu_{l_i}$ , și  $\mu_{c_h}$  reprezintă coeficienții de apartenență asociați termenilor lingvistici  $l_i$  respectiv  $c_h$  iar  $\alpha_{ih}$  reprezintă coeficientul de apartenență din noua granularitate și care este determinat cu relația:

$$\alpha_{ih} = \max(\min\{\mu_{l_i}(y), \mu_{c_h}(y)\}) \quad (4.15.)$$

Exemplul concret prezentat se referă la un mecanism de asistare a armonizării părerilor unui număr de experți care folosesc pentru evaluare valori lingvistice diferite.

Folosirea granularității pe mulțimile fuzzy determină și adaptarea metodelor de grupare. În acest domeniu trebuie subliniate lucrările lui W.Prdrycz și a colaboratorilor săi [Bag02],[Bag04],[Ped05], care au elaborat o serie de tehnici de grupare bazate pe extensia de tip fuzzy a relației de similitudine. Astfel, gruparea se face în jurul valorii unor trăsături considerate prototipuri, deci din grupare vor face parte ( în proporții diferite, în funcție de gradul de similitudine) acele elemente care se aseamănă cu

prototipul. Întreaga grupare se constituie astfel într-o granulă de tip vag, care ulterior poate fi etichetată. Rezultă că funcția obiectiv a grupării este dată de relația:

$$Q(L) = \max\left(\sum_{i=1}^N \text{sim}(x_i, v, w)\right) \quad (4.16.)$$

unde  $\text{sim}()$  este relația de similitudine,  $v$  este prototipul, iar  $w$  este ponderea fiecărei coordonate din spațiul de definiție a trăsăturilor. Prin aplicarea acestei relații se obține gruparea cea mai mare din spațiul caracteristicilor. Pentru a determina și alte grupări care să nu se suprapună peste gruparea deja determinată, se impune și condiția ca distanța dintre prototipuri să fie cât mai mare. Astfel funcția obiectiv pentru al  $L$ -lea prototip devine:

$$Q(L) = (1 - \text{sim}(v_L, v_{L-1}, 0))(1 - \text{sim}(v_L, v_{L-2}, 0)) \dots (1 - \text{sim}(v_L, v_1, 0)) \sum_{i=1}^N \text{sim}(x_i, v_L, w_L) \quad (4.17.)$$

iar valoarea optimă a ponderii unei coordonate  $w_i$  rezultă cu relația:

$$w_{L,s} = \frac{1}{\sum_{j=1}^c \frac{\sum_{k=1}^N A_{k,s} (1 - \mu_{k,s})}{\sum_{k=1}^N A_{k,j} (1 - \mu_{k,j})}} \quad (4.18.)$$

unde  $c$  reprezintă numărul de grupări care se formează,  $s$  este coordonata pentru care se calculează ponderea, iar  $\mu$  reprezintă coeficientul de similitudine dintre prototipul  $v$  și elementul  $x$ . Factorul  $A$  este o relație de prescurtare a relației canonice pe operatorii t-normă  $\otimes$  și co-normă  $\oplus$  și care are forma:

$$A_{k,s} = \otimes_{j=1, N} (w_j^2 \oplus \mu_{k,s}) \quad (4.19.)$$

Valoarea factorului  $A$  arată gradul de asemănare dintre prototip și elementele din grupare. Trebuie observat că cu cât valoarea ponderii rezultate este mai mică, cu atât coordonata este mai importantă pentru grupare. Dacă se impune o valoare pentru  $A$  se pot determina acele elemente care au coeficientul de similitudine mai mare decât o valoare dată, deci cele care fac parte din nucleul granulei. Astfel se poate transforma o granulă de tip fuzzy într-o granulă de tip ferm.

De asemenea, o granulație utilă se poate obține și prin determinarea segmentelor de pe fiecare coordonată pentru care elementele din interior au o similitudine mai mare decât o valoare dată. Se obțin astfel granule de formă dreptunghiulară, care au avantajul de a putea fi manipulate ulterior prin operații efectuate în mod independent pe fiecare axă. Deci pentru fiecare coordonată se determină intervalul pentru care avem relația:

$$(x \equiv b_v) \leq \gamma \quad (4.20.)$$

ceea ce va determina o valoare inferioară  $x_-$  și una superioară  $x_+$  reprezentând marginile intervalului. De exemplu, pentru o relație de similitudine bazată pe o t-normă de tip produs aceste valori sunt:

$$x_- = \gamma \cdot b_v \text{ respectiv } x_+ = \min(1, \frac{b_v}{\gamma}) \quad (4.21)$$

iar pentru o similitudine construită cu o t-normă de tip Lukasiewicz este:

$$x_- = \max(0, \gamma - 1 + b_v) \text{ respectiv } x_+ = \min(1, 1 - \gamma + b_v) \quad (4.22.)$$

În același mod prin modificarea funcției obiectiv se pot obține granule de tip vag, care să fie influențate de diverse condiții externe, prin care se poate dirija procesul de grupare.

## 4.6. Concluzii

În acest capitol m-am ocupat de o a doua direcție dintre cele mai noi pe care le-am găsit în literatura de specialitate. Cu toate că au denumiri diferite, între mulțimile grosiere și granularitatea informației există o legătură, ambele abordând imprecizia observației, dar noțiunea de granularitate are un conținut mai general.

Noțiunea de granularitate este una de mare actualitate în domeniul „soft computing”, fiind unul din domeniile cele mai noi. Există un număr tot mai mare de articole care se ocupă de acest domeniu. Gradul de generalizare, precum și aplicabilitatea largă pe care o are, determină o aprofundare a acestui domeniu, dar ca în orice început și în acest domeniu trebuie să se cristalizeze noțiunile și să se unifice sensurile terminologiei. În orice caz, faptul că personalități ca L.A. Zadeh sau W.Pedrycz s-au implicat în studiul acestei probleme, reprezintă importanța pe care ar putea să o dobândească în viitor acest domeniu.

Analiza și clasificarea pe care am expus-o în acest capitol s-a bazat pe un set de articole și câteva cărți, la care am avut acces și care sunt de dată foarte recentă. Tocmai din cauza noutății domeniului mi-a făcut o mare plăcere ca pe baza studiului prezentat să pot aplica aceste teorii în lucrarea de față. Stabilirea faptului că același obiect trebuie abordat prin granularități diferite în funcție de raportarea acestuia la sistemul de captare a informațiilor și că există o granularitate optimă pe intervale de observație au condus la principalele direcții de abordare a prezentei teze.

## Capitolul V. Fuziunea informațiilor

### 5.1. Introducere

Noțiunea de fuziune este relativ nouă și a apărut în cadrul inteligenței artificiale ca urmare a necesității cumulării unor informații provenite din surse eterogene. Așa cum rezultă din prezenta lucrare, o mare parte din studiile din acest domeniu s-au realizat în conexiune cu robotica, ceea ce nu este întâmplător, deoarece analizarea mediului extern implică luarea în considerare a informațiilor provenite din mai multe surse. Ceea ce își propune ca finalitate fuziunea informațiilor este obținerea unor date mai exacte și mai fiabile despre mediul analizat decât cele obținute de la oricare din sursele de informații luate în mod independent. Un alt avantaj major al fuziunii este faptul că reduce dimensionalitatea problemelor, rezultatul fuziunii putând fi privit ca informația furnizată de o sursă virtuală care înlocuiește sursele ce intră în procesul de fuziune. Din punctul meu de vedere lucrarea își propune să se concentreze pe laturile ce au conexiuni cu sistemele de alarmare, de aceea numărul exemplelor referitoare la date obținute din imagini și alte surse din domeniu este mai mare.

Capitolul de față își propune să facă o sinteză a tipurilor de fuziune existente în literatura de specialitate. Demersul este îngreunat de multitudinea exemplelor care nu sunt specificate ca fiind din domeniul fuziunii, dar care operează fuziuni de informații. Pe de altă parte fuziunea nu este prezentă în articole ca un element de sine stătător ci este inclusă în aplicația prezentată. De aceea, am considerat necesar ca modul de abordare a acestei problematice să o fac în contextul articolelor analizate, fiind prezentată și tematica articolelor. Acest procedeu, cred, are avantajul de a reliefa mai bine diversitatea domeniilor în care se aplică fuziunea informațiilor și pe de altă parte, permite realizarea unei clasificări bazată pe tipul de teorie ce stă la baza fuziunii.

Trebuie să mai subliniez că amplasarea acestui capitol se justifică prin locul central pe care îl are fuziunea informației în teză. Astfel, pe baza concluziilor pe care le-

am obținut din prezentarea care urmează, am realizat un sistem ierarhic în care am inclus tipurile de fuziune care se potrivesc sistemului descris.

## 5.2. Definirea fuziunii informațiilor

Definirea fuziunii nu are, actualmente, un format unic acceptat de toată comunitatea științifică. Există mai multe formulări ale fuziunii fiecare subliniind unele aspecte. Astfel, după R.R. Brooks și S.Iyengar „*Integrarea senzorilor se ocupă cu utilizarea sinergetică a surselor multiple de informație*”, deci fuziunea este integrare a surselor de informație într-o reprezentare comună. L.Valet propune următoarea definiție : „*Fuziunea datelor reprezintă un cadru formal în care sunt cuprinse mijloace și instrumente care reunesc date provenite de la diferite surse.*” Definiția subliniază importanța arhitecturii și a metodelor matematice în cadrul fuziunii. Dubois [Dub00] face o distincție între fuziune și agregare ( distincție care nu se face în majoritatea cazurilor), considerând că în urma procesului de fuziune trebuie să rezulte numai o valoare a gradului de posibilitate, iar mărimea caracteristică trebuie să rezulte numai în urma unui proces de agregare. Se asemenea Dubois consideră fuziune numai situația în care datele sunt colectate simultan de la surse diferite, citirea unei serii de date de la aceeași sursă ne fiind considerată fuziune. Din cauza caracterului său extrem de limitativ această abordare nu este în general folosită, utilizând-se noțiunea de fuziune pentru o varietate mai mare de procese.

Unele definiții sunt propuse pentru anumite ramuri sau scopuri.

Exemple de astfel de definiții sunt : [Bal04]

„*Fuziunea datelor este procesul prin care datele de la o multitudine de senzori sunt folosite pentru a produce o estimare a vectorului de stare al sistemului*”, care este aplicabilă în special în sisteme de reglaj, sau

„*Problema fuziunii senzorilor este aceea a combinării măsurătorilor multiple de la senzori, într-o singură măsurătoare a parametrului detectat.*” Care este adecvată fuziunii informațiilor provenite de la senzori.



Din punctul meu de vedere, fuziunea este procesul prin care din mai multe surse de informații se obține o imagine *parțial redundantă și parțial complementară* a mediului analizat, care *permite studierea atât a nivelului de încredere al surselor, cât și o mai mare informare despre mediu*. Această abordare subliniază și aspectul de verificare a surselor prin compararea cu alte evaluări ale aceluiași context extern. Rezultă că prin fuziune avem un dublu câștig. Odată, rezultatul obținut, este mai bun decât oricare dintre datele intrate în procesul de fuziune, cea ce se datorează complementarității informațiilor obținute despre același obiect sau fenomen ( care reprezintă elementul observat). Pe de altă parte, suprapunerea unei părți a informației intrate în procesul de fuziune, deci parte redondantă, permite obținerea unor informații despre fiabilitatea și gradul de încredere care poate fi atribuit elementelor captoare de informații (care reprezintă sistemul observator).

Această abordare are este concretizată în prezenta lucrare prin utilizarea fuziunii în cele două modalități prezentate anterior. Astfel informația complementară, care reliefează aspecte diferite ale aceluiași obiect este folosită la localizarea și identificarea obiectului care cauzează efracția, așa cum este descris pe larg în Capitolul IX, iar informația redondantă este utilizată pentru stabilirea gradului de încredere care poate fi atribuit unui detector, așa cum este aplicat în Capitolul VIII, la stabilirea nivelului de încredere a senzorilor de fuziune bazați pe detecția în infraroșu.

### **5.2.1. Clasificări folosite în fuziune**

Dacă se face o clasificarea a tipurilor de caracteristici ce fuzionează rezultă trei tipuri de fuziuni [Tho90]. Aceste nivele iau în considerare etapele prelucrării informației și anume: achiziția datelor de la sursele de informații, conceptualizarea informației prin determinarea unor trăsături sau proprietăți semnificative și luarea deciziilor prin clasificare sau altă operație conexasă.

- O primă fuziune se poate face la un nivel inferior de prelucrare a informației, de exemplu la nivel de senzori sau de pixeli. În aceste cazuri fuziunea are

un caracter local deoarece nu s-a efectuat corelarea surselor de informații. Trebuie menționat că la acest nivel se poate detecta cel mai bine eroarea de nepotrivire a informațiilor care teoretic ar trebui să se refere la același element din mediu, dar implică un nivel de corelare foarte strâns, cea ce implică pierderi în planul flexibilității, fapt pentru care nu am folosit această metodă.

- Nivelul al doilea de fuziune, numit soft, se poate realiza la nivelul proprietăților sau a trăsăturilor specifice ansamblului informațiilor. La acest nivel de fuziune se pot lua în considerare și relațiile existente între diferitele componente ale sistemului. În general la acest nivel se obțin mai multe informații fuzionate ce ulterior sunt folosite la nivelul de luare a deciziei, sau la fundamentarea ipotezelor care ulterior vor fi luate în considerare. Acest nivel de compromis îl consider cel mai potrivit, de altfel rezultatele obținute în cazul acestei cercetări au confirmat aceste considerente. După cum rezultă și din datele prezentate în Capitolul IX, metoda de decizie care folosește valori vagi (metoda soft), a dat rezultate mult mai bune decât cea care a folosit valori ferme (metoda hard).

- Al treilea nivel de fuziune, numit hard, este cel de la nivelul deciziei când elementele de fuzionat reprezintă deja rezultatele clasificărilor. La acest nivel de fuzionare există pericolul să se fi pierdut unele informații semnificative, în cursul clasificării, care este anterioară fuziunii, cea ce ar putea deforma rezultatul fuziunii, Acest neajuns a și fost demonstrat în cazul sistemului prezentat în această teză, unde performanțele obținute prin metoda hard au fost mai slabe decât cele prin metoda soft.

Chiar și în domeniul clasificărilor nu există un consens între autori privind terminologia. Din acest motiv o să prezint o abordare diferită de cea prezentată anterior, pentru a sublinia problematica demersului de sistematizare. Astfel în [Hou94] se face o distincție între fuziune și integrare, unde prin fuziune se înțelege procesul de folosire a informațiilor provenite din diferite surse de informații, iar prin integrare se definește combinarea diferitelor procese de fuziune. Din perspectiva acestei abordări autorii enumeră următoarele metode de fuziune:

- cele probabilistice, cele care folosesc teoria evidenței,
- cele fuzzy,

- rețelele neuronale
- bazele de cunoștințe,

iar în cazul metodelor de integrare se iau în considerare:

- metode bazate pe grafuri,
- rețele neuronale,
- sisteme expert,
- scheme descentralizate de decizie
- scheme de tip predicție-verificare.

Prin scheme descentralizate se înțelege integrarea deciziilor provenite din diferite centre de procesare. În opinia mea, consider că acest tip de integrare nu ar trebui să fie inclusă în această clasificare, ci în alta care împarte procesul de integrare (sau fuziune) în descentralizate, centralizate și mixte ( respectiv cele ierarhice ). Pe de altă, parte metoda de predicție a unor ipoteze pe baza analizei informațiilor și contextului și verificarea acestora pe baza altor informații ( care pot fi mai puțin consistente ) este o metodă pe care o consider de aplicabilitate mai largă ce se încadrează la metoda de căutare mixtă de jos în sus, paralel desfășurată cu cea de sus în jos. Revenind la articolul menționat mai sus [Hou94], se mai propune o clasificare în:

- senzori slabi cuplați, care pot funcționa și independent și
- în senzori tare cuplați, la care defectarea unor senzori produce blocarea întregii scheme de fuziune.

De asemenea se prezintă o propunere de realizarea a unui formalism al diferitelor metode de fuziune prin utilizarea unui model de senzor logic care să ia în considerare și nivelul de redundanță, respectiv de complementaritate a unui sistem de senzori. Astfel se propune un model de senzor care are ca intrări o sursă de cunoaștere, o bază de cunoștințe externă și un canal de informare a rezultatelor furnizate de alte surse de informații care ar permite interconectările între senzorii din sistem. Prin construcția acestui model se permite realizarea unei clasificări pe baze topologice în: serie, paralel și cu reacție (cele iterative). Modelul este de remarcat cu toate că nu am întâlnit nici un alt articol în care să fie utilizat.

O altă clasificare posibilă poate fi făcută luând în considerare domeniul în care este folosită fuziunea. Din această perspectivă există numeroase abordări, ca de exemplu : aplicații militare sau civile, aplicații experimentale sau comerciale și multe altele, ceea ce, după opinia mea, nu poate constitui un criteriu definitoriu pentru clasificare. Aici ar trebui menționat că există unele domenii care au beneficiat mai mult de tehnicile utilizate în fuziune, cum ar fi de exemplu robotica, imagistica în medicină sau urmărirea țintelor în domeniu militar, ceea ce ar permite o clasificare a aplicațiilor după gradul în care utilizarea fuziunii informațiilor aduce beneficii în domeniu. În acest sens sunt aplicații la care beneficiul (tehnic sau economic) este important, cum ar fi cele menționate anterior și care în general folosesc date cu un nivel ridicat de incertitudine, aplicații la care beneficiul este rezonabil, dar efortul de implementare a fuziunii trebuie analizat, cum ar fi cele din meteorologie sau analizele financiare și aplicații în care tehnicile de fuziune nu aduc beneficii notabile, cum ar fi de exemplu cele din ramuri industriale cu procese foarte bine cunoscute. Problema cu acest tip de clasificare este variabilitatea ei în timp. Astfel, fuziunea în domeniul prezentat în această lucrare, nu a mai fost abordată, dar ea este posibilă, chiar naturală, deci odată cu dezvoltarea domeniului va trece de la o categorie la alta.

### **5.2.2. Aspecte ale incertitudinii și impreciziei informației**

Toate entitățile reale fac un schimb de informații cu mediul extern, prin intermediul unor componente de intrare sau ieșire. Aceste informații provenite din exterior, în cazul sistemelor analizate, sau realizate prin mijlocele inteligenței artificiale pot fi date, simboluri sau propoziții. Pentru a determina sau măsura aceste informații se folosesc senzori, porturi, sau opinii ale unor experți. Toate aceste mijloace de colectare a datelor sunt afectate de incertitudine și imprecizie, ceea ce determină caracterul nesigur și aproximativ al informației cu care se operează în continuare. Imprecizia și incertitudinea nu pot fi complet eliminate dar se pot diminua până la obținerea unor informații care să conducă la un set de rezultate acceptabile. Imprecizia în cazul senzorilor, se referă la

existența unei diferențe dintre valoarea reală și cea citită, numită eroare de măsură. Dacă datele furnizate de sursa de informații au o eroare atât de mare încât pot conduce la concluzii neacceptabile, se consideră că ele nu sunt valabile. Rezultă că și în această apreciere există un grad de subiectivism.

În conexiune cu lipsa de valabilitate a datelor este noțiunea de inconsistență a informației. Inconsistența implică o eroare ce este relevată de context sau de alte cunoștințe anterioare referitoare la mediul extern și care contrazic, în mod direct sau în urma unei prelucrări, informațiile recente.

Dar imprecizia nu este obligatoriu legată de eroare. Ea poate apare și din cauza ambiguității, așa cum este cazul transmiterii de informații prin limbaj natural. Această situație se poate exemplifica prin cazul unui expert uman care folosește cuvinte ce implică noțiuni cu un conținut nu foarte bine definit.

Incertitudinea se referă la imposibilitatea de a determina dacă informațiile obținute sunt adevărate sau false, sau de a ști gradul de adevăr al acestora. Totuși incertitudinea în cazul informațiilor obținute din exterior nu este considerată întotdeauna completă, ci are diferite grade cuprinse între certitudinea completă, caracteristică evenimentului considerat sigur și incertitudinea totală, caz în care este o situație de ignoranță. Situația de incertitudine poate avea cauze obiective cum ar fi caracterul aleatoriu al fenomenelor externe [GUM93], sau poate avea cauze subiective cum ar fi cea a necunoașterii situației externe, caz în care intervine nivelul de încredere conferit de observator. Și sistemul de supraveghere antiefracție în mediu extern face parte din această categorie, afectată de imprecizie și incertitudine, ceea ce impune determinarea și stabilirea unei metode de determinare a incertitudinii.

Problemele legate de imprecizie și incertitudine se tratează prin diverse tehnici dintre care cele mai utilizate sunt metodele statistice, cele ce utilizează mulțimi vagi sau posibilități și metodele masice de tip Demster Shafer. Ceea ce își propune fuziunea informațiilor este o reducere, prin metodele amintite anterior, a impreciziei și incertitudinii prin creșterea gradului de informare asupra entității studiate, colectând cât mai multe aspecte sau valori caracteristice despre același obiect sau proces, deci analizând diferite fațete sau moduri de manifestare. Această abordare utilizează

informația complementară a datelor provenite din diferite surse. Latura redundantă a informațiilor furnizate de surse este un indicator al cunoașterii surselor în sine, contribuind la o informare despre furnizorii de informații. În cazul concret al prezentei teze, datorită naturii vagi a informațiilor, am optat pentru tratarea de tip fuzzy a incertitudinii, prin folosirea unei metode originale, și care a condus la obținerea unor rezultate foarte bune în cadrul experimentărilor efectuate, așa cum se va prezenta în capitolele VIII și IX.

În cele ce urmează se va trece la prezentarea clasificării pe care o propun pentru a justifica alegerea celor trei proceduri de fuziune care se potrivesc cel mai bine aplicațiilor de fuziune și decizie din sistemul de supraveghere prezentat, și care sunt utilizate în capitolul IX. În general prezentarea se va face pe trei secțiuni: una de prezentare a metodei de bază, una în care se subliniază particularitățile rezultate din aplicarea metodei pentru fuziune și una pentru exemplificarea utilizării fuziunii.

### **5.3. Fuziunea euristica**

#### **5.3.1. Fuziunea pe bază de medie**

Obținerea unei valori fuzionate din surse diferite de informație se poate face și în mod intuitiv. Astfel, dacă există o serie de măsurători furnizate de senzori diferiți care pot fi exprimate în aceeași unitate de măsură, o soluție simplă este determinarea unei medii, eventual cu dispersia corespunzătoare. Totuși trebuie subliniat că această abordare presupune o încredere uniformă în toate sursele de informare, iar în cazul în care o sursă este defectă poate să altereze informația rezultată prin fuziune. O altă problemă poate apărea dacă sursele sunt de tipuri diferite caz în care, pentru utilizarea aceleiași unități de măsură se poate folosi o medie ponderată[Yif97]. Dacă media este de tip aritmetic fuziunea este de tip sumă :

$$m_F = \sum_{i=1, n} w_i \cdot x_i \quad \text{unde } w_i \in [0, 1] \quad (5.1.)$$

În unele aplicații este dificil de stabilit care este valoarea ponderilor din cauza caracterului nedeterminat al unor parametri. Un exemplu de fuziune prin mediere este prezentat în [Ach00], în cadrul unui sistem de identificare a feței unei persoane. Sistemul de identificare utilizează două camere video dotate cu câte un proiector LCD pentru a crea o iluminare structurată. Acești senzori pot în mod independent să creeze o hartă tridimensională a imaginilor pe care le captează. Cele două structuri rezultate sunt apoi fuzionate prin mediere, iar punctele care se regăsesc doar întruna din hărți sunt eliminate. Acest model tridimensional este apoi comparat cu modele similare dar etichetate, aflate într-o bază de date. Compararea se face printr-o măsură de similitudine dată de distanța Hausdorff, după următoarea relație:

$$H(A,B) = \max (h(A,B), h(B,A)) \quad (5.2.)$$

unde

$$h(A;B) = \max_{a \in A} \min_{b \in B} \|a - b\| \quad (5.3.)$$

Se consideră că modelul analizat aparține persoanei ale cărei informații din baza de date au distanța Hausdorff cea mai mică. Experimentările efectuate au dovedit că nu este indicat să se considere toate punctele din model pentru măsura de similitudine ci numai un procent de aproximativ 90% din cele mai potrivite.

Un articol interesant ca aplicare a fuziunii prin sumă ponderată este [ Cho04], care tratează modul de formalizare a evaluării nivelului de încredere al unei informații militare pe baza recomandării NATO STSNAG 2022. Autorul, după prezentarea textului recomandării care în principiu evaluează informațiile printr-o literă ce reprezintă nivelul de încredere și printr-un număr ce reprezintă nivelul de credibilitate, propune un sistem de formalizare pe care-l consideră mai precis și în care pot apărea



mai puține situații contradictorii. Sistemul definește pentru fiecare formulă  $F$  o pereche  $\langle V, m \rangle$ , unde  $V$  este o mulțime de litere ce codifică nivelul de încredere a surselor pe care se bazează informația, iar  $m$  reprezintă consistența sau inconsistența informației cu baza de date existentă  $DB$  și cu setul de constrângeri logice  $IC$ . Pentru orice nouă formulă introdusă trebuie verificată consistența acesteia cu baza de date prin crearea unui nou set de modele format cu numărul minim de informații și care să fie în concordanță cu constrângerile impuse. Pentru a găsi răspunsul la o întrebare  $w$  se definește o metrică prin care acel model  $db_i$  este selectat care are distanța minimă față de formula întrebării. Metrica reprezintă o fuziune prin sumă ponderată de forma:

$$d_{w\Sigma}(w, [db_1, \dots, db_n]) = \sum_{i=1}^n \min_{w' \in (db_i)} d(w, w') \cdot r(db_i) \quad (5.4.)$$

unde  $w'$  este o formulă a modelului  $db$ ,  $d(\cdot)$  reprezintă distanța Hamming, iar  $r(db)$  este echivalentul numeric al unui element din mulțimea  $V$ . Deși aplicația se referă la o abordare prin logica predicatelor, modul de fuziune folosește nivele de încredere prin sumă ponderată, specifică mai mult abordării prin logica mulțimilor vagi. Formalismul este încă incomplet și greu de utilizat în practică, după cum recunoaște și autorul articolului.

O altă categorie a operațiilor de fuziune este cea de tip produs, în care elementele ce fuzionează măresc nivelul de informare al rezultatului prin limitarea gradului de libertate al stării inițiale, cea ce se obține prin înmulțirea cu valori subunitare a unor parametri, sau prin restrângerea intervalelor acceptabile :

$$m_f = \prod_{i=1, n} s \cdot x_i \quad (5.5.)$$

Un exemplu de aplicare a acestui tip de fuziune este prezentat în [Mur98], referitor la funcționarea unui vehicul autonom pentru care se propune o rută de deplasare între două puncte, pe baza unei hărți. Vehiculul este dotat cu o cameră de luat vederi, un



senzor ultrasonic și un dispozitiv de determinare a înclinației. Sistemul de navigare a fost conceput pe două nivele: unul cognitiv și unul reactiv. Componenta cognitivă primește ordinele de deplasare și harta, care prin caroiaj devine harta internă a sistemului. Fiecare element din caroiaj este marcat ca fiind permis sau interzis. Senzorul ultrasonic determină existența obstacolelor, iar camera video stabilește poziția centrului șoselei. Fuziunea celor două informații se face prin suprapunere pe harta internă deci printr-o intersecție a celor două informații. Modulul cognitiv transmite comenzi modulului reactiv de tipul: „urmărește drumul”, „virează pe drum la dreapta”. Modulul reactiv este format dintr-o serie de componente ierarhice care filtrează comenzile venite de la unitățile anterioare. Acestea în ordine sunt: unitatea de urmărire a traseului, unitatea de evitare a obstacolelor și unitatea de control a vitezei. Prima unitate verifică, pe baza informațiilor de la camera de luat vederi ca vehiculul să nu depășească limitele drumului în timp ce se execută comanda modulului cognitiv. Unitatea de evitare a obstacolelor, verifică ca pe baza informațiilor de la senzorul ultrasonic, să nu fie obstacole pe drum, în timp ce se efectuează comanda de deplasare. Iar, unitatea de control a vitezei filtrează comenzile referitoare la direcție, pe baza informației de la dispozitivul de determinare a înclinației și a ordinelor externe referitoare la limitarea vitezei și reglează direct funcționarea motoarelor. De menționat că modulul reactiv nu are nici un fel de planificator, el prelucrând direct informațiile momentane venite de la senzori. Se observă în acest caz modul de fuziune de tip produs, fiecare element introducând o restricție specifică.

Un caz particular al acestei abordări poate fi considerată fuziunea ierarhică prin arbori, în care plecând de la o situație generală, rezultatul se obține prin operații conjunctive secvențiale cu diferite constrângeri pe care le impun condițiile problemei. Un astfel de exemplu se prezintă în [Mak03], referitor la un sistem distribuit de senzori. Studiul își propune să analizeze diferiți algoritmi de determinare a mediului înconjurător și luare a deciziilor, format din mai multe platforme pe care se pot dispune noduri de comunicare și diverse tipuri de senzori ( în mod concret s-au folosit doi miniroboți cu detectoare de distanță laser, o stație fixă, o unitate de interfațare fixă și una mobilă ).

Comunicațiile dintre noduri se fac între nodurile cele mai apropiate, realizându-se o rețea aciclică, fiecare platformă având acces la orice informație. Fuziunea informațiilor de la senzori se realizează prin intersecția datelor obținute în toată rețeaua, iar fiecare ipoteză primește un grad de încredere, în funcție de tipul sensorului și de numărul de confirmări pe care la întrunește. Rețeaua de senzori se consideră a fi activă deoarece permite unor tipuri de platforme să se deplaseze pentru a obține informații suplimentare despre mediu sau să confirme poziția relativă a altor componente din rețea. Experimentele au vizat două abordări din punct de vedere a operatorilor umani, care pot fi conectați în sistem. Una, ce implică un comportament al operatorului centrat pe controlul unor componente, prin comenzi efective sau prin comutări de scop în mod specificat pentru unele platforme, iar alta, ce consideră operatorul ca orice senzor sau nod, care oferă informații despre mediu cu o anumită credibilitate. Acest al doilea mod este considerat superior primului atât din punct de vedere al traficului de informație cât și al flexibilității sistemului. Diferența dintre cazurile când operatorii sunt echivalenți senzorilor în descrierea mediului și cele în care sunt considerați de sistem ca noduri, este dată de nivelul de prelucrare a informației furnizate: strict descriptivă în primul caz, sau implicând concepte mai generale în a doua situație. O observație deosebită, ce a rezultat în urma experiențelor în care s-au folosit mai mulți operatori, a fost efectul de „propagare a zvonului”, prin care operatorii au introdus aceleași informații nu totdeauna relevante, întărind prin repetare nivelul de încredere a unor observații mai mult decât ar fi fost de așteptat.

O variantă a fuziunii pe arbori, dar cu dezvoltare în jos, apare în [Cop03]. În lucrare se descrie un sistem care oferă sprijin pentru luarea deciziilor în activitatea de supraveghere aeriană din domeniul militar. Sistemul acordă asistență în luarea unor decizii pe baza informațiilor nu totdeauna fiabile, atât pentru un operator individual cât și pentru un grup de decidenți. În cazul concret al supravegherii aeriene, fiecare operator primește date de la un senzor și ia decizii referitoare la clasificarea informațiilor pe baza unor proceduri și a experienței acumulate. Toate rezultatele clasificărilor sunt apoi confruntate de un operator de nivel tactic care evaluează și gradul de încredere al

fiecărui operator, după care se trece la o procedură de înlăturare a datelor conflictuale. Articolul propune realizarea unui sistem care nu evaluează performanțele operatorilor, ci permite fiecăruia să-și adapteze mijloacele aflate la dispoziție. Fuziunea informațiilor în cazul unui operator nu se face prin trecerea datelor printr-un lanț de clasificatoare dinainte stabilit care ar micșora incertitudinea printr-o secvență dată de intersectare, ci prin gruparea pe tipuri a clasificatoarelor și selecția în funcție de context, de către utilizator, a unui clasificator din grup, care apoi va prelucra informația. Împreună cu decizia se atribuie și un grad de încredere subiectiv variantei alese. În acest fel se obține un graf decizional aciclic dezvoltat de la o informație generală, aflat pe post de rădăcină, către diferite variante, care reprezintă terminalele grafului, iar la fiecare nivel se selectează clasificatorul utilizat. Pentru a susține procesul de rezolvare a informațiilor conflictuale din grup, sistemul pune la dispoziție metrici specifice fiecărui operator cu care se stabilesc vectori de utilitate a rezultatelor pentru fiecare utilizator, care sunt apoi sortați, în vederea luării deciziei.

Referitor la cele prezentate anterior aș dori să menționez caracterul diferit al celor două tipuri de fuziuni. Primul, cel prin medie, tratează un set de informații presupuse redundante, dar incerte și încearcă să obțină rezultatul prin evaluarea consensului dintre sursele de informații. O problemă a acestui tip de fuziune este cazul în care participă la furnizarea de date și surse false, cum ar fi în cazul senzorilor defecți, și care distorsionează rezultatul. Din acest motiv aplicarea fuziunii prin mediană este mai robustă decât media. Al doilea tip de fuziune implică aplicarea unor constrângeri asupra unei valori inițiale, deci creșterea informării prin îngrădirea posibilităților existente inițial. În cazul sistemului abordat în această teză, deoarece există două lanțuri paralele de obținere a datelor am folosit prima variantă, dar am folosit și o variantă originală a celui de al doilea tip de fuziune, adaptat informațiilor de tip fuzzy colectate.

### 5.3.2 Fuziunea prin vot

O formă specială de fuziune a informațiilor este aceea în care rezultatul se stabilește prin vot. Acest procedeu este în special folosit în cazul fuziunii informațiilor provenite de la un număr de experți umani care își exprima părerea referitor la un domeniu comun. Experții pot să exprime diferite laturi ale domeniului, deci nu trebuie să aibă toți același domeniu de preocupări. Votul poate fi de tip democratic, în care toate opiniile au același efect asupra rezultatului, sau de tip elitist în care unor experți li se acordă o încredere mai mare decât altora ( este de fapt o formă medie ponderată ), sau de tip ierarhic în care se efectuează o primă etapă de votare democratică între experți de aceeași credibilitate, iar în etapa a doua se trece la un vot cu ponderi diferite între rezultatele din prima etapă, în funcție de credibilitatea fiecărui grup. Metoda de votare (dacă există mai multe păreri) poate fi cu majoritate absolută, cu majoritate relativă sau acceptată prin unanimitate. Acest ultim caz este de fapt identic cu cea de tip produs. Se mai folosește uneori și votul median în care se consideră că distribuția părerilor este de tip gaussian și deci opinia de mijloc este cea corectă. Dintre metodele de fuziune prin votare mai trebuie amintită și cea care se bazează pe procedeu de votare introdus de Jean Charles Borda în 1770, în care fiecărui expert i se cere să stabilească o listă a opțiunilor ordonată după prioritatea pe care o consideră. Fiecare alegere primește un punctaj pe fiecare listă întocmită de câte un expert: maximum de puncte primul, iar celelalte opțiuni punctaje în ordine descrescătoare. Este declarată câștigătoare opțiunea care întrunește cele mai multe puncte prin însumarea rezultatelor de pe fiecare listă.

Nu este obligatoriu ca votul să fie dat de experți umani. În [Bak01] se prezintă o metodă de fuziune a informațiilor printr-un procedeu numit „mașină virtuală de votare”. Acesta este de fapt un program la nivelul middleware-ului unei rețele de calculatoare, care acceptă o serie de comenzi prin care se poate modifica modul de decizie al mașinii. În afară de rezultatele fuziunii programul mai permite și obținerea unui nivel de încredere în datele furnizate, ceea ce mărește posibilitățile de utilizare a acestuia. Arhitectura unității cuprinde trei module, dintre care primul este o coadă de așteptare până ce există suficiente răspunsuri ca să se poată trece la fuziune. Al doilea modul este

o unitate de excludere pentru candidații care nu corespund unor cerințe și care sunt eliminați (de exemplu, cauzate de modulele de securitate a informațiilor). Ultimul modul este cel de fuziune propriu-zisă și care permite utilizarea a diferite metode de votare în mod dinamic, în funcție de condiții. Tot în acest modul se determină și nivelul de încredere al rezultatului.

Această metodă de fuziune este un caz simplificat al fuziunii prin sumă și este influențată de posibilitatea apariției unor erori cauzate de informarea decidenților din aceleași surse de informații sau surse dependente. Pentru a obține rezultate bune este necesar ca votanții să aibă în vedere aspecte diferite ale evenimentelor, caracterizate printr-un nivel cât mai ridicat de completitudine, ceea ce am și folosit în cazul deciziei de tip hard din capitolul IX. Un alt aspect ce trebuie analizat în cazul votanților este „efectul de zvon”, deci a unei dependențe între voturi, care se poate manifesta prin observația simultană a aceleiași caracteristici minore de către mai mulți decidenți, ceea ce conduce la o supraevaluare a acestei trăsături.

Referitor la acest capitol așa menționa valoarea practică a acestor metode. În multe cazuri fuziunea informațiilor nici nu apare în studii în mod explicit, ci se folosesc aceste metode euristice ca fiind în mod implicit valabile. De exemplu, se pot găsi exemple ca cel menționat mai sus, în care rezultatul prin metoda votului se consideră implicit adevărat, fără să se facă nici o altă analiză a condițiilor în care se face colectarea informațiilor. Totuși nu trebuie subestimată importanța acestor metode care s-au dovedit eficiente în numeroase aplicații, inclusiv în sistemul descris în această teză, dar mai trebuie subliniat caracterul rigid al metodei, care, așa cum se va prezenta și în partea a 3-a a lucrării, nu ia în considerare caracterul schimbător al condițiilor de achiziție a datelor.

## 5.4. Fuziunea prin metode probabilistice

### 5.4.1. Elemente din teoria probabilităților folosite în fuziune

Teoria probabilității este una din ramurile matematice care au ajuns la maturitate, având un trecut de trei secole, în care s-au publicat nenumărate tratate în acest domeniu.

Referitor la abordarea incertitudinii și impreciziei prin metode probabilistice, trebuie subliniate două probleme. Prima are în vedere axioma probabilității care solicită observarea unui număr foarte mare de evenimente. Teoretic ar trebui să existe o infinitate de evenimente, dar practic avem un număr finit. De la ce număr de evenimente se poate considera că avem o populație la care se pot aplica în mod rezonabil legile teoriei probabilităților, este o întrebare la care răspunsurile pot varia. A doua problemă are în vedere unele aprecieri referitoare la ceea ce în mai multe lucrări se numește probabilitatea subiectivă [Bal04], deci la o probabilitate estimată de un observator în legătură cu șansa de apariție a unui eveniment. Aceste valori atribuite probabilității subiective sunt apoi prelucrate cu tehnici specifice teoriei probabilităților. Există păreri ca cea din [Spi04] care nu subscriu la această abordare, considerând că nu există premisele axiomatice pentru a considera o estimare subiectivă ca fiind o probabilitate. Din punct de vedere al proceselor de fuziune relația care se aplică cel mai des, incluzând aici și abordările derivate, este teorema lui Bayes în forma sa generalizată. Formula se poate folosi pentru a face o legătură între dovezile unei afirmații și ipotezele care pot fi luate în considerare. De asemenea transformă o probabilitate apriorică într-una aposteriori [Neg02]. Forma generală este:

$$p(h_i | d_1 \wedge d_2 \wedge \dots \wedge d_n) = \frac{p(d_1 \wedge d_2 \wedge \dots \wedge d_n) \bullet P(h_i)}{\sum_{j=1}^m p(d_1 \wedge d_2 \wedge \dots \wedge d_n | h_j) \bullet P(h_j)} \quad (5.6)$$

unde  $P(h_i)$ ,  $p(d | h)$  este probabilitatea evenimentului  $h_i$ , respectiv probabilitatea condiționată.

Folosirea acestei forme generale este de multe ori dificilă de utilizat deoarece necesită determinarea probabilităților tuturor combinațiilor din cadrul parametrilor, ceea ce presupune un număr mare de cunoștințe apriorice. Din acest motiv, în multe abordări ale acestei formule se face o presupunere referitoare la independența evenimentelor apriorice, determinând transformarea probabilității conjunctive într-un produs de probabilități uniparametrici:

$$p(d_i \wedge d_j | h) = p(d_i | h) \cdot p(d_j | h) \quad (5.7.)$$

Derivate din teoremele probabilităților condiționate sunt structurile mixte numite rețele Baysiene, având două moduri de abordare, ca rețele deterministe și ca rețele stohastice. Rețelele deterministe îmbină metode probabilistice cu metode combinatoriale [Spi03]. Ele sunt formate dintr-un graf orientat aciclic, ale cărui noduri sunt etichetate cu variabile aleatoare și ale cărui arce reprezintă relații de condiționalitate. Între nodurile adiacente pot să existe următoarele trei situații:

1. un nod părinte A, are un singur nod copil B. În această situație se aplică relația :

$$p(a | b) = \frac{p(b | a) \cdot P(a)}{p(b | a) \cdot P(a) + p(b | \neg a) \cdot P(\neg a)} \quad (5.8.)$$

2. un nod părinte A, are două sau mai multe noduri copil (de exemplu B<sub>1</sub> și B<sub>2</sub>), caz în care se utilizează relația:

$$p(a | b_1 \wedge b_2) = \frac{p(b_1 \wedge b_2 | a) \cdot P(a)}{p(b_1 \wedge b_2 | a) \cdot P(a) + p(b_1 \wedge b_2 | \neg a) \cdot P(\neg a)} \quad (5.9.)$$

3. un nod copil B, are două sau mai multe noduri părinte (de exemplu A<sub>1</sub> și A<sub>2</sub>), situație când aplicăm una din formulele similare:



$$p(a_1 \wedge \neg a_2 | b) = \frac{p(b | a_1 \wedge \neg a_2) \cdot P(a_1 \cdot \neg a_2)}{P(b)} \quad (5.10.)$$

Determinarea valorilor necunoscute se poate afla și printr-o metodă iterativă prin introducerea secvențială a informațiilor din mediu.

Rețelele bayesiene stohastice [Ciu82] folosesc un graf orientat în care nodurile au atașate evenimente probabilistice, iar arcele reprezintă probabilități de condiționare. Cele mai utilizate distribuții pentru probabilitățile condiționate sunt cele gaussiene și cele uniforme. Ceea ce trebuie rezolvat în aceste situații este estimarea mediei și dispersiei pentru toate distribuțiile care intervin, pentru a putea modela comportamentul rețelei. Acest deziderat se realizează în mod iterativ prin introducerea unor serii de informații provenite de la sursele care participă la fuzionare.

#### 5.4.2. Fuziunea informațiilor folosind teoria probabilităților

Abordarea statistică este o metodă des utilizată în fuziunea datelor, folosind diferite nivele de complexitate. O analiză laborioasă a fuziunii de acest tip este prezentată în [Kit98], prin sistematizarea unui număr mare de aplicații. Astfel plecând de la relația de decizie a uneia din cele  $m$  clase  $\omega_j$ , la care se atribuie obiectul  $Z$  observat de vectorii  $x_i$  în cazul fuziunii:

$$P(\omega_j | x_1, \dots, x_R) = \max_k P(\omega_k | x_1, \dots, x_R) \quad (5.11.)$$

se studiază principalele tipuri de fuziuni ce folosesc probabilități.

Fuziunea prin produs se obține din relația generalizată a lui Bayes (a se vedea relația 5.6.) prin presupunerea independenței statistice a vectorilor  $x_i$ , cea ce conduce la formula :



$$P(\omega_k | x_1, \dots, x_R) = \frac{P(\omega_k) \prod_{i=1}^R p(x_i | \omega_k)}{\sum_{j=1}^m P(\omega_j) \prod_{i=1}^R p(x_i | \omega_j)} \quad (5.12.)$$

iar din relațiile ( 3.6.) și ( 3.7.) prin trecere în termeni aposteriori rezultă:

$$P^{(1-R)}(\omega_j) \prod_{i=1}^R P(\omega_j | x_i) = \max_{k=1}^m P^{(1-R)}(\omega_k) \prod_{i=1}^R P(\omega_k | x_i) \quad (5.13.)$$

Această relație este una severă, care anulează rezultatul și în cazul unui singur termen devenit egal cu zero. Dacă se mai presupune că probabilitatea aposteriori nu diferă semnificativ de probabilitatea de repartiție a claselor:

$$P(\omega_k | x_i) = P(\omega_k)(1 + \delta_{k,i}) \quad \text{unde } \delta_{k,i} \ll 1 \quad (5.14.)$$

atunci un termen al fuziunii devine:

$$P^{(1-R)}(\omega_k) \prod_{i=1}^R P(\omega_k | x_i) = P(\omega_k) \prod_{i=1}^R (1 + \delta_{k,i}) \approx (1-R)P(\omega_k) + \sum_{i=1}^R P(\omega_k | x_i) \quad (5.15.)$$

unde aproximarea s-a obținut prin liniarizare, iar relația finală este:

$$(1-R)P(\omega_j) + \sum_{i=1}^R P(\omega_j | x_i) = \max_{k=1}^m ((1-R)P(\omega_k) + \sum_{i=1}^R P(\omega_k | x_i)) \quad (5.16.)$$

rezultând formula fuziunii prin sumă. Din cele prezentate se observă că acest tip de fuziune implică presupuneri ce nu se îndeplinesc în multe din aplicații, iar rezultatul poate fi afectat în cazul unei creșteri semnificative a aproximării. Fuziunea prin vot se obține din cea prin sumă dacă impunem o decizie fermă:

$$\Delta_{k,i} = 1 \quad \text{dacă } P(\omega_k | x_i) = \max_{j=1}^m P(\omega_j | x_i) \quad (5.17.)$$

sau  $\Delta_{k,i} = 0$  în restul situațiilor

iar fuziunea se face prin:

$$\sum_{i=1}^R \Delta_{i,j} = \max_{k=1}^m \sum_{k=1}^R \Delta_{k,i} \quad (5.18.)$$

deci prin determinarea numărului mai mare rezultat din însumare.

Fuziunea prin maxim se obține prin aproximarea inferioară a celei prin sumă, iar fuziunea prin minim se obține prin aproximarea superioară a celei prin produs. Fuziunea prin medie aritmetică se obține din cea prin sumă în cazul în care probabilitățile claselor sunt egale. O problemă interesantă este cea a sensibilității la eroare a estimărilor făcute de clasificatoare. Deoarece clasificarea rezultată de la unitățile de clasificare nu sunt decât estimări, rezultatul poate fi afectat de eroarea  $e_{i,j}$ , iar rezultatul fuziunii prin produs devine:

$$\begin{aligned} P^{(1-R)}(\omega_j) \prod_{i=1}^R (P(\omega_j | x_i) + e_{i,j}) &= \max_{k=1}^m P^{(1-R)}(\omega_k) \prod_{i=1}^R (P(\omega_k | x_i) + e_{k,i}) \\ &\approx \max_{k=1}^m (P^{(1-R)}(\omega_k) \prod_{i=1}^R P(\omega_k | x_i)) \left(1 + \sum_{i=1}^R \frac{e_{k,i}}{P(\omega_k | x_i)}\right) \end{aligned} \quad (5.19.)$$

iar în cazul fuziunii prin sumă devine :

$$\begin{aligned} (1-R)P(\omega_j) + \sum_{i=1}^R (P(\omega_j | x_i) + e_{i,j}) &= \max_{k=1}^R ((1-R)P(\omega_k) + \sum_{i=1}^R (P(\omega_k | x_i) + e_{k,i})) \\ &\approx \max_{k=1}^m ((1-R)P(\omega_k) + (\sum_{i=1}^R P(\omega_k | x_i)) \left(1 + \frac{\sum_{i=1}^R e_{k,i}}{\sum_{i=1}^R P(\omega_k | x_i)}\right)) \end{aligned} \quad (5.20.)$$

Ambele aproximări se obțin prin liniarizare. Comparând cele două relații finale și având în vedere că probabilitățile sunt subunitare, rezultă că fuziunea de tip produs este afectată mai mult de eroarea cumulată decât fuziunea de tip sumă. Această concluzie este importantă deoarece explică rezultatele observate în practică și anume că fuziunea prin sumă indică valori de performanță mai bune decât cea prin produs, chiar dacă se impun presupuneri mai severe pentru ea.

Tot aici trebuie menționat articolul [Alk02] în care, pe baza a numeroase experiențe, se arată că fuziunea de tip produs, așa cum este cea din relația (5.13.), dă rezultate slabe odată cu creșterea numărului factorilor, deoarece oricare valoare de zero anulează întreg termenul, cauzând o condiționare care este prea severă. Pentru condiții de determinare a factorilor ce au un nivel al zgomotului sau un nivel al incertitudinii ridicat este preferabilă utilizarea unei fuziuni de tip sumă, cum ar fi media ponderată. Pentru a elimina acest dezavantaj se propune un operator numit produs modificat  $\hat{P}$  care în cazul probabilităților condiționate este de forma:

$$\begin{aligned} \hat{P}(a|b) &= t && \text{dacă} && P(a|b) \leq t && (5.21.) \\ \hat{P}(a|b) &= P(a|b) && \text{dacă} && P(a|b) > t \end{aligned}$$

unde  $t$  este o valoare de prag ce nu permite anularea termenului. Experimental s-a demonstrat că acest tip de operator dă rezultate mult mai bune decât fuziunea prin produs sau sumă.

Un alt studiu care abordează analiza diferitelor tipuri de fuziuni utilizabile folosind probabilități ca variabile, este [Kun02], în care se face o comparație a erorilor care pot să apară în cazul a cinci metode de fuziune folosite pentru obținerea unui rezultat din  $L$  clasificatoare ce au fiecare numai două opțiuni. În cadrul articolului se analizează din punct de vedere teoretic probabilitatea de eroare a celor cinci metode pentru cazul în

care datele de intrare au o distribuție normală și pentru cazul când au o distribuție uniformă. Cele cinci metode studiate sunt : minim, maxim, medie, mediană și vot majoritar. Autorul menționează că nu se studiază un caz important și anume cel pentru produs, deoarece modelul propus nu se poate adapta acestei fuziuni. Probabilitatea de eroare se calculează pentru medie, mediană și vot majoritar cu relația:

$$P_e = P(\text{eroare} | x) = P(\hat{P}_1 \leq 0,5) \quad (5.22.)$$

unde  $\hat{P}_1$  este probabilitatea variantei corecte și deci dacă este mai mică de 0,5 atunci se alege în mod eronat varianta contrară  $\hat{P}_2$ . Iar în cazul fuziunii prin minim sau maxim se folosește relația pentru calculul probabilității de eroare:

$$P_e = P(\text{eroare} | x) = P(\hat{P}_1 \leq \hat{P}_2) \quad (5.23.)$$

Din analiza rezultatelor a reieșit că în cazul repartiției de probabilitate normală există variații mici între rezultatele diferitelor metode de fuzionare, deci nu contează atât de mult procedeele de fuziune cât diversitatea metodelor de clasificare care fuzionează. Pentru repartiția de probabilitate uniformă cele mai bune rezultate se obțin prin fuziunea de tip minim și maxim (care pentru cazul clasificatoarelor cu două clase sunt simetrice). Nu s-a remarcat o concluzie trasă de Alkoot și Kittler, obținută în mod experimental, și anume că în cazul distribuției normale, de la o valoare de prag a mediei, fuziunea prin minim sau maxim încep să aibă o performanță care devine de la bună, foarte rea, chiar mai rea decât rezultatul fără fuziune. În articol se mai subliniază că prezumția de independență a estimărilor este restrictivă, iar în multe cazuri nu poate fi aplicată. Referitor la acest articol ar fi de menționat caracterul restrictiv al studierii numai a claselor cu două opțiuni, ceea ce determină o analiză și o concluzie particularizată, concluziile rezultate din [Alk02] fiind mai generale și deci cu o aplicabilitate mai mare.

### 5.4.3. Aplicații ale fuziunii folosind probabilități

O abordare intuitivă ce nu folosește un aparat matematic complicat este cea prezentată în [Tre95], în care se analizează fuziunea senzorială implicată în mișcarea unui deget de robot. Studiul își propune să micșoreze spațiul de evenimente care pot apărea în cadrul funcționării degetului. În acest scop se împart caracteristicile care se pot extrage din informațiile provenite de la senzori în două grupe: unele ce depind de senzori cum ar fi eroarea de poziționare, forța de contact, tensiunea din membrana degetului și altele care depind de context sau de model cum ar fi accelerația dorită, viteza impusă sau produsul dintre viteză și forță în cazul contactului. Un eveniment poate apărea în cazul existenței unui anumit set de caracteristici, dar apariția nu este obligatorie. Fiecărei caracteristici  $i$  se atribuie o funcție probabilistică ce indică nivelul de încredere în apariția evenimentului dacă se observă caracteristica. Caracteristicile de tip senzor  $f_i$  reprezintă incertitudini și perturbații de aceea fuziunea încrederilor  $\Psi(f_i)$  poate fi descrisă ca o sumă ponderată a acestora, pe când caracteristicile de tip contextual  $f_j$  reprezintă cunoștințe care condiționează apariția evenimentului iar funcțiile corespunzătoare de încredere  $\Psi(f_j)$  vor influența încrederea în mod multiplicativ. Rezultă că valoarea fuzionată a încrederii va fi:

$$\Psi_f = \prod_{j=1}^m \Psi(f_j) \times \sum_{i=1}^n \omega_i \cdot \Psi(f_i) \quad (5.24.)$$

unde  $m$  reprezintă numărul de caracteristici contextuale, iar  $n$  reprezintă numărul de caracteristici de tip senzor.

Experiențele de laborator au confirmat această relație. Această concluzie cred că merită reținută, deoarece are o largă aplicabilitate și este ușor de integrat, problema care rămâne de rezolvat este cea a determinării probabilităților printr-o metodă fundamentată teoretic, ceea ce nu este totdeauna ușor de realizat.

O altă lucrare, ce nu face apel la o abordare complexă din punct de vedere probabilistic, este [Sha02], în care se prezintă o idee interesantă de a combina metodele de clasificare clasice (cu măsurare a distanței față de prototip) cu o fuziune de tip probabilistic. În articol se analizează o metodă de fuziune a trăsăturilor feței cu cea a mersului pentru a identifica o persoană. Sistemul folosește patru camere video dispuse în jurul spațiului de analizat. Tipul de fuziune ales este cel la nivel de decizie, rezultând că prima dată trebuie efectuată clasificarea pentru fiecare dintre sursele de informare. Din informațiile furnizate de camere se construiește un model tridimensional al siluetei prin aproximări conice, după care prin presupunerea că persoana se deplasează în picioare și are privirea orientată aproximativ în sensul mersului, se localizează fața. Identificarea se face prin calcularea unei distanțe  $D_f(w_k | f)$  dintre trăsăturile feței  $f$  a persoanei din imagini și cele a persoanelor din baza de date  $w_k$ :

$$D_f(w_k | f) = \|w_k - f \cdot B_k\| \quad (5.25.)$$

unde  $B_k$  este operatorul de extragere a trăsăturilor. Identitatea persoanei fiind atribuită la modelul care are distanța minimă. La fel și pentru identificarea mersului, se determină o distanță prin compararea distanțelor între situația analizată și cele din baza de date, dar analiza trebuie făcută pe secvențe de imagini  $\gamma(S)$ :

$$\Gamma(w_k | S) = \min \|\gamma(S) - \gamma(S_w)\| \quad (5.26.)$$

Trecerea la analiza probabilistică se face prin observația că distanțele calculate au o distribuție ce poate fi aproximată printr-o funcție probabilistică. Această aproximare se poate face empiric ca în cazul articolului sau prin regresie statistică. După transformarea în termeni probabilistici se efectuează fuziunea care, în cazul citat, a fost testată experimental pe patru variante de fuziune: produs, medie aritmetică, minim și maxim obținându-se cele mai bune rezultate pentru produs. Presupunerea pe care o fac autorii

cu privire la distribuția normală a trăsăturilor luate în considerare, cu toate că nu este demonstrată, este justificată. Ceea ce cred eu că este o problemă în cazul de față, este tratarea prin probabilități a unui număr relativ mic de cazuri (de ordinul a câteva zeci de exemple), pentru fiecare persoană studiată având între 2 și 14 modele. Din acest motiv o fuziune printr-o altă metodă ar fi fost poate mai justificată.

O abordare deosebită a fuziunii este cea prezentată în [Par00], în care se descrie o metodă de urmărire a mișcărilor unui actor cu un detector de mișcări în vederea realizării unui film animat cât mai veridic. Sistemul este compus din senzori magnetici, care au un nivel de zgomot ridicat și necesită amplasarea unor fire pe costumul actorului, și senzori optici, dar care în unele momente ale mișcării actorului sunt obturate față de echipamentul de captură. Pentru a avea o informație cât mai completă despre fiecare mișcare, se propune dublarea senzorilor optici cu senzori magnetici, realizându-se o fuziune a celor două informații. Soluția propusă de autori se bazează pe corelația puternică care există între datele celor doi senzori atât timp cât senzorii optici nu sunt obturați, fuziunea realizându-se prin autoregresie a mediei celor două intrări, iar când senzorul optic are semnal zero, se folosește numai informația provenită de la senzorul magnetic. Procedeu utilizat este simplu și ușor de folosit, ilustrând o idee pe care am folosit-o și eu în experiențe, și anume folosirea tuturor surselor de informații disponibile la un moment dat, pentru a obținerea rezultatului, luând în considerare că nivelul de încredere al surselor trebuie actualizat în permanență, fiind un parametru dinamic.

În cazul fuziunii diferitelor imagini se folosesc tehnici specifice, cum este cea a rețelelor neuronale cu autoorganizare de tip Kohonen sau a analizei componentelor principale descrise în [Sch00]. Aplicația ce se dorește soluționată este obținerea unei singure imagini sintetice din mai multe imagini ale aceleiași regiuni dar luate de diferite camere video în benzi spectrale diferite. Metoda analizei componentelor principale are o abordare globală a imaginilor în care se calculează o matrice a covarianței mediilor din imaginile ce se doresc fuzionate, dar această abordare nu permite reliefarea tuturor



---

detaliilor tocmai din cauza abordării globale. Din acest motiv în articol se propune realizarea unor fuziuni pe domenii locale prin determinarea matricei de covariație locală care este apoi diagonalizată după vectorii proprii și sortată după valorile proprii în mod descrescător. Pentru vizualizare se alege proiecția după primul vector propriu al matricei, obținându-se astfel variațiile cele mai mari ale ferestrei. Pentru a nu avea discontinuități între ferestre se face o mediere ponderată cu distanța pe ferestre de 3x3 puncte în jurul pixelilor de la marginile domeniilor locale. Aplicarea acestei metode a pus în evidență o creștere a vizibilității detaliilor din imaginea obținută prin fuziune. Mărimea ferestrelor folosite în acest articol nu este specificată și depinde de mărimea obiectelor, măsurate în pixeli, aflate în imagine. Deci propunerea pe care o fac autorii articolului de a folosi ferestre de mărime fixă nu dă în general o soluție bună, iar folosirea unor domenii de dimensiuni variabile implică alte probleme (cum ar fi o segmentare în prealabil a imaginii). O altă problemă care este specifică metodei prin analiza componentelor principale se referă la stabilirea empirică, în funcție de caz, a numărului de valori proprii luate în considerare.

Determinarea unui algoritm de urmărire a deplasării unei persoane într-o incintă este abordată în [Loy02] prin prisma unei analize stohastice. În acest sens se propune utilizarea a două automate. Primul este destinat pentru localizarea obiectivului prin folosirea unui algoritm de condensare, ce implică în faza inițială, distribuirea aleatoare în spațiul de căutare a unor entități numite „particule” și care reprezintă locații presupuse ale persoanei. În faze succesive, pe măsură ce sunt prelucrate imagini, particulele se deplasează stohastic pe baza probabilității calculate pentru fiecare în parte de celălalt automat. Locația optimă este determinată prin determinarea poziției unde se aglomerează cele mai multe particule. Al doilea automat calculează funcția de distribuție a probabilității pentru fiecare particulă prin fuziunea informațiilor referitoare la caracteristicile obținute din imagine și anume culoarea pielii, aproximarea ovală a feței, determinarea poziției ochilor și calcularea distanței față de camera video. Pentru această ultimă caracteristică a fost nevoie să se facă măsurători stereoscopice folosind două camere video. Fuziunea s-a făcut printr-un operator de tip produs cu prag:



$$P(e | s_t) = \prod_{j=1}^N (P(e_j | s_t)(1-\alpha) + \alpha) \quad (5.27.)$$

unde  $e_j$  reprezintă una din cele  $N$  caracteristici,  $s_t$  este locația  $s$  la momentul  $t$ , iar  $\alpha \in [0,1]$  este pragul de prevenire a anulării termenului. Aplicarea în practică a acestei metode a dovedit viabilitatea ei dar a și scos în evidență timpul de calcul foarte mare pe care-l implică, ceea ce presupus adoptarea unei optimizări prin ierarhizare a timpilor de calcul alocați. În afară de dezavantajul timpului de calcul mare, metoda are câteva avantaje importante, cum ar fi posibilitatea urmării obiectelor multiple. Abordarea seamănă cu cea din algoritmi genetici, care sunt recunoscuți ca fiind robusți la diferite perturbații și obțin rezultate suboptimale, dar evită maximele locale. Din aceste considerente, prima parte a metodei cred că poate fi folosită și în alte combinații, în care al doilea automat funcționează după alte principii.

Există un număr de lucrări care fac o analiză comparativă a mai multor metode probabilistice, un astfel de exemplu este cel al articolului [Gun01], care abordează problematica detecției minelor militare prin folosirea unui senzor inductiv electromagnetic, al unui radar cu penetrare și a unei camere video în infraroșu. Fuziunea este analizată comparativ prin trei metode: una efectuată la nivelul trăsăturilor, o fuziune hard la nivelul deciziei și o fuziune soft tot la nivelul deciziei. În primul caz fuziunea se face prin determinarea minimului riscului condiționat Bayesian plecând de la relația:

$$\min R_j(D) = \min \sum_{i=1}^K C_{i,j} P(H_i | D) \quad (5.28.)$$

unde  $R_j(D)$  este riscul condiționat,  $C_{i,j}$  este penalitatea pentru alegerea uneia dintre ipoteze,  $H_i$  este una din cele  $K$  ipoteze posibile, iar  $D$  este data colectată de unul din

cele  $j$  detectoare de mine. Datele colectate sunt presupuse a fi formate dintr-un semnal ce reprezintă semnătura minei  $g_i$  și semnalul de zgomot din locația analizată  $n_i$ , deci:

$$d_i(R_{i,j}) | H_k = g_i(R_{i,j}; \Theta_{i,k}) + n_i(R_{i,j}) \quad (5.29)$$

unde  $\Theta_{i,j}$  reprezintă vectorul trăsăturilor, iar  $R_{i,j}$  locația măsurătorii. Pentru a nu fi nevoiți să stabilească coeficienții de penalitate autorii determină numai probabilitățile a posteriori și curbele ROC (Receiver Operator Curve), care au pe axa  $X$  probabilitatea alarmelor false și pe axa  $Y$  probabilitatea de detecție. Pentru obținerea acestora se fac presupunerile că datele colectate  $D$  implică în mod major trăsăturile minelor  $\Theta$  și că aceste trăsături nu sunt prea specifice (deci au o distribuție a probabilității mai amplă). Atunci probabilitățile condiționate ale ipotezei sunt aproximativ egale:

$$P(H_k | D) \approx P(H_k | \Theta) \quad (5.30.)$$

și se demonstrează că raportul densităților de probabilitate în caz de detecție corectă și detecție falsă este:

$$\Lambda(D) = \frac{f_{D|H_1}(D)}{f_{D|H_2}(D)} \approx \frac{f_{\Theta|H_1}(\hat{\Theta}_1)E_1}{f_{\Theta|H_2}(\hat{\Theta}_2)E_2} \quad (5.31.)$$

unde  $\hat{\Theta}$  este valoarea care maximizează densitatea de probabilitate.

În cazul fuziunii prin decizie hard pentru fiecare senzor se ia mai întâi o decizie, dacă este probabil să existe o mină sau nu, după care se face fuziunea datelor ținând cont de încrederea acordată fiecărui senzor. Relația folosită este:

$$P(H_k | U, T) = \left( \prod_{i=1}^N U_i \right) P(H_k | P(U, T)) \quad (5.32.)$$

unde  $U_i$  este decizia fiecărui senzor ( 0 dacă nu există mină și 1 dacă există)  $U$  este vectorul deciziilor,  $N$  este numărul de detectori, iar  $T$  este vectorul valorilor de prag folosite la discriminarea deciziilor. De observat că valorile de prag se determină în general suboptimal prin metode euristice.

Pentru metoda fuziunii prin decizie soft, fiecare senzor determină pe lângă valoarea deciziei și un nivel de încredere în această decizie,  $P(u_i | \Theta_i, t_i)$  calculat în funcție de corespondența trăsăturilor și de pragul de decizie ales, aducând o informație suplimentară. În acest caz se utilizează relația :

$$P(H_k | \Theta) = \sum_{u=1}^Q \sum_{un=1}^Q P(H_k | U, T) \prod_{i=1}^N P(u_{un} | \Theta_i, t_i) \quad (5.33.)$$

unde  $Q$  reprezintă numărul de ipoteze presupuse egale pentru toți senzorii.

Toate aceste metode au fost testate rezultând o clasificare a lor în funcție de ROC. Astfel s-a constatat că cele mai slabe rezultate se obțin prin folosirea separată detectorului inductiv și a camerei video în infraroșu. Detectorul radar cu penetrare a obținut un rezultat mai bun, iar fuziunea prin decizie hard unul mai bun dar foarte apropiat. Cel mai bun rezultat a fost obținut prin fuziunea la nivelul trăsăturilor, rezultat care a devansat metodele de fuzionare prin decizii soft. Din rezultatele acestui articol ar trebui subliniat, rezultatele bune obținute prin utilizarea fuziunii la nivel de trăsături, dar care implică o analiză mai specifică și uneori aproximări sau restricții care nu totdeauna pot fi justificate. Foarte aproape ca performanțe ale rezultatelor se situează fuziunea prin decizie soft, dar care nu implică o analiză atât de laborioasă, de cea în experimentările pe care le efectuez am optat pentru acest nivel de fuziune, care în mai multe articole este recomandat ca fiind compromisul cel mai bun.

O metodă mai rar folosită în fuziune este cea a minimizării entropiei sistemului, deci a creșterii nivelului de informare. O astfel de abordare se prezintă în [Yi97], unde se

consideră un număr de  $N$  senzori fuzionați prin medie aritmetică ponderată (prezentată în formula 2.1.) și ale căror ieșiri sunt afectate de semnale de zgomot  $n_i(t)$  identice, independente și cu medie zero.

$$x_i(t) = s(t) + n_i(t)$$

Se introduce ca măsură a informării norma varimax, definită astfel:

$$V[x(t)] = \frac{\frac{1}{N} \sum_{i=1}^N |x(t)|^4}{\left(\frac{1}{N} \sum_{i=1}^N |x(t)|^2\right)^2} \quad (5.34.)$$

unde  $N$  este numărul de senzori fuzionați, iar  $x(t)$  este semnalul de ieșire a senzorilor. Norma varimax este o măsură a simplității semnalului și este invers proporțională cu valoarea entropiei. Rezultă că ceea ce urmărește este alegerea ponderilor mediei astfel încât să maximalizeze funcția  $V$ . Optimizarea este neliniară și implică metode numerice mai complicate. În articol se mai demonstrează și că entropia rezultatului fuziunii este totdeauna mai mare decât a semnalelor de zgomot, deci o optimizare a normei varimax a rezultatului fuziunii va maximaliza și norma semnalelor de zgomot, rezultând o micșorare a incertitudinii. Metodele de tip entropic caracterizează obiectele analizate în mod global, din această cauză consider că sunt mai potrivite pentru faza de evaluare a performanțelor unui sistem decât în faza de decizie, respectiv în cea de fuziune.

Dintre lucrările care abordează fuziunea prin prisma rețelelor Bayesine voi prezenta pe scurt articolul [Bea03]. În acest studiu se urmărește realizarea urmării unei persoane într-o încăpere prin fuziunea informațiilor provenite de la două microfoane și o cameră video. Modelul matematic este construit sub forma unui graf orientat în care un set de parametri sunt considerați ca variabile de intrare, care modelează probabilistic semnalul audio emis și imaginea reală. Toate variabilele sunt considerate a fi sau

discrete sau probabilistice cu distribuție gaussiană. Aceste intrări condiționează semnalele stereofonice audio și imaginea captată care sunt singurele date cunoscute. Modelul matematic pentru sistemul audio este:

$$\begin{aligned}
 p(r) &= \pi_r \\
 p(a | r) &= N(a | 0, \eta) \\
 p(x_1 | a) &= N(x_1 | \lambda_1 a, \nu_1) \\
 p(x_2 | a, \tau) &= N(x_2 | \lambda_2 L_\tau a, \nu_2)
 \end{aligned}
 \tag{5.35}$$

unde  $r$  este spectrul de putere al semnalului audio,  $a$  care are probabilitatea apriorică  $\pi_r$ , și matricea de precizie  $\eta$ . Funcția  $N(m, \sigma)$  reprezintă o funcție a probabilității condiționate de tip gaussian, care are media  $m$  și dispersia  $\sigma$ . Variabilele  $x_1, x_2$  reprezintă semnalul  $a$  captat de cele două microfoane care au atenuările  $\lambda_1, \lambda_2$  și sunt influențate de zgomotele  $\nu_1, \nu_2$ , iar  $\tau$  reprezintă întârzierea dintre cele două semnale din microfoane, unde  $L_\tau a$  este un operator de shift temporal.

Pentru sistemul video modelul matematic este:

$$\begin{aligned}
 p(s) &= \pi_s \\
 p(v | s) &= N(v | \mu_s, \phi_s) \\
 p(y | v, l) &= N(y | G_l v, \psi)
 \end{aligned}
 \tag{5.36}$$

unde  $v$  este imaginea reală modelată prin parametrul  $s$  de probabilitate apriori  $\pi_s$  și având o distribuție cu media  $\mu_s$  și dispersia  $\phi_s$ . Imaginea reală se consideră deplasată cu  $l$  în cadrul imaginii captate  $y$  care este afectată de zgomotul  $\psi$ . Operatorul  $G_l v$  realizează o shiftare spațială de dimensiune  $l$ .

Legătura care se consideră că există între cei doi senzori este dată de relația dintre întârzierea ce apare între cele două microfoane și deplasarea față de centru care apare pe ecran pentru elementului urmărit. Această relație se exprimă prin :

$$p(\tau | l) = N(\tau | \alpha \cdot l_x + \alpha' \cdot l_y + \beta, \omega) \quad (5.37.)$$

unde  $\alpha, \alpha', \beta$  reprezintă parametri de conversie din dimensiunea spațială în cea temporală, iar  $\omega$  este dispersia. De menționat că se consideră deplasarea pe  $y$  apropiată de zero, deoarece microfoanele sunt așezate coliniar în plan orizontal.

Algoritmul este realizat iterativ în doi pași; în primul, se corectează distribuțiile a posteriori ale variabilelor ascunse, iar în al doilea se actualizează parametrii de intrare. Astfel se calculează pentru fiecare cadru, în mod secvențial cea mai probabilă poziție  $l$  de pe ecran unde se află persoana urmărită:

$$\hat{l} = \max P(l | x_1, x_2, y) \quad (5.38.)$$

Rezultatele experimentale prezentate în lucrare au permis să se concluzioneze că metoda de fuziune este mult mai precisă decât folosirea numai a microfoanelor sau numai a camerei video, permițând urmărirea persoanei și când nu este vizibilă din cauză obturării, ca și în situația când există perturbații sonore. Aplicația ilustrează foarte bine posibilitățile rețelelor Bayesiene atunci când modelul este bine conceput. De asemenea dintr-o analiză mai atentă rezultă și deficiențele pe care le poate avea fuziunea cu un număr mic de elemente. În acest sens autorii sunt obligați să considere ambele surse de informare ca fiind perfect fiabile, modelul funcționând numai în aceste condiții. Pentru a avea o posibilitate de apreciere a fiabilității componentelor trebuie să luăm în considerare minim trei surse, dacă dorim să obținem și informație fuzionată și o apreciere a nivelului de încredere a senzorilor. Acest fapt a determinat opțiunea făcută în experimentele pe care le efectuez pentru trei categorii de surse de informații.

O abordare similară dar cu câteva diferențe majore se regăsește în [She01]. Lucrarea propune un sistem de urmărire a persoanelor dintr-o imagine dar fără folosirea altor senzori, ci prin extragerea a diferite caracteristici din imagine și fuziunea acestora.

Un exemplu de astfel de caracteristici sunt culoarea pielii feței, determinarea mișcării sau forma aproximativ ovală a feței. Aceste trăsături sunt fuzionate prin intermediul unei rețele Bayesiene care are în nodurile principale elemente de codificare a pozițiilor posibile din imagine. Fiecărui astfel de nod  $i$  se atribuie o funcție de probabilitate care are o distribuție gaussiană. De asemenea nodurile principale sunt conectate cu noduri copii la care le sunt atribuite caracteristicile obligatorii ale nodurilor principale și noduri părinți la care le sunt atribuite caracteristicile opționale. Fiecare nod de tip caracteristică are asociate legături cu noduri care indică nivelul de încredere al trăsăturii respective, care poate lua una din valorile: mare, mediu sau mic. Calcularea probabilităților condiționate se face prin interferențe de funcții gaussiene de tipul:

$$p(e | z) = \sum_{k=1}^K \alpha_k G(z; \mu_k, \sigma_k) \quad (5.39.)$$

unde  $z$  este variabila spațială,  $e$  este evenimentul condiționat,  $K$  reprezintă numărul de funcții care sunt implicate în punctul  $z$ ,  $\alpha_k$  este un factor de ponderare proporțional cu influența fiecărei funcții, iar  $G(z; \mu_k, \sigma_k)$  este una din cele  $K$  funcții gaussiene. Autorii notează cu  $P(e_x^- | X)$  probabilitățile nivelelor de încredere a ramurilor de tip copil al punctului spațial  $X$  și cu  $P(X | e_x^+)$  probabilitățile nivelelor de încredere a ramurilor de tip părinte a aceluiași punct. Folosind aceste notații probabilitatea condiționată a posteriori Bayes pentru un punct  $X$  se determină cu relația:

$$P(X | e) = \beta \cdot P(e_x^- | X) P(X | e_x^+) \quad \text{unde } \beta = P(e_x^+) / P(e) \quad (5.40.)$$

Deoarece condiționarea poate fi făcută de mai mulți termeni, se consideră evenimentele independente, ceea ce permite folosirea produsului de termeni în locul probabilităților multiplu condiționate care ar fi greu de calculat. Algoritmul se poate modifica și pentru urmărirea simultană a mai multor persoane. În urma experimentărilor a rezultat un efort de calcul ridicat ceea ce a determinat o rărire a grilei de puncte posibil

de selectat ca centre ale distribuțiilor probabilistice, precum și o ierarhizare a trăsăturilor după timpul de calcul implicat, astfel încât să se încerce determinarea pozițiilor cu cât mai puține trăsături care consumă cât mai puțin timp. Cu toate că folosește același aparat matematic, abordarea acestui articol este complet diferită față de cel anterior. În această lucrare nodurile au o structură topologică, în care se calculează probabilitatea de existență a obiectului, față de abordarea anterioară în care se urmărea stabilirea parametrilor modelului. Această metodă implică, de asemenea, un efort de calcul mult mai mare, dar determinarea localizării obiectelor printr-o rețea de carioaj este de reținut. O astfel de abordare a determinării poziției experimentând și eu.

Din articolele prezentate reiese numărul mare de abordări posibile folosite în fuziune prin aplicarea teoriei probabilităților, dar și aparatul matematic complex și nu întotdeauna suficient argumentat care se folosește. Așa cum am prezentat și la începutul capitolului, aplicarea probabilităților în domeniul fuziunii trebuie să se facă după o analiză a presupunerilor și condițiilor implicite care fundamentează teoria ce se aplică, iar numărul evenimentelor din proces trebuie să fie suficient de mare pentru a justifica caracterul probabilistic al fenomenelor. Din aceste cauze, nu am optat pentru aplicarea acestui tip de fuziune în realizarea sistemului din această teză.

## **5.5. Fuziunea prin metode fuzzy**

### **5.5.1. Elemente din teoria mulțimilor vagi folosite în fuziune**

Mulțimile vagi sau fuzzy, cum au fost introduse de L.A. Zadeh în 1965, se doresc a fi o extensie a logicii formale prin introducerea unor valori de apartenență  $\mu$  care să nuanțeze nivelul de adevăr al unei declarații. Astfel în locul unor propoziții care pot fi considerate sau adevărate sau false, se introduce un interval care să caracterizeze gradul de adevăr al propoziției. Această abordare implică definirea unor generalizări a operatorilor SI logic și SAU logic, generalizare realizată printr-o



familie de funcții numite t-norme respectiv s-norme, care în cazurile speciale de extrem se comportă ca funcțiile logice pe care le generalizează.

Cele mai utilizate t-norme sunt funcțiile:

- minim:  $x \text{ t } y = \min(x,y)$ , cu s-norma maxim:  $x \text{ s } y = \max(x,y)$ ,
- produs:  $x \text{ t } y = xy$  cu s-norma  $x \text{ s } y = x+y-xy$  și
- Lukasiewicz:  $x \text{ t } y = \max(0,x+y-1)$ , cu s-norma  $x \text{ s } y = \min(1,x+y)$ .

De asemenea se definesc și familii de funcții de complementaritate pentru generalizarea negației, precum și funcții de generalizare a diferenței și implicației logice [Dub00a].

De remarcat că în cadrul logicii mulțimilor vagi, legea terțului exclus nu se aplică, dar rămâne valabilă legea lui De Morgan.

În cele mai multe aplicații folosirea mulțimilor vagi implică realizarea secvențială a trei proceduri : fuzzyficarea , operațiile și inferențele de tip fuzzy, și defuzzyficarea [Nqu98].

Fuzzyficarea implică atribuirea la datele de intrare a gradelor de apartenență. Trebuie subliniat că nu există o regulă strică în această privință, rămânând la latitudinea factorului uman să stabilească metrica. După părerea lui M.Sugeno nici nu este determinantă această alegere empirică deoarece ceea ce în mulțimile fuzzy are importanță este relația de ordine și nu metrica. De asemenea tot în această fază, dacă se folosește metoda Mandami, se determină și forma funcțiilor de apartenență, formă care uneori se mai ajustează în cadrul experimentărilor.

Operațiile folosite sunt de tipul celor menționate mai sus, funcția t-normă și conorma corespunzătoare folosită, fiind date de tipul problemei. Inferențele de tip fuzzy sunt asemănătoare cu cele din logica predicatelor, adică de tipul: dacă <condiție> atunci <concluzie>.

Defuzzyficarea implică trecerea din domeniul gradelor de apartenență la cel al valorilor concrete. Există diferite metode folosite în acest scop, cele mai des utilizate fiind metoda centrelor de greutate sau metoda maximului [Bal02]. Modul de abordare specific mulțimilor vagi se poate folosi fără modificări în fuziunea informației deoarece

atribuirea valorilor de apartenență diferitelor componente ce participă la fuziune determină unificarea tipurilor de informații.

### 5.5.2. Fuziunea informațiilor folosind teoria mulțimilor vagi

În cazul fuziunii problemele apar ca și la orice abordare de tip fuzzy, la modul de determinare a coeficienților de apartenență și a formelor funcțiilor de distribuție a acestora, deci în operația de fuzzyficare. În etapa următoare trebuie avută în vedere realizarea modelului de fuziune care în cazurile mai simple poate fi o operație de intersecție. Pentru modele mai complexe trebuie construite relațiile de inferență.

O abordare sistematică referitoare la fuziunea informației se face în [Yag97], analizată printr-o abordare similară cu cea a operatorilor OWA, introduse tot de Yager în 1988 [Dub00a]. Operatorii de mediere ponderați după ordonare OWA permit o agregare a informațiilor în mod gradat între maxim (folosit ca s-normă) și minim (folosit ca t-normă). Rezultatul aplicării operatorului OWA este produsul scalar dintre vectorul informației de agregat, dar care are datele ordonate în mod crescător și un vector  $W$  de ponderare, ale cărui componente au următoarele proprietăți :

$$w_i \in [0,1] \quad \text{și} \quad \sum_{i=1,n} w_i = 1 \quad (5.41.)$$

Pentru diferite configurații ale vectorului de pondere  $W$  se pot obține funcțiile de maxim, minim, mediană sau medie. În realizarea unei fuziuni, conform lucrării, este necesară utilizarea unei funcții care să fie idempotentă, comutativă și monotonă, care poate genera un rezultat în intervalul cuprins între valoarea obținută prin t-normă și valoarea obținută prin s-normă. Pentru a modela cât mai fidel realitatea se propune introducerea unei funcții suplimentare numită „relație de combinabilitate” care să ia în considerare gradul în care informațiile ce intervin în fuziune se pot agrega, notată  $R(x,y)$ . Această funcție se poate stabili a fi, de exemplu, invers proporțională cu o distanță. Metrica folosită pentru determinarea distanței poate să difere în funcție de

natura elementelor ce intră în procesul de fuziune. De exemplu, în cazul informațiilor fuzzy se poate utiliza o măsură fuzzy așa cum a fost definită de Sugeno și care poate reprezenta gradul de încredere al observațiilor corespunzătoare fuziunii sau o funcție ce depinde de numărul de observații care au aceeași valoare. Influența relației de combinabilitate asupra rezultatului poate varia între două limite. Prima este situația în care toate elementele se pot fuziona având deplină încredere. Această situație se caracterizează prin relația:

$$R(x,y) = 1 \quad \text{pentru } \forall x,y \quad (5.42.)$$

iar a doua când elementele fuziunii se pot combina numai cu ele însele, caz în care avem relațiile :

$$R(x,x) = 1 \text{ și } R(x,y) = 0 \text{ pentru } \forall x \neq y \quad (5.43.)$$

Valorile rezultate din relația de combinabilitate au un efect de ponderare asupra informațiilor ce participă la fuziune, valoarea ponderii depinzând de numărul și natura elementelor de agregat. Pentru cazul în care și informația de fuzionat și rezultatul relației sunt mulțimi vagi se efectuează o intersecție a suprafețelor corespunzătoare mulțimilor fuzzy.

O idee interesantă este prezentată în [Duj98], referitoare la operatorii de agregare comparativ cu fuziunea informațiilor observată la oameni. În aceasta autorul observă o înclinație a factorului uman de a accentua o anumită tendință. Astfel dacă o caracteristică rezultată în urma unei fuziuni are valoarea lingvistică „bine”, oamenii au tendința, bazându-se numai pe repetarea caracteristicii, de a o include la valoarea lingvistică „foarte bine”, ca un fel de extrapolare a tendinței. Această observație a determinat introducerea unei funcții de accentuare a agregării, notată  $h$ . Caracteristica aceste funcții poate fi de tip optimist dacă este monoton crescătoare, de tip pesimist

dacă este monoton descrescătoare sau de tip neutru dacă este o funcție constantă. Funcția de fuziune se obține prin compunerea funcției de agregare cu funcția de accentuare:  $f(a) = h \circ g(a)$  dar, din motive de continuitate a funcției de fuziune, atunci când funcția de agregare este definită folosind o distanță, s-a modificat relația de definiție astfel:

$$f(a) = \left( \lim_{\substack{x \rightarrow a_1 \\ x \neq a_1}} (h \circ g(x, a_2 \dots a_n)) \dots \lim_{\substack{x \rightarrow a_n \\ x \neq a_n}} (h \circ g(a_1 \dots a_{n-1}, x)) \right) \quad (5.44.)$$

Într-un caz general se pot stabili doi parametri  $\alpha, \beta$ . Primul specifică de la ce valoare să înceapă să acționeze funcția  $h$ , iar al doilea indică nivelul de amplificare a funcției. Un avantaj al acestei abordări ar putea fi introducerea unor coeficienți de ponderare variabili care să țină cont de context. Cu toate acestea operatorul este destul de greu de aplicat din cauza lipsei unei modelări care să determine una din numeroasele familii de funcții ce pot fi alese, lăsând multe elemente la nivel empiric.

### 5.5.3 Aplicații ale fuziunii folosind mulțimi vagi

Un exemplu clasic de fuziune prin metoda fuzzy este [Yen96], care abordează problema fuzionării informațiilor provenite din două nivele de control al unui robot mobil și anume de la modulul ce urmărește scopul mișcării și de la modulul ce analizează mediul înconjurător. În cadrul modulului de urmărirea scopului se determină locația unde se dorește să se ajungă pe baza unei hărți incomplete a mediului. Din această informație și din cunoașterea poziției curente se determină direcția de mers, respectiv unghiul în care trebuie să se facă avansul mobilului. După determinarea unghiului se startează două din regulile fuzzy cele mai apropiate de scop și se calculează o medie ponderată de tip interpolativ între concluziile obținute. Din informațiile primite de la senzorii de distanță, modulul de analiză a mediului extern determină dacă există obstacole în cale mobilului. În funcție de poziția senzorilor care detectează obstacole se startează regulile fuzzy de inferență care apreciază direcțiile interzise de avans. Gradele

de apartenență  $\mu$ , corespunzătoare celor două rezultate sunt apoi fuzionate printr-un operator conjunctiv, în care al doilea termen este negata rezultatului din modulul de analiză a mediului:

$$\mu_{fuziune}(x) = t - \text{norm}(\mu_{scop}(x), \mu_{mediu}) \quad (5.45.)$$

în cazul concret al problemei, în care s-a ales t-norma, minim și negata ca 1-directă, relația devine:

$$\mu_{fuziune}(x) = \min(\mu_{scop}, 1 - \mu_{mediu}) \quad (5.46.)$$

În finalul algoritmului se face defuzzificarea, pentru a obține unghiul concret de avans. Experiențele au arătat că cea mai bună metodă în acest caz este determinarea centroidului suprafeței celei mai mari din diagramele fuzzy. Încercările aplicative făcute în laborator au confirmat comportamentul bun al mobilului care folosește acest algoritm. Acest tip de fuziune pare simplu, dar determinarea funcțiilor de apartenență precum și a regulilor de inferență, ceea ce reprezintă de fapt modelul fenomenului, nu este simplu de realizat. Din această cauză rezultatele acceptabile se obțin numai după ajustări iterative, obținute în urma experimentărilor.

Un experiment similar este prezentat în [Ayc97] cu un robot comercial de navigație dotat cu 20 de senzori de contact, 16 senzori ultrasonici și 16 senzori în infraroșu, toți amplasați circular la distanțe egale. Dar spre deosebire de exemplul precedent fuziunea informațiilor se face în două etape, una la nivel de grupe de senzori și una la nivel de ansamblu, în care se efectuează doar însumarea algebrică a comenzilor inițiate de primul nivel. Această posibilitate apare, deoarece autorii consideră comportamentul reactiv al sistemului echivalent din punct de vedere al grupelor de senzori, deci ocolirea obstacolelor se face cu aceeași prioritate indiferent din ce parte apar acestea. Din cele prezentate rezultă că fuzzyficarea, stabilirea regulilor, inferențele

acestora, precum și defuzzyficarea se face separat pentru fiecare grupa de senzori (grupa senzorilor din față, lateral-față și lateral), rezultând comenzi referitoare la unghiurile de deplasare și la vitezele de mișcare separate pentru fiecare grupă. Un caz aparte îl reprezintă introducerea obiectivului mișcării care se suprapune peste comportamentul reactiv. În acest caz rezultatul procesului de defuzzyficare, respectiv unghiul și viteza de avans stabilite pentru îndeplinirea scopului sunt considerate de prioritate mai mică decât rezultanta comenzilor reactive, iar funcția de fuziune va fi de tip prioritar. Pentru a se realiza comenzile impuse de atingerea obiectivului este necesar să nu existe comenzi venite din partea componentei reactive, de ocolire a obstacolelor. Modul de abordare este interesant dar limitat pentru unele aplicații. De exemplu acest tip de robot nu ar putea intra pe o ușă mai îngustă chiar dacă ar avea loc din punct de vedere al gabariturii, pur și simplu pentru că ar considera marginile ușii ca fiind obstacole.

În [Nel00] se descrie un echipament de detecție a minelor antitanc printr-o abordare care folosește fuziunea prin metoda mulțimilor vagi. Sistemul este dotat cu senzor radar de penetrare în adâncime, senzor inductiv electromagnetic și cu o cameră video în infraroșu. Articolul se ocupă numai de fuziunea a trei caracteristici obținute din informațiile video. Prima operație în pregătirea procesului de fuziune este normalizarea histogramei imaginii pentru a obține un contrast optim, după care se creează o imagine binarizată prin aplicarea unui prag de valoare fixă. În urma acestui proces minele se disting în imagine ca zone luminoase eliptice de o mărime comparabil mai mare cu alte obiecte false. În procesul de fuziune se folosesc următoarele caracteristici: aria obținută din imaginea binarizată prin numărarea pixelilor fiecărei zone de alb, un parametru de formă obținut prin raportul numărului de pixeli din rândul cel mai mare pe numărul de pixeli din coloana cea mai mare și raportul de intensitate determinat cu relația :

$$rata\_gri = \frac{mediana(nivel\_zona)}{mediana(nivel\_imagine)} \quad (5.47.)$$

unde  $mediana(nivel\_zona)$  este valoarea mediană a tuturor pixelilor zonei studiate ca posibilă mină, din imaginea originală, iar numitorul relației  $mediana(nivel\_imagine)$  este mediana corespunzătoare întregii imagini. S-a ales mediana deoarece este mai puțin sensibilă la zgomot decât media. Pentru aceste trei caracteristici s-au construit câte trei funcții de apartenență de tip trapezoidal a căror parametri au fost determinați experimental și apoi îmbunătățiți prin încercări efectuate timp de doi ani. Inferențele s-au făcut prin 13 reguli fuzzy dintre care una de disjunctiv și restul de tip conjunctiv, folosindu-se operatorii de tip maxim și respectiv minim. În final s-au determinat cinci funcții de apartenență pentru rezultat care apoi au fost transformate în decizii prin aplicarea unor coeficienți de prag stabiliți de utilizator. Încercările efectuate pe teren au demonstrat o creștere a procentelor de detecție corectă a minelor de la 80 %, la 89 % și în special o scădere cu un ordin de mărime a detecțiilor false. Articolul deși nu aduce noutăți majore în domeniu are calitatea de a face o prezentare amănunțită și documentată pe baza unei îndelungate experimentări, evidențiind timpul îndelungat necesar uneori pentru a obține o fuziune fuzzy bună.

Fuziunea informațiilor utilizată în imagistică este descrisă în [Gul99] prin prezentarea unei metode ce utilizează operatori dependenți de context. Articolul își propune să obțină o delimitare mai corectă a zonelor afectate de tumoare într-o mamografie în comparație cu rezultatele obținute prin segmentare bazată pe discontinuitate cum este de exemplu delimitarea conturului și în comparație cu metodele bazate pe similitudine cum ar fi cea de creștere a regiunilor. Algoritmul propus este de tipul fuziunii la nivel de pixel și presupune atribuirea unui nivel de încredere fiecărui pixel dintr-o imagine segmentată prin delimitare prin contur  $C_c$  și atribuirea unui nivel de încredere  $C_r$  pixelului corespunzător din imaginea segmentată prin creștere de regiune. Operatorul de fuziune ales este o combinație stabilită în mod euristic de autori între fuziune prin conjuncție, disjuncție și mediere în funcție de poziția pixelului față de cele două regiuni : în afara, în interior sau chiar pe contur. În funcție de nivelul de încredere obținut se atribuie pixelul regiunii fuzionate sau nu. Este de remarcat că în aplicația prezentată nivelele de încredere nu au decât două valori : slab și ridicat, ceea ce



nu este în spiritul logicii fuzzy, iar coeficienții folosiți precum și operatorii de fuziune sunt stabiliți euristic, ceea ce reprezintă un handicap al metodei, dar abordarea contextuală este un element pozitiv al studiului. În partea experimentală autorii exemplifică tehnica printr-o imagine mamografică, în care metoda prin fuziune este mai aproape de conturul trasat de un expert decât cele două metode care au fost fuzionate.

Tot din domeniul fuziunii prin metoda fuzzy a imaginilor este și sistemul prezentat în [Rui00], inspirat din studiile de neurologie și cu aplicare în determinarea defectelor din materiale textile. Sistemul folosește două camere video, una optică și una în infraroșu și este compus din mai multe module fiecare având o corespondență în zonele din creier. Imaginea video este descompusă în trei imagini din culori opuse, roșu-verde, galben-albastru și alb-negru, corespunzător zonei LGN, și având drept scop obținerea unei constanțe cromatice. Aceste imagini sunt prelucrate de modulele de procesare a culorilor și texturilor, corespunzător zonei corticale  $V1$ , în care se face o egalizare a histogramelor și de modulul de procesare a formelor, corespunzător zonei corticale  $V2$ , în care se extrage conturul. Cele două imagini rezultate sunt fuzionate în modulul de segmentare vizuală, corespunzător zonei  $V4$ . Modul de prelucrare a imaginii în infraroșu este realizat într-o manieră mai simplă: prin prelucrarea în paralel a imaginii într-un modul pentru obținerea segmentării prin metoda creșterii regiunilor și într-un modul pentru obținerea conturului, care apoi sunt fuzionate. Cele două tipuri de imagini prelucrate sunt în final fuzionate prin integrare de tip fuzzy, corespunzător hipotalamusului.

În partea de prezentare a aplicației autorii recunosc că nu au reușit să realizeze ceea ce și-au propus. Rezultatele experimentale nu au condus la performanțe deosebite, pe măsura complexității sistemului. De altfel copierea modelului este aproximativă, existând corespondență numai la nivel de module nu și în cadrul funcționării interne a acestora (care de altfel nu sunt încă elucidate).

Pentru cazul general de fuziune a informațiilor din două imagini este recomandat articolul [Sin04], în care se expun doi algoritmi de fuziune, unul fuzzy și al doilea neuro-fuzzy. Fuziunile se fac la nivel de pixel, de aceea operația este calibrată la



valorile celor mai mici dimensiuni. În cazul fuziunii fuzzy se pot stabili parametri de formă și valorile de apartenență ale celor două imagini de intrare, precum și regulile de fuziune. Pentru fuziunea neuro-fuzzy, în afară de parametri amintiți în cazul precedent, mai este necesar un set de valori de învățare ( propus de autori la trei coloane din imagine ) și un set de valori de testare (propus de autori la două coloane). Exemplificarea aplicațiilor acestor algoritmi este din domeniu medical (două imagini tomografice) și din domeniu militar (două imagini din satelit). În articol, evaluarea performanțelor fuziunii se face prin metode subiective, analiză a texturii de către un expert, și obiective, prin determinarea dispersiei gaussiene și prin calculul entropiei după relația clasică:

$$H = -\sum_{g=1}^L p(g) \log_2 p(g) \quad (5.48.)$$

unde  $p(g)$  este probabilitatea nivelului de gri  $g$ , iar  $L$  reprezintă numărul pixelilor. Avantajele propuse de lucrare sunt date de un raport bun între complexitatea algoritmilor ( de fapt a simplității lor ) și performanțe, dar lucrarea se rezumă la fuziunea pe pixeli și nu permite o mărire a flexibilității prin creșterea numărului de parametri.

O abordare origine de fuziune a informațiilor prin metode fuzzy este prezentată în [Bar04b], care are ca tematică determinarea condițiilor dintr-o seră de legume. Această lucrare va fi prezentată pe scurt, cu scopul de a sublinia caracterul general al acestei metode, precum și rezultatele bune care se pot obține printr-o metodă ce nu necesită calcule laborioase. În articolul amintit se prezintă o metodă de determinare a masei vegetale dintr-o seră prin fuziunea informației obținute de la o cameră video și de la un dispozitiv de măsurare a bioxidului de carbon. Aceste două tipuri de surse de informație s-au ales deoarece sunt complementare. Astfel, ziua se poate folosi informația video, când din cauza circulației aerului prin căile de acces și prin ventilație, nivelul de încredere a informațiilor date de senzorul de CO<sub>2</sub> scade, iar noaptea, când

camera video nu mai poate fi utilizată și fenomenul de fotosinteză nu mai are loc, se poate stabili volumul masei vegetale prin măsurarea nivelului de bioxid de carbon. Măsurarea masei de vegetație prin mijloace vizuale se face prin obținerea de imagini de la o cameră video în mod activ, deci prin deplasarea camerei prin seră și obținerea de imagini în plan orizontal și vertical. Imaginile obținute sunt preprocesate prin normalizarea histogramei nivelelor de gri, atât pe axa Y cât și pe X. Prin normalizarea după axa Y se obține o îmbunătățire a contrastului constant, iar prin normalizarea pe axa X se obține o ameliorare a luminozității. Determinarea masei de vegetație prin determinarea concentrației de bioxid de carbon se bazează pe ciclul predominant al fotosintezei plantei în comparație cu metabolismul din timpul zilei, când concentrația de CO<sub>2</sub> scade, față de ciclul nocturn, când metabolismul devine predominant față de fotosinteză și concentrația de CO<sub>2</sub> crește.

Așa cum rezultă din figura 5.1. gradientul concentrației de CO<sub>2</sub> este proporțional cu fluxul de CO<sub>2</sub>. Informațiile de la cele două tipuri de senzori se introduc într-un sistem de inferență, obținându-se o estimare bună a masei vegetale, utilizând următoarea relație:

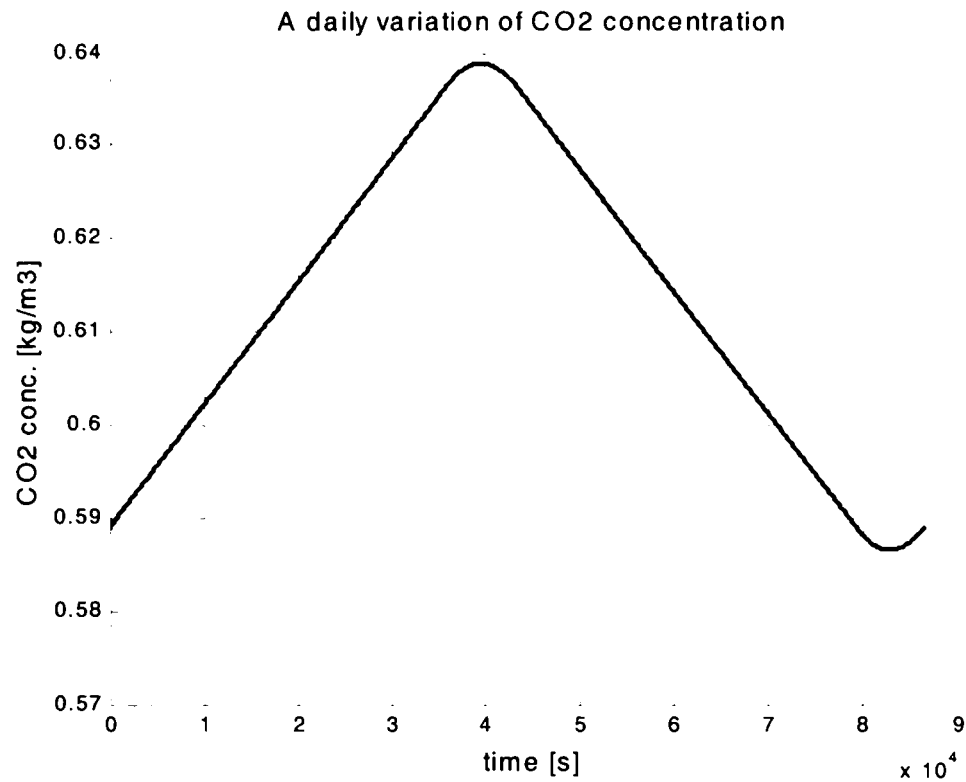
$$v = \frac{\mu_{CCD} \cdot v_{CCD} + \mu_{CO_2} \cdot v_{CO_2}}{\mu_{CCD} + \mu_{CO_2}} \quad (5.49.)$$

unde

$v_{CCD}$ ,  $v_{CO_2}$ ,  $v$  sunt masele de vegetație estimate de sistemul video, de senzorul de bioxid de carbon, respectiv estimarea globală, iar  $\mu_{CCD}$ ,  $\mu_{CO_2}$  reprezintă coeficienții de încredere în fiecare estimare determinați prin reguli fuzzy de tipul:

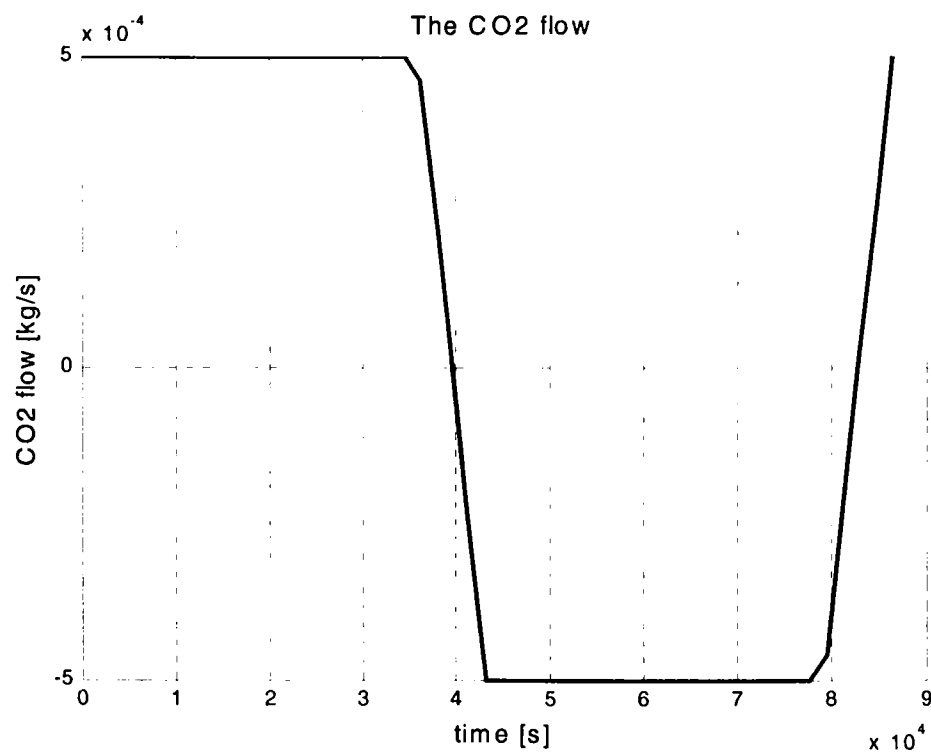
- dacă este întuneric atunci  $\mu_{CCD} = 0$
- dacă fluxul de aer nu este zero atunci  $\mu_{CO_2} = 0$

Pentru experimentări s-a folosit o cameră de vederi de tipul [M17] cu 420 de linii pe cadru conectat la o placă de achiziție de tipul [M18], care permite captarea a 25 de frame-uri pe secundă la o rezoluție de 800x600 de pixeli, conectată la un calculator cu procesor AMD la 800 MHz.



**Figura 5.1.** Variația fluxului de CO<sub>2</sub> în cursul unei zile

a) în figura 5.1. se prezintă variația pe parcursul unei zile a fluxului de CO<sub>2</sub>



**Figura 5.2.** Variația concentrației de CO<sub>2</sub> pe parcursul unei zile

b) în figura 5.2. se prezintă variația, în timpul unei zile, a concentrației de CO<sub>2</sub>

Experimentările efectuate au dat rezultate satisfăcătoare, dar nu ne putem pronunța numai după efectuarea de măsurători pe cel puțin un ciclu de vegetație. Pentru experimentările ulterioare luăm în considerare și o variantă în care este folosită o cameră în infraroșu care să pună în evidență nivelul metabolismului masei vegetale.

În modul de abordare a fuziunii prin metoda mulțimilor vagi, așa cum am menționat, problema cea mai dificilă este cea a rafinării modelului, dar metoda în sine este eficientă și bine structurată. Deoarece în cadrul sistemului de supraveghere se obțin date de tip vag, aplicarea acestei metode în cadrul tezei este naturală. Metoda mai are avantajul, așa cum se va prezenta în capitolele următoare, de a ține cont de caracterul variabil al condițiilor externe. Totuși trebuie remarcată o deficiență a metodei și anume că acordă elementelor ce intră în procesul de fuziune ponderi de valoare constantă.

În numeroase articole se utilizează în loc de varianta clasică, provenită din domeniul reglării, metoda neuro-fuzzy, în care regulile de inferență sunt ascunse într-o rețea neuronală, ceea ce permite obținerea lor prin învățare. Dar și în această metodă rămâne deschisă problema fuzzyficării, care trebuie rezolvată la început prin metode empirice. Deoarece, în Capitolul IX am folosit metoda fuzzy, iar apropierea metodologică este evidentă, nu am optat pentru folosirea metodei neuro-fuzzy, în virtutea principiului de a avea o divergență cât mai mare între bazele teoretice ale metodelor de fuzionare.

## **5.6. Fuziunea prin metode ce folosesc teoria posibilității**

### **5.6.1. Elemente din teoria posibilității folosite în fuziune**

Fuziunea informațiilor se poate realiza și prin metode posibilistice. Teoria posibilităților a fost introdusă de Zadeh în 1978 [Zad78] ca o extensie a teoriei

mulțimilor vagi și stabilește o funcție de posibilitate definită pe o mulțime fuzzy, care este numeric egală cu funcția de apartenență definită pe aceeași mulțime.,  $\pi(x) = \mu(x)$ .

Funcțiile de posibilități se utilizează în cazurile în care nu există condițiile de aplicare a teoriei probabilităților. De exemplu, nu există suficient de multe evenimente astfel încât să se poată aproxima axioma numerelor mari, sau nu se poate determina distribuția densității de probabilitate și nu există premise să se facă o estimare a acesteia.

Noțiunea de posibilitate este diferită ca și conținut de noțiunea de apartenență chiar dacă numeric sunt egale. Astfel, funcția de apartenență definește gradul în care un atribut bine definit aparține unei mulțimi fuzzy, pe când funcția de posibilitate definește gradul în care unele elemente satisfac anumite constrângeri slab definite.

Măsura de posibilitate pe un interval este dată de relația :

$$\Pi(X) = \max \pi(x) \text{ unde } x \in X \quad (5.50.)$$

În dualitate cu posibilitatea se definește noțiunea de necesitate, după relația :

$$N(A) = 1 - \Pi(\neg A) \quad (5.51.)$$

Dacă gradul de posibilitate reprezintă o încredere optimistă asupra evenimentelor, gradul de necesitate reprezintă nivelul certitudinii asupra evenimentelor.

Fiind date două mulțimi A , B și două măsuri de posibilitate avem următoarele relații :

$$\Pi_A(X \cup Y) = \max (\Pi_A(X), \Pi_A(Y)) \quad (5.52.)$$

$$\Pi_{A \cup B}(X) = \max (\Pi_A(X), \Pi_B(X))$$

Iar prin dualitate :

$$N_A(X \cap Y) = \min (N_A(X), N_A(Y)) \quad (5.53.)$$

$$N_{A \cap B}(X) = \min (N_A(X), N_B(X))$$

De remarcat că relațiile similare pentru operația de intersecție, în cazul posibilității și operația de reuniune, în cazul necesității nu sunt valabile.

O observație importantă este cea referitoare la relația dintre valorile măsurii de posibilitate și cea de necesitate. Astfel, dacă valoarea necesității este mai mică decât unu, rezultă o valoare a necesității obligatoriu egală cu zero, iar dacă valoarea necesității este mai mare decât zero rezultă o valoare a posibilității egală cu unu.

$$\Pi(A) < 1 \Rightarrow N(A) = 0 \quad (5.54.)$$

$$N(A) > 0 \Rightarrow \Pi(A) = 1$$

Din aceste relații rezultă că suma dintre posibilitatea unei submulțimi și posibilitatea negatei sale este mai mare sau egală cu unu, iar suma dintre necesitatea unei submulțimi și necesitatea negatei sale este mai mică sau egală cu unu

$$N(A) + N(\neg A) \leq 1 \quad (5.55.)$$

$$\Pi(A) + \Pi(\neg A) \geq 1$$

Ultimele relații demonstrează că gradul de posibilitate este o limită superioară a oricărei funcții de probabilitate, iar gradul de necesitate este o limită inferioară a oricărei funcții de probabilitate care se referă la evenimentele avute în vedere.

### 5.6.2. Fuziunea informațiilor folosind teoria posibilităților

În mod asemănător cu celelalte metode prezentate cele mai simple exemple de fuziune sunt cele derivate din metodele empirice, aplicate funcțiilor de posibilitate. Astfel în modul cel mai simplu se pot aplica operațiile de t-normă, s-normă și mediere (cu sau fără ponderare) a două sau mai multe fluxuri de date provenite din diferite surse de informații. În aceste cazuri se va aplica una din următoarele relații:

$$\text{Pentru } \forall u \in U \text{ avem: } \pi_F(u) = t\text{-normă}(\pi_1, \dots, \pi_n)(u) \quad (5.56.)$$

$$\text{sau } \pi_F(u) = s\text{-normă}(\pi_1, \dots, \pi_n)(u)$$

$$\text{sau } \pi_F(u) = \frac{1}{n} \Sigma(\pi_1, \dots, \pi_n)(u)$$

Modul de selecție a unuia dintre operatori se face după cum se dorește să se realizeze o îngredire a spațiului posibilităților, prin t-normă, o lărgire a spațiului, prin s-normă sau o determinare a proporției în care sursele de informare, consideră posibile unele valori, caz în care se va alege operația de mediere. Dacă se folosește operația de medie geometrică, în locul celei aritmetice, se accentuează natura conjunctivă a rezultatului.

O lucrare de referință în acest domeniu este [Dub94] în care se propune o abordare a fuziunii informației numai din prisma funcțiilor de distribuție a posibilității. Autorii nu iau în considerare și fuziunea valorilor, operație pe care o consideră agregare. Ei studiază formele care se obțin prin combinarea a două sau mai multe funcții de distribuție din domeniul posibilităților. Astfel o distribuție ce are pe întreg intervalul studiat valoarea 1 corespunde situației de ignoranță totală ( orice valoare este la fel de posibilă ). De aceea, pe măsură ce avem informații, trebuie restrâns nivelul de posibilitate la valori cât mai mici, în mod ideal având un singur punct cu posibilitatea 1, restul intervalului având posibilitatea 0.

De asemenea se face distincție între senzori a căror informații coincid fie și parțial și care sunt considerați senzori în care se poate avea încredere și senzori a căror informație este divergentă și deci cel puțin unul dintre ei furnizează informații false. În primul caz se propune utilizarea operatorilor t-normă pentru a reduce incertitudinea, iar în al doilea caz se propune utilizarea operatorilor s-normă pentru a acoperi” ambele posibilități. În continuare se va folosi ( așa cum apare și în lucrarea amintită ) cazul particular în care t-norma va fi funcția minim, iar s-norma va fi funcția maxim.

O primă analiză se face pentru situația în care avem de determinat distribuția de posibilitate a fuziunii dintre doi senzori care pot fi considerați ambii fiabili. Pentru a

întări încrederea în zona de distribuție care este comună senzorilor, se propune, normalizarea intersecției graficelor de distribuție cu un coeficient al gradului de concordanță. Acest coeficient este propus a fi înălțimea suprafeței de acoperire dintre cele două distribuții

$$h(\pi_1, \pi_2) = \sup_{u \in U} (\min(\pi_1(u), \pi_2(u))) \quad (5.57.)$$

unde  $U$  este universul în discuție.

Rezultă că distribuția de posibilitate normalizată a fuziunii senzorilor este:

$$\forall u \in U, \pi_f(u) = \min(\pi_1, \pi_2)(u) / h(\pi_1, \pi_2) \quad (5.58.)$$

Dacă se consideră situația în care unul dintre cei doi senzori nu este considerat fiabil, se aplică, o fuziune cu prioritate, în care, în caz de neconcordanță a informațiilor cel de al doilea sensor este dezafectat.:

$$\pi_f = \min(\pi_1, \max(\pi_2, 1 - h(\pi_1, \pi_2))) \quad (5.59.)$$

Prin asimetria sa, această relație denotă tratarea diferită a celor două surse de informație. O abordare care se întâlnește mai des în practică este cea în care nici unul din senzori nu are credibilitate maximă. În acest caz este indicat ca în situație de dezacord să considerăm că ambii senzori nu sunt fiabili, iar rezultatul să fie proporțional cu nivelul conflictului. Relația numită de autori „fuziune adaptivă” este:

$$\pi_f = \max(\min((\pi_1, \pi_2) / h(\pi_1, \pi_2)), 1 - h(\pi_1, \pi_2)) \quad (5.60.)$$

Pentru cazurile când avem mai multe surse de informații, cele prezentate mai sus se pot adapta prin combinarea serie sau paralel a senzorilor. În prelucrarea de tip serie, se calculează informația fuzionată treptat prin aplicarea formulelor anterioare unor



rezultate parțiale și câte unui senzor pe rând. În cazul paralel se generalizează operatorii pentru mai mulți operanzi. De exemplu relația ( 5.60.) devine :

$$\pi_F = \max(\min((\pi_1, \dots, \pi_n)/h(\pi_1, \dots, \pi_n), 1-h(\pi_1, \dots, \pi_n))) \quad (5.61.)$$

Problema care se ridică și în acest caz este legată de robustețea rezultatelor în cazul operanzilor echivalenți ai intersecției și reuniunii. Această situație apare datorită dominanței pe care o poate impune rezultatului orice operand marginal. De exemplu, pentru funcția maxim, dacă oricare din senzori este defect și are distribuția de posibilitate 1, va anula orice informație provenită de la restul senzorilor. Rezultă că cu cât numărul surselor de informație este mai mare, indiferent că combinarea este serie sau paralelă, robustețea procesului devine tot mai mică.

Această deficiență se poate ameliora prin clasificarea surselor de informație după nivelul de încredere și fuziunea, în primă fază, a informațiilor din cadrul aceleiași clase. În etapa a doua se folosește fuziunea cu priorități ( a se vedea relația 5.59. ), în care grupul de fuziune care are un nivel mai ridicat de încredere este considerat grupa principală. De exemplu, dacă  $K1$  reprezintă clasa care are un nivel al încrederii mai mare decât clasa  $K2$  atunci avem relația:

$$\pi_F^{K1, K2} = \min(\pi_F^{K1}, \max(\pi_F^{K2}, 1-h(\pi_F^{K1}, \pi_F^{K2}))) \quad (5.62.)$$

unde coeficientul gradului de concordanță  $h$  se calculează cu relația (5.57.).

O altă modalitate de fuziune care implică mai multe surse de informații este cea denumită de autori „fuziunea cuantificată”. Această metodă stabilește două grupări extreme de senzori. Una, care cuprinde senzorii ce dau informații convergente, deci distribuțiile de posibilitate ale tuturor au o intersecție diferită de zero, numită estimare pesimistă și pentru care  $h(\pi_1, \dots, \pi_n) = 1$ . Numarul maxim de senzori care îndeplinesc această condiție se va nota cu  $J^-$ . Cealaltă clasă va cuprinde senzorii care au măcar cu un alt senzor o intersecție a distribuției de posibilitate diferită de zero, deci care au

$h(\pi_1, \dots, \pi_n) > 0$  și care este numită estimarea optimistă. Numărul maxim de senzori care îndeplinesc această condiție se va nota cu  $J^+$ . Prin fuziune pentru aceste clase se obțin două distribuții notate  $\pi^-$  respectiv  $\pi^+$ . Distribuția de posibilitate adaptivă pentru ele este:

$$\pi_F = \max(\pi^+ \wedge h(J^+), \min(\pi^-, 1 - h(J^+))) \quad (5.63.)$$

unde  $h(J^+)$  reprezintă valoarea maximă a coeficientului  $h$  pentru estimarea optimistă.

### 5.6.3. Aplicații ale fuziunii folosind teoria posibilităților

Un exemplu tipic de fuziune prin folosirea nivelelor de posibilitate este abordat în [Rou95]. Această lucrare prezintă fuziunea dintre informații numerice provenite din imaginile transmise în patru benzi spectrale de către un satelit și informații simbolice sub forma unor reguli, provenite de la un expert și se referă la determinarea tipului de vegetație existentă în sudul Indiei. Analiza, ca de altfel și fuziunea se face la nivel de pixel prin clasificarea acestora în una din categoriile luate în considerare. Pentru a realiza obiectivul, prima etapă este determinarea probabilităților fiecărei categorii de vegetație în fiecare din cele 4 benzi spectrale, prin construirea unei histograme pe baza nivelelor de gri ale imaginilor. Trecerea de la distribuția probabilităților la cea a posibilităților se face pe baza metodei tăieturilor- $\alpha$  propuse de Dudois și Prade, astfel distribuția posibilității  $\pi(x_i)$  în punctul  $x_i$  este:

$$\pi(x_i) = \sum_{k=1}^N \min(p(x_i), p(x_k)) \quad (5.64.)$$

unde  $N$  este numărul de nivele de gri, iar  $p(x_i)$  este probabilitatea determinată din histogramă în punctul  $x_i$ .

Determinarea nivelului de posibilitate pentru informația provenită de la expert se face după metode fuzzy, stabilind reguli lingvistice de tipul „ *vegetația din clasa A se găsește în principal pe versanții sudici, cel mai adesea între înălțimile X și Z*”, care folosesc variabile lingvistice și modificatori lingvistici. Pe baza calculării nivelului de apartenență a concluziilor se stabilește nivelul posibilității prin relația de echivalență numerică a lui Zadeh (a se vedea relația 5.49.). Pentru a determina nivelele de posibilitate pentru fiecare dintre pixeli s-au antrenat un set de rețele neuro-fuzzy, câte o rețea pentru fiecare clasă. Fuziunea se face în conformitate cu formula normaliză pentru informații fiabile (a se vedea relația 5.58.), prin operatorul t-normă de conjuncție, normalizat cu maximul nivelului de suprapunere. În mod concret pentru situația analizată formula devine:

$$\pi(C_i, x) = \frac{\min_s(\pi_s(C_i, x))}{\max_k(\min_k(\pi_s(C_k, x)))} \quad (5.65.)$$

unde  $C_i$  reprezintă una din cele  $k$  clase, iar  $s$  este numărul de surse de informație fuzionate. În final clasificarea pixelilor se face prin atribuirea la clasa pentru care are valoarea posibilității maxime. Rezultatele experimentale au confirmat avantajele utilizării fuziunii, dar trebuie să menționez complexitatea procesului și volumul experimentărilor necesare pentru realizarea modelului fuzzy. De asemenea trebuie să subliniez că în această aplicație folosirea fuziunii la nivel de pixel este justificată, dar în general informația ar trebui să fie fuzionată la nivele de sinteză mai înalte.

Tot din domeniul fuziunii imaginilor dar utilizate pentru aplicații medicale și cu o altă abordare se prezintă în [Abd98], în care este studiată o metodă de îmbunătățire a imaginilor obținute prin tomografie, ce pot cuprinde trei tipuri de țesuturi. Studiul prezintă în mod amănunțit modul de determinare a valorilor pentru obținerea distribuțiilor de posibilitate. Autorii utilizează trei distribuții, una a valorilor de gri, o alta a claselor posibile și una de corecție a contrastului intern. În primă fază se

determină apartenența fiecărui pixel la una din clase, pe baza posibilității fuzionate prin conjuncție, între primele două posibilități, astfel: pentru valorile de gri distribuțiile se calculează pe baza offset-ului determinat experimental și a dispersiei datorată zgomotului, care este obținut prin estimare anterior, rezultând o funcție sub forma de clopot. Funcțiile de posibilitate ale claselor sunt determinate prin calcul, cunoscând caracteristicile de impedanță electrică a fiecărui tip de țesut. Operatorul de conjuncție t-normă utilizat este de tip produs și nu de tip minim pentru a fi mai restrictiv.

$$\pi_f(x) = (\pi_p(x) \wedge \pi_c(x)) \quad (5.66.)$$

În a doua etapă se face corecția nivelelor de gri pentru ca toate valorile care sunt cuprinse într-o clasă să aibă în final aceeași valoare a posibilității. Forma funcției de compensare este a unui trapez, iar parametrii depind de clasa cu care este corelată. Operațiile se fac pentru fiecare pixel și clasă, iar clasificarea se face prin etichetarea pixelului la clasa la care a obținut posibilitatea maximă.

Este de apreciat numărul mare de detalii tehnice pe care le furnizează articolul precum și amănunțimea datelor referitoare la rezultatele experimentale, dar pe de altă parte subiectul este tratat specific, pentru un anumit tip de analiză imagistică.

În mai multe articole [Bis97a], [Bis97b], un colectiv de lucru din Padova a prezentat o abordare din punct de vedere al logicii predicatelor a teoriei posibilităților. Trebuie menționat că această variantă a teoriei este totuși limitativă, în sensul existenței unor restricții axiomatiche. Adaptarea majoră constă în atribuirea fiecărei propoziții a unei funcții de distribuție a posibilităților de valoare arbitrară. De asemenea pentru operații cu posibilități se folosesc doi operatori de conjuncție : un operator & pentru a defini intersecția și unul  $\otimes$  pentru a defini t-norma care în aplicațiile prezentate a fost aleasă conjuncția Lukasiewicz  $\alpha \otimes \beta = \max(\alpha + \beta - 1, 0)$  deoarece este mai restrictivă. Aplicația prezentată constă în navigarea a doi roboți într-o clădire a cărei topologie este parțial cunoscută. Primul robot „master” este dotat cu o centură de 12 senzori sonici

pentru aprecierea distanței față de un obstacol și față de pereți și o cameră video folosită pentru detectarea poziției relative față de robotul „slave” și are rol de explorare. Cel de al doilea robot are atașată o sursă de lumină a cărei intensitate este sesizată de robotul „master”, și are doar rol de baliză. Cei doi roboți se deplasează secvențial unul după celălalt. Metoda de fuziune utilizată se bazează pe calculul global al necesității. Pentru determinarea nivelului de posibilitate al fiecărei informații provenite de la senzori se face presupunerea că valoarea dispersiei  $\sigma$  este proporțională cu măsura posibilității  $\pi$ , deci mărimea necesității negatei va avea relația:

$$N_{\pi}(p) = \Pi_{\pi}(\neg p) = 1 - \sigma(p) \quad (5.67.)$$

Experimentul a constatat din deplasarea roboților pe o traiectorie prestabilită printr-un spațiu format din mai multe încăperi, unde se aflau diverse obiecte ce trebuiau ocolite. Modul de inferență a necesității de a fi ajuns într-un punct  $p_i$  din colțul încăperii  $r_j$  în momentul  $t$  este următorul:

$$(locul\_tip(pt_a, t) \& in\_camera(r_j, t)) \rightarrow la\_locul(p_i, t) \quad (5.68.)$$

unde

$$\begin{aligned} & (\exists t_1 \leq t)((sens\_camera(r_j, t_1) \oplus int\_ra\_camera(r_j, t_1) \& \neg((\exists t_2)(\exists r)((t_1 \leq t_2 \leq t) \\ & \& (r \neq r_j) \& (sens\_camera(r, t_2) \oplus (int\_ra\_camera(r, t_2))))) \rightarrow in\_camera(r_j, t) \\ & (la\_locul(p_k, t) \& merge(directie) \rightarrow int\_ra\_camera(r_i, t) \\ & semnal\_sonar(perete_l, directie, t) \& distanța(perete_l, perete_m) > \\ & latime \rightarrow int\_ra\_camera(r_j, t) \end{aligned}$$

reprezintă inferențele de existență a roboților în camera  $r_j$ , fără să părăsească camera după intrare, deplasarea fiind efectuată de-a lungul pereților, iar

$$semnal\_sonar(colt\_numar, t) \oplus semnal\_video(s_a, t) \rightarrow locul\_tip(pt_a, t) \quad (5.69.)$$

reprezintă inferența prin care se stabilește poziția în cadrul camerei, care poate fi furnizată de sonar sau de baliză. Nivelul informației fuzionate  $A$  între evenimentul  $M$  de dispersie  $\gamma$  și evenimentul  $L$  de dispersie  $\delta$  este dată de relația :

$$\text{dacă } (M \oplus L) \rightarrow A \text{ atunci } (\gamma \oplus M) \otimes (\delta \oplus L) \rightarrow (\gamma \otimes \delta) \oplus A \quad (5.70.)$$

unde  $\otimes$  este t-norma, deci nivelul de necesitate crește în urma fuziunii.

Trebuie menționat că există astăzi în unele limbaje Prolog module de inferență pentru posibilități și fuzzy, de maniera formalizărilor introduse în acest articol dar utilizarea inferențelor este restrictivă și greoaie fiind forțată peste metodele din calculul predicatelor.

Ca și o concluzie a utilizării teoriei posibilității în fuziune aș menționa avantajul pe care-l oferă aducerea tuturor mărimilor în același spațiu comun al măsurii de posibilitate. Pe de altă parte faptul că variația posibilității implică necesitate de valoare zero, iar variația necesității implică posibilitate de valoare unu, conduce la o metodologie mai restrictivă, care impune ori o constrângere superioară prin limitarea posibilității sau o constrângere inferioară în cazul necesității. Din punct de vedere al aplicării metodei în prezenta teză, în afară de dezavantajele menționate, o altă cauză pentru care nu am folosit această abordare este apropierea bazei teoretice de cea a mulțimilor fuzzy. Dar trebuie să menționez, că metoda de stabilire a nivelului de incertitudine din capitolul VII este înrudit cu metoda posibilităților prin faptul că stabilește o zonă alocată domeniului de incertitudine, similar celui din teoria posibilităților.

## 5.7. Fuziunea prin metode ce folosesc teoria Dempster-Shafer

### 5.7.1. Elemente din teoria Dempster-Shafer folosite în fuziune

Plecând de la o critică a tratării prin probabilități subiective a unor probleme care limitează estimarea părților unui eveniment, Dempster (în 1968 ) și Shafer (în 1976) au elaborat o teorie ce introduce noțiunea de măsură a credibilității și a plauzibilității. Teoria, ce are aplicabilitate și în domeniul fuziunii informațiilor, introduce funcția de distribuție a masei, definită pe mulțimea părților unei mulțimi de definiție X,[Spi03]. Axiomele pe care trebuie să le îndeplinească definirea maselor sunt:

$$m(\emptyset) = 0 \quad \text{și} \quad \sum_{A \subseteq X} m(A) = 1 \quad (5.71.)$$

Se observă faptul că definirea maselor se face aproape la fel cu cea a probabilităților, dar în acest caz suma cuprinde și mulțimi de evenimente nu numai elemente atomice ca în cazul probabilităților, deci valoarea masei unei mulțimi nu va fi condiționată de valoarea maselor componentelor din mulțime. Astfel se poate ca masa mulțimii de definiție X să fie zero pe când masele diferitelor submulțimi să fie diferite de zero. Conform terminologiei introdusă în teorie, elementele care au masa diferite de zero se numesc focale.

Credibilitatea unei submulțimi A se definește ca fiind suma maselor părților componente :

$$\text{Bel}(A) = \sum_{B \subseteq A} m(B) \quad (5.72.)$$

și definește un grad de încredere maximal în submulțimea A. Se observă că credibilitatea include numai submulțimile complet incluse în A. Plauzibilitatea se definește ca sumă a maselor care au măcar o intersecție nevidă cu submulțimea A:

$$Pl(A) = \sum_{B \cap A \neq \emptyset} m(B) \quad (5.73.)$$

Plauzibilitatea definește un grad de încredere minimal în submulțimea A. Pentru ambele situații se definesc funcțiile de credibilitate respectiv plauzibilitate, de pe mulțimea părților mulțimii A, pe intervalul [0,1].

De obicei valoarea plauzibilității este mai mare decât cea a credibilității, diferența dintre ele reflectând nivelul de incertitudine al distribuției. De altfel, ca și în cazul necesității și posibilității, avem următoarele proprietăți:

$$Bel(A) + Bel(\neg A) \leq 1 \quad (5.74.)$$

$$Pl(A) + Pl(\neg A) \geq 1$$

O relație foarte importantă din cadrul acestei teorii este formula lui Dempster care permite să se combine două distribuții, obținându-se credibilitatea comună. Astfel dacă considerăm distribuțiile :

$$\sum_{B \subseteq X} m_1(B) = 1 \text{ și } \sum_{C \subseteq X} m_2(C) = 1$$

atunci

$$m(A) = \frac{1}{1-K} \sum_{B \cap C = A} m_1(B) \bullet m_2(C) \quad (5.75.)$$

unde

$$K = \sum_{B \cap C = \emptyset} m_1(B) \bullet m_2(C)$$

Dacă fiecare distribuție se consideră a fi opinia unui expert, sau datele furnizate de o sursă de informații, atunci această relație permite realizarea fuziunii dintre ele. De remarcat că coeficientul K reprezintă cazurile în care nu există suprapuneri între unele submulțimi, deci se poate interpreta ca o măsură a dezacordului dintre cele două opinii.



În situațiile în care acest dezacord este mare pot apărea rezultate deformate, în care are câștig de cauză o ipoteză mai puțin credibilă așa cum este prezentat într-un exemplu a lui Zadeh din 1984.

### 5.7.2. Fuziunea informațiilor folosind teoria Dempster-Shafer

Relația de bază care permite fuziunea informațiilor este formula de combinare a lui Dempster prezentată anterior ( a se vedea relația 5.76.), care permite combinarea maselor determinate prin mai multe ipoteze. Plecând de la această relație au fost propuse diferite extensii. Una dintre acestea este utilizarea teoriei maselor pentru fuziunea nesupravegheată, propusă în [Pie04]. Plecând de la formula lui Dempster se determină distribuția fiecărei mase cu relația:

$$\pi_i^y = \sum_{\omega \in \Omega_m} \pi_i m(A) = \pi_i \sum_{\omega \in \Omega_m} f_{\Omega}(y) \quad (5.76.)$$

unde  $\pi_i$  este distribuția apriorică a evenimentului,  $y$  reprezintă observația evenimentului  $x$ ,  $\Omega$  este mulțimea claselor în care poate fi repartizat evenimentul, iar  $f$  reprezintă funcția de distribuție condiționată a clasificării de observația  $y$ . Fuziunea se face prin estimarea distribuțiilor apriorice și a funcțiilor de distribuție condiționată, printr-un algoritm iterativ de îmbunătățire a valorii distribuției  $\pi^j$ , iar apoi a funcției  $\hat{f}_A^j$ . În fiecare iterație se calculează masa evenimentului  $x^j$  folosind relația:

$$m(x^j) = \pi^j \prod_{a \in A} \hat{f}_a^j(y) \quad (5.77.)$$

Un exemplu de utilizare a metodei este cel de determinare din satelit a suprafețelor cultivate. Dacă se presupune că trebuie determinate trei clase:  $\omega_1$

reprezintă suprafață cu pajiște,  $\omega_2$  reprezintă culturi de orez, iar  $\omega_3$  reprezintă suprafețe acoperite cu apă și sunt la dispoziție două tipuri de senzori, unul optic și unul radar. Există posibilitatea de a obtura vizibilitatea satelitului datorită norilor, iar radarul nu deosebește orezările de suprafețele deschise de apă, rezultă că vor fi 6 funcții de distribuție de tipul  $f(y_1, y_2)$  și anume  $F1=f((\omega_1, \omega_2), (\omega_1))$ ,  $F2=f((\omega_1, \omega_2), (\omega_2, \omega_3))$ ,  $F3=f((\omega_3), (\omega_2, \omega_3))$ ,  $F4=f((\omega_1, \omega_2, \omega_3), (\omega_1))$ ,  $F5=f((\omega_1), (\omega_3))$ ,  $F6=f((\omega_1, \omega_2, \omega_3), (\omega_2, \omega_3))$  care vor trebui să fie determinate în mod iterativ.

O abordare a fuziunii de tip Dempster-Shafer prin prisma logicii formale este descrisă în [Cho00], în care se prezintă un model logic echivalent al metodei de fuziune a maselor, dar valabil numai pentru numere raționale. Astfel masa unui eveniment este determinată ca raport dintre numărul de observații care confirmă evenimentul și numărul total de observații efectuate de o sursă de informații  $S = \langle O, BDC \rangle$ , unde prin BDC se notează o bază de date care relaționează fiecare observație cu o propoziție din domeniul de definiție. Această abordare verifică formula de combinare a asignării maselor:

$$m(A) = \frac{\sum_{A_i \cap B_j = A} m_1(A_i) \cdot m_2(B_j)}{\sum_{A \neq \emptyset} \sum_{A_i \cap B_j = A} m_1(A_i) \cdot m_2(B_j)} \quad (5.78.)$$

noua sursă de informații devenind  $S' = \langle O_1 \oplus O_2, BDC_1 \oplus BDC_2 \rangle$

unde  $\oplus$  este operația de intersecție dintre mulțimi. De asemenea modelul logic verifică metoda de asignare a maselor a lui Appriou pentru informațiile provenite de la senzori. Asignare se bazează pe „Criteriul măsurii specifice” care stabilește ca masa să fie atribuită evenimentului cel mai puțin specific. Din aceste considerente pentru o frecvență de apariție  $P(i | K_j)$  a unei observație de valoare  $i$  a unui eveniment  $K$ , de către un senzor  $j$ , se stabilesc următoarele relații:

$$\begin{aligned}
 m_{i,j}(\bar{K}_j) &= 1 - P(i | K_j) \\
 m_{i,j}(K_1 \vee \dots \vee K_n) &= P(i | K_j)
 \end{aligned}
 \tag{5.79.}$$

unde  $n$  reprezintă numărul de evenimente observate. Pentru a determina masa unui sensor se aplică relația de compunere (5.79.) Transpus în formalismul logic masa unui sensor devine:


$$S_j = S_{j,1} \oplus \dots \oplus S_{j,n} \tag{5.80.}$$

Folosind aceste relații precum și formula de compunere a credibilității se poate calcula orice fuziune a datelor provenite de la surse de informații.

Metoda are totuși câteva neajunsuri majore, precum faptul că pentru fiecare observație stabilește o regulă din baza de date, iar masa evenimentului o calculează prin raport între numere de observații, cea ce determină ca în cazul unor volume mari de observații, sau în caz de operație de tip produs cartezian, numărul relațiilor să devină prohibitiv, fără ca măcar semnificația regulii să aibă vreo importanță, ea fiind utilizată numai la numărare.

### 5.7.3. Aplicații ale fuziunii folosind teoria Dempster-Shafer

Metoda Dempster-Shafer este relativ greu de utilizat în aplicații autonome din cauza necesității de a evalua masele diferitelor evenimente. O aplicație în care se încearcă să se depășească această problemă este prezentată în [Ari03], care își propune să realizeze un sistem de identificare a persoanelor pe baza semnăturii. Pentru a obține masele fiecărui eveniment, se propune extragerea unor trăsături din fiecare semnătură ( în articol nu se dau detalii referitoare la tipul și modul de obținere a trăsăturilor ) și realizarea unei clasificări pe baza votului de tip Borda. Astfel pentru fiecare semnătură analizată se calculează o distanță între trăsăturile ei și cele din baza de date (în care se



consideră câte o clasă semnăturile aceleiași persoane), după care se stabilește o ierarhie a distanțelor. Semnătura din baza de date care are distanța cea mai mică primește ponderea cea mai mare  $W(R_i)$ , prin atașarea sumei distanțelor care au o ierarhizare mai mică. În mod asemănător se determină ponderile tuturor semnăturilor preînregistrate. Stabilirea mulțimilor de evenimente  $E_i$ , pentru care se calculează masele se face prin considerarea în mulțimea  $i$  a tuturor claselor mai importante în ierarhie decât clasa  $i$ , iar pentru determinarea maselor se folosește relația:

$$m(E_i) = \frac{W(R_i)}{\sum_{j=1}^N W(R_j)} \quad (5.81.)$$

unde  $N$  este numărul de semnături din baza de date. După stabilirea maselor se calculează credibilitatea fiecărei clase prin relația de combinare a lui Dempster. Din analiza rezultatelor practice în care s-a comparat această metodă cu cea a posibilităților și cea prin vot de tip Borda a rezultat un procent mai bun de identificare pentru metoda descrisă anterior. Articolul prezintă destul de sumar atât baza teoretică a metodei, fără să rezulte dacă există o justificare teoretică a procedurii prezentate sau ea s-a stabilit în mod empiric, cât și experiențele pe care se bazează rezultatele, unde nu se prezintă condițiile și parametri utilizați; totuși metoda este o alternativă la procedura Appriou prezentată în secțiunea anterioară.

Un studiu interesant care folosește fuziunea prin metoda Dempster-Shafer este [Hun04], în care se prezintă o metodă de sinteză a informațiilor din texte științifice scrise în XML. Autorii propun un mod imbricat de prezentare a informațiilor care au un caracter de incertitudine, și utilizarea unor cuvinte cheie specifice, care permit codificarea datelor după metoda maselor. Astfel se propune un formalism echivalent descrierii prin arbori, care au ca noduri neterminale cuvinte cheie, iar ca noduri terminale-date. De exemplu, descrierea unei mase se face prin : `<maseitem>` „nume-variabilă”

</maseitem>, iar valoarea masei se specifică prin: <mase-value = „număr”>, iar pentru a se declara că se folosește o informație de tip incertitudine se folosesc cuvintele cheie <belfunction> și </belfunction>. Se mai definesc un număr de predicate necesare operațiilor cu mase, credibilități și plauzabilități. Astfel, la utilizarea predicatului *Dempster* ( $\tau_1, \tau_2, X$ ), unde  $\tau_i$  este o declarație de tip <belfunction> de valoare  $k_i$ , se face compunerea celor două credibilități, după relația lui Dempster :

$$k = \frac{\sum k_1 \times k_2}{1 - k_T} \quad \text{unde} \quad k_T = \sum k_n^1 \times k_m^2 \quad (5.82.)$$

iar rezultatul se regăsește în variabila  $X$ . La utilizarea predicatului *Propagate*( $\tau_i, X$ ) se poate echivala un nivel de credibilitate dintr-un text în altul, realizându-se o rafinare sau o agregare de mase ( de exemplu se poate rafina masa variabilei „lichid” în masele variabilelor „apă” și „petrol”), prin operația :

$$m_{\Omega_2}(B) = \sum_A m_{\Omega_1}(A) \quad (5.83.)$$

unde  $B$  este mulțimea echivalentă clasei de mulțimi  $A$ ,

Prin predicatul *Projection*( $\tau_i, V_p, X$ ) se poate realiza o proiecție sau o extensie în sens Dempster dintr-o mulțime de variabile  $V_q$  în altă mulțime  $V_p$  ( de exemplu proiecția de la mulțimi de trei variabile la mulțimi de două variabile) prin operația :

$$m_{V_p}(H) = \sum_{H \subseteq \Omega_{V_p}} (m(G) | G \subseteq \Omega_{V_q}) \quad (5.84.)$$

Lucrarea este de remarcat prin aplicația sa deosebită. Dacă s-ar folosi formalismul prezentat, ar permite realizarea unor fuzionări de informații direct în texte, prin luarea în considerare a mai multor lucrări. Totuși nu cred că este probabilă utilizarea metodei în

viitor, deoarece ar trebui ca utilizatorii să fie familiarizați cu această metodă de fuziune, cea ce ar implica o disponibilitate și alocarea unui timp de instruire ce nu totdeauna este în concordanță cu dorința utilizatorilor.

Avantajele utilizării metodei Dempster-Shafer sunt legate de relația de combinare a mai multor mase ( relația 5.76.), care poate fi interpretată ca o metodă de fuziune a diferitelor ipoteze provenite de la diverse surse de informare. Dar problema principală a acestei teorii este modul de determinare a maselor. O variantă a rezolvării acestei probleme constă în considerarea probabilităților, dar această abordare contravine ideii de bază a teoriei. De aceea, considerarea masei ca o frecvență de apariție a unui complex de evenimente, așa cum este tratat de Appriou este mai corectă dar implică un efort de calcul mare, iar structura sistemului trebuie să fie analizată pe cazuri. Din aceste motive nu am folosit acest tip de fuziune în realizarea sistemului de supraveghere.

## 5.8. Metode combinate de fuziune

Combinarea metodelor de fuziune este un procedeu des folosit în aplicații, în special în sistemele adaptative unde se alege o metodă sau alta în funcție de context. Alegerea mai multor tipuri de fuziuni într-o aplicație permite o mai mare flexibilitate și o adaptare a metodelor la natura informațiilor utilizate. Un astfel de exemplu este prezentat în [Kob04], în care clasică aplicație a robotului mobil este tratată din punct de vedere a fuziunii printr-o metodă combinată fuzzy-rețele neuronale. Articolul dorește să demonstreze avantajele utilizării fuziunii în două etape față de fuziunea globală a tuturor surselor de informare. Cele două etape sunt: prima care este o selecție a senzorilor mai fiabili, iar a doua, o fuziune cu învățare. Pentru a pregăti prima etapă este necesară stabilirea unui criteriu de selecție, care în acest caz este determinarea senzorilor cei mai fiabili. Stabilirea fiabilității unui senzor se face prin determinarea distribuției de posibilitate după cum urmează:

- se stabilește în avans intervalul de variație a semnalului de la senzor și se divide la un număr de subintervale de mărime  $dx$ ,
- se determină valoarea reală a senzorului care, de exemplu, aparține subintervalului cu acuratețea  $ds$ ,
- se transformă distanțele de măsură în valori adimensionale :

$$\omega(t) = \frac{s(t) - (k-1)dy}{dy} \quad \text{dacă } s(t) \leq (k - \frac{1}{2})dy \quad (5.85.)$$

sau

$$\omega(t) = \frac{kdy - s(t)}{dy} \quad \text{dacă } s(t) > (k - \frac{1}{2})dy$$

- se calculează distribuția de posibilitate :

$$\pi(\omega) = \frac{dy}{ds} \quad \text{dacă } 0 \leq \omega \leq \frac{ds}{dy} \quad (5.86.)$$

sau

$$\pi(\omega) = 1 \quad \text{în rest.}$$

Măsura posibilității  $\lambda = \max(\pi(\omega))$  dă nivelul de neîncredere în senzorul respectiv. Selecția senzorilor se face după reguli fuzzy care țin cont de valoarea posibilității unui senzor pe ultimul interval  $k \cdot t$  de timp. Funcțiile de ieșire ale regulilor sunt binare: se selectează sau nu. Există posibilitatea de a îmbunătăți procedura selectând pentru fiecare senzor în parte unele reguli, prin folosirea unui algoritm genetic care să minimizeze eroarea globală.

Fuziunea informațiilor obținute de la senzorii selectați se face printr-o rețea neuronală cu strat ascuns, care are un număr de neuroni la intrare egal cu maximumul de

senzori ai sistemului și la care s-a efectuat instruirea prin metoda propagării înapoi în mod off-line.

Metoda prezentată este complexă și elastică dar din datele prezentate în articol nu rezultă o îmbunătățire semnificativă a performanțelor care să justifice creșterea complexității. O metodă asemănătoare intenționez și eu să utilizez, în sensul folosirii surselor după un nivel de încredere stabilit în mod dinamic, cu o selecție care nu este binară, și atribuirii nivelelor prin algoritmi genetici.

Fuziunea informațiilor se poate aplica și în domenii deja des utilizate, cum ar fi rețelele de culegere a datelor dintr-un sistem monitorizat. O astfel de abordare este prezentată în [Rez04], în care se subliniază necesitatea folosirii simultane a metodelor neuro-fuzzy cu cele probabilistice deja consacrate în domeniul evaluării măsurătorilor în rețele de senzori. Din implementarea acestei fuziuni între cele două metode ar rezulta posibilitatea realizării unor noduri de sinteză a informațiilor, descongestionând astfel fluxul de informații în sistemele de achiziție-distribuție, care au un număr foarte mare de senzori. Acest proces ar permite realizarea unor sisteme ce ar funcționa după metode folosite în sistemele multiagent. Pe de altă parte, cu toate că teoretic valorile măsurate ar trebui să fie tratate ca valori probabilistice, caracterizate de o medie și o dispersie, în realitate de multe ori se stabilesc acești parametri pe baze intuitive pe un eșantion foarte mic de valori. Din această cauză există unele preocupări de a introduce elementele de incertitudine în evaluarea măsurătorilor. De exemplu, în unele standarde s-a introdus în locul termenului de „eroarea măsurătorii”, termenul de „incertitudinea măsurătorii”. Din aceste considerente ar fi mai corect să se realizeze o fuziune a metodelor statistice cu cele neuro-fuzzy în cazul evaluării măsurătorilor, articolul propunând o metodă de tip optimizare. Cu toate că problematica prezentată este reală și interesantă, autorii nu fac decât o analiză și recomandări de ordin general, lăsând abordarea soluțiilor deschisă pentru studii ulterioare. Utilizarea principiilor din sistemele multiagent mi-am propus-o și eu dar pe moment nu o consider justificată. În sistemul de fuziune, așa cum este el proiectat azi, sistemele multiagent ar crește complexitatea fără să aducă pe moment o îmbunătățire, dar pentru o etapă viitoare problema rămâne încă deschisă.



Ceea ce rezultă din metodele combinate este eficiența lor mai mare în obținerea constrângerilor aplicate incertitudinii informațiilor prin abordări din diferite perspective teoretice. Ambele articole prezentate au o structură serială a combinării. În teză, eu încerc o abordare paralelă a trei metode, tocmai pentru a accentua posibilele răspunsuri diferite ale unor metode ce au baze teoretice independente.

## 5.9. Alte metode folosite în fuziune

Rețelele neuronale au o mare aplicabilitate în clasificare, dar pot fi folosite împreună cu alte componente în realizarea unei fuziuni de informații. Un astfel de exemplu se găsește în [Shu02], în care este abordată problema obținerii unei imagini în care toate obiectele conținute să fie bine focalizate indiferent la ce distanță se află față de aparatul foto. Acest deziderat se poate obține prin fuziunea mai multor imagini luate cu diferite distanțe focale, obținându-se din fiecare porțiunea cea mai clară. Principiul de realizare a fuziunii se bazează pe împărțirea imaginilor în blocuri, determinarea a trei caracteristici pentru fiecare bloc, clasificarea cu o rețea neuronală a blocurilor din diferite imagini care au aceleași coordonate în imagini, selecția blocului cel mai clar dintre acestea și recompunerea imaginii finale. Cele trei caracteristici utilizate evidențiază claritatea blocului prin analiza frecvențelor spațiale, un coeficient de vizibilitate, și prin numărul de margini detectate. Frecvența spațială măsoară variația nivelelor de gri prin relația :

$$SF = \sqrt{RF^2 + CF^2} \quad (5.87.)$$

unde  $RF$  este frecvența spațială pe rânduri:

$$RF = \sqrt{\frac{1}{MN} \sum_{m=1}^M \sum_{n=2}^N (F(m, n) - F(m, n-1))^2}$$

iar CF este frecvența spațială pe coloane:

$$CF = \sqrt{\frac{1}{MN} \sum_{n=1}^N \sum_{m=2}^M (F(m, n) - F(m-1, n))^2}$$

unde M reprezintă numărul de coloane, iar N reprezintă numărul de rânduri. Coeficientul de vizibilitate se determină prin relația:

$$VI = \sum_{m=1}^M \sum_{n=1}^N \frac{|F(m, n) - \mu|}{\mu^{\epsilon+1}} \quad (5.88.)$$

unde  $\mu$  este media valorii intensităților din tot blocul, iar  $\alpha$  este o constantă de amplificare. Numărul marginilor observabile în bloc se obține prin numărarea lor după ce au fost generate printr-un detector de contur. Rețeaua neuronală folosită este de tip probabilistic, având funcția de densitate probabilistică de tip gaussian. În finalul articolului se prezintă o serie de rezultate experimentale care susțin folosirea acestei metode în comparație cu altele. Fuziunea prin rețele neuronale este o tehnică indirectă, deoarece rețeaua face de fapt o clasificare, iar în cazul prezentat în articol fuziunea este mai mult o compunere a elementelor care au câștigat clasificarea; totuși tehnica este de reținut, având și alte aplicații.

O abordare originală referitoare la fuziunea informațiilor este prezentată în [Tho90], având ca exemplificare o metodă de realizare a vederii stereoscopice, folosind o cameră video și un radar în impulsuri. Sistemul este structurat pe trei nivele, la fiecare etapă realizându-se o fuziune. Nivelul inferior propune o determinare a registrării pixelilor între cele două imagini care formează stereoscopia, deci determinarea corespondențelor dintre pixelii din imaginea stângă cu pixelii din imaginea dreaptă. La acest nivel, soluția aleasă este uzuală, necesitând o rețea neuronală de tip Kohonen. Dar la nivelul următor

autorul propune o metodă originală de fuziune a informațiilor de la cei doi senzori, prin optimizarea unei funcții de cost:

$$R = \sum_i \sum_j C_{i,j} P_j \int_{Z_i} dP(z | H_j) \quad j=0,1 \text{ și } i=0,1,2 \quad (5.89.)$$

unde  $P_j$  și  $H_j$  este probabilitatea respectiv ipoteza ca observația  $z$  să provină de la camera video sau de la radar, iar  $C_{i,j}$  este costul în unul din cazurile în care observația este corectă, falsă sau incertă. Valorile coeficienților de penalizare  $C$  nu sunt precizate în articol, doar se recomandă să se considere  $C_{i,i}=0$  în caz de observație corectă și să se utilizeze o valoare de penalizare mai mare în caz de informație falsă decât în caz de incertitudine. Chiar și din lucrare rezultă că optimizarea implică calcule laborioase și folosirea a unor coeficienți aleși euristici. O abordare asemănătoare dar care ocolește etapa de atribuire a coeficienților prin impunerea unor restricții este prezentată la capitolul de abordare statistică [Gun01]. Ultima etapă a metodei presupune realizarea unui model matematic al sistemului într-o manieră asemănătoare cu cea folosită în teoria sistemelor:

$$G(X_i, X_i^k, U_m, W_n, t) = 0 \quad (5.90.)$$

unde  $X_i$  este un set de parametri ai senzorilor,  $U$  reprezintă intrările în sistem,  $W$  semnifică perturbațiile și  $t$  este timpul. În cadrul procesului de fuziune se urmărește estimarea parametrilor  $X$

$$\hat{x} = \hat{x}(z) \quad (5.91.)$$

astfel ca modelul să corespundă observațiilor  $z$  făcute pe parcursul funcționării sistemului. Și în acest caz tehnica utilizată este o adaptare a metodelor folosite în alte domenii, respectiv în acest articol din teoria reglării.

Adaptări ale unor metode pentru a obține fuziunea informațiilor se pot realiza plecând și de la alte teorii. Astfel, există posibilitatea de a utiliza sisteme expert care în cadrul regulilor de inferență să includă procese de fuziune, sau de a folosi algoritmi genetici adaptați unui caz concret de fuziune. Utilizarea lor este conjuncturală, de aceea eu nu le consider metode propriu zise de fuziune a informațiilor și nu le-am aplicat în prezenta teză.

## 5.10. Concluzii

Din cele prezentate în această parte a rezultat progresul realizat în ultimii aproximativ zece ani în domeniul fuziunii. Astfel, plecând de la metode empirice, odată cu creșterea complexității problemelor s-a trecut la alte abordări mai sistematice. Clasificarea pe capitole făcută de mine nu este unica posibilă, dar o consider una bine fundamentată. De altfel, cum rezultă și din paginile anterioare, în acest domeniu destul de nou trebuie efectuate încercări spre cristalizare, numeroase probleme conceptuale și metodologice nefiind încă unanim acceptate. În acest sens împărțirea, pe care am făcut-o, în cinci grupe mari de fuziune a fost determinată de o încercare de a lega metodele de fuziune de câteva teorii care sunt frecvent utilizate în acest domeniu. Deoarece le consider mai mult metode de clasificare, nu am tratat separat fuziunea prin rețele neuronale și prin sisteme expert, acestea fiind incluse la capitolul de alte metode. Pe de altă parte, am tratat separat fuziunea prin teoria mulțimilor vagi de cea prin teoria posibilităților, considerându-le teorii și proceduri separate chiar dacă au o origine comună. Astfel, teoria mulțimilor fuzzy este axată pe conceptul de apartenență, pe când teoria posibilităților stabilește nivele de incertitudine, al căror domeniu se încearcă să fie restrâns. De altfel, modul meu de delimitare este confirmat de diferențele de metode folosite în cele două tipuri de abordări.

În prezentarea aplicațiilor se constată că unele dintre ele seamănă ca finalitate, încercând să rezolve aceeași problemă, dar prin metode diferite. Din acest motiv am

considerat justificat să prezint diferite articole care se referă de exemplu la detectarea minelor antitanc sau la sisteme de navigare autonome, abordate prin tehnici diferite. De asemenea, am prezentat articole care se referă la aceeași problematică, cum ar fi, de exemplu, cele referitoare la performanțele comparate între fuziunea prin produs și cea prin sumă, dar apărute în diferiți ani, considerând important de urmărit evoluția unor cercetări precum și argumentele aduse în sprijinul lor. Oricum problematica nu este închisă.

Din perspectiva preocupărilor tezei, aș sublinia unele concluzii referitoare la fuziunea în condiții de incertitudine în care sursele de informații nu furnizează date după o lege dinainte cunoscută. Astfel, unul din cei mai robuști operatori euristici este mediana, deoarece nu este puternic influențată de situațiile extreme sau marginale cum este media aritmetică și nici nu are un caracter puternic de penalizare a informațiilor eronate, sau omise. Din aceste motive am ales ca unul din procesele de fuziune să se bazeze pe metoda euristică dar, deoarece în sistemul prezentat în această teză nu avem decât două lanțuri de informare, voi folosi media aritmetică. Pentru luarea în considerare a constrângerilor un operator potrivit este produsul modificat, care împiedică anularea rezultatului din cauza unor condiții, determinate nejustificat, prea severe, și permite recuperarea rezultatului după un număr de reevaluări. Aici aș menționa importanța analizei în cazul imaginilor, atât din punct de vedere spațial cât și temporal, pentru a avea posibilitatea de a colecta cât mai multe informații și deci a reduce incertitudinea.

Așa cum se arată și în unele articole [Bas97], se poate obține o creștere a performanței dacă se folosesc clasificatoare care să aibă principii de funcționare cât mai diverse, astfel încât fuziunea să primească informații cât mai puțin corelate. Aceasta a implicat folosirea în prezenta teză a trei tipuri principal diferite de fuziuni a informației.

O concluzie care trebuie reținută este că nu există o metodă de fuzionare bună pentru toate aplicațiile și de aceea trebuie făcut un studiu sau trebuie obținute prin încercări informații despre performanțele diferitelor metode pentru aplicația concretă. Totuși unele linii orientative se pot stabili din analiza gradului de incertitudine estimat al datelor de intrare. Pentru condițiile existente în cazul sistemului de supraveghere

prezentat în această lucrare, avantajele și dezavantajele pentru fiecare dintre metodele de fuziune folosite, sunt analizate în capitolul IX.

În legătură cu nivelul de decizie ar fi de concluzionat că cele mai bune rezultate se obțin cu extragerea informațiilor de decizie din trăsături, unde există deja o corelare a datelor și nu s-a pierdut încă multă informație, dar din punct de vedere a modului de implementare implică uneori determinarea unor modele ce pot fi dificil de realizat. Din această cauză, se pot accepta și deciziile de tip soft care conduc la soluții mult mai bune decât cele hard. Aceste concluzii au fost confirmate și de rezultatele stabilite în capitolul IX, unde sunt prezentate cele două metode de decizie; hard și soft, și unde se reliefează performanța superioară a celei de a doua metode.

### **PARTEA III. Contribuții la proiectarea, realizarea și testarea sistemelor de supraveghere în mediu extern**

Partea a treia face o prezentare a contribuțiile autorului la proiectarea, realizarea și testarea sistemelor de supraveghere în mediu extern. În această parte se concretizează contribuțiile teoretice și se analizează rezultatele experimentale obținute pe baza studiului propus. Această parte a tezei are în componență patru capitole.

Capitolul VI face o prezentare a sistemului cu care s-au efectuat experimentările. Astfel după expunerea celor două structuri studiate care permit compararea performanțelor modurilor de decizie, se face o descriere a componentelor care au compus ansamblul, împreună cu caracteristicile acestora. În continuare se prezintă pe scurt suportul soft folosit și se justifică folosirea scalei logaritmice, în cazul senzorilor de tip conic, așa cum sunt și cei folosiți în această lucrare.

În Capitolul VII se studiază componentele ce formează lanțul video de colectare a informațiilor. În acest sens sunt prezentate metodele de stereoscopie folosite, cele de localizare și stabilire a caracteristicilor și cele de urmărire. De asemenea se prezintă modul de stabilire a marginilor de incertitudine și de determinare a granularității optime.

Capitolul VIII descrie modul de proiectare, realizare și testate a sistemelor bazate pe detectori PIR. În acest scop se expune metoda de proiectare și testare a unor astfel de sisteme, precum și metoda de localizare și estimare a suprafeței radiante a obiectului intrus

Ultimul capitol din această parte, care are numărul IX, prezintă modul de realizare a fuziunii informației și a deciziei. Astfel descriu cele trei metode de fuziune utilizate, precum și cele două metode de decizie propuse. Se evidențiază avantajele structurii ierarhice și se face o comparație între metodele de decizie utilizate.

---

## Capitolul VI. Arhitectura sistemului de supraveghere

### 6.1. Introducere

Pentru realizarea unui sistem de supraveghere este necesară crearea unui lanț de procese, care să permită anunțarea unei efracții, reducând pe cât posibil numărul alarmelor false. Rezultă că sistemul minimal trebuie să fie format din elemente de detecție sau captură a informației parvenită din zona supravegheată, un echipament de conversie a informației într-un format ce permite prelucrarea și un sistem de prelucrare și interfațare cu utilizatorul, aceasta din urmă fiind componenta de complexitate cea mai mare. Sistemul de avertizare în cazul prezentei teze va fi redus la o informare a utilizatorului, direct pe monitor, deoarece nu prezintă nici o importanță din punct de vedere al scopului propus. De altfel, utilizarea unei sirene sau anunțarea unui serviciu de dispecerizare pentru a trimite o echipă de intervenție, presupune folosirea unor echipamente obișnuite, care nu au nici o relevanță pentru modul de activare a sistemului, iar principalele probleme din punct de vedere teoretic apar chiar în domeniul oportunității declanșării semnalului de alarmare.

Pentru a arăta modul în care concluziile prezentate în capitolele anterioare se regăsesc în tematica pe care o studiez, va trebui să fac o scurtă prezentare a problematicii de care mă ocup. Ceea ce mi-am propus este realizarea unui sistem de localizare și alarmare antiefracție în mediu extern, care are în componență următoarele surse de informații: senzori de mișcare de tip PIR, și camere video. Supravegherea în mediu extern ridică câteva probleme, care nu pot fi rezolvate principial prin metode convenționale. Aceste dificultăți sunt datorate condițiilor variabile de iluminare și temperatură, numărului mare de evenimente colaterale care acționează ca zgomot cauzator de alarme false și complexității informațiilor provenite din spațiul analizat. Inițial îmi propusesem să folosesc și o metodă de localizare acustică prin goniometrie, realizată cu microfoane, dar experimentările pe care le-am efectuat nu au dat rezultatele așteptate. Motivul acestei nereușite se datorează reflexiilor multiple care fac dificil



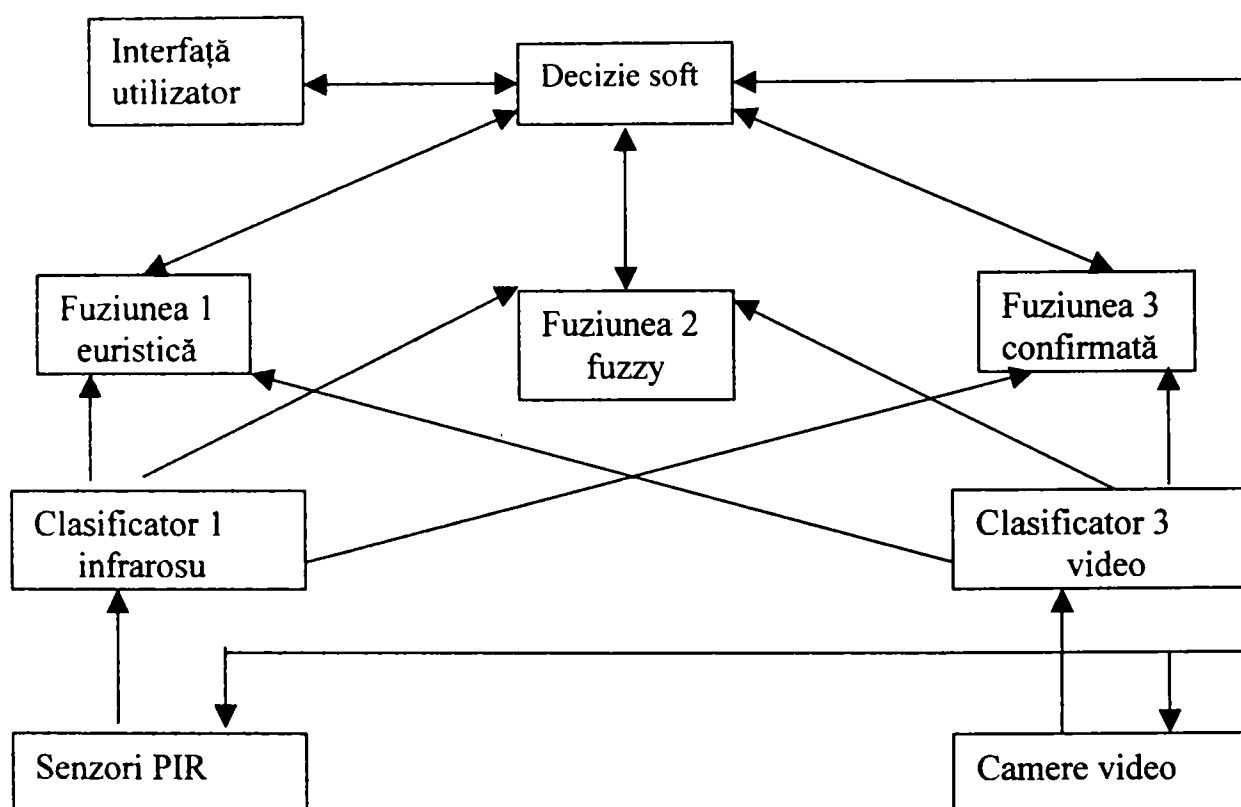
procesul de localizare, respectiv necesitatea de a măsura timpi foarte scurți, de felul celor care apar în localizările acustice efectuate pe distanțe scurte.

Problematica specifică sistemelor de supraveghere în medii externe este dată de condițiile schimbătoare ale mediului, care influențează capacitatea de informare a diferitelor tipuri de senzori. Alte probleme sunt ridicate de îmbătrânirea prin „orbire” în timp a senzorilor PIR, de imprecizia ridicată de localizare a senzorilor de tip PIR, mai ieftini, și de prețul ridicat, comparativ cu rezultatele, al unui sistem de urmărire cu multe camere video. În cazul unei singure camere pot apărea dificultăți datorită zonelor de ocluziune care pot împiedica urmărirea obiectelor. Obiectivele pe care mi le propun să le îndeplinească sistemul sunt :

- Stabilirea unei metode de măsurare a gradului de incertitudine prin coeficienți bazați pe nivelul de disimilitudine
- Demonstrarea utilității folosirii granulației multiple și determinarea granularităților optime pentru obiectele dintr-un sistem video
- Stabilirea și verificarea unor metode de proiectare și testare pentru sisteme cu detectoare PIR
- Reliefarea unei metode de localizare a obiectelor folosind sisteme bazate pe detectori în infraroșu
- Determinarea și fundamentarea unei tehnici de estimare a suprafeței radiante pentru sistemele cu detectori PIR
- Realizarea unei ierarhii ale proceselor de fuziune, folosind metode ce au baze teoretice diferite
- Realizarea și compararea rezultatelor folosind metode de decizie soft și hard
- Determinarea intruziunii în zonele stabilite, concomitent cu reducerea alarmelor false și determinarea gradului de încredere în fiecare sursă de informații.

## 6.2. Organizarea sistemului

Structura sistemului este format din cele două ansamble de senzori de fuziune, două procese de localizare, respectiv clasificare, trei implementări ale metodelor de fuziune, un modul de determinare a fiabilității componentelor și o interfață cu utilizatorii [Bar05d]. În scopul de a reliefa performanțele metodelor de decizie studiate în capitolul IX, s-au realizat două module de decizie, unul bazat pe informații de tip fuzzy, denumit modul de decizie soft, prezentat în fig.6.1.

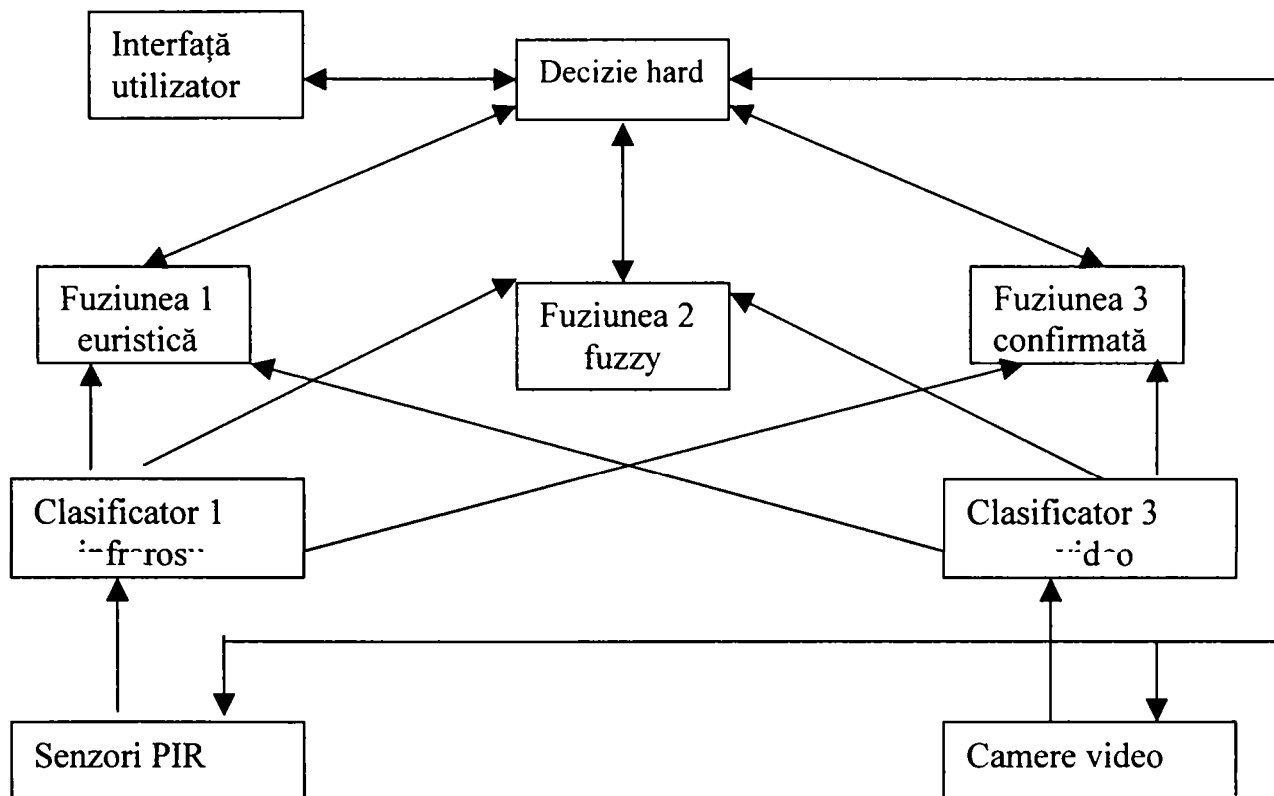


**Figura 6.1.** Structura sistemului pentru cazul deciziei soft

și altul bazat pe o decizie ce folosește date de tip ferm, denumit modul de decizie hard, așa cum se prezintă în fig. 6.2.

Pentru componenta sistemului care utilizează camere video, numit în continuare sistem video, localizarea se face prin stereoscopie, urmat de o determinare a caracteristicilor obiectului intrus și de o urmărire a obiectului, așa cum vor fi prezentate în continuare.

Detectorii PIR cu detecție în infraroșu constituie sursa de informații pentru a doua ramură a sistemului, numit sistemul bazat pe detectori PIR, în care localizarea se face printr-o metodă a mulțimilor grosiere, folosind simultaneitatea semnalizărilor provenite de la senzori, precum și istoricul acestor semnalizări. În acest mod se face, pe lângă o localizare a obiectului intrus, și o estimare a suprafeței acestuia.



**Figura 6.2.** Structura sistemului pentru cazul deciziei hard

Având la dispoziție aceste informații provenite de la cele două sisteme, se realizează un set de trei fuziuni, independente ca principii teoretice, care permit obținerea unor estimări superioare calitativ față de cele avute inițial. Metodele alese sunt: fuziunea euristică, având avantajul unei simplități mai mari, fuziunea de tip fuzzy, care ia în considerare, cu precădere, complementaritatea celor două sisteme și fuziunea prin confirmare, care subliniază diferența de calitate a informațiilor furnizate de cele două sisteme.


Apoi se stabilește rezultatul final, constând în decizia de alarmare sau de ignorare a eventualelor perturbații, precum și stabilirea, în cazul alarmei, a localizării

efracției. Sunt prezentate două tipuri de decizii, una de tip vot, în care intră rezultate ferme de la modulele de fuziune și una de tip vag, în care se iau în considerare coeficienții de încredere furnizați de modulele de fuziune.

În continuare, materialul este organizat pe structura logică de desfășurare a fenomenelor. Astfel, după o prezentare de ordin general, referitoare la echipamente și programe, se trece la analiza propriu-zisă, fiind prezentate pe rând considerentele teoretice și rezultatele practice ale modulelor de localizare și determinare a mărimii obiectului intrus, ale proceselor de fuziune și a modului de luare a deciziei.

### 6.3. Construcția sistemului

Pentru verificarea considerațiilor teoretice s-au efectuat experimentări practice folosind o serie de echipamente specifice domeniului studiat. Astfel, lanțul de prelucrare a informației a cuprins elementele de captură, achiziție, prelucrare și interfațare cu utilizatorul (figura.6.3.).




**Figura 6.3.** Organizarea sistemului pe cele două lanțuri de supraveghere

În echipamentele utilizate pe lanțul de achiziție a semnalelor provenite de la detectorii PIR în infraroșu s-au utilizat senzori de fuziune de tip celor prezentate în [M3], acesta fiind unul dintre cei mai importanți fabricanți din domeniu.

Acest tip de detector, se încadrează la clasa medie, având un unghi de deschidere de 89 de grade și trei grupe de franjuri pentru detecție.

S-au mai folosit, pentru experimentările referitoare la localizare, detectoare de tip DOOM, cu prindere pe tavan. S-a făcut această alegere, deoarece acest tip de detectori permite o densitate mai mare de elemente pe spațiul supravegheat. Ca și mod de funcționare, acestea nu diferă de cele cu prindere pe perete, dar, prin schimbarea tipului de lentile, unghiul de supraveghere este de 360 de grade, ceea ce implică și o reducere a razei medii de detecție de la 8 metri la 4 metri.




**Figura 6.4.** Echipamentul de achiziție a semnalelor provenite de la detectorii PIR

Ca echipament de achiziție pentru semnalele provenite de la detectorii PIR s-a utilizat un convertor analog-digital pe 4 canale prezentat în [M16]. Rata de eșantionare este mică, de doar 100 Hz pe canal, suficientă însă, pentru viteza de reacție a detectoarelor, care este de cca 1 secundă. Plaja valorilor admise la intrare este 0 la 10 volți, ceea ce a permis ca pe o singură cale să se conecteze mai mulți senzori (cu ieșirile de tip binar) prin folosirea unor divizoare rezistive conectate în serie cu detectoarele (de

fapt, ieșirile senzorilor sunt formate de niște rele normale închise). Aparatul este prezentat în imaginea 6.4.

Conectarea la calculator a acestui echipament se face prin port USB, ceea ce îl face ușor de transportat și utilizat.


Pentru lanțul de achiziție video s-au utilizat o serie de echipamente specifice, Astfel, în general, acolo unde nu am menționat altfel, am utilizat camere video de tipul celor specificate în [M17], prezentată și în imaginea 6.5.



**Figura 6.5.** Tipul de cameră video utilizat

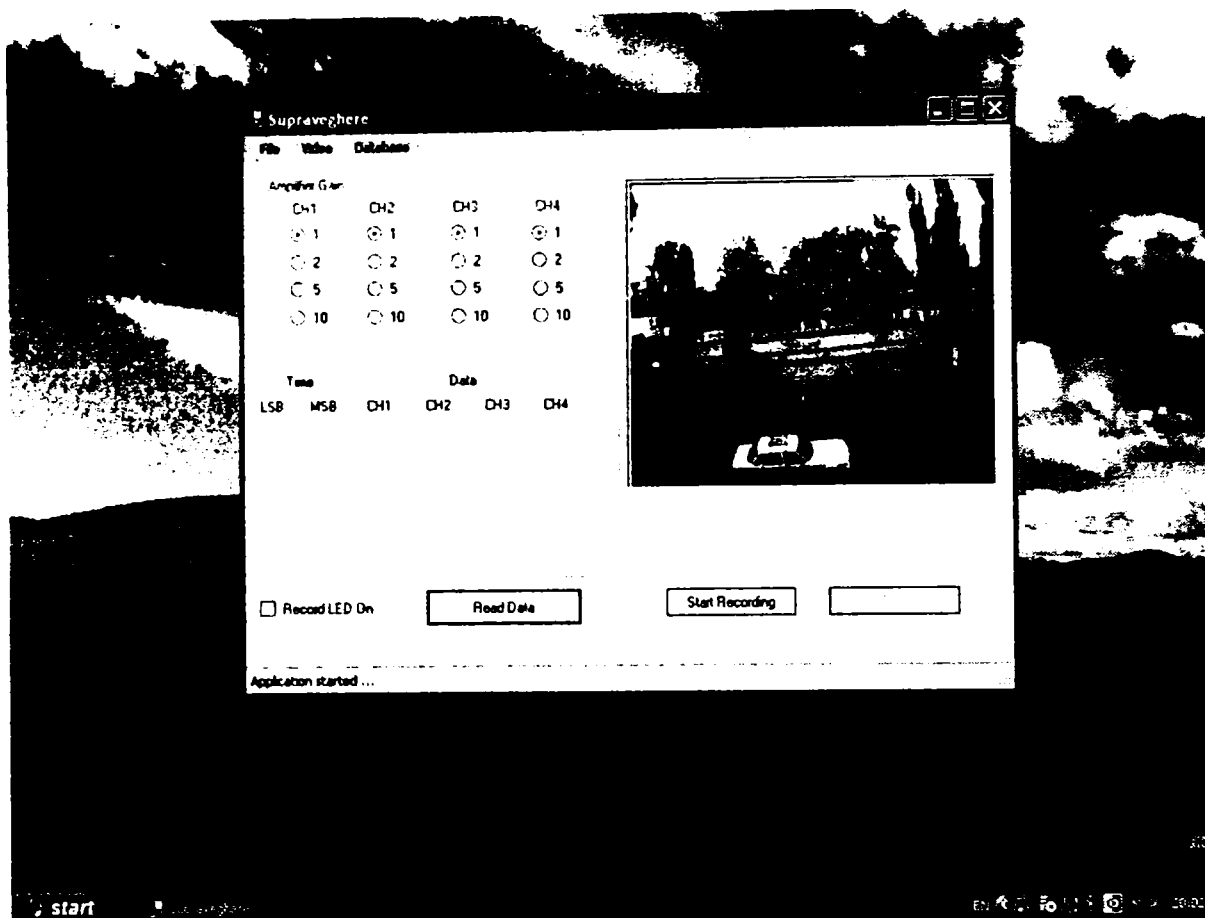
Acest tip de echipament are o rezoluție orizontală de 420 de linii TV, ceea ce corespunde unei clase de tip mediu. Formatul semnalului este de tip EIA/CCIR, cu ieșire standard de 1 V vârf la vârf, luminozitatea minimă este de 0,02 Lux, sau 0 dacă are activate ledurile în infraroșu din jurul obiectivului.

Achiziția semnalelor video se face printr-o placă de captură cu 4 canale de tipul specificat în [M18], prezentată în imaginea 6.6.



**Figura 6.6.** Placa de achiziție video

Principalele caracteristici ale acestei plăci sunt rata de eșantionare de 100 de cadre pe secundă (deci o rată de 25 de cadre pe cameră), o rezoluție a imaginii de 720 pe 576, cu posibilitate de codare în principalele formate utilizate.



**Figura 6.7.** Exemplu de fereastră a programului

Programele de prelucrare au fost realizate în diferite limbaje, de-a lungul celor 7 ani de studiu. Astfel s-a folosit programul MATLAB R12 și limbajul C++ folosind mediile de programare Visual Studio 6 și apoi Visual Studio NET 2003 ale firmei Microsoft.

Un exemplu de interfațare cu utilizatorul este prezentat în imaginea 6.7. Se observă accesibilitatea la informațiile provenite din sistemul video și sistemul bazat pe detectori PIR.



## 6.4. Stabilirea scalei pentru detectori conici

O primă problemă de ordin teoretic abordată este legată de câteva considerente referitoare la particularitățile pe care le au informațiile obținute de elementele de captare care sunt utilizate în această lucrare.

În cazul unor detectori care primesc informațiile din mediu printr-o investigație de tip conic este important să stabilim tipul de scală care să fie utilizată. Pentru a răspunde la această întrebare mi-am propus să stabilesc modul de variație a semnalului recepționat în cazul unei mișcări de apropiere având viteză constantă a unui obiect din raza de recepție a senzorului. Deci se consideră situația în care un obiect de dimensiune  $D$ , aflat inițial la distanța  $L$  se apropie cu o viteză constantă  $V$  de un detector care are distanța focală de recepție  $F$ . Mișcarea este sesizată în captor printr-o deviație inițială  $d$  și o creștere a suprafeței de detecție cu o viteză  $v$ .

Din asemănarea triunghiurilor care se creează rezultă proporția:

$$\frac{v \cdot t}{F} = \frac{D}{L - V \cdot t} \quad (6.1.)$$

unde  $t$  reprezintă timpul.

Prin derivare în raport cu timpul se obține relația de determinare a vitezei de creștere a imaginii obiectului în captor:

$$\frac{v}{F} = \frac{D}{(L - V \cdot t)^2} \cdot V \quad (6.2.)$$

de unde

$$v = \frac{D \cdot F}{L^2} \cdot \frac{1}{\left(\frac{1}{V} - \frac{2t}{L} + \frac{Vt^2}{L^2}\right)} \quad (6.3.)$$

unde  $D, F, L$  și  $V$  sunt constante,

deci viteza  $v$  este într-o relație de tip  $\frac{1}{t^2}$ , cea ce înseamnă a variație foarte mică pentru obiecte aflate la distanță și o creștere bruscă pentru obiecte apropiate. Dar dacă se logaritmează relația se obține:

$$\log(v) = \log(D \cdot F \cdot V) - 2\log(L - V \cdot t) \quad (6.4.)$$

Se observă că relația obținută este una liniară. Deci, dacă se folosește o scală logaritmică se îmbunătățește posibilitatea de percepție a obiectelor. Această concluzie, pe care am obținut-o prin demonstrația originală de mai sus, este de altfel în concordanță cu modul de funcționare a senzorilor de tip conic pe care îl au și oamenii (ochii și urechile), ce folosesc scări logaritmice și este o contribuție la realizarea de ansamblu a sistemului de supraveghere. Din aceste considerente scara adoptată în prezenta lucrare este de tip logaritmice.

## 6.5. Concluzii

Structura sistemului este menită să permită evidențierea metodelor utilizate în această lucrare, fără a introduce module irelevante din punct de vedere a scopului tezei. În acest sens, pentru realizarea fuziunii se utilizează două lanțuri de localizare, care se bazează pe două metode de detecție. De asemenea, echipamentul folosit are o structură minimală, dar care permite reliefaarea tuturor metodelor prezentate. Aparatura utilizată este din categoria celor medii și ieftine, dar care corespund cerințelor impuse. Astfel, numărul de camere video este de numai două, dar dacă s-ar folosi un număr mai mare de camere nu s-ar schimba cu nimic metodele utilizate. Placa de achiziție video este una de clasă medie, având capacitatea de conversie 25 de cadre pe secundă, care este suficientă pentru obținerea unor imagini acceptabile. De asemenea, tipul de detectori PIR este unul comercial, dar a permis, în cadrul experimentărilor, obținerea unor rezultate relevante, iar echipamentul de conversie analog-numeric, deși are o frecvență

de eșantionare joasă, este corespunzător pentru prelucrarea semnalelor de ieșire din detectori (care au variație lentă). Echipamentul cel mai performant este calculatorul de tip desktop cu procesor de tip Intel la 3GHz, care este impus de complexitatea metodelor folosite.



## Capitolul VII. Sistemul Video

### 7.1. Introducere

Sistemul de detecție video este principalul furnizor de informații pentru procesele de fuziune din nivelul ierarhic superior. În cadrul sistemului sunt aplicate metode de stabilire a locației obiectului intrus, precum și unele caracteristici geometrice și cromatice ale acestuia, ceea ce permite atribuirea unei etichete. Secțiunile din acest capitol sunt organizate pe baza secvenței de desfășurare a prelucrării informației. În lucrare nu se pune accent pe obținerea imaginilor de către camere și procesul de digitizare, deoarece acestea nu prezintă nici un grad de noutate, fiind utilizate echipamente și programe comerciale.

Un prim subcapitol se ocupă de stabilirea depărtării la care se află obiectul prin metode de stereoscopie. Urmează o abordare mai extinsă a modului de determinare a caracteristicilor obiectului, în care se introduc aplicații ale teoriei mulțimilor grosiere și a granularității, fiind expus caracterul multiplu al trăsăturilor definiției pentru un obiect, respectiv modificarea acestora în funcție de distanța de la care se face observația. Tot în acest subcapitol se definește o modalitate de măsurare a incertitudinii în spațiul de definire a caracteristicilor unui obiect.

Un ultim subcapitol prezintă două metode bazate pe principii diferite, pe care le-am experimentat, și anume, de urmărire a unui obiect aflat în spațiul de supraveghere, o metodă clasică și, respectiv una bazată pe teoria mulțimilor fuzzy. Aceste metode permit reducerea efortului de calcul și a necesităților de resurse, odată ce s-a realizat recunoașterea și nu se propune decât furnizarea în continuare a informațiilor despre localizarea obiectului.

## 7.2. Metode de stereoscopie utilizare

Pentru cunoașterea locației obiectului care a produs efracția este necesară stabilirea tuturor celor trei coordonate spațiale. Deoarece două dintre ele sunt cuprinse direct în informația din imagini, trebuie stabilită doar a treia, respectiv distanța dintre sistemul de camere video și obiect. Obținerea celei de a treia dimensiuni, prin folosirea unor camere video, se poate face prin mai multe metode dintre care cele mai cunoscute sunt prin flux de imagini și prin stereoscopie. Prima grupă de metode presupune analizarea unui număr succesiv de imagini, cea ce necesită și timp și o putere de calcul mai ridicată. De aceea, dacă este necesar un timp de calcul scurt, se impune utilizarea metodelor bazate pe stereoscopie.

În acest sens, pentru acest tip de localizare prin stereoscopie, am experimentat un algoritm bazat pe similitudinea pixelilor[Bar04c]. Sistemul a constatat din două webcam-uri conectate prin USB la un calculator portabil. Metoda de determinare a distanțelor a utilizat proprietatea de similitudine a punctelor aflate în cele două imagini și este definită de relația:

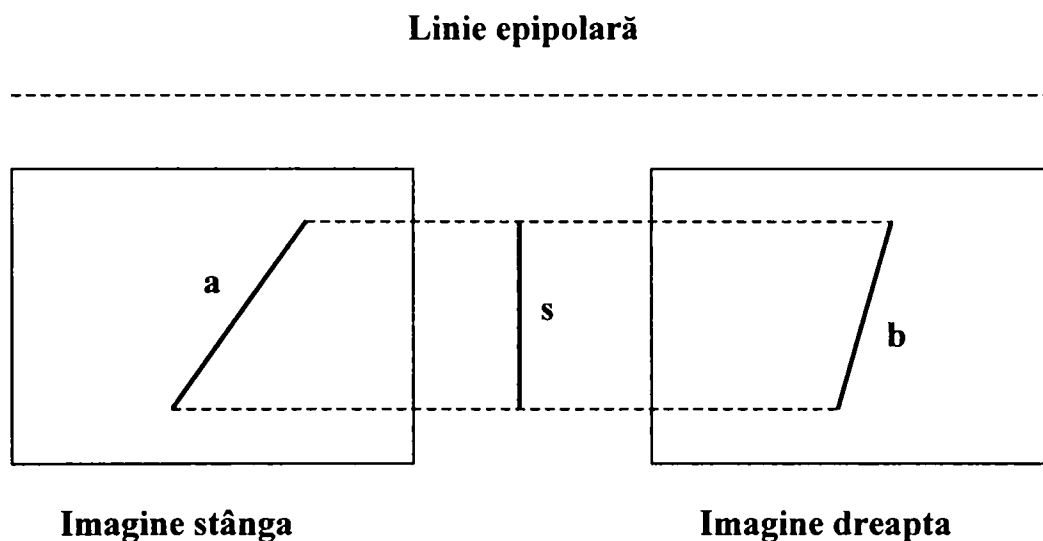
$$d = |(x_2, y_2) - (x_1, y_1)| = B \cdot \frac{f}{Z} \quad (7.1.)$$

unde

$d$  reprezintă disparitatea dintre coordonatele  $(x_i, y_i)$  a aceluiași punct fizic în imaginea din stânga respectiv în imaginea din dreapta,  $f$  este distanța focală,  $Z$  este distanța până la obiect iar  $B$  este o constantă ce ia în considerare caracteristica camerei video.

Datorită amplasării celor două camere video în plan orizontal, perpendicular cu axa  $Z$ , rezultă că se pot determina în cele două imagini capturate, mulțimi de puncte similare folosind numai axele orizontale. Gradul de deplasare relativă a acestora permitea determinarea distanței până la obiectul căruia îi aparțineau pixelii. Pentru un punct al unui obiect se cercetează pe axa epipolară un interval de până la  $D$  pixeli spre dreapta respectiv stânga în imaginile obținute după prelucrare. Din figura 7.1, în care se prezintă proiecțiile  $a$  și  $b$  ale unei drepte, precum și linia de suprapunere  $s$ , se observă

faptul că dacă se folosește o rezoluție mică (așa cum a fost cazul nostru) se pot aproxima cele două proiecții ca fiind similare. Utilizând această observație s-a determinat nivelul de similitudine direct între pixelii corespondenți fără o altă prelucrare.



**Figura 7.1.** Proiecțiile unei drepte **a**, **b**, precum și linia de suprapunere **s**

Algoritmul utilizat este următorul:

- 1. achiziționarea imaginilor,
- 2. determinarea unui punct de referință pe axa epipolară,
- 3. stabilirea dacă există puncte de aceeași culoare în imaginea opusă în intervalul  $(x-D, y)$  pentru imaginea din stânga sau  $(x+D, z)$  pentru imaginea din dreapta,
- 4. determinarea numărului maxim de puncte vecine care îndeplinesc condițiile anterioare,
- 5. dacă mai există puncte neanalizate se trece la punctul 2,
- 6. se revine la punctul 1.

În mod concret experimentările s-au realizat cu două camere video, având caracteristicile descrise în [M19], conectate prin interfețe USB la calculator. După achiziția simultană a celor două imagini (fig.7.2.) s-a trecut la reprezentarea prin mai puține nivele de gri pentru a mări corelația dintre punctele similare. Valoarea vecinătății de  $D = 14$  pixeli s-a determinat experimental și depinde de tipul camerei video și de rezoluția folosită.



**Figura.7.2.**Exemplu de imagini obținute de cele două camere video

După ce s-a stabilit o pereche de pixeli similari, s-a încercat determinarea unei corespondențe pentru cât mai multe puncte vecine. Cu cât valoarea de shift este mai mare cu atât obiectul a cărui puncte au fost identificate este mai aproape. În vederea afișării s-a ales ca pentru un obiect mai apropiat să se atribuie o valoare mai mare, deci în imagine să fie mai alb, așa cum se prezintă în figura 7.3.





**Figura 7.3.** Rezultatul prelucrării imaginilor stereoscopice

În cadrul experimentărilor s-a stabilit că algoritmul folosit obține rezultate bune. Rezultatele obținute s-au dovedit a fi în funcție de rezoluție și numărul nivelelor de culoare folosite, iar cu cât crește distanța cu atât rezultatele sunt mai slabe. Determinările s-a efectuat pentru trei cazuri de nivele maxime ale culorilor, respectiv pentru 64, 32 și 16. Rezultatele sunt prezentate în tabelul 7.1.

**Tabelul 7.1.** Dependența rezoluției de numărul de culori și distanță

		Distanță (m)					
		0,1	0,2	0,5	1	2	5
Nr. cul.	64	64	16	4	1	1	1
	32	32	16	8	4	1	1
	16	16	16	16	8	4	1

---

## 7.3. Metodele de localizare și stabilire a caracteristicilor

### 7.3.1. Extragerea trăsăturilor

Cea ce se obține din informațiile furnizate de orice detector sunt imaginea uneia sau mai multor trăsături a obiectelor din raza de detecție a senzorului. Din acest punct de vedere recunoașterea, respectiv etichetarea unui obiect se face prin recunoașterea, respectiv etichetarea unei mulțimi de atribute sau trăsături care sunt cunoscute ca aparținând obiectului [Sto93].

#### 7.3.1.1. Problematika generală

Sistemele de supraveghere și recunoaștere fac parte din categoria mai largă a sistemelor de recunoaștere a formelor, de aceea problematica generală a domeniului se aplică și sistemelor tratate în prezenta teză.

În acest context, sistemele conform [Tor92] vor fi formate din următoarele blocuri funcționale:

- echipamente de achiziție a informațiilor, în cazul nostru din camere video,
- module de preprocesare a informației, respectiv de îmbunătățire a contrastului, de focalizare automată, de filtrare și netezire sau de redistribuire a histogramei nivelelor de cuantificare,
- module de realizare a segmentării,
- module de reprezentare și interpretare care reprezintă transpunerea propriu-zisă a algoritmilor de recunoaștere a formelor,
- module de fuziune a informațiilor, de sinteză, aplicând tehnici din domeniul sistemelor expert.

Dintre aceste module extensia cea mai mare, în studiile actuale din domeniul sistemelor de supraveghere și recunoaștere, o are partea referitoare la tehnicile și algoritmi de recunoaștere a formelor.

Recunoașterea formelor a fost definit de Duda și Hart [Dud73] ca „*domeniul preocupat de recunoașterea automată a regularității semnificative în medii complexe și alterate de zgomot*”. O altă definiție a aceluși autori, concluzionează recunoașterea formelor ca o „*căutare a unor structuri utile în cadrul unui masiv de date*”.

Din punct de vedere a ariilor subsidiare, recunoașterea formelor se poate despărți în mod formal în patru domenii, dar care nu sunt independente ca abordare, existând o interdependență între ele. Acestea sunt: definirea caracteristicilor, analiza caracteristicilor, efectuarea clasărilor și definirea clasificatorilor urmată de determinarea clasificărilor. O altă sistematizare a tehnicilor abordate în acest domeniu se poate efectua după structuralitatea analizei imaginilor în analize regionale în care datele sunt cu preponderență reprezentări de obiecte și analize sintactice unde datele sunt relații între două sau mai multe obiecte. Din prima categorie se desprind analizele pe bază de model, cele folosind tehnici statistice, metodele ce utilizează teoria mulțimilor vagi și cele ce sunt implementate cu sisteme neuronale artificiale. Unele tehnici nu pot fi atribuite în mod categoric uneia din clasificările anterioare, deoarece s-a dovedit că cele mai bune rezultate se obțin prin folosirea simultană a mai multor domenii de abordare.

Indiferent de metoda folosită pentru recunoașterea formelor, trebuie identificat un set de trăsături care să permită etichetarea unui obiect ca aparținând unei clase de obiecte sau alteia. Această identificare se face pe baza partiționării sau clasificării unui număr de caracteristici considerate determinante pentru obiectul analizat, precum și a relațiilor dintre aceste caracteristici. Tehnicile nesintactice au ca obiectiv clasarea sau clasificarea caracteristicilor și deciderea asupra naturii obiectului prin corelarea caracteristicilor obținute. Procesul de extragere a unei caracteristici reprezintă o funcție prin care din spațiul tuturor formelor posibile se trece în spațiul caracteristicilor definitorii pentru forme [Rus03]. Deci orice funcție

$$f: \mathfrak{R}_p \rightarrow \mathfrak{R}_q \quad \text{unde } p > q \quad (7.2.)$$

poate fi considerată ca un extractor de caracteristici, în care caracteristica este o proiecție a spațiului de forme. Rezultă că prin această operație se pierde o mare parte din informația inițială, care se consideră a fiind nerelevantă sau neimportantă, urmărindu-se să se păstreze numai informațiile esențiale. Astfel, se reduce volumul datelor de prelucrat, implicit se reduce spațiul și timpul necesar a fi alocat algoritmului.

Modul de selecție a caracteristicilor și numărul acestora este o trăsătură majoră a oricărui algoritm. O problemă principală a oricărei tehnici de recunoașterea formelor este obținerea caracteristicilor definitorii pentru obiectele analizate, altfel pierderea de informație având un rol negativ, deoarece din datele rezultate nu se mai poate face o atribuire corectă a obiectului clasei din care face parte. De asemenea așa cum arată în [Hol89] o problemă importantă este și raportul dintre numărul  $m$  de forme luate în considerare și numărul  $n$  de caracteristici independente ce definesc formele.

Dacă

$$m/n < 3$$

atunci există pericolul ca discriminarea dintre forme să se facă în mod aleatoriu.

În spațiul mulțimii caracteristicilor orice punct este definit de un vector, iar partiționarea sau clasificarea unei forme se realizează prin etichetarea vectorului corespunzător punctului ce corespunde caracteristicilor formei respective. În funcție de metoda folosită, rezultatul poate fi o etichetare de tip concret, o etichetare de tip probabilistic sau o etichetare de tip vag. Astfel dacă notăm cu  $c$  numărul de clase, unde  $1 < c < n$  și cu  $Y$  vectorul rezultat într-un spațiu normalizat, putem avea următoarele situații :

$$Y_{fcu} = \{ Y \in \mathfrak{R}_c \mid y_k \in [0,1], k \in c \} \quad (7.3.)$$

avem etichetare de tip vag neconstrâns

$$Y_{fc} = \{ Y \in \mathfrak{R}_c \mid \sum y_k \in [0,1] = 1, k \in c \} \quad (7.4.)$$

avem etichetare de tip probabilistic sau de tip vag constrâns

$$Y_c = \{ Y \in \mathfrak{R}^c \mid y_k \in \{0,1\}, k \in c \} \quad (7.5.)$$

avem etichetare de tip ferm.

Ca reprezentare în spațiul claselor, etichetarea de tip concret  $Y_c$  nu poate fi decât în vârfurile cubului, deci aparținând în mod categoric unei clase, adică fiind descrisă de un vector unitate. Etichetarea de tip probabilistic sau de tip vag constrâns  $Y_{fc}$  nu poate fi decât pe diagonalele laturilor, deoarece suma elementelor vectorului trebuie să fie egală cu unitatea. Iar etichetarea de tip vag  $Y_{fcu}$  poate ocupa orice punct din spațiu, neavând nici o constrângere. Totuși trebuie menționat că orice tip de algoritm se va folosi, deci indiferent de modul de etichetare, în final se va face o defuzzificare sau o evaluare a probabilității astfel încât rezultatul dat de algoritm va fi o clasare sau o clasificare cu numere concrete, atașându-se forma unei categorii bine determinate.

### **7.3.1.2. Recunoașterea formelor prin clasare**

Principiul metodei constă în determinarea unui număr de caracteristici ale modelelor sau prototipurilor reprezentative pentru fiecare partiție sau clasă și luarea deciziei asupra fiecărei forme pe baza apropierii caracteristicilor acestora de ale modelelor.

Clasarea sau partiționarea constă în asignarea unor obiecte prin etichetare la o subgrupă la care îi aparțin în mod natural. Prototipurile pot fi date apriori pe baza unor cunoștințe anterioare sau prin mod de învățare. Învățarea poate fi supervizată, când există un lot de forme de învățare, fiind indicat cărei grupări îi aparține fiecare astfel de formă, sau nesupervizată, când algoritmul determină gruparea în mod iterativ pe baza informațiilor acumulate pe parcursul clasării.

Algoritmul de partiționare constă în esență în determinarea unei matrici de transformare având dimensiunea de  $c \times n$ , unde  $c$  este numărul de clasări, iar  $n$  este

numărul de caracteristici ale unei forme. În acest fel, după determinarea acestei matrici, chiar și într-o formă implicită, la aplicarea transformatei vectorului neetichetat, va rezulta partiția căruia îi este atribuită forma, ceea ce este echivalent cu atașarea unei etichete vectorului. Ca și în cazul etichetării vectorilor și în această situație elementele matricii de transformare pot fi de diferite naturi, în funcție de datele folosite și de tipul algoritmului folosit. Astfel, matricea de transformare  $T$  poate să aibă una din următoarele componente :

$$T_{fcu} = \{ t \in \mathfrak{R}^{c \times n} \mid t_{i,j} \in [0,1], \sum t_{i,j} < n \} \quad (7.6.)$$

unde  $i, j \in N, i \in [0, c]$  și  $j \in [0, n]$

pentru algoritmi de tip vag neconstrâns,

$$T_{fc} = \{ t \in \mathfrak{R}^{c \times n} \mid t_{i,j} \in [0,1], \sum t_{i,j} = 1 \} \quad (7.7.)$$

pentru algoritmi de tip probabilistici și de tip vag constrâns,

$$T_c = \{ t \in \mathfrak{R}^{c \times n} \mid t_{i,j} \in \{0,1\} \} \quad (7.8.)$$

pentru algoritmi de tip concret.

Fiecare matrice de transformare, numită și matrice de partiționare, va genera un vector etichetat după tipul matricii folosite.

Conform [Neg02] utilizarea matricilor de tip probabilistic și în special a celor de tip vag dau rezultate mai bune, deoarece nuanțează problematica deciziei, oferind soluții plauzibile și mai apropiate de percepția umană.

De fapt, partiționarea optimă depinde și de natura problemei care urmează să fie rezolvată, la diferite întrebări ridicate de diferite probleme se obțin diferite soluții optime. Pentru a se obține soluția optimă, în funcție de tipul problemei se pot aplica

diferiți algoritmi cu aceiași parametri, sau același algoritm cu parametri diferiți, iar în caz general diferiți algoritmi cu parametri diferiți, fiecare tip de algoritm permițând folosirea mai ușoară a unor criterii sau a altora. Astfel, tehnicile ce folosesc numere concrete folosesc subseturi reale de vectori, permițând definirea mai ușoară a unor măsurători, ca cele de volum sau separabilitate. Aceste valori se pot obține prin calcule directe din datele de intrare, ca de exemplu în [Mor02]. În cazul algoritmilor probabilistici se poate obține direct din datele inițiale densitatea de probabilitate, iar în cazul algoritmilor ce utilizează mulțimi vagi se pot face determinări de măsurători directe după defuzzificare.

O altă categorie de algoritmi determină mărimi ce reflectă repartiții structurale ale datelor de intrare, măsurătorile fiind de tip indirect, ca de exemplu calculul entropiei informaționale [Jun01]. Pentru aceste tipuri de algoritmi se face determinarea performanțelor și luarea deciziei asupra partiționării prin compararea acestor mărimi unificatoare pentru o varietate de tipuri de date. Drept rezultat, acești algoritmi sunt incluși în cadrul metodelor indirecte. În general valorile rezultate prin aplicarea algoritmilor indirecti sunt expresii ale distribuțiilor sau ale repartiției datelor primare. Rezultă că avantajul principal este posibilitatea comparării unor date de naturi diferite, dar există și un dezavantaj, ce constă în pierderea unor informații specifice care ar putea ulterior să fie folosite la realizarea unei structurări.

În această ordine de categorizare, o a treia grupă de algoritmi o reprezintă cea care propune efectuarea unei sarcini și calcularea unui indice de performanță care să facă diferențierea între diferite seturi de date de intrare, iar în funcție de trecerea sau nu peste anumite praguri să facă validarea sau nu a rezultatului și implicit clasarea. Acești algoritmi au avantajul de a putea opera cu seturi eterogene de date. Deci pot fi utilizate atât numere concrete, cât și numere probabilistice sau vagi.

Cea mai reprezentativă metodă de partiționare, care are un număr mare de variante, este cea a prototipului determinat prin medie, cunoscut în literatura de specialitate prin algoritmul c-means. Pentru numere concrete metoda își propune să minimizeze suma pătratică a erorii. Forma cea mai răspândită a acestei relații este cea în care eroarea se măsoară ca distanță euclidiană între prototip și vectorul formei ce se analizează :

$$E_{i,j} = \sqrt{\sum_{i=1,n} \sum_{j=1,c} (x_i - v_j)^2} \quad (7.9.)$$

unde  $v = (v_1, v_2, \dots, v_c)$  este vectorul centrului de greutate al formelor preexistente sau învățate, respectiv prototipul,  $c =$  numărul de partiții posibile, iar  $x = (x_1, x_2, \dots, x_n)$  este vectorul formei de analizat. Obiectul va fi etichetat ca aparținând partiției față de care eroarea relativă este cea mai mică.

Algoritmul ISODATA pornește de la o metodă de calcul identică dar consideră că numărul  $c$  de partiționări este necunoscut, optimul clasării fiind determinat pe baza unui prag de minim local.

Variantele la metoda prototipului prin centru de greutate generalizează formula de calcul prin diferite metode. O abordare care include o mare parte din algoritmi folosiți este reprezentată de formula de mai jos :

$$E_m(t, v, x) = \sum_{i=1,n} \sum_{j=1,c} (t_{i,j})^m D_{i,j}(v, x) \quad (7.10.)$$

unde  $t_{i,j}$  este o transformare de ponderare,  $v = (v_1, v_2, \dots, v_c)$  este vectorul centrului de greutate al formelor preexistente sau învățate, respectiv prototipul,  $c =$  numărul de partiții posibile,  $x = (x_1, x_2, \dots, x_n)$  este vectorul formei de analizat, iar  $D_{i,j}$  este o distanță generalizată folosind de obicei o normă Minkowski de forma :

$$D_{i,j} = \|x_j - v_i\| = [(x_j - v_i)^T A (x_j - v_i)]^{1/m} \quad (7.11.)$$

cu  $A$  reprezentând orice matrice pozitiv definită.

Metoda se poate adapta și pentru cazurile când nu se dă apriori un centru de greutate sau nu există la învățare un set de vectori pentru antrenament. În acest caz, se recalculază după fiecare clasare noile centre de greutate pe baza formelor deja clasate, iar în acest



mod iterativ se determină o aproximare din ce în ce mai bună a prototipurilor. Metoda are avantajul evident că nu necesită supervizare dar este sensibilă la setul inițial de forme și la ordinea în care sunt prezentate formele. Rezultatele sunt cu atât mai nesigure cu cât numărul formelor de clasat este mai mic. Cu toate dezavantajele enumerate algoritmi bazați pe această tehnică, precum și alții derivați din acesta, sunt larg utilizați deoarece reprezintă o modalitate relativ ușoară și naturală de implementare.

### **7.3.1.3 Extragerea trăsăturilor de tip vag**

Deoarece elementele cu care operăm sunt de tip vag atunci și extragerea trăsăturilor se va face cu o metodă de același tip adică prin grupare de tip fuzzy. Metoda utilizată pentru extragerea trăsăturilor din această lucrare se bazează pe o abordare originală a determinării gradului de incertitudine folosind relația de similitudine prezentată în [Ped05].

O primă observație se referă la legătura dintre valoarea informației, așa cum a fost definită de Shannon și măsura în care un obiect poate fi recunoscut. În acest sens, ambele măsurători au aceeași limita inferioară, respectiv unde nu există informație în sens Shannon, nu există gradient care să creeze o caracteristică care să poată fi observată. Un captor care indică mereu aceeași stare nu poate fi folosit pentru recunoaștere. În schimb la limita superioară, asemănarea nu mai este valabilă. O informație maximă din punct de vedere a definiției Shannon nu reprezintă obligatoriu o posibilitate mai bună de etichetare, respectiv de recunoaștere. Pentru recunoaștere nu este atât de importantă variabilitatea (dacă aceasta a depășit un anumit prag), ci raportul existent între componente, deoarece recunoașterea se bazează pe identificarea unei relații deja cunoscute. Deci, dacă nu se determină relațiile căutate nu se face recunoașterea, indiferent de variația informației.

O altă observație se referă la semnificația observației, care este externă procesului de etichetare. Prin atribuirea unei semnificații, obiectul primește un nume și

în același timp i se atribuie un set de proprietăți, precum și o serie de relații de asociere în care intră cu alte entități:

$$A_j \rightarrow NUME(A_j) \mid NUME(A_j) \in \{Clase Prop + Asoc\} \quad (7.12.)$$

unde  $A_j$  reprezintă atribute ale obiectului  $O_j$ .

Prin atribuirea semnificației obiectul  $O_j$  este inclus ca element al unei granule într-un concept, atribuindu-se și atribute, respectiv proprietăți care nu au fost determinate prin observația inițială ce a determinat etichetarea. În [You02] se face o definiție a noțiunii de *atribut canonic* al unui obiect, care reprezintă un element din mulțimea atributelor ce nu au nume, deci nu au fost interpretate, iar o granulă obținută prin partiționarea determinată de acest atribut, se numește domeniu canonic. Folosind aceste noțiuni se poate stabili relația de izomorfism care există între patern-urile din reprezentări prin atribute diferite ale aceluiași obiect sau fapt. Dar după interpretare acest izomorfism dispare, așa cum am arătat în capitolul precedent. Trebuie menționat că modul de abordare din articolul citat, cu toate că este justificat în contextul demonstrației pe care o face, este restrictiv, în măsura în care o etichetare respectiv un proces de recunoaștere nu este obligatoriu legat de un proces de interpretare

### 7.3.2. Stabilirea marginilor de incertitudine

Din cele prezentate pe parcursul lucrării se observă utilizarea a diferite metode prin care se stabilesc margini superioare și inferioare pentru caracterizarea obiectelor. În acest sens generalizarea teoriei probabilităților prezentată de Demster și Schaffer în teoria maselor, a impus introducerea noțiunilor de plauzabilitate și credibilitate ca limite ale unei zone de incertitudine rezultată din calculul efectuat asupra elementelor constitutive, numite mase (a se vedea cap.4). Noțiunile astfel introduse sunt relaționate prin formula de complementaritate. Asemănător, în teoria posibilității există o complementaritate între cele două limite care sunt definite. Astfel gradul de posibilitate

și cel de necesitate sunt limite între care pot exista incertitudini referitoare la un fenomen. Însă restricțiile legate de valoarea fixă a uneia dintre margini, când cealaltă variază, limitează operabilitatea acestora. Teoria mulțimilor grosiere este prin definiție axată pe două limite, respectiv aproximarea superioară și aproximarea inferioară a unei submulțimi, spațiul dintre cele două aproximări fiind considerat ca o regiune de graniță în care definirea este incertă. Până și în teoria fuzzy există o abordare dualistă a gradului de apartenență. Astfel Atanassov a introdus un concept legat de gradul de neapartență [Vla05] ca o estimare a nivelului în care se consideră că un atribut nu aparține unui obiect. Acest coeficient nu este definit ca fiind obținut prin operația de complementare, ci se stabilește prin aceeași metodologie ca și coeficientul de apartenență, unica limitare fiind ca suma celor doi coeficienți să fie mai mică sau cel mult egală cu unitatea. O abordare mai apropiată de cele ce urmează să fie prezentate în această lucrare este modul de mapare a granularității specificat în [Bor97]. În această abordare se consideră două aproximări ale unei funcții de apartenență prin două serii de drepte ce delimitează superior, respectiv inferior curba funcției de apartenență pe intervalele definite de granularitate.

Relația de calcul a delimitării superioare este:

$$\hat{R} = \sup\{a \in [0,1] \mid a \otimes A(x) \leq \lambda\} \quad (7.13.)$$

unde  $\otimes$  este t-norma aleasă, iar  $\lambda$  este posibilitatea atributului  $A(x)$

iar relația de calcul a delimitării inferioare este:

$$\tilde{R} = \inf\{a \in [0,1] \mid a \oplus (1 - A(x)) \geq \mu\} \quad (7.14.)$$

unde  $\oplus$  este co-norma aleasă, iar  $\mu$  este necesitatea atributului  $A(x)$

Toate teoriile prezentate au în comun stabilirea a doua nivele între care se definește zona de incertitudine. Pe baza acestor observații se vor introduce două grade de asemănare care să delimiteze în mod fuzzy o zonă de incertitudine [Bar06b], în care nu se poate stabili o etichetare a trăsăturii observate. O astfel de limită este gradul de asemănare între trăsătura observată și unul dintre prototipurile existente (notată cu  $S$  de la *sameless* și nu cu  $A$ , pentru a nu introduce o confuzie cu notația atributelor), iar cea de-a doua este gradul de deosebire dintre trăsătura menționată anterior și o vecinătate de prototipuri ce implică alte etichetări (notată cu  $D$ ). În acest mod se pune în evidență posibilitatea de confuzie între două etichetări, dacă trăsătura este apropiată atât de un prototip, deci având un grad de asemănare mare cât și de un alt prototip față de care are un grad de deosebire mică. Rezultă într-un astfel de caz că nivelul de incertitudine (stabilit de diferența mare dintre nivelul de asemănare și cel de diferențiere) este mare, etichetarea fiind mai incertă. Dacă în schimb gradul de asemănare cu un prototip este mare și gradul de diferențiere față de alte prototipuri este de asemenea mare, atunci zona de incertitudine este mică, etichetarea având un grad ridicat de încredere. Dacă gradul de asemănare cu un prototip este mic și gradul de deosebire față de altul este mic rezultă ca trăsătura este mai apropiată de al doilea prototip și se cere recalcularea nivelelor față de altă referință. O altă posibilitate o constituie cazul în care nivelul de asemănare este mic iar cel de deosebire este mare față de toate celelalte prototipuri. În acest caz trăsătura nu este utilă pentru procesul de etichetare. Bineînțeles, gradele de asemănare și deosebire fiind de tip vag, valorile obținute sunt încadrate în intervalul  $0,1$ .

Pentru experimentări am folosit ca funcție în vederea calculării gradului de asemănare relația de similitudine față de prototipul de referință, așa cum este definită în [Bar02], iar ca funcție de deosebire, minimul complementarelor funcțiilor de similitudine față de celelalte prototipuri. Trebuie menționat că similitudinea este o relație mai tolerantă decât echivalența, deoarece din cele trei proprietăți ale echivalenței: reflexibilitate, simetrie și tranzitivitate, nu utilizează decât două: reflexibilitatea și simetria [Ped02]. Din lipsa proprietății de tranzitivitate rezultă că două trăsături similare cu o a treia, pot să nu fie similare între ele.

Funcția de similitudine este definită ca o conjuncție între o funcție de incluziune și una de dominanță:

$$sim(x, a, b) = incl(x, a) \otimes dom(x, b) \quad (7.15.)$$

în care incluziunea este o funcție de tip implicație a lui  $a$  în  $x$ , iar dominația este o funcție de tip implicație a lui  $x$  în  $b$ . Deci:

$$sim(x, a, b) = (a \rightarrow x) \otimes (x \rightarrow b) \quad (7.16.)$$

iar implicația este definită prin relația:

$$a \rightarrow x = \sup\{c \in [0,1] \mid a \otimes c \leq x\} \quad (7.17.)$$

ceea ce în cazul t-norme de tip produs devine:

$$a \rightarrow x = \begin{cases} 1 & \text{daca } x \leq a \\ \frac{a}{x} & \text{daca } x > a \end{cases} \quad (7.18.)$$

iar în cazul t-norme de tip Lukasiewski devine:

$$a \rightarrow x = \begin{cases} 1 & \text{daca } x \leq a \\ 1 - x + a & \text{daca } x > a \end{cases} \quad (7.19.)$$

Reprezentarea grafică a celor două cazuri de t-norme este prezentată în figura 7.4.


Rezultă că gradul de asemănare se determină cu relația:

$$S(x, a, b) = sim(x, a, b) \quad (7.20.)$$

iar gradul de deosebire se determină [Bar06e] prin relația:

$$D(x,a,b) = \min_{i=1,N} (1 - \text{sim}(y, a_i, b_i)) \quad (7.21.)$$

unde  $\text{sim}(y, a_i, b_i)$  este funcția de similitudine cu celelalte prototipuri în afara celui de referință.



**Figura 7.4.** Reprezentarea grafică a funcției de similitudine pentru t-norma produs și Lukasiewski

### 7.3.3. Determinarea granularității optime

Nivelul de granularitate cu care un detector poate observa un obiect se încadrează de obicei într-o plajă largă de valori și este o funcție de rezoluția spațială și temporală cu care poate obține informații precum și de numărul și dispunerea elementelor de recepție de care dispune senzorul. Rezultă că orice detector are două limite între care poate varia granularitatea informațiilor, una superioară, corespunzătoare granulației celei mai fine, în care se utilizează fiecare semnalizare a tuturor elementelor de captare, și una inferioară care consideră întreaga informație a detectorului ca o singură granulă de informație. Între aceste două limite trebuie aleasă granularitatea optimă care să ofere maximul de semnificație din cazul granularității celei mai mici.

După cum este evident, există două tipuri de granularități, una, a obiectului  $O$ , al cărui set de trăsături  $A_i$  este observat

$$O \rightarrow \{A_1, \dots, A_i, \dots, A_n\} \quad (7.22.)$$

și alta, legată de detector, în care se proiectează trăsăturile obiectului  $P$ , la care se adaugă zgomotul indus de mediul de propagare și modul de recepție din captor  $N_i$  :

$$P(\{A_1 + N_1, \dots, A_i + N_i, \dots, A_n + N_n\}) \rightarrow I_c \quad (7.23.)$$

Această proiecție poate distorsiona, sau chiar anula unele trăsături, ceea ce poate afecta într-o măsură importantă procesul de etichetare.

Pe de altă parte stabilirea nivelului de granularitate este determinantă de cerința de a obține unele trăsături semnificative. Astfel, din punct de vedere al detectorului, o granularitate prea mare implică o cantitate mare de informații care, pe lângă volumul mai mare de prelucrare, conține un nivel mai mare de zgomot și o variabilitate care perturbă extragerea unor trăsături semnificative. Pe de altă parte, o granularitate prea mică implică pierdere de informație și deci un grad mai mare de incertitudine referitor la determinarea trăsăturilor.

Din punct de vedere al unui obiect, trăsăturile după care poate fi etichetat sunt diferite în funcție de granularitatea obiectului în procesul de observare.. Astfel un obiect observat la o distanță mare va avea alte atribute caracteristice, față de același obiect observat la distanță mică, eventual încadrat incomplet în zona de observabilitate. Acest fapt este cauzat de structura obiectului. Astfel, considerăm un obiect având o structură ierarhică (de exemplu structura atomilor care formează materialul), în care structura inferioară  $S^n$ , care are caracteristicile  $A_i^n$ , formează o structură superioară  $S^{n+1}$ , care are caracteristicile  $A_i^{n+1}$ . În acest caz, granule formate din elemente ale structurii inferioare vor forma elemente ale structurii superioare:

$$\bigcup_{j=1}^p S_j^n = S_k^{n+1} \quad (7.24.)$$

dar atributele  $A_i^{n+1}$  nu vor putea fi considerate ca o reuniune al caracteristicilor  $A_i^n$ , deoarece aceste atribute au în mod intrinsec relații poziționale, ierarhice și de altă natură diferite decât elementele constituente. Aceasta datorită, printre altele și a modului de formare a granulelor (care este variabil). Rezultă că pentru fiecare astfel de structură, posibilitatea de etichetare, respectiv de recunoaștere și atribuire a semnificației, depinde de granularitatea observației. Putem deci concluziona că, indiferent de rezoluția cu care se face observația, determinarea caracteristicilor unui nivel de structură se face într-o anumită plajă de granularitate, cu alte cuvinte, chiar dacă în captor avem o informație de rezoluție mare, pentru a eticheta o structură din ierarhia superioară, va trebui să se creeze granularități mai grosiere.

În situațiile reale, când există mai mulți detectori care observă același obiect, granularitățile folosite de fiecare senzor pot fi diferite. Din această cauză trebuie ca înainte de fuziunea informațiilor să fie aduse la un numitor comun, deci la același nivel de granularitate, respectiv la granularitatea cea mai mică.

$$D_{i,j} = S^{-1}(g) \otimes D_N \quad (7.25.)$$

Pe de altă parte detectorul care are posibilitatea de observație mai mare are și informațiile cele mai detaliate despre obiect deci ar avea un nivel de încredere mai mare decât unul care primește o informație de granularitate mai mică.

$$D_j = \oplus (D_{i,j} \otimes r_i) \quad (7.26.)$$

unde



$D_{i,j}$  este informația detectorului  $i$  ponderată cu nivelul de încredere  $r_i$  iar

$\otimes, \oplus$  sunt t-norma respectiv co-norma utilizată.

Totuși, trebuie menționat că cele expuse anterior sunt valabile numai dacă detectorii au acces la același trăsături corespunzătoare aceluiași nivel de granularitate a obiectului observat. Dacă detectorii au posibilități de a furniza informații despre trăsături diferite, datorate granularității diferite, înseamnă că nu se operează pe același set de trăsături, deci nu se poate stabili o granularitate comună a detectorilor. De altfel, dacă există un nivel de încredere ridicat în unul din detectorii care au o granularitate ridicată, nu mai este necesară aducerea senzorilor la aceeași nivel de granularitate, informația provenind de la restul detectorilor fiind ignorată. Această situație este, de exemplu, întâlnită în cazul urmăririi unui obiect deja identificat, așa cum se va prezenta în capitolul următor.

Pentru un anumit set de trăsături specifice unui obiect aferent unei categorii de distanțe, determinarea granularității optime se obține prin determinarea „contrastului” cel mai bun, deci stabilirea nivelului la care avem derivatele de ordinul unu ale funcțiilor de delimitare a grupărilor, se anulează. Iar în cazul soluțiilor multiple se alege granularitatea ce mai mică. Deci se alege granularitatea care dă informația cea mai evidentă.

Dar, deoarece în majoritatea cazurilor nu avem o funcție de clasificare determinată analitic, iar granularitatea în captor variază în mod discret, soluția pe care o adoptăm este determinarea nivelului de diferențiere a grupării pentru diferite granularități. Metoda, deși conduce la o soluție suboptimală, are avantajul de a avea un algoritm relativ simplu. De asemenea, voi lua în considerare continuitatea transformării frontierelor din grupări, în raport cu o modificare monotonă a granularității. Pentru determinarea gradului de delimitare între grupări voi folosi ca funcție obiectiv formula entropiei aplicată asupra factorului de incertitudine:

$$H(I) = - \sum_{i=1, N} (I_i \cdot \log I_i) \quad (7.27.)$$

unde  $I$  este gradul de incertitudine a unui element și se determină cu relația  $I=S-D$ , sau, dacă se folosește forma normalizată, se poate utiliza relația:

$$I = \left| \frac{S-D}{S} \right| = \left| 1 - \frac{D}{S} \right| \quad (7.28)$$

Granularitatea suboptimală  $G_{opt}$  este stabilită pentru cazul în care funcția obiectiv are cea mai mică valoare:

$$G_{opt} = \{G_j \mid H_j = \min_{j=1,N} H(I)\} \quad (7.29.)$$

Trebuie menționat că pentru diferite seturi de trăsături utilizabile, pentru etichetarea unui obiect observat la diferite granularități, vor exista diferite granularități optime ale informației din detector. Deci la intervale mai mari de variație a granularității de a observare a unui obiect, există diferite seturi de trăsături ce permit etichetarea, iar în cadrul acestor intervale există cel puțin o granularitate optimă care pune în evidență cel mai bine respectivul set de trăsături. În zonele de trecere de la o trăsătură caracteristică la alta gruparea corespunzătoare unei trăsături se estompează și se configurează o altă grupare a următoarei trăsături caracteristice.

## 7.4. Urmărirea obiectului

Metodele de urmărire a obiectelor (tracking) își propun să stabilească, pe tot parcursul existenței unui obiect într-o imagine, poziția acestuia în spațiul prezent în cadru. Prin aceste proceduri se obține o reducere a efortului de calcul și o economie a resurselor necesare recunoașterii scenelor din imagini, deoarece odată rezolvată problema recunoașterii obiectelor, acestea sunt numai urmărite, păstrând-și etichetarea primită la început pe tot parcursul apariției lor în cadre. Din multitudinea de abordări


posibile, am ales două: una, ce folosește valori ferme și se bazează pe principiul continuității mișcării, și una fundamentată pe teoria mulțimilor fuzzy.

O primă abordare, pe care am experimentat-o, folosește o metodă de tip clasic, cu valori concrete și a fost finalizată în 2003 [Bar03]. Urmărirea se face cu o cameră video ce se poate roti după două axe, încercând să aibă imaginea centrată pe obiectul studiat. Procedura implică o analiză spațio-temporală, în care se determină diferențele dintre cadrele consecutive și centrarea camerei pe noua poziție. Metoda se bazează pe presupunerea de continuitate a mișcării, cea ce implică regăsirea obiectelor într-o vecinătate apropiată de la un cadru al imaginii la altul. Probabilitatea de a găsi pixeli corespunzători unui obiect este dată, pentru intervalele în care nu se schimbă condițiile de iluminare, de relația:

$$P(x, y, t) = \alpha(|I(x, y, t) - I(x + \delta x, y + \delta y, t + \delta t)|) \quad (7.30)$$

unde  $\delta x = v_x \cdot \delta t$ ,  $\delta y = v_y \cdot \delta t$ , iar  $I(x, z, t)$  reprezintă intensitatea unui pixel dat în nivele de gri. Deci se condiționează ca viteza de deplasare a obiectelor să fie mult mai mică decât frecvența de captură a imaginilor, ceea ce în general nu este o cerință prea severă.

Aplicația realizează captura a două imagini consecutive, fără a mișca camera video și efectuează o normalizare a capturilor. Un astfel de exemplu este prezentat în figura 7.5.




Imagine 1

Imagine 2

**Figura 7.5.** Exemplu de două imagini consecutive ale unui obiect

După descompunerea imaginilor în RGB se stabilesc pixeli corespondenți a căror diferență depășesc o valoare de prag stabilită experimental la 45 din cele 256 de valori posibile și care sunt considerați pixeli din zona de mișcare. În acest mod se creează o nouă imagine care delimitează zona ce cuprinde pixeli extrași ca diferență dintre cele două cadre succesive din imaginile de bază (fig. 7.6.). Pentru acest domeniu ce conține mișcarea se determină coordonatele centrului, care vor fi memorate pentru a fi folosite în stabilirea impulsurilor care comandă motoarele pas cu pas ce rotesc camera video și pentru a stabili o zonă de căutare în următoarea iterație.



**Figura 7.6.** Imaginea deplasării obiectului

Pentru realizarea practică s-a folosit o camera video de tipul descris în [M19] conectat la un calculator prin interfață USB. Rezoluția utilizată a fost de 640x480 de pixeli. În urma experimentelor, rezultatele obținute au fost bune pentru cazul în care în zona de urmărire din imagine era în mișcare numai obiectul studiat, chiar dacă erau modificări ale condițiilor de iluminare, care apar la rotirea camerei în procesul de urmărire. Dar, dacă simultan cu obiectul urmărit se mai mișcau și ale elemente din imagine era posibil să se piardă urmărirea, camera trecând la determinarea poziției unei ținte false. Pentru eliminarea acestui neajuns ar fi trebuit să se extragă câteva caracteristici ale obiectului urmărit (ca de exemplu: culoarea sau forma) și îmbunătățit algoritmul prin determinarea mișcării numai pentru elementele din imagine care au aceste trăsături. Un alt element care îmbunătățește algoritmul de tracking este folosirea determinării poziției tridimensionale a obiectelor, ceea ce intenționez să realizez în cadrul tezei.

Pentru a doua metodă experimentată, am utilizat o abordare bazată pe teoria

mulțimilor vagi [Bar05b]. În literatura de specialitate există deja numeroase articole care abordează problema urmării unui obiect în mișcare prin aceste metode. De exemplu în [Yen96] este prezentat un robot de navigație care în mod reactiv evită obstacole, urmărite cu o cameră video. Lucrarea [Ayc97] descrie un mobil având detectori ultrasonice și senzori în infraroșu, care are misiunea de a ajunge la o destinație stabilită, iar în articolul [Mur98] se prezintă de asemenea un vehicul experimental pentru navigație. Spre deosebire de aceste studii, în cazul prezentat în continuare se folosește o metodă mixtă, de urmărire, respectiv după determinarea zonei în care are loc mișcarea, se face o recunoaștere stereoscopică, care este urmată de o procedură de urmărire a obiectului numai după o singură trăsătură caracteristică, respectiv după aria suprafeței observate.

Pentru o bună supraveghere a mediului înconjurător, având un unghi mare și o rezoluție înaltă și în același timp pentru a folosi un număr cât mai mic de aparate video de supraveghere (pe cât posibil având performanțe obișnuite, pentru a nu ridica prea mult prețul de achiziție al echipamentelor) s-a folosit un sistem format din 3 camere video fixe cu CCD și unul mobil aflat în mijlocul sistemului, orientat înainte, care are posibilitatea de a se roti cu 60 de grade la dreapta și 60 grade la stânga. Două dintre camerele video fixe sunt plasate, în plan orizontal față de cel mobil, la dreapta și la stânga între ele existând un unghi de 120 grade ( camera mobilă fiind la mijloc), iar al treilea s-a montat în plan vertical față de camera mobilă.

Fiecare dintre camerele video fixe vizualizează o parte din spațiul de supravegheat, iar împreună cu camera mobilă pot să formeze o imagine stereoscopică. Rezultă că în funcție de poziția pe care o are camera video mobilă, una din imagini va fi stereoscopică, iar celelalte două vor fi monoscopice. Rezultă că în combinație cu camera video mobilă, sistemul are o linie epipolară orizontală pentru camerele din partea stângă și din partea dreaptă, și o linie epipolară verticală pentru camera din față.

Pentru fiecare sistem stereoscopic s-a folosit același algoritm bazat pe metoda 3D Depth Flow, care definește un vector de mișcare 3D pentru fiecare punct. Aceasta înseamnă că se urmărește o evoluție spațială cât și temporală a tuturor punctelor. Prima dată după achiziție, se construiește histograma imaginilor. Normalizarea histogramei se

realizează pentru nivelele de gri, mai întâi pe orizontală pentru a se obține aproximativ aceeași nivel de iluminare, iar apoi pe verticală, pentru a se obține un contrast cât mai constant. Chiar și așa, fiind o ambianță naturală, poate să apară o fluctuație a strălucirii obiectelor în imagine. Acest fapt impune folosirea unui prag de sensibilitate pentru variația culorilor și a strălucirii, sub care obiectele să poată să-și modifice aceste caracteristici de la un cadru la altul. Astfel, se creează granule de informație, mici variații ale caracteristicilor fiind considerate ca neglijabile. Vectorul de mișcare este definit de un vector de diferență MV având forma

$$\begin{bmatrix} x_j^L(t_{i+1}) - x_j^R(t_i) \\ y_j^L(t_{i+1}) - y_j^R(t_i) \\ E_j(t_{i+1}) - E_j(t_i) \end{bmatrix} \quad (7.31.)$$

unde  $E_j(t_i)$  este distanța pe linia epipolară între punctele corespondente din imaginea stângă respectiv din imaginea dreaptă. Punctele corespondente se determină pe baza similitudinii de intensitate a pixelilor din cele două imagini. Relația de stabilire a acestor perechi de puncte este:

$$C(x_j, y_j, e_j) = \min_{k,m} |I_j(x_j + k, y_j + m) - I_{i+1}(x_j + e_j + k, y_j + k)| \quad (7.32.)$$

În cazul liniei epipolare verticale, relația este asemănătoare, doar că coordonatele x sunt înlocuite cu y. După stabilirea distanței între puncte corespondente, și cunoscând distanța focală optică, se poate calcula distanța de la camerele video la obiect. Această metodă poate fi îmbunătățită printr-un algoritim iterativ, similar celui prezentat în [Kag00].

Dimensiunea unui obiect în cadrul unei imagini depinde de distanța la care se află acel obiect față de camera video. Din acest motiv, odată stabilită distanța față de un obiect, se poate înlocui procesul de calculare a distanței cu cel de stabilire a mărimii ariei obiectului în cadrul imaginii. Astfel, se obține o reducere semnificativă a timpului

de calcul, precum și a resurselor utilizate de unitatea de procesare. Deci, pur și simplu se va folosi o estimare a distanței  $d$  față de obiect prin determinarea mărimii ariei  $a$ . Precizia de estimare depinde de calitatea, respectiv rezoluția imaginii precum și de distanța la care se află obiectul (a se vedea considerentele despre senzorii conici din subcapitolul următor). Funcția  $a(d)$  este neliniară și depinde de caracteristicile optice ale camerelor video. De asemenea, trebuie stabilite două praguri de detecție. Unul minim, sub care variația ariei poate fi considerată ca fiind cauzată de zgomotul ce afectează informația, și unul maxim, peste care se consideră încălcată legea de continuitate a mișcării. O astfel de situație poate fi determinată de cauze cum ar fi obturarea obiectului, sau schimbarea condițiilor de vizibilitate, ceea ce determină trecerea la o nouă stabilire a distanței prin stereoscopie.

Experimentările efectuate au stabilit, confirmând considerațiile teoretice, posibilitatea de a realiza o urmărire a unui obiect prin această metodă. Camerele video folosite au fost de tipul [M17], având 420 de linii pe cadru, iar digitizarea s-a realizat printr-o placă de captură de tipul [M18]. Obiectele observate au fost monoculore, fără textură. Pentru obiectele care au o textură complexă, mai sunt necesare și alte experimente.

## 7.5. Concluzii.

Despre prelucrarea semnalelor video, s-au scris numeroase lucrări, existând publicații specializate pe acest domeniu, iar unul din subiectele cele mai frecvente abordează tematica referitoare la recunoașterea formelor. Lucrarea de față nu își propune să analizeze în detaliu modul de segmentare a imaginii sau felul în care se obțin trăsăturile din imagini, pentru stabilirea trăsăturilor fiind utilizate unele metode cunoscute, bazate pe prototipuri. Ceea ce aduce nou prezenta teză este legat de considerentele teoretice și verificări practice referitoare la aplicarea în domeniul supravegherii video a unor teorii noi din domeniul „soft computing”. În acest sens s-a fundamentat o metodă de stabilire a intervalului de incertitudine, în spațiul




caracteristicilor unui obiect, folosind mulțimile de tip robust introduse de Pawlak în 1982 [Paw82], prin folosirea noțiunii de disimilitudine. Chiar măsura denumită de disimilitudine este o aplicare a teoriei mulțimilor grosiere la gruparea prin similitudine de tip fuzzy prezentată de Pedrycz [Ped05]. De asemenea, folosirea granularității multiple și determinarea granularității optime este o aplicare a noțiunii de granularitate la obținerea caracteristicilor unui obiect care se apropie sau se depărtează de un sistem video.



## Capitolul VIII. Sistemul bazat pe detectori PIR

### 8.1. Introducere

Așa cum s-a mai menționat cele mai multe sisteme de alarmă antiefracție folosite astăzi utilizează ca senzori de mișcare detectori PIR. Răspândirea acestui tip de detector se datorează în primul rând prețului scăzut și modului simplu de utilizare. Cu toate acestea, există câteva inconveniente legate de utilizarea acestor senzori. Astfel, principiul de funcționare este, așa cum am mai arătat, bazat pe detectarea gradientului de temperatură. Din această cauză, detectorul nu poate face deosebire între mișcările efectuate de obiecte și cele accidentale, cum ar fi rafalele de vânt, sau curenții de aer. De asemenea, din chiar principiul de funcționare, există posibilitatea unui număr mare de alarme false, deoarece nu se poate discrimina între un om și animalele care pot apărea în zona de supraveghere.



**Figura 8.1.** Reprezentarea modului de detecție a senzorului PIR

Acest fapt este cauzat de detecția de tip conic, care sesizează obiectele mari dar îndepărtate, la fel ca obiectele mici și apropiate. Astfel, deși există detectori care au în specificație că sesizează obiecte mai grele de 30 de kilograme (PET detectors), în realitate, dau alarme și la obiecte mai mici dar apropiate. În afară de aceste considerente mai trebuie reamintit că modul de receptare a informației în cadrul detectorului se face prin lentile Frenel, ceea ce determină formarea unor fante de

deteție (a se vedea fig.8.1.), a căror caracteristică este dificil de analizat de instalator. Acest fapt se datorează fișei tehnice care însoțește detectorul și care este foarte sumară, conținând mai multe elemente de prezentare a modului de montare pe perete, decât date tehnice referitoare la funcționare.

Mai trebuie amintit și efectul numit de „orbire” pe care îl au aceste tipuri de detectoare odată cu trecerea timpului. Acest efect este produs de opacizarea lentilei, care din cauza căldurii ambientale, își pierde calitățile optice și cu vremea are o rază de dectecție tot mai mică. Ca rezultat al acestui fenomen și a lipsei de informații provenite de la fabricant, nu se poate stabili în timpul funcționării raza certă de acțiune a detectorului. Pe de altă parte, când nu există mișcare, sistemul de alarmare nu poate detecta dacă senzorii din componență sunt complet, sau numai parțial în stare de funcționare, acest fapt rezultând numai în procesul de dectecție a mișcării. Toate aceste considerente fac ca metodele legate proiectarea, testarea și modul de localizare a intruziunii să se facă de obicei pe baze empirice.

Din considerentele mai sus amintite, se va prezenta în continuare o metodă de proiectare, una de testare și una de localizare pentru acest tip de detector. Astfel, se poate stabili o determinare a poziției, a suprafeței de radier și o estimare a încrederii acordate sistemului de detectori, ceea ce permite realizarea fuziunii informației cu cele provenite din sistemul video și deci o creștere a gradului de performanță a întregului sistem.

## 8.2. Metoda de proiectare a sistemului

Analizând modul de funcționare a detectorului, se poate observa că detectarea semnalului de ieșire este o funcție ce depinde de mai mulți parametri ambigui:

$$D_{i,j} = f(\Delta T, l, v, S) \quad (8.1.)$$

unde :

$D_{i,j}$  este valoarea semnalului de ieșire furnizat de senzorul  $i$ , corespunzătoare detectării locației  $j$ ,

$\Delta T$  este diferența de temperatură între mediul ambiant și obiectul ce este sesizat în zonă,

$l$  este distanța între detector și obiect,

$v$  este viteza cu care se mișcă obiectul în spațiul supravegheat ,

$S$  este suprafața termică a obiectul sesizat.

Rezultatul obținut din relația precedentă îi este aplicată o funcție de prag, rezultând semnalul de alarmare furnizat de detector. În condiții reale, elementele constituente ale funcției sunt estimate în mod grosier din cauza condițiilor incerte și a domeniului mare în care poate varia multitudinea obiectelor detectate.

Toate aceste argumente, ce au un caracter vag, conduc la propunerea de a utiliza metodele de tip fuzzy pentru proiectarea și testarea unui sistem de alarmă. Prin această abordare se poate opera mai natural cu parametrii ce influențează detecția [Bar05]. Astfel, suprafața radiantă poate fi evaluată prin variabile lingvistice precum : mică, medie sau mare; viteza obiectului poate să fie: repede, normală sau lentă, iar temperatura poate să aibă atașate valorile lingvistice: rece, normal sau caldă. Pentru toate aceste variabile lingvistice s-a luat în considerație o funcție de apartenență fuzzy de tip de triunghiulară.


Algoritmul se desfășoară în două faze :

**FAZA 1.** Prima etapă a acestui algoritm este comună atât proiectării cât și procesului de testare și constă din determinarea trăsăturilor de tip fuzzy pentru fiecare tip de detector PIR folosit. Această fază este necesară deoarece fiecare producător are un portofoliu larg de echipamente, care nu sunt cuprinse în cadrul nici unei standardizări. Pentru acest proces dispozitivul PIR este montat într-un spațiu gol, a cărui dimensiuni este de dorit să aibă valori mai mari decât de raza de sensibilitate indicată în foaia

tehnică (fig. 8.2.). Spațiul (sau suprafața) este împărțit printr-un caroiaj în suprafețe ce sunt considerate semnificative pentru aplicație (de exemplu având latura de 1 m ) și care aproximează forma spațiului de detecție indicat în documentație (care în cele mai multe cazuri are aspectul unui sector de cerc).

Un obiect (sau o persoană) este poziționat consecutiv în centrul pătratelor de pe o diagonală a razei de detecție (caracteristicile sunt aceleași la aceeași distanță de detector) și se efectuează câte o mișcare cu diferite suprafețe de radiație termică, având diferite viteze. De exemplu, în cazul unei persoane, i se va cere să-și miște mâna (H), brațul și corpul (B) cu trei viteze diferite: lentă (S), normală și rapidă (F), ceea ce înseamnă 9 experiențe pentru fiecare componentă. Pentru fiecare experiență, se va observa valoarea semnalului de ieșire a detectorului, ceea ce, în general, este semnalizat de un LED aflat în componența sensorului. Aceste informații vor permite realizarea unor hărți cu caracteristicile fuzzy pentru fiecare dispozitiv de tip PIR. Această determinare a caracteristicilor trebuie făcută doar odată pentru fiecare tip de dispozitiv.

**FAZA 2.** În această etapă, pentru optimizarea proiectului, se va utiliza un program bazat pe un algoritm genetic (GA). Funcția obiectiv pentru algoritm va fi nivelul de protecție pentru întreg spațiul supravegheat.



**Figura. 8.2.** Exemplu ariei de detecție a doi detectori S1 și S2

Ca rezultat, algoritmul furnizează pozițiile optime ale detectoarelor PIR care pot să acopere suprafața de supraveghere astfel ca factorul de protecție să fie maxim. Intrările

algoritmului genetic sunt:

- granularitatea spațiul analizat (respectiv dimensiunea rastrului),
- numărul de detectoarele PIR folosite și
- caracteristicile fuzzy ale detectoarelor, obținute în primul pas.

Am folosit un program de tip Holland standard GA [Neg02] în care fiecare individ al populației supusă selecției este formată dintr-o poziție a detectoarelor (se consideră că detectoarele pot fi montate numai pe muchia pătratelor din caroiaj).

În finalul metodei de proiectare, se determină valoarea funcției de încredere a senzorilor. Aceasta este un tip de cost, și include o estimare a fiabilității detectorilor în funcție de gradul de încredere stabilit în cadrul fiecărei granule spațiale, Relația este de forma:

$$C = \max \sum_{i=1}^n C_i \quad (8.2.)$$

unde  $n$  este numărul de celule în care este împărțit spațiul supravegheat. Valorile coeficienților de cost sunt codificate după gradul de detectare. Astfel, după defuzzyficare coeficientul  $C$  se egalează cu 0 dacă celula nu poate să fie detectă, cu 1 dacă celula are un nivel de detectare slab, ia valoarea 2 dacă celula are o posibilitate de detectare mijlocie și  $i$  se atribuie valoarea 4 dacă celula are un grad de detectare bun.

### 8.3. Metoda de testare

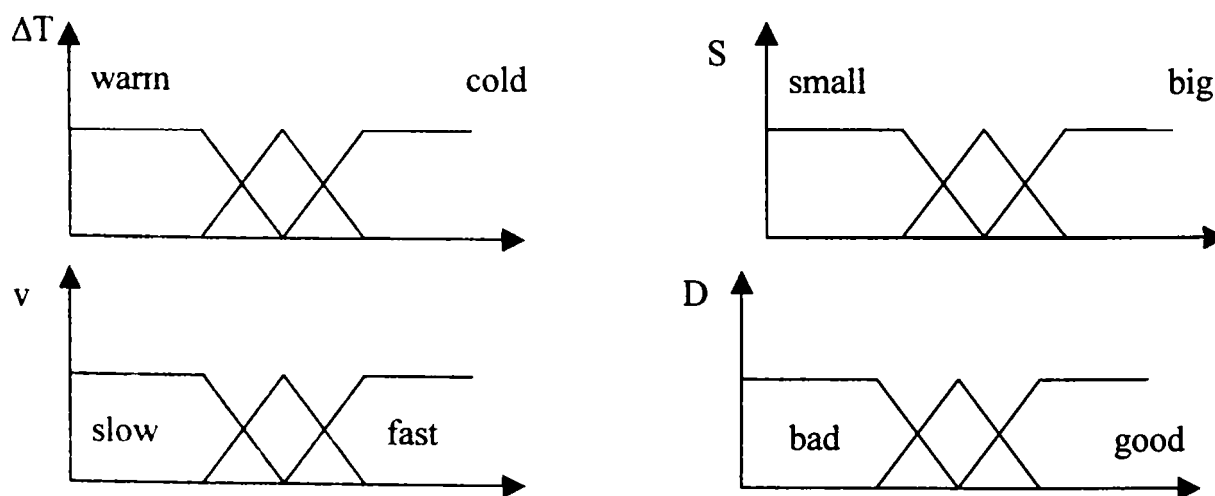
Așa cum s-a arătat anterior, prima fază a metodei este comună cu cea de proiectare.

**FAZA 2.** Pentru testarea modului de funcționare a detectorilor se utilizează un program de asistență a persoanei de service [Bar06d]. Datele de intrare ale programului cuprind:

- poziția pe care o are fiecare detector PIR,
- tabelele ce cuprind valorile caracteristice de tip fuzzy stabilite în FAZA 1 precum și
- configurația spațiului testat.

Programul furnizează la ieșire valoarea lingvistică a fiecărei granule spațiale, ca de exemplu, cea prezentată în figura 8.2. De la acest rezultat furnizat de program, se poate să se determine locațiile unde spațiul inspectat este supravegheat cu un singur sau două detectoare [Bar05c]. În aceste locații se execută aceleași tipuri de determinări ale caracteristicilor senzorilor ca și în faza 1 (respectiv, se testează activarea semnalului de ieșire al detectorului pentru diferite suprafețe termice, deplasate cu diferite viteze). Dacă rezultatul în una sau mai multe asemenea locații este diferit de rezultatul grafic furnizat cu programul, el poate să concluzioneze că unele dintre acele detectoare PIR sunt afectate de „orbire”. Indicând locația care ridică probleme și rezultatul fuzzy așteptat, programul de calculator servește pentru a obține amplasarea detectorului defect, gradul de „orbire” și dacă, în noua situație au apărut spații nesupravegheate. De fapt programul simulează pe diferite grade de reducere a sensibilității detectoarelor PIR care acoperă spațiul supravegheat. Astfel, pot apărea situații în care programul va cere mai multe informații de la operator, ca de exemplu, dacă există posibilitatea ca două sau mai multe detectoare să cauzeze aceeași acoperire nesatisfăcătoare. În această situație, se va repeta determinarea caracteristicilor fuzzy într-o altă locație.

Baza teoretică pentru această metodă este următoarea: pentru fiecare pătrat din caroiaj influența detectoarelor este determinată combinând efectele tuturor parametrilor din funcția de activare, mai puțin cel al distanței, care este inclus în determinările efectuate în pasul 1. Diagramele fuzzy ale parametrilor pentru un detector generic sunt prezentate în figura 8.3.:



**Figura 8.3.** Diagramele fuzzy ale parametrilor detectorului



Relația folosită pentru stabilirea gradului de detecție este:

$$D_{i,j} = \Delta T \otimes S \otimes v \quad (8.3.)$$

unde  $\otimes$  este t-norma folosită.

În cadrul experimentărilor pe care le-am făcut, am folosit funcția minim ca t-normă, astfel relația devine:

$$D_{i,j} = \min_{x \in A} (\Delta T, S, v)(x) \quad (8.4.)$$

Pentru senzorii PIR care nu au vizibilitate de detecție pentru o anumită locație, din cauza faptului că sunt obturați, gradul de detecție este considerat zero.

După ce nivelul de detecție pentru fiecare senzor a fost calculat, fuziunea informațiilor se determină folosind relația :

$$D_j = \oplus_{i=1,N} D_{i,j} \quad (8.5.)$$

unde  $\oplus$  este s-norma.

Deoarece am folosit ca s-normă funcția max, relația devine :

$$D_j = \max_{i=1,N} (D_{i,j}) \quad (8.6.)$$

care reprezintă gradul de detecție global din locația j.

Conform cu [Roy02], se poate stabili o funcție de extensie care să ia în considerare necesitatea unei continuități a mișcării, respectiv o creștere a încrederii în posibilitatea detecției, dacă a fost determinată anterior o detecție la granulele spațiale vecine. Pentru această relație am ales o funcție liniară:

$$D_N = [a_j^l, a_j^m, a_j^r] \oplus [b, b_j^m, b_j^r] \otimes t \quad (8.7.)$$

Acesta înseamnă că dacă un semnal de alarmare este determinat într-o celulă, atunci posibilitatea ca celulele vecine să detecteze o mișcare este sporită. Relația este exprimată prin :

$$D_j^* = (D_N \oplus D_j) \quad (8.8.)$$

Experimentările efectuate pentru această aplicație au vizat testarea eficienței algoritmului prezentat. Am folosit detectori de mișcare prezentați în [M3] care reprezintă un model des folosit în sistemele de alarmare antiefracție.

Așa cum s-a prezentat anterior, prima fază din ambele metode, constă în determinarea caracteristicilor fuzzy ale detectorului. Acest experiment s-a efectuat într-o încăpăre cu o lungime mai mare de 10 m. Detectorul PIR s-a montat frontal pe perete la o înălțime de 4 m. Caroiajul care a fost folosit pentru stabilirea granularității a fost format din pătrate cu latura de 1 m, pe lungimea franjurilor frontale ( a se vedea fig. 8.1.) Testele au fost efectuate în patru condiții ambientale, și anume:

- într-un spațiu cald (notat cu W), folosind obiecte cu o suprafață de radieră termică mică (notat cu S), (condițiile combinate s-au notat cu WS),
- într-un spațiu cald (notat cu W), folosind o suprafață de radieră mare (notat cu B ), (condițiile combinate s-au notat cu WB),
- într-un spațiu rece(notat cu C), folosind obiecte cu o suprafață de radieră termică mică (notat cu S), (condițiile combinate s-au notat cu CS) și
- într-un spațiu rece (notat cu C), folosind o suprafață de radieră mare (notat cu B), (condițiile combinate s-au notat cu CB).

Rezultatele sunt prezente în Fig. 8.4.

**1. condiție caldă și suprafață mică – notat prin WS**

AS	AS	AN	AF	BN	BN	BF	BF	BF	BF
----	----	----	----	----	----	----	----	----	----

10m

**2. condiție caldă și suprafață mare – notat prin WB**

HF	AS	AN	AF	AF	BN	BN	BF	BF
----	----	----	----	----	----	----	----	----

**3. condiție rece și suprafață mică – notat prin CS**

HF	AS	AN	AN	AF	BN	BN	BF	BF
----	----	----	----	----	----	----	----	----

**4. condiție rece și suprafață mare – notat prin CB**

HF	AS	AN	AF	AF	BN	BN	BF
----	----	----	----	----	----	----	----

**Figura 8.4.** Rezultatele determinărilor obținute pentru caracteristicile fuzzy ale unui detector PIR

unde așa cum s-a prezentat și în partea teoretică H semnifică o mișcare pe o suprafață mică (corespunzătoare unei mâini), A semnifică o mișcare pe o suprafață medie (corespunzătoare unui braț) și B semnifică o mișcare pe o suprafață mare (corespunzătoare întregului corp), respectiv S corespunde unei mișcări lente, N corespunde unei mișcări normale și F corespunde unei mișcări rapide, iar testele s-au efectuat în condițiile combinării unei valori fuzzy pentru suprafață, cu una corespunzătoare vitezei. Se observă că rezultatele sunt în concordanță cu previziunile. Astfel, cazul de minimă sensibilitate, a fost cazul WS, iar situația cu sensibilitatea cea mai mare, a fost CB. Se poate remarca, de asemenea, că cazurile WB și CS au fost foarte asemănătoare, deoarece condiția cea mai defavorabilă de temperatură în WB este compensată cu condiția cea mai bună a suprafeței de radiație termică.

În faza 2, din metoda de proiectare, s-au folosit pe rând 1, 2, 4 respectiv 8 detectori PIR și s-au comparat rezultatele în patru condiții de testate. În primul set de teste, s-a simulat prin program, un spațiu de 5 pe 10 m, fără nici un obstacol în interior. În al doilea set de teste s-a utilizat același spațiu, dar având unul din caroiagele din

mijlocul încăperii ocupat cu un obstacol. O problemă care a apărut, a fost creșterea rapidă a populației din algoritmul genetic, față de creșterea pozițiilor posibile ale elementelor de detecție. Acest neajuns poate fi rezolvat printr-o optimizare a algoritmului. Rezultatele pentru primul set de teste care a implicat 1, 2, 4, respectiv 8 detectori PIR și în care nu a existat nici un obstacol, sunt prezente în Tabelul 8.1.

**Tabelul 8.1.** Rezultatele primului set de teste

	1PIR	2PIR	4PIR	8PIR
WS	BF	BN	BN	AF
WB	BF	AF	AF	AS
CS	BF	AN	AN	AS
CB	BN	AN	AS	

**Legendă :**

W = cald                      B = corp  
 C = rece                      A = braț  
 S = mic                        H = mână  
 B = mare                      F = repede  
                                      N = normal  
                                      S = încet

iar pentru al doilea set, care a avut același număr de detectori PIR, dar în care a existat un obstacol, sunt prezentate în Tabelul 8.2.:

**Tabelul 8.2.** Rezultatele setului al doilea de teste

	1PIR	2PIR	4PIR	8PIR
WS	NO	BN	BN	AF
WB	NO	AF	AF	AS
CS	NO	AN	AN	AS
CB	NO	AN	AS	

**Legendă :**

W = cald                      B = corp  
 C = rece                      A = braț  
 S = mic                        H = mână  
 B = mare                      F = repede  
                                      N = normal  
                                      S = încet  
                                      NO = neoperațional

Din tabelele prezentate rezultă că creșterea numărului de detectoare de la unul la două, nu a îmbunătățit gradul de protecție al sistemului în primul caz, în schimb, în a doua configurație, când a existat și un obstacol care a obturat parțial detectorii, creșterea este justificată. Un grad de supraveghere bun se poate realiza folosind 8 detectori PIR dar deoarece creșterea prețului este semnificativă, o astfel de soluție trebuie să fie

analizată și din această perspectivă.

Pentru verificarea metodei de testare, s-au folosit 2 detectoare PIR amplasate în colțurile diagonale ale unei încăperi (considerate în continuare pe plan ca fiind, una în colțul din stânga sus și alta în colțul drept jos). Temperatura obiectului intrus, luată în considerație a fost etichetată cu valoarea lingvistică „cald”. În prima situație s-a considerat că ambii detectori funcționează bine, iar în al doilea caz unul din detectori a fost parțial „orbit” (cel plasat în colțul de jos).

Valorile obținute pentru primul caz sunt prezentate în tabel 8.3:

**Tabelul 8.3.** Valorile obținute pentru primul caz, în care ambii detectori funcționează corect

	HF	AS	AN	AF
HF	HF	AS	AN	AN
AS	AS	AS	AS	AS
AN	AN	AS	HF	HF
AF	AN	AS	HF	

**Legendă :**

B = corp            F = repede  
A = braț            N = normal  
H = mână           S = încet

Iar pentru al doilea caz am consemnat următoarele valori lingvistice (Tabelul 8.4.):

**Tabelul 8.4.** Valorile obținute pentru al doilea caz, în care doar unul dintre detectori funcționează corect

	HF	AS	AN	AF
HF	HF	AS	AN	AF
AS	AS	AS	AN	AN
AN	AN	AN	AS	AS
AF	AF	AN	AS	HF

**Legendă :**

B = corp            F = repede  
A = braț            N = normal  
H = mână           S = încet

Prin compararea rezultatelor din cele două tabele se constată că odată cu

pierderea caracteristicilor de detecție, apare o modificare a valorilor lingvistice determinate în cadrul rastrului, ceea ce permite personalului de service să stabilească, prin compararea valorilor obținute cu cele furnizate de program, care dintre detectori începe să își piardă din caracteristicile de funcționare normale.

#### 8.4. Metoda de localizare și estimare a suprafeței radiate

Pentru stabilirea acestei metode se va folosi pe lângă elemente din teoria mulțimilor vagi și noțiuni din teoria mulțimilor grosiere a lui Pawlak's. Pentru obținerea scopului propus va fi necesară parcurgerea următorului algoritm: [Bar06c]:

- stabilirea caracteristicilor fuzzy pentru detectoarele folosite,
- determinarea granulației care va fi utilizată,
- stabilirea tipului de obiect pe baza gradientului de temperatură,
- localizarea obiectului,
- determinarea vitezei de deplasare a obiectului prin spațiul analizat,
- determinarea tipului de obiect, din punct de vedere al suprafeței de radiație termică,
- aprecierea gradului de încredere a detectorului.


Mai menționez că, fără a pierde din generalitate, în această metodă se vor folosi detectori PIR de tavan, care au unghiul de acțiune de 360 de grade, dar au raza de sesizare mai mică decât senzorii de perete.

**Pasul 1.** Din relația de funcționare a detectoarelor PIR se poate determina o funcție a distanței dacă se cunoaște răspunsul detectorului. Pentru a obține acest deziderat vom determina relația de tip fuzzy între distanța de detecție și restul parametrilor. Se obține astfel formula

$$I_i = f(\Delta T \otimes S \otimes v) \otimes D_j \quad (8.9.)$$


unde  $\otimes$  reprezintă t-norma folosită.

Observând reacția detectorului pentru diferite distanțe, se obține caracteristica de tip fuzzy (modul de determinare a valorilor lingvistice este cel prezentat în paragraful precedent). Se constată că există o incluziune cvasi triunghiulară, așa cum este prezentă în Fig. 8.4. Adică obiectele mai mici pot fi sesizate numai la distanțe apropiate, pe când obiectele mari pot fi observate și la distanțe mari.



**Figura 8.4.** Distanța de detecție a unui obiect în funcție de mărime

**Pasul 2.** De obicei în spațiile mari supravegheate detectorii de tavan sunt amplasați într-o rețea, fiind dispuși la distanțe egale unul de celălalt. Și în acest caz se va lua în considerație o astfel de distribuție a detectorilor, detectorii fiind dispuși în colțurile unor pătrate egale. În acest caz, granularitatea de supraveghere are formă pătrată, centrată pe fiecare detector, iar delimitarea dintre două granule se face la jumătatea distanței dintre detectori. Acest mod de organizare a granularității este justificată de forma triunghiulară a funcției de apartenență a zonei la câte un detector, care are valoarea 1 sub detector și valoarea 0 la coordonatele detectorilor vecini. Rezultă că valoarea maximă de incertitudine (de  $\frac{1}{2}$ ) este la mijlocul distanței dintre detectori, așa cum rezultă și din Fig.8.5.



**Figura 8.5.** Funcția de apartenență a unei locații la un detector  $D_i$

**Pasul 3.** Este determinată variația de temperatură prin măsurarea temperaturii mediului ambiant și presupunerea temperaturii pielii persoanelor care realizează efracția la valoarea lingvistică „cald”, sau se poate estima temperatura externă, în mod empiric, („afară este cald” sau „frig”). Se selectează apoi setul de caracteristici fuzzy, determinate în pasul 1 care corespund variației de temperatură estimată. Se observă care dintre detectori se activează când un obiectul intrus se mișcă în zona supravegheată. Pentru fiecare granulă se va determina tipul de obiect posibil, care a cauzat activarea. Acest deziderat se obține prin stabilirea zonei în care este posibil să fie obiectul (pentru obiecte mici zona va fi mai restrânsă, iar pentru obiecte mari zona va fi mai mare), ceea ce în mod concret presupune suprapunerea vectorilor caracteristicilor fuzzy ale detectorilor și locațiile granulelor din vecinătatea detectorilor activați:

$$T_{i,j} = \otimes_{k=1,n} (Car_k(l)) \quad (8.10.)$$

unde  $T_{i,j}$  este tipul locației (reprezentând gradul în care este posibilă existența obiectului în granulă), iar  $Car_k(l)$  este caracteristica senzorului activat la distanța  $l$  dintre detector și granulă.

Motivul pentru care se utilizează această relație este că detectorul cel mai mult îndepărtat stabilește tipul obiectului (obiectele mari sunt sesizate și de senzorii mai îndepărtați). Dacă sunt mai multe valori ale caracteristicilor care se suprapun în granulă (suprafața granulei s-ar putea să acopere mai multe valori lingvistice), se va determina aproximarea inferioară cât și cea superioară a granulei, corespunzător teoriei mulțimilor grosiere. Pentru detectorii activi, se va considera gradul de apartenență egal cu zero la granule care nu aparțin domeniului de activare. Această operație se face pentru fiecare granulă din spațiul de supraveghere.

**Pasul 4.** În acest pas se determină locația estimată a obiectului intrus prin reunirea tuturor granulelor care au gradul de apartenență diferită de zero .



$$A_h = \bigcup_{T < 0} T_{i,j} \quad (8.11.)$$

Existând o aproximare inferioară și o aproximare superioară pentru granule, rezultă că va exista și o aproximare inferioară și una superioară a zonei posibile de existență a obiectului intrus  $\underline{A}_h, \overline{A}_h$ . Acest rezultat va fi obținut pentru fiecare tip de vector al caracteristicii (câte una pentru fiecare tip de suprafață radiantă și viteză de mișcare). Rezultă, de asemenea, că cea mai probabilă localizarea a obiectului este în mijlocul suprafeței determinate.

**Pasul 5.** Se observă evoluția în timp a mișcării obiectului observat prin estimarea locației, repetând periodic pașii de la 1 la 4. Cunoscând spațiul de mișcare și timpul, se poate estima viteza obiectului.

**Pasul 6.** Prin aprecierea vitezei obținută în pasul 5 se va selecta vectorul caracteristici fuzzy care corespunde vitezei estimate, rezultând din caracteristica fuzzy selectată, suprafața radiantă estimată (fiecare caracteristică are etichetată o viteză și o suprafață radiată). De asemenea știind viteza putem estima și zona de mișcare (pentru o viteză mare corespunde o arie estimată mare, și localizarea este mai nesigură).

**Pasul 7.** Din estimarea locației în care se efectuează mișcarea și din presupunerea de continuitate a pozițiilor succesive ale unei deplasări, se face o estimare a gradului de încredere pe care o are funcționarea fiecărui detector [Bar06]. În această metodă se utilizează aceeași relație liniară ca în paragraful precedent

$$L_N = [a'_j, a''_j, a'_j] \oplus [b, b''_j, b'_j] \otimes t \quad (8.12.)$$

Pentru locațiile care nu sunt în raza de detecție a senzorului, coeficientul de apartenență se consideră ca având valoarea zero.

Încrederea în fiecare detector este determinată în funcție de gradul de apartenență a locației. așteptat  $L_N$  și cel calculat  $L_R$ , în granula de timp  $t$  și  $t+1$ .

$$R_i(t) = R(t-1) + \alpha \cdot \Delta R \quad (8.13.)$$

dacă  $0 < R_i(t) < 1$

sau în rest  $R_i = 1$ , pentru un detector ce funcționează perfect respectiv  $R_i = 0$ , pentru unul complet defect, iar

$$\begin{aligned} \alpha &= \text{sign}[(|L_N - L_R|) - \theta] \\ \Delta R_i &= w \cdot |L_N - L_R| \end{aligned} \quad (8.14.)$$

unde  $\text{sign}$  = este funcția semn, iar  $\theta$  are în general valoarea  $\frac{1}{2}$ .

Pentru experimentări s-a folosit o incintă de 10 pe 10 metri în care au fost au montate detectoare de tavan de tip Dome. Detectoarele au fost poziționate sub formă de pătrat de 4x 4 la distanță de 2 metri unul de celălalt.

**Pasul 1.** În cadrul funcției de apartenență se vor lua în considerație trei valori lingvistice pentru fiecare dintre parametri. Astfel, pentru variația de temperatură s-au considerat valorile lingvistice: mică, medie și mare; pentru viteză: lentă, normală și rapidă; iar pentru suprafața de radiație termică s-au stabilit valorile: mică, normală și mare. Au fost efectuate o serie de 9 experimente, câte una pentru fiecare combinație a variației de temperatură a suprafeței de radiație și a vitezei de mișcare a obiectului. Rezultatele obținute au fost în mare măsură în concordanță cu presupunerile teoretice. Astfel, o viteză mare (respectiv o variație de temperatură ridicată), au fost întotdeauna observate de la o distanță mai mare în comparație cu o viteză mică (respectiv cu variație de temperatură mică). Îndepărtând metru cu metru obiectul de detector, au fost efectuate mișcări cu 3 viteze diferite și s-au notat reacțiile (de activare sau nu) ale detectorului. Pentru fiecare experiment a fost creat un vector cu valorile observate.

**Pasul 2.** Distanța între detectoare fiind de 2 metri, granularitatea inițială a fost stabilită la 2 pe 2 metri.

**Pasul 3.** Experiențele au fost efectuate cu trei 3 tipuri de obiecte, anume cu unul considerat mic, unul mediu și unul mare. Variația de temperatură a fost determinată ca fiind normală. Pentru fiecare tip de obiect au fost realizate câte un set de 3 experiențe, în fiecare obiectul având viteze diferite. Experiențele au fost repetate cu un subiect uman îmbrăcat în modurile diferite, astfel încât suprafața sa radiantă să fie cât mai variată și vitezele de mișcare să fie diferite.

**Pasul 4.** Conform experiențelor, s-a confirmat că granularitatea obținută pentru obiectul observat este în legătură cu viteza obiectului. În cazul creșterii vitezei a fost observată o creștere a dimensiunii granulelor. Aceasta este determinată cu relația dintre viteză și distanța de sesizare a detectoarelor. Obiectele care au o viteză mare sunt detectate de mai mulți senzori, determinând o creștere a incertitudinii localizării.

**Pasul 5.** Aprecierea vitezei a fost obținută în mod corect, dar au fost observate unele probleme în estimare, când obiectul s-a mișcat în apropiere de marginile zonei de supraveghere.

**Pasul 6.** Au fost obținute estimările suprafețelor de radiație termică, a zonelor estimate ale mișcării, și o aproximare a mărimii acestora.

**Pasul 7.** Comparând condițiilor normale de funcționare, cu situațiile în care detectoarele au fost acoperite cu pungi de plastic, a fost verificat modul de determinare a gradului de încredere în corectitudinea semnalizării efracțiilor.

## 8.5. Concluzii

Metodele prezentate au abordat într-o manieră nouă câteva probleme mai puțin întâlnite în literatura de specialitate. Modul de proiectare, testate și determinare a localizării obiectului intrus, în cazul sistemelor de supraveghere care folosesc detectori PIR este foarte puțin abordată. Aceste studii sunt cu atât mai importante de realizat, cu cât răspândirea acestor tipuri de senzori bazați pe determinarea gradientului de temperatură, este foarte mare în prezent. Pe de altă parte, datorită principiului de funcționare, o tratare coerentă, care să aibă o fundamentare teoretică solidă, nu poate fi făcută decât folosind tehnici de tip vag sau teorii care permit abordarea situațiilor de incertitudine. Toate rezultatele experimentale au confirmat concluziile teoretice așteptate. Trebuie menționat totuși, că există unele probleme care au fost observate în cursul experiențelor, și anume : dacă apare o mișcare suplimentară, ca de exemplu balansarea mâinii, acest fapt introduce un efect de zgomot, mișcarea fiind asimilată cu o creștere a suprafeței de radieră. Acest efect nu deranjează în general la luarea deciziei finale, deoarece folosind metodele fuzzy, se introduce implicit un coeficient de toleranță mare. De asemenea, a fost observat, un efect de granularitate, care înseamnă că vitezele reduse sunt mult mai dificil de observat decât cele mari pentru cazul în care granulele au suprafețe mari. Compensarea granularității grosiere se poate face prin mărirea vitezei de mișcare a obiectului observat.

## Capitolul IX. Fuziunea rezultatelor

### 9.1. Introducere

Această fază a prelucrării are ca scop reunirea rezultatelor furnizate de cele două sisteme în vederea obținerii deciziei referitoare la alarmare și stabilirea cât mai exactă a parametrilor efracției, respectiv evaluarea localizării și a caracteristicilor obiectului intrus.

Acest deziderat se obține printr-o ierarhie de procese. La primul nivel se realizează fuziuni prin trei metode diferite: fuziune euristică, de tip fuzzy și prin confirmare, care accentuează fiecare o anumită componentă a procesului. Rezultatul final se ia la al doilea nivel ierarhic printr-o decizie ce poate implica elemente de tip ferm sau vag.

Deoarece metodele prezentate în acest capitol au un caracter mai general decât cazul sistemelor de supraveghere în mediu extern, elementele de detecție ale celui de al doilea lanț de colectare de informații, vor fi denumite mai general ca senzori de fuziune. Menționez că pentru exemplificare, experimentările au fost efectuate folosind ca senzori de fuziune, detectori PIR în infraroșu.

### 9.2. Fuziunea euristică

O primă modalitate de a realiza fuziunea între datele furnizate de cele două sisteme prezentate anterior, este utilizarea unei metode de tip euristic ca de exemplu operatorii produs sau o medie ponderată. Așa cum am arătat în capitolul dedicat fuziunii informației, aceste metode, deși simple, permit obținerea unor rezultate acceptabile. Mai trebuie menționată robustețea operațiilor de tip adunare, comparativ cu cele de tip produs, iar dintre acestea, cel mai performant este operatorul de tip mediană. Totuși în cazul de față nu se va putea folosi mediana, deoarece avem numai două seturi de rezultate. În acest caz se va folosi media aritmetică ponderată, care permite o

flexibilitate a fuziunii, prin posibilitatea de a alege valorile coeficienților de ponderare, dar în același timp ridică problema determinării cât mai optime a acestor coeficienți.

Relația ce definește în mod generic această fuziune este:

$$F_E = a \cdot R_V + b \cdot R_D \quad (9.1.)$$

unde

$a$ ,  $b$  sunt coeficienții de ponderare și trebuie să îndeplinească condițiile:

$a+b=1$  și  $a, b \in [0, 1]$ , iar  $R_V, R_D$  reprezintă rezultatele obținute de sistemul video, respectiv sistemul format din detectoarele de fuziune.

Stabilirea coeficienților  $a$ , respectiv  $b$  se poate face în diferite moduri. Dintre acestea, în lucrarea de față, ponderile s-au determinat prin supervizare, pe principiul învățării din erorile anterioare, respectiv, pentru fiecare caz se stabilește eroarea sistemului video  $\varepsilon_V$  și eroarea sistemului cu senzori de fuziune  $\varepsilon_D$ . Coeficienții de ponderare  $a$ ,  $b$  se stabilesc prin normalizarea erorii sistemului complementar:

$$a = \frac{\varepsilon_D}{\varepsilon_V + \varepsilon_D} \quad \text{respectiv} \quad b = \frac{\varepsilon_V}{\varepsilon_V + \varepsilon_D} \quad (9.2.)$$

Deși pentru un număr mai mare de evaluări ale rezultatelor această metodă își îmbunătățește performanța, ea are ca principal dezavantaj faptul că ia în considerare numai situațiile din trecut, deci va fi sensibilă la modificările intervenite în condițiile de detecție (de exemplu schimbarea condițiilor de luminozitate sau temperatură), caz în care erorile pot fi semnificative.

Pentru a stabili dacă a avut loc o efracție sau nu, se folosește tot un criteriu bazat pe eroare. Astfel, dacă între localizările celor două sisteme există o marjă de eroare  $\varepsilon_E$  mai mare decât un prag prestabilit  $\theta_E$ , atunci se consideră că avem de a face cu o alarmă falsă, sau cu o situație de defecțiune a cel puțin unuia din sisteme. În caz contrar, dacă localizările celor două sisteme sunt aproximativ aceleași atunci alarmarea se consideră corectă.

Cu toate că această metodă nu este specifică pentru metodele de tip soft, putem și în acest caz să determinăm un coeficient de încredere în rezultat. De exemplu, se poate folosi relația:

$$\mu_E = 1 - \left| \frac{\min(2\theta_E, \varepsilon_E)}{2\theta_E} \right| \quad (9.3.)$$

unde  $\mu_E$  este coeficientul de încredere obținut prin metoda euristică. Trebuie totuși menționat că folosirea pragului  $\theta_E$  în această relație, determină un anumit grad de arbitrar al rezultatului obținut.

### 9.3. Fuziunea prin metode fuzzy

Această metodă se bazează pe caracterul vag al rezultatelor furnizate de cele două sisteme de supraveghere, respectiv pe gradul de apartenență a acestor rezultate la soluția sigură. Rezultă că această metodă de fuziune își propune să stabilească coeficienții de apartenență pentru fiecare dintre rezultate, urmând a folosi aceste valori în cadrul relației de fuziune.

Pentru a stabili criteriile de determinare a coeficienților de apartenență se vor analiza particularitățile celor două sisteme. Astfel, o primă observație se referă la parametrii care influențează în mod major posibilitățile de detecție a sistemelor. Considerând echipamentele în stare perfectă de funcționare, se observă că informațiile obținute pot fi parțial sau total compromise de alterarea purtătorului principal de informație. Astfel, în cazul sistemului cu camere video, apariția condițiilor de întuneric fac sistemul inutilizabil, iar în cazul sistemului bazat pe detectori de fuziune, creșterea temperaturii mediului supravegheat, face discriminarea de temperatură imposibilă. Rezultă că în procesul de fuziune, cele două sisteme trebuie să aibă grade de participare diferite în funcție de condițiile externe. Considerând că între luminozitatea mediului și valoarea temperaturii externe există o relație monoton crescătoare (respectiv în timpul

zilei este mai cald, iar noaptea mai răcoare), se poate realiza o utilizare continuă în bune condiții a sistemului pe tot parcursul zilei. În acest mod se realizează o funcționare complementară: când nivelul de luminozitate este redus, fuziunea se va baza pe informațiile furnizate de sistemul cu detectori de fuziune, iar când temperatura este ridicată, rezultatul va fi dat de informațiile provenite de la sistemul video. Folosind acest tip de fuziune, în cazul în care ambele sisteme pot funcționa, rezultatul va fi o medie a informațiilor provenite din cele două sisteme.

Rezultă că relația de calcul a fuziunii va fi:

$$F_F = \frac{\mu_V \cdot R_V + \mu_D \cdot R_D}{\mu_V + \mu_D} \quad (9.4.)$$

unde

$F_F$  este valoarea rezultată în urma fuziunii,  $\mu_V, \mu_D$  sunt coeficienții de apartenență corespunzătoare informațiilor provenite din sistemul video, respectiv sistemul cu detectori de fuziune, iar  $R_V, R_D$  reprezintă rezultatele obținute de sistemul video, respectiv sistemul format din detectoarele de fuziune, iar

$$\mu_F = \frac{1}{2}(\mu_V + \mu_D) \quad (9.5.)$$

reprezintă coeficientul de apartenență al fuziunii, folosit în continuare în procedura de decizie.

Pentru stabilirea coeficienților  $\mu_V, \mu_D$  se calculează rapoartele dintre valorile curente ale diferenței luminozității, respectiv a variației de temperatură și plaja acestora care asigură o funcționare corectă. Pentru sistemul video se determină histograma nivelelor de gri ale imaginilor, determinându-se astfel lățimea efectivă ocupată de majoritatea pixelilor  $\Delta H_o$ , față de spectrul minim necesar funcționării în condiții bune a camerelor  $\Delta H_N$ , iar pentru sistemul cu detectori de fuziune se determină variația de



temperatură actuală, în raport cu variația de temperatură minim necesară pentru funcționarea corectă a senzorilor.

Coeficienții de apartenență corespunzători informațiilor provenite din sistemul video și sistemul bazat pe detectori de fuziune se determină cu relațiile:

$$\mu_v = \min\left(1, \frac{\Delta H_a}{\Delta H_N}\right) \text{ respectiv } \mu_D = \min\left(1, \frac{\Delta T_a}{\Delta T_N}\right) \quad (9.6.)$$

unde funcția de minim se utilizează pentru a limita variația raportului.

#### 9.4. Fuziunea prin confirmare

Această metodă se bazează pe observația că rezultatele obținute de sistemul video provin din prelucrarea unei surse mult mai complexe de informații decât cele obținute de sistemul bazat pe detectori de fuziune. Informația obținută de la un detector este de tip binar (este activ sau nu), iar complexitatea informației este cel mult unidimensională, dată de axa timpului, deci de seria temporală a rezultatelor obținute de la senzor. Pe de altă parte, complexitatea datelor video este mult mai mare, de exemplu, în cazul în care se utilizează o stereoscopie, implică 3 dimensiuni spațiale, o dimensiune temporală, o dimensiune dată de intensitatea luminoasă și o dimensiune dată de variația cromaticității. Rezultă că informația provenită de la o sursă video este mai semnificativă decât una provenită de la detectori de fuziune. Această constatare îndreptățește tratarea diferită a celor două surse de informații. Deci sursa principală va fi considerată cea video, iar informația din sistemul cu senzori de fuziune va avea numai rol de confirmare, respectiv de infirmare a rezultatelor video.

Din aceste motive se va folosi relația:

$$U^F = \min(1, U^1) \quad (9.7.)$$

unde

$$U^1 = \frac{1}{K} U \left( 1 + \alpha \frac{|l_v - l_l|}{|l_v|} + \beta \frac{|S_v - S_l|}{|S_v|} \right) \quad (9.8.)$$

iar

$l_v, l_l$  reprezintă localizările obținute prin metoda video, respectiv prin metoda detectorilor de fuziune;  $S_v, S_l$  sunt suprafețele estimate ale obiectelor prin metoda video, respectiv prin metoda ce utilizează senzori de fuziune;  $\alpha, \beta \in [0,1]$  specifică coeficienții de ponderare, și  $K$  este un factor de normalizare.

Trebuie observat că relația dintre coeficienți este  $\alpha > \beta$  deoarece, așa cum am prezentat pe parcursul tezei, estimarea suprafeței obiectului este mai puțin precisă decât estimarea localizării.

De fapt, cea de a doua relație este cea de fuziune propriu zisă, incertitudinea fiind incrementată sau nu, existența unui eventual dezacord între cele două sisteme. Prima relație are rol numai de a limita valoarea coeficientului de incertitudine, care prin definiție nu poate fi mai mare de 1.

Dacă se alege, de exemplu, coeficientul  $K$  stabilit prin relația:

$$K = \frac{1 + \alpha + \beta}{2} \quad (9.9.)$$

atunci se obține un grad de încredere mai mare dacă termenii în care intervin  $\alpha, \beta \in [0,1]$  sunt mai mici, deoarece divergența dintre cele două localizări, respectiv între cele două estimări ale suprafețelor este mai mică, deci gradul de incertitudine reprezentat de coeficientul  $U$  scade. Pe de altă parte dacă termenii care reprezintă gradul de dezacord dintre cele două metode este mare, atunci și coeficientul final de incertitudine va fi mare.

Pentru a se obține o compatibilitate cu coeficienții de apartenență din teoria fuzzy, se poate considera gradul de incertitudine ca fiind inversul celui de apartenență, respectiv:

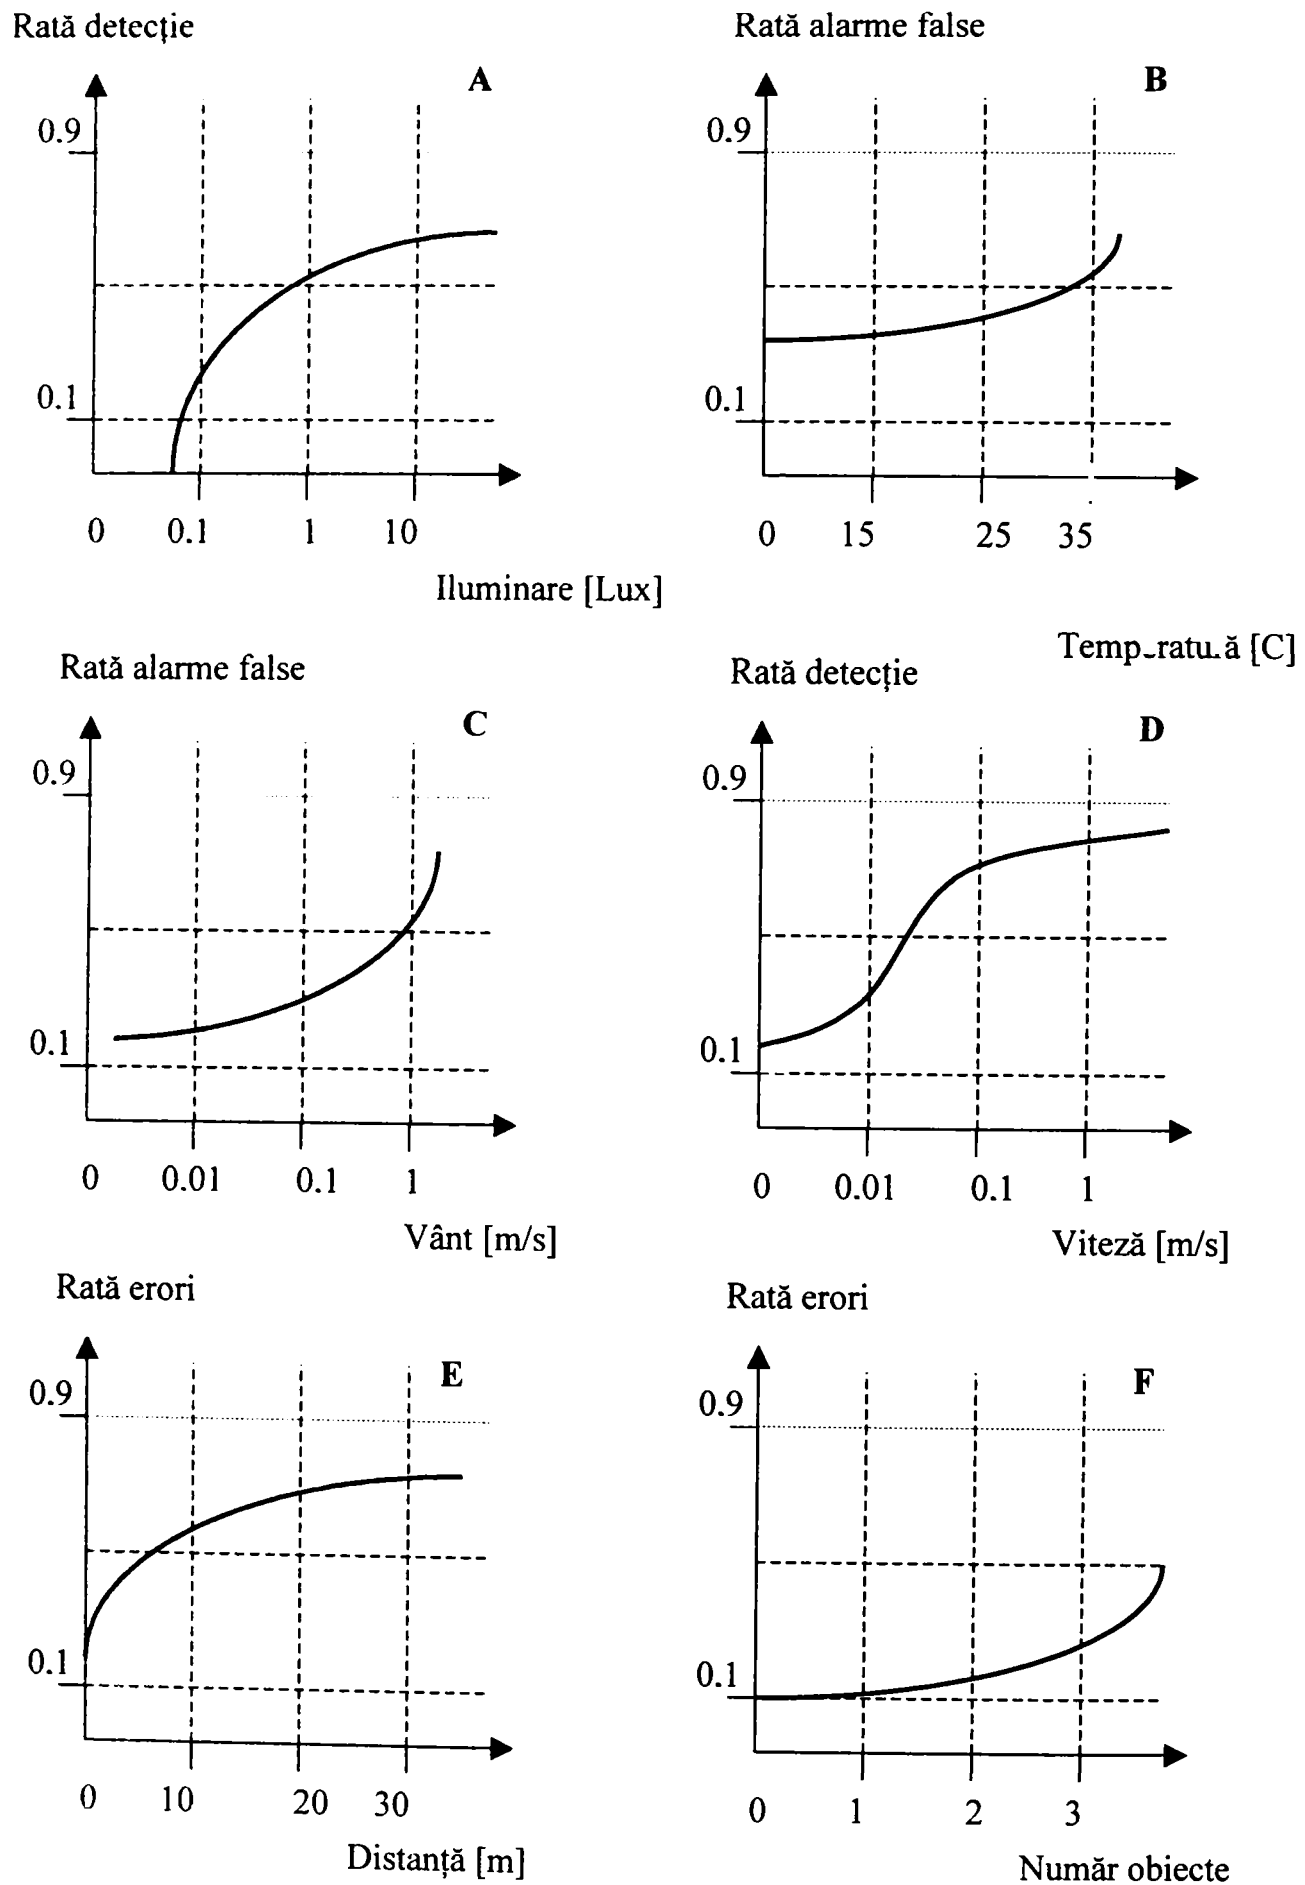
$$\mu_c = 1 - U^f .$$

Trebuie remarcat că această metodă are o formă matematică asemănătoare cu fuziunea prin medie aritmetică ponderată. Dar trebuie observat că în acest caz nu se operează cu valori ale trăsăturilor sau caracteristicilor, ci cu coeficienți de incertitudine, ceea ce face această metodă compatibilă cu celelalte două.

## 9.5. Compararea metodelor

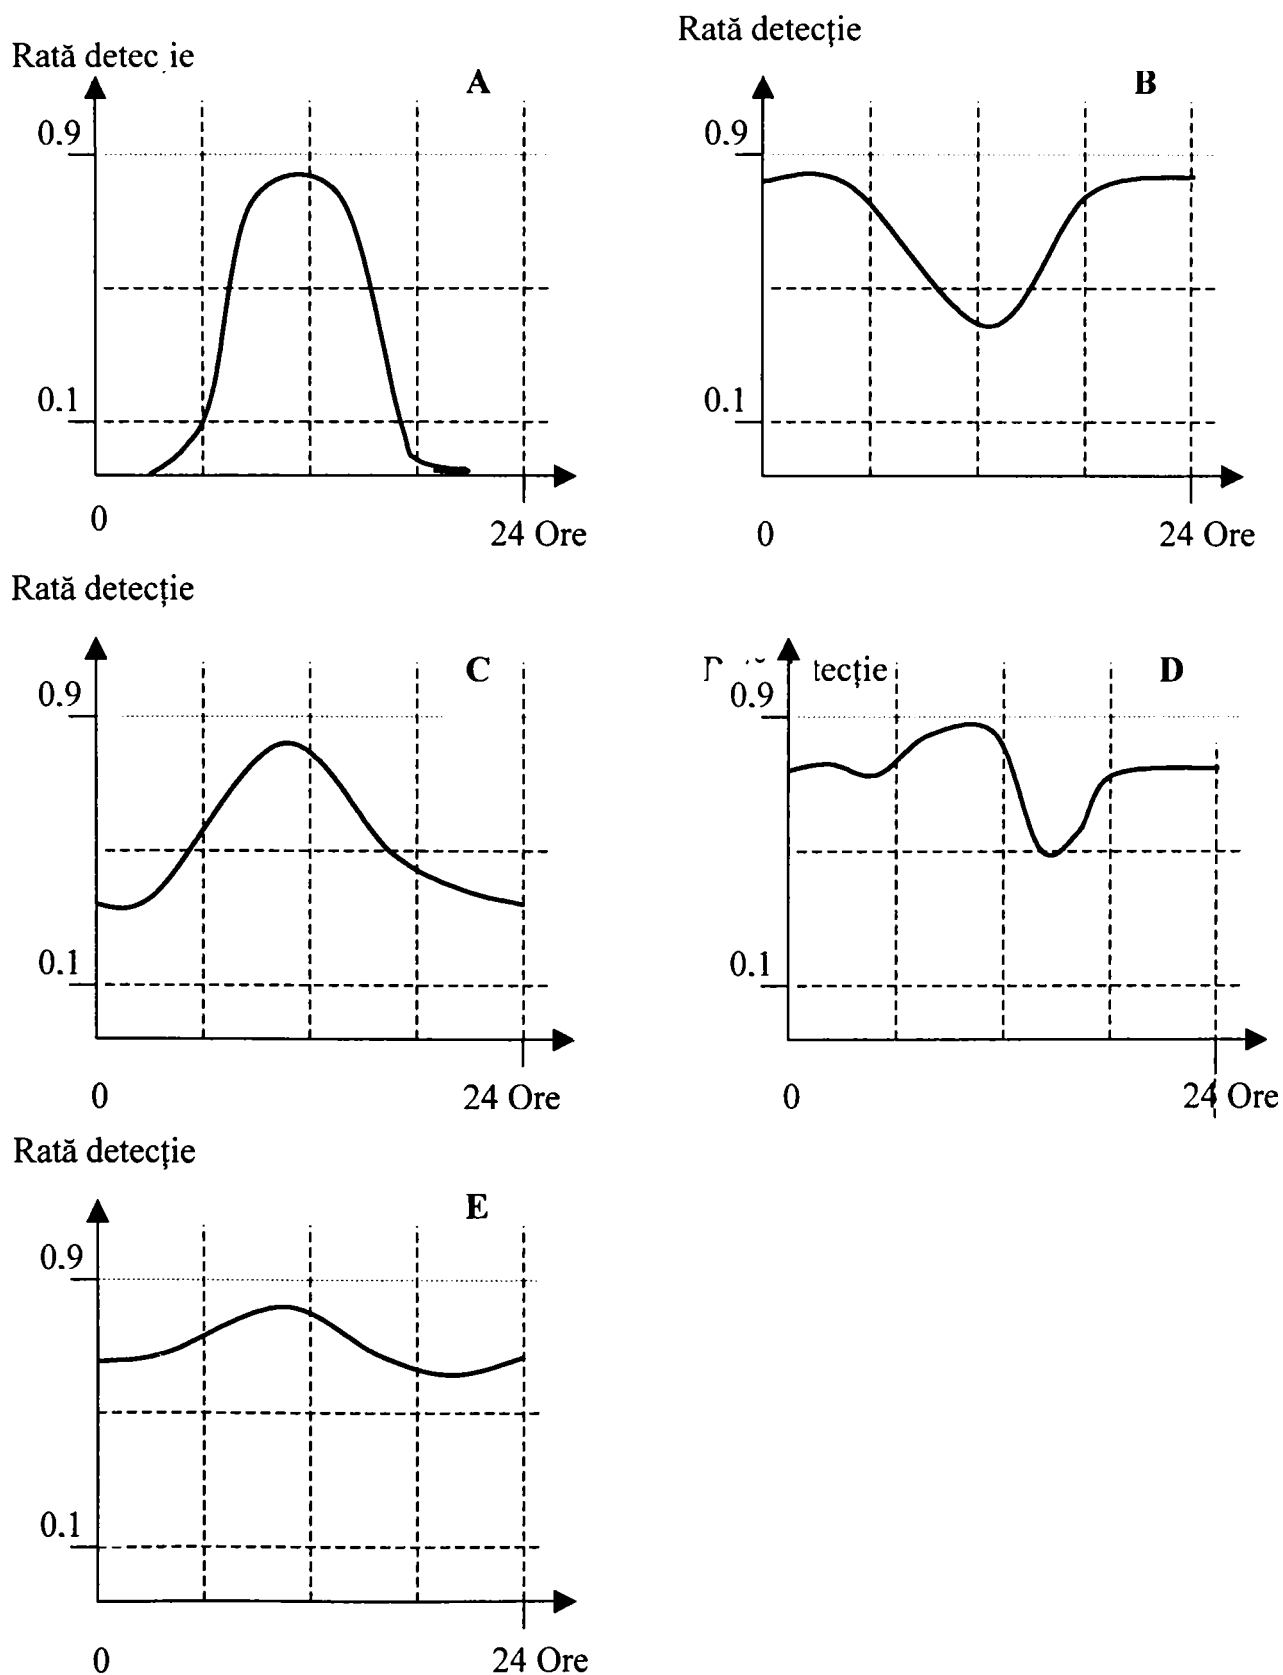
Dacă se compară situația fără efectuarea fuziunii și cea în care se face fuziunea, se observă în mod clar avantajul utilizării metodelor de fuziune. Astfel, în urma experimentărilor au fost puse în evidență deficiențele celor două lanțurilor de obținere a informației. După cum rezultă din figura 9.1.A, sistemul video este dependent de intensitatea luminoasă; noaptea detecția fiind mai dificilă, chiar imposibilă dacă se ajunge cu iluminarea sub nivelul de sensibilitate a camerelor video. De asemenea figurile 9.1.E și 9.1.F. evidențiază dependența performanțelor sistemului video de distanța la care se face detecția, respectiv de numărul de obiecte existente în imagini. Astfel cu cât distanța este mai mare sau sunt mai multe obiecte în imagine, cu atât scad performanțele sistemului video.

Dacă analizăm comportamentul sistemului bazat pe detectori de tip infraroșu, se constată dependența pe care o au aceste componente față de temperatură, așa cum rezultă din figura 9.1.B. De asemenea numărul alarmelor false este determinat în mod major de mișcările de aer din incinta supravegheată, așa cum rezultă în figura 9.1. C . Un alt element care influențează sistemul bazat pe detectori PIR, este viteza obiectelor din spațiul observat. După cum rezultă și din figura 9.1.D cu cât viteza este mai mare cu atât gradul de detecție este mai bun.



**Figura 9.1.** Dependența performanțelor sistemelor video și PIR de parametrii externi

În cazul în care există un proces de fuziune aceste elemente perturbatoare sunt compensate de informațiile provenite din sistemul complementar, performanțele fiind mult îmbunătățite.



**Figura 9.2.** Variația ratei de detecție pe parcursul unei zile

În figurile din 9.2. sunt prezentate comportamentele celor două sisteme separat; cel video în figura 9.2.A, iar cel pe bază de detectori de fuziune în figura 9.2.B, comparativ cu rezultatele obținute după fuziunea de tip euristic (figura 9.2.C), de tip fuzzy (figura 9.2.D) și prin confirmare prezentat în figura 9.2.E

Din analiza datelor, se observă că rezultatele obținute cu oricare dintre metodele de fuziune este superioară celor provenite de la sistemele separate. De asemenea, se constată variabilitatea mai mare a fuziunii euristice, care nu ia în considerare evoluția condițiilor din mediu și performanța mai bună a fuziunii prin confirmare, față de celelalte două metode de fuziune.

## 9.6. Stabilirea deciziei

Așa cum s-a arătat în capitolul despre fuziune, decizia finală poate fi luată în mod hard, când informațiile luate în considerare sunt deja prezentate printr-o valoare certă sau în mod soft. În modul soft informațiile au caracterul unor valori vagi fiind reprezentate printr-o funcție de apartenență, sau eventual printr-o valoare estimată însoțită de un coeficient de încredere.

### 9.6.1. Metode hard

Metoda hard utilizează o abordare clasică, în care elementele de intrare sunt considerate sigure și ferme. În acest procedeu, într-o primă fază se stabilește o decizie la nivelul fiecărui proces de fuziune, iar apoi aceste rezultate de tip binar sunt supuse unui proces de votare. Dacă decizia finală este afirmativă ( deci există o efracție ) atunci se acceptă valorile parametrilor obiectului intrus (de exemplu cele calculate prin relațiile prezentate anterior în paragraful despre fuziunea euristică ).

Decizia la nivel de unitate de fuziune  $D_i$  se realizează prin compararea coeficienților de încredere  $\mu_i$  ( unde  $i \in \{E, F, C\}$  ) cu câte un prag  $\theta$ , care de obicei are

valoarea corespunzătoare incertitudinii complete, respectiv  $\frac{1}{2}$ . Pentru decizia finală, votul se realizează utilizând relația :

$$D_H = \begin{cases} 1 & | \text{card}(D_i = 1) \in \{2;3\} \\ 0 & | \text{card}(D_i = 1) \in \{0;1\} \end{cases} \quad (9.10.)$$

unde  $D_H$  reprezintă valoarea deciziei hard.

Acest rezultat este apoi trimis unității de alarmare, respectiv sistemelor de dispecerizare.

### 9.6.2. Metode soft

Această metodă realizează decizia finală pe baza informațiilor compuse de tip vag, luând în considerare și valorile coeficienților de încredere furnizate de fiecare tip de fuziune prezentat anterior. Deoarece cuprinde o cantitate mai nuanțată de informație și rezultatele obținute sunt mai corecte.

Dacă am considera că toți coeficienții au aceeași relevanță s-ar putea folosi o medie aritmetică a lor, dar deoarece, așa cum s-a arătat pe parcursul tezei, există diferențe de performanțe între diferitele metode de fuziune, se va folosi pentru luarea deciziei o relație ce implică o medie ponderată prin coeficienții  $a, b, c$ .

$$D_H = \begin{cases} 1 & | (a \cdot \mu_E + b \cdot \mu_F + c \cdot \mu_C \geq \theta \\ 0 & | (a \cdot \mu_E + b \cdot \mu_F + c \cdot \mu_C < \theta \end{cases} \quad (9.11.)$$

unde

coeficienții trebuie să îndeplinească condițiile  $a, b, c \in [0;1]$  și  $a+b+c=1$

Se observă din relația anterioară că decizia de tip concret se stabilește prin compararea mediei ponderate cu un prag  $\theta$ , care de obicei are valoarea corespunzătoare incertitudinii complete, respectiv  $\frac{1}{2}$ . Rezultă din compararea acestei metode cu cea anterioară, că modul de trecere la valori ferme este același, doar momentul în care este efectuată trecerea diferă. Dar deoarece prin trecerea la o decizie de tip ferm se pierde o

parte importantă a informației, folosirea ei cât mai târziu în procesul de decizie conduce la un rezultat mai bun.

Stabilirea coeficienților de ponderare se poate face prin diferite metode, una din ele fiind cea a evaluării efectuate pe baze euristice. Totuși am preferat să stabilesc aceste valori pe baze mai riguroase, de aceea am folosit o metodă adaptată din rețelele neuronale artificiale de tip Hebb, în care se realizează un proces de învățare nesupervizat. Relația inițială [Neg02] era de forma:

$$\Delta w_{ij} = \alpha \cdot y_j \cdot x_i - \phi \cdot y_j \cdot w_{ij} \quad (9.12.)$$

unde  $x_i, y_j$  reprezintă intrarea  $i$ , respectiv ieșirea  $j$ ,  $w_{ij}$  este valoarea ponderii conexiunii dintre ele, iar  $\alpha, \phi$  reprezintă coeficienții de învățare respectiv uitare folosiți în procesul de instruire. Relația propusă de mine este de forma:

$$\Delta coef_i^t = \alpha \cdot D_i - \phi \cdot \varepsilon_i \quad (9.13.)$$

unde  $i \in \{E, F, C\}$ , iar variabila  $coef_i^t = \begin{cases} a^t & | i = E \\ b^t & | i = F \\ c^t & | i = C \end{cases}$

Coeficienții  $a$ ,  $b$  și  $c$  se obțin prin actualizarea la momentul  $t+1$  a vechilor coeficienți din momentul de timp  $t$ , urmată de o operație de normalizare pentru a satisface condițiile impuse. Relația pentru determinarea coeficientului  $a$  este :

$$a = \frac{a^{t+1}}{a^{t+1} + b^{t+1} + c^{t+1}} \quad (9.14.)$$

unde

$$a^{t+1} = a + \Delta a^t \quad (9.15.)$$

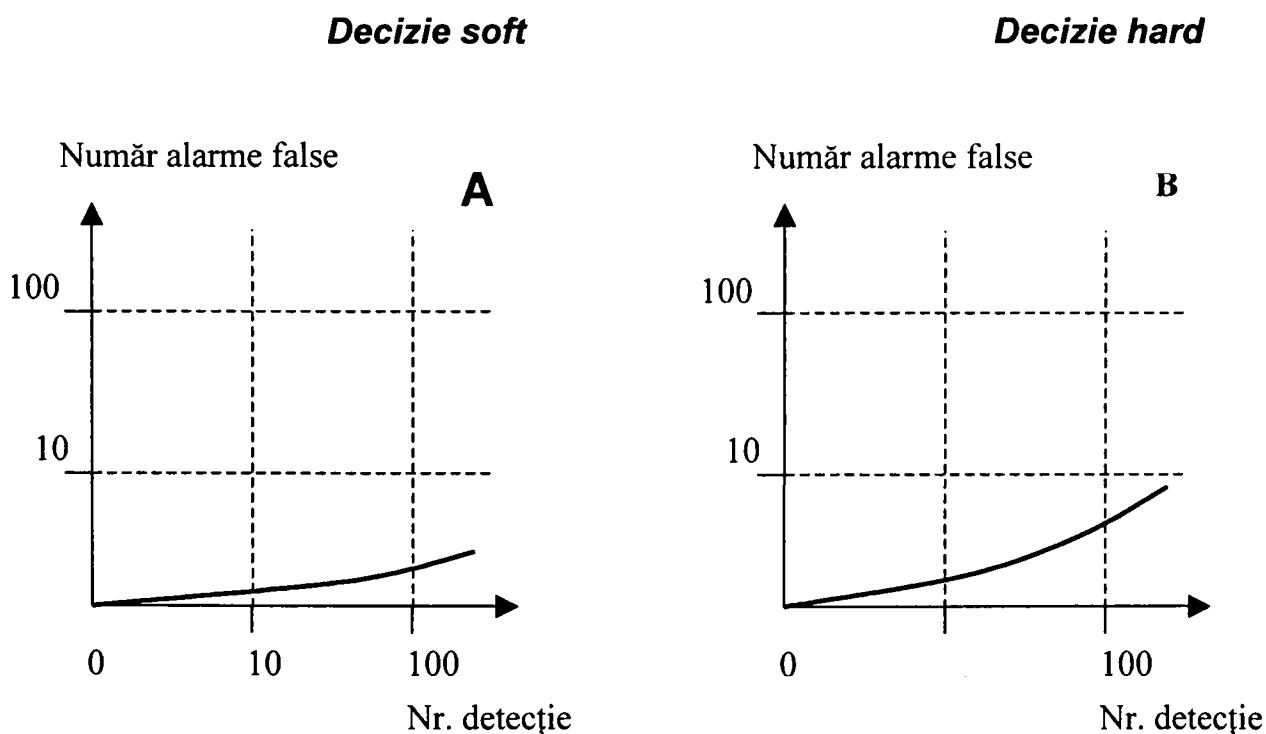
Coeficienții  $b$  și  $c$  se obțin în mod asemănător.



Valoarea coeficienților de învățare, respectiv de uitare s-au stabilit la valorile  $\alpha = 0,1$ , respectiv  $\phi = 0,01$ , ca și la metoda originală din rețelele neuronale artificiale.

Metoda Hebb folosește acești doi coeficienți cu funcțiile care rezultă din denumire, respectiv pentru învățare și uitare, dar în cazul propus de mine, rolul lor este adaptat procesului de decizie. În acest sens coeficientul  $\alpha$  are rol de a pondera gradul în care o decizie corectă influențează creșterea importanței metodei de fuziune care a fost confirmată. Coeficientul  $\phi$  are rolul de a pondera scăderea importanței unei metode de fuziune, datorată erorii constatate.

În urma experimentărilor efectuate, au rezultat dependențele numărului de alarme false, raportate la numărul de detecții, pentru cazul deciziei soft (fig.9.3.A) și pentru decizia hard (fig.9.3.B).



**Figura 9.3.** Performanțele deciziilor soft și hard

Din analiza datelor prezentate în fig. 9.3 se observă o rată mai mică a alarmelor false în cazul deciziei prin metoda soft (fig.9.3.A), decât în cazul deciziei prin metoda hard (fig. 9.3.B), ceea ce confirmă studiile teoretice prezentate anterior.

## 9.7. Concluzii

Procesul de fuziune a informațiilor este ultima parte a lanțului de determinare a efracției. Soluția prezentată își are originalitatea în ierarhizarea fuziunii, permițând astfel să se beneficieze de avantajele mai multor metode dintre cele prezentate în capitolul dedicat acestora.

Experimentările efectuate au confirmat avantajul acestei abordări prin punerea în evidență a proprietăților fiecărei metode. Astfel metoda euristică s-a dovedit a fi simplă, dar expusă unor erori importante la schimbarea condițiilor de mediu, ceea ce în supravegheri externe este important. Metoda fuzzy a dovedit o adaptare la schimbările de mediu, dar a tratat la fel cele două sisteme de localizare, ceea ce a mărit eroarea, în special în condițiile în care predominantă era influența sistemului bazat pe detectori de fuziune. Iar metoda prin confirmare a prevenit neajunsul metodei fuzzy prezentat anterior.

Metoda de decizie a fost testată și prin soluția hard și prin soluția soft. Așa cum era de așteptat, metoda soft a avut rezultate mai bune decât cea hard din motive care au fost prezentate la paragraful respectiv.

Pe ansamblu, se poate concluziona, că experimentările realizate au scos în evidență rezultatele mai bune obținute cu metodele prezentate în această lucrare, față de sistemele folosite azi în supravegherea mediului extern. Astfel, metodele expuse, iau în considerare modificările condițiilor de mediu, permițând o adaptare dinamică la variațiile parametrilor de intrare. De asemenea, sistemul prezentat prin utilizarea unei ierarhii de procese de fuziune, permite o modificare activă a ponderilor cu care contribuie fiecare tip de fuziune, pe baza unui proces de învățare. În acest fel metodele de fuziune care prezintă avantajele cele mai mari, în condițiile date ale mediului, vor avea o pondere mai mare în stabilirea rezultatului final, față de cele mai puțin adecvate situației concrete de funcționare.

## PARTEA IV. Concluzii finale

Partea a patra a acestei teze are un singur capitol care conține concluziile finale, care se pot trage din precedentele părți ale lucrării. De asemenea prezintă un rezumat sistematizat al capitolelor anterioare. În acest sens sunt expuse din diferite abordări, conținutul prezentei teze, precum și a activității autorului.

## Capitolul X. Concluzii finale

Tratarea corespunzătoare a subiectului tezei „CONTRIBUȚII LA DEZVOLTAREA SISTEMELOR DE SUPRAVEGHERE ÎN MEDIU EXTERN” solicită acoperirea unui domeniu vast de metode.

Contribuțiile și aplicațiile autorului sunt rezultatul unei activități de cercetare focalizate pe tema tezei, în ultimii 7 ani în cadrul colectivului Universității „Aurel Vlaicu” din Arad, precum și al activității didactice desfășurate, în calitate de cadru didactic al Facultății de Inginerie, secția Automatizări și Informatică Aplicată.

Din parcurgerea lucrării se desprind următoarele:

- după cum rezultă din disponerea în timp a publicațiilor, la tema prezentată s-a lucrat pe parcursul a mai multor ani. Studiind temele se poate observa că informațiile din atâtea domenii au necesitat parcurgerea bazelor de cunoștințe din diferite puncte de vedere pentru a reuși ierarhizarea și structurarea lor,
- autorul s-a familiarizat cu domenii foarte diverse ce țin de sistemele de alarmare și supraveghere, inteligență artificială, prelucrări de imagini și recunoașteri de forme,
- dar mai importantă este stăpânirea domeniului inteligenței artificiale, a metodelor fuzzy, a teoriei mulțimilor grosiere, a elementelor de granularitate a informației și fuziunea informației,
- așa cum se va prezenta în acest capitol, pe parcursul tezei sunt prezentate o serie de contribuții teoretice și aplicative,
- lucrarea are o structură coerentă, ce servește scopul propus, de a prezenta contribuțiile autorului la dezvoltarea sistemelor de supraveghere în mediu extern.

## 10.1. Structura tezei

Partea întâia intitulată **Introducere** cuprinde 2 capitole astfel:

În **Capitolul I.** având titlul de **Introducere** se prezintă problematica abordată în prezenta teză, precum și principalele informații legate de lucrare.

**Capitolul II.** denumit **Stadiul actual în domeniul sistemelor de supraveghere** prezintă echipamentele folosite în domeniu, precum și modul de utilizare, avantajele și dezavantajele fiecărui tip de componentă. Sunt prezentate pe rând elementele de detecție și de avertizare, unitățile de comandă, iar în cadrul sistemelor de supraveghere video sunt descrise camerele video, echipamentele de prelucrare a semnalelor, echipamentele de înregistrare, cele de achiziție și de afișare.

Partea a doua intitulată **Contribuții la fundamentarea alegerii metodelor** se compune din 3 capitole, după cum urmează:

**Capitolul III.** intitulat **Mulțimi grosiere** face o prezentare pe larg a teoriei mulțimiilor grosiere. În acest sens după expunerea noțiunilor și a proprietăților se propune o clasificare și de asemenea sunt descrise aplicațiile pe care le au aceste teorii. De asemenea se stabilește tipul de mulțime care se potrivește problematicii prezentei lucrări.

**Capitolul IV.** prezintă **Granularitatea informației**, cuprinzând o descriere a problemelor legate de granularitatea informației. Sunt prezentate noțiunile și proprietățile conexe, precum și diferențele dintre metodele ce utilizează valori ferme și cele bazate pe valori de tip fuzzy.

**Capitolul V.** denumit **Fuziunea informațiilor** prezintă pe larg tematica acestui domeniu. Materialul este prezentat pe baza unei clasificări stabilite de autor în funcție de domeniile ce contribuie la realizarea unificării. Astfel sunt prezentate fuziuni pe baze euristice, prin metode probabilistice, prin metode fuzzy, folosind teoria posibilităților, prin teoria Dempster Shafer și prin combinații ale acestora.

Partea a III-a, intitulată **Contribuții la proiectarea, realizarea și testarea sistemelor de supraveghere în mediu extern** are 4 capitole, fiecare cu un număr de subcapitole

**Capitolul VI.** denumit **Arhitectura sistemului** are menirea de a descrie concepția după care a fost realizat sistemul ca un tot unitar. Astfel se descrie organizarea sistemului, fiind prezentat fiecare modul component. De asemenea, se trece în revistă echipamentele folosite, precum și caracteristicile tehnice ale acestora. Tot în acest capitol se face o demonstrație a temeiniciei utilizării scalei logaritmice, în cazul folosirii captoarelor de informații conic.

**Capitolul VII.** intitulat **Sistemul video** descrie metodele folosite pentru obținerea localizării obiectului intrus și a determinării caracteristicilor necesare pentru etichetare. După o scurtă introducere, se prezintă într-un subcapitol separat, metoda stereoscopică folosită pentru determinarea distanței dintre obiect și sistemul video. În subcapitolul următor este descrisă metoda de extragere a trăsăturilor, stabilirea marginilor de incertitudine precum și determinarea granularității optime. Un alt subcapitol tratează metodele utilizate în urmărirea obiectului. Trebuie menționat aplicarea în acest capitol a informațiilor prezentate anterior în capitolele III și IV.

**Capitolul VIII.** prezintă **Sistemul bazat pe detectori PIR** și se ocupă de modul de localizare și estimare a suprafeței radiante în cazul folosirii celui de al doilea sistem de supraveghere format din detectori PIR. În subcapitole distincte se prezintă metode originale de proiectare, testare, localizare și stabilirea suprafețelor radiante folosind acest sistem. Se descrie de asemenea o metodă originală de stabilire a gradului de încredere în sistem, care este folosit ulterior în faza de fuziune.

**Capitolul IX.** denumit **Fuziunea rezultatelor** descrie o structură ierarhică de fuziune, care prin utilizarea a 3 tipuri de metode, permite compensarea neajunsurilor specifice fiecărei metode în parte. După operațiile de fuziune efectuate în paralel se trece la etapa de decizie, care poate fi efectuată în două moduri: hard, folosind date

ferme și soft folosind informații vagi. Pe baza rezultatului obținut în urma deciziei se trece la activarea sau nu a sistemului de supraveghere.

Ultima parte a lucrării având denumirea **Concluzii finale** prezintă concluziile finale, precum și un rezumat al problemelor abordate în prezenta teză și este format dintr-un singur capitol : **Capitolul 10 Concluzii finale.**

## 10.2. Clasificarea contribuțiilor pe aspecte

Teza aduce contribuții la dezvoltarea domeniului sub diverse aspecte:

### A. Referitor la metodele testare

- s-a testat sistematic modalitatea de aplicare a metodelor din domeniul inteligenței artificiale, se studiază eficiența și limitele lor
- s-a testat modalitatea practică de aplicare a lor
- s-a testat aplicarea teoriei fuzzy, pentru stabilirea caracteristicilor obiectului intrus, pentru urmărirea obiectului și pentru fuziunea informației
- s-a testat teoria mulțimilor grosiere la determinarea trăsăturilor și a fuziunii
- s-a testat aplicarea noțiunea de granularitate a informației la determinarea localizării și evaluarea caracteristicilor obiectului intrus

### B. Referitor la varietatea domeniilor acoperite

- Domeniul sistemelor de supraveghere
- Domeniul teoriei mulțimilor vagi
- Domeniul mulțimilor grosiere
- Domeniul granularității informației
- Părți din domeniul inteligenței artificiale

- Părți din domeniul calculului evolutiv

### **C. Referitor la volumul de experimente efectuate**

- au fost realizate experimentări pentru determinarea distanței prin stereoscopiei.
- au fost experimentate metodele de stabilire a granularității optime
- au fost determinate trăsăturile obiectului intrus și s-au stabilit marginile de incertitudine,
- s-au realizat experimentări pentru urmărirea obiectului,
- s-a realizat proiectarea și testarea sistemului PIR conform metodelor propuse,
- s-au determinat experimental modul de localizare și de evaluare a suprafeței radiante, conform metodelor prezentate în lucrare,
- s-au realizat procesele de fuziune și decizie descrise în teză.

### **D. Referitor la aplicabilitate**

- prezintă un interes deosebit prin impactul economic avut,
- se aplică la o gamă largă de produse de securitate care necesită observarea, supravegherea și alarmare în caz de efracție,
- îmbunătățește gradul de încredere acordat sistemelor actuale, în urma modernizării.

### **E. Referitor la caracterul didactic și aplicativ al prezentării**

- aplicațiile sunt descrise amănunțit, se detailează părțile cele mai importante din punct de vedere al metodei utilizate,
- acoperă un domeniu complet referitor la metodele de supraveghere.



**F. Referitor la direcțiile de cercetare deschise**

- măsurarea gradului de incertitudine prin coeficienți bazați pe nivelul de disimilitudine,
- folosirea granulației multiple și determinarea granularităților optime pentru obiectele dintr-un sistem video,
- folosirea unor metode de proiectare și testare pentru sisteme cu detectoare PIR,
- localizarea obiectelor folosind sisteme bazate pe detectori de fuziune,
- estimarea suprafeței radiante pentru sistemele cu detectori PIR,
- determinarea gradului de încredere în sisteme de alarmare.

**G. Referitor la volumul de muncă înglobat în lucrare**

- s-au realizat două sisteme de supraveghere, pentru fiecare tip de decizie, prin interfațarea componentelor și modulelor amplasate în mediul testat,
- s-au realizat programele de prelucrare cerute de fiecare metodă

**H. Referitor la numărul de lucrări științifice publicat**

- autorul are un număr de 15 lucrări publicate sau în curs de publicare, dintre care:
  - i. 8 sunt lucrări la conferințe internaționale susținute în străinătate,
  - ii. 3 sunt lucrări la simpozioane și sesiuni de comunicări științifice din țară,
  - iii. 2 sunt lucrări publicate în buletine științifice din țară
  - iv. un articol într-o revistă internațională
  - v. un curs de formare profesională, la care este co-autor.

Se remarcă interesul științific și economic al sistemului de supraveghere în mediu extern propus, identificându-se domenii de cercetare noi și soluții personale.

### 10.3. Contribuții teoretice și aplicative

#### 10.3.1. Contribuții teoretice

- reliefarea necesității folosiri granulației multiple și determinarea granularităților optime, prezentat în Capitolul VII, stabilește o metodă de determinare a nivelului de granularitate care permite extragerea trăsăturilor în condiții de minimă incertitudine,
- stabilirea unei metode de măsurare a gradului de incertitudine prin coeficienți bazați pe nivelul de disimilitudine, descris în Capitolul VII, stabilește o măsură de tip fuzzy pentru determinarea nivelului de incertitudine,
- determinarea unei metode de localizare a obiectelor folosind sisteme bazate pe detectori în infrarosu, expus în Capitolul VIII, stabilește prin tehnici fuzzy, o abordare a localizării unui obiect, în cazul utilizării unor senzori ce furnizează informații de tip vag,
- realizarea fuziunii informației printr-un sistem ierarhic în două etape, descris în Capitolul IX, descrie două metode de stabilire a decizie în cazul unui sistem eterogen de detectori, utilizând mai multe metode de fuziune,
- stabilirea unui proces de adaptare a coeficienților de decizie printr-o metodă de învățare, prezentat în Capitolul IX, realizează o abordare într-un context nou a metodei de tip Hebb,
- determinarea unei tehnici de estimare a suprafeței radiante pentru sistemele cu detectori PIR, expus în Capitolul VIII, reliefează o

metodă de estimare de tip fuzzy a unei caracteristici importante a unui obiect, în cazul utilizării unor senzori de tip vag.

- analiza critică a diferitelor metode folosite în fuziunea informațiilor pentru a stabili avantajele și deficiențele fiecăreia în parte, descris în Capitolul V, urmărește din perspectiva aplicației propuse, realizarea unei fundamentări a metodelor de fuziune selectate pentru aplicare,
- clasificarea diferitelor abordări ale noțiunii de granularitate a informației, prezentat în Capitolul IV, realizează o ordonare originală a acestei perspective noi din cadrul „soft computing”,
- gruparea categorială a aplicațiilor mulțimilor grosiere, expus în Capitolul IV, stabilește o structurare a informațiilor din cadrul acestui nou domeniu ce aparține Inteligenței Artificiale
- gruparea tehnicilor de fuziune a informației printr-o viziune originală, care are la bază principiul teoretic aplicat, prezentat în Capitolul V, sistematizează pe baza unei abordări de tip „soft computing” metodele de fuziune a informației.

### **10.3.2. Contribuții aplicative**

- Stabilirea unei metode de proiectare pentru sistemele de supraveghere cu detectoare PIR,
- Stabilirea unei metode de testare pentru sistemele de supraveghere cu detectoare PIR,
- Stabilirea unei metode de determinare a gradului de încredere în sistemele de alarmare.



**BIBLIOGRAFIE**

- [Abd98] N.Abdolhossein,I.Ciric: *Novel image fusion methodology using fuzzy set theory*, Optical Eng. Vol.37 nr.2 1998
- [Ach00] B.Achermann,H.Bunke: *Classifying Range Images of Human Faces with Hausdorff Distance*, Inter'l Conf. On Pattern Recognition 2000
- [Alk02] F.Alkoot,J.Kittler: *Modified product fusion*, Pattern Recognition Letters Vol 23,Nr.8 2002
- [Ari03] M.Arif,N.Vincent: *Comparison of Three Data Fusion Methods for an Offline Signature Verification Problem* ,Vol Univ.Tour 2003
- [Ayc97] O.Aycard,F.Charpillet&co: *A new approach to design fuzzy controllers for mobile robots navigation*, IEEE CIRA 1997
- [Bag02] Bargiela A, Pedrycz W, Hirota K *Logic-based granular prototyping* COMPSAC 2002 26-th Internat.Computer Software and Applic.Coference
- [Bag04] Bargiela A.,Pedrzy W.,Hirota K. *Granular Prototyping in Fuzzy Clustering* IEEE Trans. On Fuzzy Systems vol.12 no.5 2004, pag: 697-709
- [Bak01] D.Bakken,C.Jones&co: *Middleware Support for Voting and Data Fusion*, Inter'l Conf. On Dependable System 2001
- [Bal02] M.Balas: *Regulatoare fuzzy-interpolative*, Editura Politehnică 2002
- [Bal04] V.Balas: *Senzori inteligenți cu model intern și fuziune fuzzy* Ed Politehnica 2004
- [Bar03] C.Barna, S.Silvașan: *Detectarea și urmărirea mișcării* Proiect diploma UAV Arad 2003
- [Bar04] C.Barna,S.,V.Bălaș: *The Estimation of vegetation stage of greenhouse plants by fuzzy fused sensors of images and CO<sub>2</sub>*, Sesiunea de comunicari Arad 2004

- 
- [Bar04b] C.Barna &co *Tehnician pentru sisteme de detecție, supraveghere video și monitorizare control acces și comunicații* Manual de formare profesională ARTS, IBR București 2004
- [Bar04c] C.Barna, D.Apostol, *A Navigation Robot*, Final Paper UAV Arad 2004
- [Bar05] C.Barna *An Alarm System Design with PIR using Fuzzy Sensor Fusion and Genetic Algoritm Program* IEEE SOFA 2005 Szeged-Arad pag.195-199
- [Bar05b] C.Barna, M.Bălaș, *Using CCD Cameras for Car Following Algorithms* IEEE International Symposium on Industrial Electronics ISIE, June 20-23 Duvrovnik 2005 pag.57-62
- [Bar05c] C.Barna, *A testing method for PIR detections system* CIMCA 2005 International Conference on Computational Intelligence Viena pag.199-204
- [Bar05d] C.Barna *Surveillance System using Information Fusion* Analele Universității din Oradea 2005 pag.24-27
- [Bar06] C.Barna *A granular-based method for position and reliability estimation in alarm systems* - în curs de publicare IEEE International Conference in Mechatronics ICM 2006 Budapesta Ungaria
- [Bar06b] C.Barna *Measuring Feature uncertainty by using similarity* - în curs de publicare WSEAS 2006 Dubrovnik Croatia
- [Bar06c] C.Barna, M.Stratulat *A localization method based on infrared detectors for surveillance areas* CINSIA 2006, în curs de publicare Coruna, Spania
- [Bar06d] C.Barna, M.Stratulat, *Assistant software for alarm systems* RAIC 2006 Canterbury, Marea Britanie -în curs de publicare
- [Bar06e] C. Barna, *Video Surveillance using a New Uncertainty Mesurment* WSEAS Transactions on Computers Issue 8, Vol.5 2006 pag.1739-1744 ISSN: 1109-2750
- [Bas97] A.Bastiere, *Fusion method for multisensor clasification of airborne targets*, Aerospace Science and Tehnology nr.1 1997

- [Bea01] Beaubouef T, Petry F *Vague Regions and Spatial Relationships: A Rough Set Approach* 4-th International Confer on Computational Intelligence 2001 pag.1-5
- [Bea03] M.Beal,N.Jojic: *A Grafical Model for Audiovisual Object Traching*, IEEE Transaction on Pattern Anal. Vol25/7 2003
- [Ber01] Bertino E, Ferrari E., Guerrini G., Merlo I, *Navigating through Temporal Granularitz Objects*, 8-th Inter. Symposium on Temporal Representation 2001
- [Bis97a] P.Bison,G.Chemello&co: *A Possibilistic Approach to Sensor fusion in Mobile Robotics*, IEEE EUROBOT 1997
- [Bis97b] P.Bison,G.Chemello&co: *Logic-Based Sensor Fusion for Localization*, IEEE CIRA 1997
- [Bor97] Bortolan G, Pedrycz W *Reconstruction problem and information granularity* IEEE Trans. On Fuzzy Systems, vol.2 1997 pag.234-248
- [Cam02] Camossi E, Bertino E, Guerrini G, Mesiti M, *Evolution Specification Of Multigranular Temporal Objects* 9-th Inter. Symposium on Temporal Representation 2002
- [Car94] D.I. Cârstoiu, *Sisteme expert*, Ed.All 1994
- [Ciu82] G.Ciucu,V.Craiu,etc: *Statistică matematică și cercetare operațională*, Ed.didactică 1982
- [Cho00] L.Cholvy: *Applying Theory of Evidence in multisensor data fusion: a logical interpretation*, IPMU 2000
- [Cho04] L.Cholvy: *Information Evaluation in fusion:a case study*, IPMU Perugia 2004
- [Coc03] De Cock, C Cornelis *Fuzzy Rough Set: Beyond the Obvious* IEEE International Conference on Fuzzy Systems 2004 pag.103-108
- [Cop03] G.Coppin,A.Skrzyniarz: *Human-Centered Processes Individual and Distributed Decision Support*, IEEE Intelligent system nr.4 2003

- [Cor02] Cordon O.,Herrera F., Zwir I. *Linguistic Modeling by Hierarchical Systems of Linguistic Rules* IEEE Trans. On Fuzzy Systems Vol.10 no.1 2002 pag:2-20
- [Dub94] D.Dubois,H.Prade: *La fusion d'informations imprecises*, Traitement du signal Vol.11 nr.6 ,1994
- [Dub00] D.Dubois,H.Prade: *Possibility Theory in Information Fusion* ISIF 2000, pag.6-19
- [Dub00a] D.Dubois,H.Prade: *Fundamentals of fuzzy sets* ,Ed. Kluwer Academic Publishers, 2000
- [Dud73] R.Duda, P.Hart, *Pattern classification and scene analysis*, Ed. Wiley-Interscience Publication 1973
- [Duj98] C.Dujet: *Data Fusion Modeling Human Behavior*, Inter'l Journal of Intelligent Systems Vol.13 1998
- [Gua03] Guan J.,Bell D.,Liu D, *The Rough Set Approach to Association Rule Mining* 3-rd IEEE International Confer. On Data Mining ICDM 2003
- [Gul99] D.Guliatto,R.Rangayyan&co: *Fuzzy Fusion of Results of Medical Image Segmentation* , EISA Vol.3 1999
- [Gun01] A.Gunatilaka,B.Baertlein: *Feature-Level and Decision- Level Fusion of Noncoincidentally Sampled Sensors for Land Mine Detection*, IEEE Transactions on Pattern Vol23 nr.6 2001
- [Her05] Herrera-Viedma E., Martinez L.,Chiclana F. *A Consensus Support Model For Group Decision-Making Problems With Multigranular Linguistic Preference Relations* IEEE Trans. On Fuzzy Systems vol.13 no.5 2005 pag:644-658
- [Hir01] Hirano S.,Tsumoto S. *A Knowledge-Oriented Clustering Technique Based on Rough Sets* 25-th International Computer Software Cofer. 2001
- [Hol89] S.Holban, R.Vancea, D.Ciubotariu, *Recunoașterea formelor Aplicații* Ed. Academiei 1989



- [Hou94] S.Houzelle,G.Giraudon: *Contribution to multisensor fusion formalization*, Robotics and Autonomous Systems Vol.13 nr.1 Elsevier 1994
- [Hu96] Hu X, Cercone N *Mininig Knowledge Rules from Databases: A Rough Set Approach* 12-th International Confer. On Data Engineering 1996 pag.96-105
- [Hun04] A.Hunter,W.Liu: *Logical reasoning with multiple granularities of uncertainty in semi-structured information* , IPMU 2004
- [Huy04] Huynh V. Nakamori Y. *An Approach to Rouhness of Fuzzy Sets* IEEE Inter. Conference on Fuzzx Systems 2004 Budapest pag.115-120
- [Inu04] Inuiguchi M. *Classification – versus Approximation – oriented Fuzzy Rough Sets* IPMU 2004 Perugia
- [Jen04] Jensen R, Shen Q *Semantisc-Preserving Dimensionality Reduction: Rough and Fuzzy-Rough-Based Approaches* IEEE Transaction on Knowledge Vol. 16 nr.12 2004 pag.1457-1471
- [Jun01] J.Yun, M.D.Srinath, *An efficient method for scene cut detection* Pattern Recognition Letters Vol 22 nr.13Ed.Elsevier 2001
- [Kag00] S.Kagami, K.Okada, M.Inaba, H.Inaba, *Real 3D Depth Flow Generation and itsApplication to Track to Working Human Being*. IEEE Conference on Pattern Recognition, ICPR 2000
- [Kim00] Kim D,Bang S. *A Handwritten Numeral Character Classification Using Tolerant Rough Set* IEEE Tran.on Pattern Analysis vol.22 2000 pag.923-937
- [Kit98] J.Kittler,M.Hater&co: *On Combining Classifiers*, IEEE Transaction on Pattern Analysis Vol.20,nr.3 1998
- [Kob04] F.Kobayashi,D.Masumoto&co: *Sensor Selection based on Fuzzy Inference for Sensor Fusion* IEEE ICFS 2004
- [Kot98] P.Kotler, G.Armstrong, J.Saunders, V.Wong *Principiile Marketingului* Ed.Teora Bucuresti 1998

- [Kun02] L.Kuncheva : *A Theoretical Study on Classifier Fusion Strategies*, IEEE Transact. Pattern Analysis Vol.24,nr.2 2002
- [Lev74] L.Levitchi, & co *Dicționar Englez-Român* Ed.Academiei 1974
- [Li03] Li Y, Zhong N. *Interpretations of Association Rules by Granular Computing* 3-rd IEEE International Conference on Data Mining ICDM 2003
- [Liu05] Liu X., Wang H. *A Discretization Algorithm Based on a Heterogeneity Criterion* IEEE Trans. On Knowledge and Data Engineering vol.17,no.9 2005, pag.1166-1173
- [Lop02] D.Lopez, S.Espana, *Error-correcting tree language inference* Pattern Recognition Letters Vol22 nr.1,3Ed.Elsevier 2002
- [Loy02] G.Loy,L.Fletcher&co: *An Adaptive Fusion Architecture for Target Tracking* IEEE Inter'l Conf.onFace Recognition 2002
- [Mak03] A.Makarenko,T.Kaup: *Scalable Human-Robot Interactions in Active Sensor Networks*, IEEE PervasiveComputing 2003
- [Mel99] V.Melnic, *Sisteme electronice de supraveghere*, Ed. Teora 1999
- [Mor02] J.Morovic, J.Show, L.Sun, *A fast non-iterative histogram matching algorithm*, Pattern Recognition Letters Vol23 nr.1,3Ed.Elsevier 2002
- [Mor97] Barber F., Moreno S. *Representation of Continuous Change with Discrete Time* 4-th International Workshop on Temporal Representation 1997 pag.175-179
- [Mur98] R.Murphy: *Sensor and Information Fusion for Improved Vision-Based Vehicle Guidance.*, IEEE Intelligent System Nr.6 1998
- [Neg02] M.Negnevitsky, *Artificial Intelligence A guide to intelligent systems* Ed. Addison-Wesley London 2002
- [Nel00] B.Nelson: *Region of Interest Identification, Feature Extraction, and Information Fusion in a Forward Looking Infrared Sensor Used in Landmine Detection*, IEEE International Conference 2000
- [Ngu98] H.Nguyen,M.Sugeno: *Fuzzy Systems – Modeling and Control*, Ed. Kluwer Academic Publishers, 1998

- [Pal04] Pal S. Mitra P *Case Generation Using Rough Sets with Fuzzy Reprerentation* IEEE Transaction on Knowledge Vol. 16 nr.3 2004 pag.292-300
- [Par00] C.Park,H.Kim,I.&co: *Sensor Fusion for Motion Capture System Based on System Identification* IEEE CA2000
- [Paw01] Pawlak Z *Rough sets* International Journal of Computer and Information Sciences vol.11, 1982 pp.341-356
- [Ped02] W.Pedrycz, *Collaborative fuzzy clustering*, Pattern Recognition Letters Vol 23 nr.14Ed.Elsevier 2002
- [Ped05] Pedrycz W. *Knowledge-Based Clustering From Data to Information Granules* Ed.Wiley 2005
- [Pedr5] Pedrycz W.*From Granular Computing to Computational Intelligens and Human-centric System* IEEE Connections May 2005 pag.6-11
- [Pie04] W.Pieczynski: *Unsupervised Dempster-Shafer Fusion of Dependent Sensore* IEEE ICFS 2004
- [Rad04] Radzikowska A. Kerre E. *An Algebraic Characterisation of Fuzzy Rough Sets* IEEE Inter. Conference on Fuzzx Systems 2004 Budapest pag.109-114
- [Rez04] L.Reznik,V.Kreinovich: *Fuzzy and Probabilistic Models of Association Information in Sensor Networks*, IEEE ICFS 2004
- [Rou95] L.Roux,J.Desachy: *Information fusion for supervised classification in a satellite image*, IEEE 1995
- [Roy02] S.Roychowdhury, W.Pedrycz, *Modeling temporal functions with granular regression and fuzzy rules* Fuzzy sets and systems, vol.126, nr.3 2002 pag.177-185
- [Rui00] J.Ruiz,A.Soria: *Bio-inspired Framework for the Fusion of Cromatic, Infrared and Texture Information*, ICPR 2000
- [Rus03] S.Russell, P.Norvig, *Artificial Intelligence – A modern Approach* Ed. Prentice Hall 2003

- [Sch00] P.Scheunders: *Multispectral Image Fusion using Local Mapping Techniques*, Pattern Recognition ICPR 2000
- [Sha02] G.Shakhnarovich,T.Darrell: *On Probabilistic Combination of Face and Gaze Cues for Identification*, IEEE FGR 2002
- [Sha96] J.Shao, *Using Rough Sets for Rough Classification* 7-th Intl. Workshop on Database and Expert Systems 1996 pag.268-273
- [She01] J.Sherrah,S.Gong: *Continuous Global Evidence-Based Bayesian Modality Fusion for Simultaneous Tracking of Multiple Objects*, IEEE Inter'l Conf. Computer Vision 2001
- [Shu02] L.Shutao,J.Kwok,Y.Wang: *Multifocus image fusion using artificial neural network*, Pattern Recognition Vol23nr8 2002
- [Sin04] H.Singh,J.Raj&co: *Image Fusion using Fuzzy Logic and Applications*, ICFS Budapest 2004
- [Slo00] Slowinski R, Vanderpooten D *A Generalized Definition of Rough Approximations Based on Similarity* IEEE Transaction on Knowledge Vol. 12 nr.2 2000 pag.331-336
- [Spi03] T.Spircu: *Raționamentul aproximativ din punct de vedere probabilis, posibilist, credibilist, vag*, Șc.vara Arad 2003
- [Sto93] R.Stoinescu, *Prelucrarea imaginilor*, Ed. Politehnica Timișoara 1993
- [Str00] Strauss O,Comby F, Aldon M *Rough Histograms for Robust Statistics* International Confer.on Pattern Recognition ICPR 2000
- [Tak02] M.Takatsuka, T.Caelli, G.West, S.Venkatesh, *An application of agent-oriented techniques to symbolic matching and object recognition* Pattern Recognition Letters Vol 23 nr.4 Ed.Elsevier 2002
- [Tan03] Tanaka H. *Dual Interval Model and Its Application to Decision Making* IFSA 2003 pag.39-51
- [Tho90] S.Thomopoulos: *Sensor Integration and Data Fusion*, Journal of Robotic System 7(3) 1990, pag.337-372
- [Tor02] C.Torras, *Computer vision: Theory and Industrial Applications* Ed.Springer- Verlag 1992

- [Tre95] M.Tremblay,M.Cutkosky: *Using Sensor Fusion and Contextual Information to Perform Event Detection during a Phase-Based Manipulation Task*, Inter'l Intelligent Robots 1995
- [Tsu99] Tsumoto S. *Discovery of Rules for Medical Expert System Rough Set Approach* Pattern Recognition Letters Vol 20 nr.3 Ed.Elsevier 1999
- [Vla05] Vlackos K.I. Sergiadis G. *On the Entropy of Intuitionistic Fuzzy Events* CIMCA 2005 Viena pag.162-167
- [Wan04] Wang Y, Zhao J, Wu Y *Theoretical Study on Attribute Reduction of Rough Set Theory* Proceedings of the 3-rd IEEE Inter. Conf. On Cognitive Informatics 2004
- [Xuo4] Xu Y.,Winter J.,Lee W. *Dual Prediction-based Reporting for Object Tracking Sensor Networks* Internat. Conference on Mobile & Ubiquitous Systems 2004
- [Yag97] R.Yager: *A General approach to the Fusion of Imprecise Information*, Inter'l Journal of Intelligent system Vol.12 1997
- [Yao02] Yao Y. *On Modeling Data Mining with Granular Computing* 25-th Intern. Computer Software and Application Conference COMPSAC 2002
- [Yao04] Yao Y. *Concept Formation and Learning: A Cognitive Informatics Perspective* 3.rd Internat. Conference on Cognitive Informatics ICCI 2004
- [Yen96] J.Yen,N.Pfluger: *A fuzzy Logic Based Extension to Pyton and Rosenblatt's Command Fusion Method for Mobile Robot Navigation*, IEEE Transactions on Systems, Vol.25,nr.6 1996
- [Yif97] Z.Yifeng,H.Leung: *Minimum Entropy for Multisensor Data Fusion*, Signal Processing Workshop 1997
- [You02] Young T. Lin *Attribute (Feature) Completion – The Theory of Attributes from Data Mining Prospect* Intern. Conference on Data Mining ICDM 2002

- [You04] Young Tsay Lin *Granular Computing* IEEE Computational Intelligence Society November 2004 pag.10-13
- [Yo04b] Young T. Lin *Mining Associations by Linear Inequalities* 4-th Internat. Conference on Data Mining ICDM 2004
- [Zad78] L.Zadeh: *Fuzzy Sets as a Basic for a Theory of Possibility*, Fuzzy Sets and Systems, Ed.North-Holland Publishing 1978
- [Zad04] Zadeh L. *Precisiated Natural Language (PNL)*, *AI Magazine*, Vol. 25, No. 3, pag.74-91, 2004.
- [Zad05] Zadeh L *Computing with Information Deccribed in Natural Language* International Confer. On Computational Inteligence CIMCA2005 Vienna
- [GUM93] \*\*\*, *Guide for the expression of Uncertainty in Measurement*, ISO 1993
- [M 1] \*\*\*, *Manual de instalare PC 832*, Digital Security Controls Ltd, Canada
- [M 2] \*\*\*, *Manual de utilizare FARFISA*,ACI Farfisa Intercoms, SUA
- [M 3] \*\*\*, *Manual de utilizare PIR Bravo*,Digital Security Controls ,Canada
- [M 4] \*\*\*, *Manual de utilizare AT 171*, Bentel Sistemi, Italia
- [M 5] \*\*\*, *Manual tehnic*, SECO-Larm Inc.SUA
- [M 6] \*\*\*, *Manual Patrol STP*, Patrol Inc.Canada
- [M 7] \*\*\*, *Manual de instalare PC 4020*, Digital Security Controls Ltd
- [M 8] \*\*\*, *Manual de programare PC 4020*, Digital Security Controls Ltd
- [M 9] \*\*\*, *Manual de programare Esprit*, Paradox Inc.Canada
- [M10] \*\*\*, *Manual de programare S 4000*, CROW Elecronic Sesurity, Israel
- [M11] \*\*\*, *Manual de instalare XL 2S*, Fire Burglary Instruments Inc.SUA
- [M12] \*\*\*, *Manual de inatalare PC 510*, Digital Security Controls Ltd
- [M13] \*\*\*, *Manual de operare DigiScan*, GYYR Inc.Taiwan
- [M14] \*\*\*, *Manual de instructiuni SUR-GARD* Security Sys. Ltd Cnada.
- [M15] \*\*\*, *Fise de programare PC 4202,4116*,Digital Security Control Canada
- [M16] \*\*\*, *Manual de utilizare PCS10* , Velleman ,Belgia.
- [M17] \*\*\*, *Manual de prezentare TEM 412*, distribuție DSC ,Coreea
- [M18] \*\*\*, *Manual de utilizare DVR 4-100*, GeoVision ,SUA
- [M19] \*\*\*, *Manual de utilizare WebCam Pro*, Creativ, SUA

## LISTA PUBLICAȚIILOR PERSONALE

- C. Barna, *Tendențe în sistemele de supraveghere video*, Sesiune de comunicări Arad Iulie 2002, Analele UAV seria Electronică, pag.3-10, ISSN: 1582-3377
- C. Barna, *Tehnici de îmbunătățire a imaginilor utilizate în sisteme video*, Sesiune de comunicări, Arad, Iulie 2002, Analele U.A.V. seria Electronică, pag.11-18, ISSN: 1582-3377
- C. Barna, V.Bălaș, S.Bălaș, *The estimation of vegetation stage of greenhouse plants by fuzzy fusioned sensors of images and CO<sub>2</sub>*, Sesiunea de comunicari, Arad, 2004, Analele UAV 2004 seria Textile, ISSN: 1582-3431
- C. Barna, *Some aspects of the digital processing for fusion of information*, Scientific and Tehnical Bulletin Seria EEACCS Vol.1, U.A.V. Arad, 2004, pag.35-54, ISSN: 1584-9198
- C. Barna, & Co., *Tehnician pentru sisteme de detecție, supraveghere video și de moniorizare control acces și comunicații*, Curs de formare profesională, 2004, Institutul Bancar Român, București, Cap.10 *Supraveghere video*, pag.135-158
- C. Barna, *An Alarm System Design with PIR using Fuzzy Sensor Fusion and Genetic Algoritm Program*, IEEE International Workshop on Soft Computing Applications SOFA 2005, Szeged-Arad, pag.195-199, ISBN: 963-219-001-7
- C. Barna, *Surveillance System Using Information Fusion*, Analele Univ. din Oradea, 2005, fascicula Electrotehnică, pag.24-27, ISSN: 1223-2106
- C. Barna, M.Bălaș, *Using CCD Cameras for Car Following Algorithms*, IEEE International Symposium on Industrial Electronics ISIE, June 20-23, Duvrovnik Croația 2005, pag.57-62, ISBN: 0-7803-8738-4
- C.Barna, M. Bălaș, V.Bălaș, *The Constant Effort Imposed Distance Breaking for Urban Railwaz Vehicles*, The International Conference of „Computer as a Tool” EUROCON 2005, pag. 21-24, Belgrad, Serbia, ISBN: 1-4244-0050-3



- 
- C. Barna, *A testing method for PIR detections system*, CIMCA 2005 Inter.Conf. on Computational Intelligence for Modelling, Control and Automation, Viena Austria, pag.199-204, ISBN-10: 0-7695-2504-0
  - C.Barna, *Video Surveillance using a New Uncertainty Measurement*, WSEAS Transactions on Computers Vol.5 Issue8 2006, pag.1739-1744, ISSN 1109-2750
  - C. Barna, *A granular-based method for position and reliability estimation in alarm systems*, în curs de publicare IEEE International Conference in Mechatronics ICM 2006, Budapesta Ungaria
  - C. Barna, *Measuring Feature uncertainty by using similarity* 7-th WSEAS Conference on Fuzzy Systems 2006, Dubrovnik, Croatia ISBN: 960-8457-46-7
  - C. Barna, *Video Surveillance using a New Uncertainty Mesurment* WSEAS Transactions on Computers Issue 8, Vol.5 2006 pag.1739-1744 ISSN: 1109-2750
  - C. Barna, M. Stratualt, *A localization method based on infrared detectors for surveillance areas*, în curs de publicare IEEE CIMSA-VECIMS 2006, Coruna, Spania
  - C. Barna, M. Stratulat, *Assistant software for alarm systems* în curs de publicare 6-th International Conference on recent Advances in Soft Computing RASC 2006, Canterbury, Marea Britanie