


Ing. Valentina Emilia Bălaș

**SENZORI INTELIGENȚI CU MODEL INTERN ȘI
TEHNICI FUZZY**

TEZĂ DE DOCTORAT



Conducător Științific

Prof. dr. ing. MIRCEA CIUGUDEAN

2003

MULȚUMIRI

O teză ca aceasta nu ar fi fost posibilă fără ajutorul și influența unui mare număr de oameni.

Domnul Profesor Mircea Ciugudean, conducătorul acestei teze, m-a învățat multe lucruri, dar cel mai important a fost acela cum să faci o cercetare și cum să o scrii bine. A fost un inepuizabil tezaur de cunoștințe foarte fine, influența sa fiind răspândită în această teză. Cultura sa științifică și mai ales intuiția sa nu au încetat să mă impresioneze, la fel ca și rigoarea sa intelectuală și spiritul deschis. Am apreciat mult libertatea mare pe care mi-a lăsat-o, capacitatea de a relansa cercetarea în momente de îndoială. Prin entuziasmul său, competența dar mai ales încrederea sa, mi-a dat curajul să învăț și să progrez.

Țin să-i mulțumesc foarte mult pentru cele două burse acordate în cadrul stagiilor de câte o lună, efectuate la laboratorul de microinformatică industrială de la Universitatea de Savoia din Annecy.

În acești ani, întreaga familie CIUGUDEAN a știut să mă încurajeze, să-și arate disponibilitatea și căldura să mă ajute.

Sunt extrem de recunoscătoare pentru faptul că am avut un astfel de conducător de teză, lucru pe care îl doresc și altora.

Îmi exprim recunoștința mea Domnului Profesor Toma Leonida Dragomir care prin competența, rigoarea științifică și altruismul său, m-a ghidat într-un mod deosebit de-a lungul elaborării tezei. Sfaturile sale au fost deosebit de prețioase și întotdeauna potrivite. Remarcile și întrebările sale mi-au ridicat numeroase subiecte de reflexie care rămân în continuare ca teme de aprofundat.

Îmi exprim gratitudinea mea tuturor Domnilor Profesori care au acceptat să fie referenții acestei lucrări și pentru onoarea care mi-au acordat-o de a accepta să fie membrii acestei comisii de examen.

Doresc să mulțumesc Domnului Profesor Laurent Foulloy director al laboratorului LAMII Annecy pentru invitațiile pe care mi le-a făcut și acceptarea efectuării stagiilor de documentare în cadrul echipei conduse de domnia, sa în domeniul senzorilor simbolici fuzzy. Vreau să-i mulțumesc pentru disponibilitatea, prietenia pe care mi-a arătat-o și discuțiile interesante avute în România și în Franța.

Mulțumesc Domnișoarei Profesor Sylvie Galichet, Domnilor Profesori Gilles Mauris și Eric Benoit, de la Universitatea de Savoia din Annecy pentru numeroasele discuții, sfaturile și comentariile bine argumentate. De asemenea mulțumesc Doamnei Secretare Joelle Pellet de la laboratorul LISTIC – Annecy, pentru sprijinul și prietenia sa.

Apreciez disponibilitatea constantă, sfaturile și cordialitatea cu care mi-a împărtășit opiniile Domnul Profesor Radu Emil Precup.

Mulțumesc Domnilor Profesori Tiberiu Mureșan, Virgil Tiponut și Mircea Vlăduțiu pentru încurajări și numeroasele discuții.

Mulțumiri pentru entuziasmul și generozitatea Domnului Profesor Eugene Roventza de la Universitatea York din Toronto, care m-a ajutat constant în documentare și este sincer alături de mine.

Mulțumesc pentru încurajările, sprijinul moral și căldura sufletească, acordate de la distanță, de către Domnul Profesor Lotfi A. Zadeh de la Universitatea Berkeley, California, un om de o rară inteligență și umanitate.

Îmi exprim mulțumirile tuturor colegilor pentru suportul moral, administrativ și tehnic.

Întreaga familie m-a încurajat și motivat să continui de-a lungul urcușurilor și coborâșurilor care au condus spre această teză.

Mulțumiri speciale aduc mamei mele Emilia și fratelui Mircea Putin-Racoviță care au crezut cu tărie în reușita acestei teze. Am simțit permanent dragostea și susținerea constantă a fiicelor noastre gemene Sanda și Dana.

În final și cel mai important, doresc să mulțumesc soțului meu Marius Mircea Bălaș, care a ascultat cu răbdare toate ideile mele, a citit toate rândurile lucrării, a fost un adevărat suport moral de dragoste și de motivație pentru a termina teza.

Cuprins

Introducere.

0.1.	Obiectul tezei	pag. 0.1
0.2.	Suportul teoretic și contribuțiile teoretice originale	pag. 0.2
0.3.	Contribuțiile aplicative originale	pag. 0.3

Capitolul 1. Introducere în problematica senzorilor inteligenți

1.1.	Definirea senzorului inteligent	pag. 1.1
1.2.	Integrarea senzorilor inteligenți într-un sistem automat de producție	pag. 1.4
1.3.	Credibilitatea măsurii	pag. 1.5
1.4.	Funcțiunile senzorului inteligent	pag. 1.6
1.5.	Noi modalități de creștere a capacității de prelucrare a datelor	pag. 1.10
1.6.	Concluziile capitolului 1	pag. 1.11

Capitolul 2. Validarea și fuziunea senzorilor în condiții de incertitudine

2.1.	Reducerea imperfecțiunii prin validare și fuzionare	pag. 2.1
2.1.1.	Obiectivele validării și fuzionării	pag. 2.1
2.1.2.	Tehnici de validare și de fuziune	pag. 2.3
2.1.2.1.	Fuziunea prin selectarea senzorilor	pag. 2.3
2.1.2.2.	Fuziunea posibilistică	pag. 2.9
2.1.2.3.	Fuziunea informațiilor complementare	pag. 2.16
2.1.2.4.	Fuziunea bazată pe produs și pe sumă probabilistică	pag. 2.18
2.2.	O metodă originală de fuziune prin mediere ponderată neliniară	pag. 2.19
2.2.1.	O arhitectură fundamentală de fuziune prin mediere ponderată	pag. 2.19
2.2.2.	Grade de încredere neliniare	pag. 2.21
2.3.	Concluziile capitolului 2	pag. 2.22

Capitolul 3. O nouă structură de senzor inteligent cu model intern

3.1.	Metode de reglare și identificare bazate pe modele interne	pag. 3.1
3.1.1.	Sisteme de reglare adaptive cu model intern	pag. 3.1
3.1.2.	Variante ale reglării adaptive cu model intern	pag. 3.3
3.1.3.	Identificarea proceselor prin metoda modelului intern	pag. 3.5
3.1.4.	Soluții de modelare	pag. 3.6
3.2.	Un senzor inteligent cu fuziunea datelor și model intern	pag. 3.8
3.2.1.	Senzor inteligent adaptiv cu model intern	pag. 3.8
3.2.2.	Modelul matematic al SIAMI	pag. 3.11
3.4.	Concluziile capitolului 3	pag. 3.12

Capitolul 4. Senzor inteligent cu model intern al vitezei unui vagon

4.1.	Un senzor inteligent al vitezei unui vagon pe durata frânării ABS	pag. 4.1
4.1.1.	Frânarea ABS, un proces afectat de incertitudine	pag. 4.1
4.1.2.	Introducerea unui accelerometru	pag. 4.4
4.1.3.	Structura și funcționarea senzorului inteligent	pag. 4.5
4.1.3.1.	Fuzionarea fuzzy asistată de un model intern	pag. 4.5
4.1.3.2.	Modelul funcțional al frânei ABS	pag. 4.8
4.1.3.3.	Implementarea modelului vagonului în SIMULINK	pag. 4.9
4.1.3.4.	Estimatorul coeficientului de aderență	pag. 4.15
4.1.3.5.	Fuziunea fuzzy	pag. 4.16
4.1.3.6.	Descrierea funcționării SIVV	pag. 4.18

	4.1.3.7 Autodiagnosticarea prin intermediul fuzionării fuzzy.....	pag. 4.19
	4.1.3.8. Autoadaptarea prin intermediul fuzionării fuzzy.....	pag. 4.19
	4.1.4. Rezultate obținute prin simulare.....	pag. 4.20
4.2	Estimarea on-line a uzurii frânci disc.....	pag. 4.23
4.3	Avantajele SIVV.....	pag. 4.25
4.4	Concluziile capitolului 4.....	pag. 4.26

Capitolul 5. Senzor inteligent cu model intern al temperaturii în cuptoare

5.1.	Aplicarea fuziunii asistată de model intern în cazul măsurării pentru cupatoare.....	pag. 5.1
	5.1.1. Structura unui senzor inteligent de temperatură pentru cuptoare....	pag. 5.1
	5.1.2. Implementarea în SIMULINK.....	pag. 5.3
5.2	Fuziunea prin mediere ponderată neliniară cu senzorii primari etalonați...	pag. 5.7
5.3	Fuziunea fuzzy.....	pag. 5.9
5.4	Concluziile capitolului 5.....	pag. 5.12

Concluzii și contribuții personale

C.1	Concluzii.....	pag. C.1
C.2	Contribuții personale.....	pag. C.2
	C.2.1. Contribuții teoretice.....	pag. C.2
	C.2.2. Contribuții aplicative.....	pag. C.3

Referințe bibliografice

Anexa 1. Măsurători și traductoare

Anexa 2. Imperfecțiunea informației

Anexa 3. Fuziunea datelor și informațiilor

Anexa 4. Teoria posibilităților. Fuzionarea posibilistică

0.1. Obiectul tezei

„În primul rând calculul cu cuvinte este o necesitate atunci când informația disponibilă este prea imprecisă pentru a justifica utilizarea numerelor. În al doilea rând atunci când există o toleranță față de imprecizie, ea poate fi exploatată pentru a obține flexibilitate, robustețe, costuri scăzute și o mai bună raportare față de realitate. Exploatarea toleranței față de imprecizie este o caracteristică de mare importanță în calculul cu cuvinte”

Contextul general fixat de cuvintele profesorului Lotfi A. Zadeh prezentate mai sus [Zade96], reprezintă fundamentul acestei lucrări. Demersul pe care l-am urmărit a fost aplicarea procedurilor de calcul cu cuvinte în cazul senzorilor inteligenți și a fuzionării informației. Bineînțeles că succesul procedurii este legat de calitatea cunoștințelor pe care se fundamentează.

Măsurarea presupune construirea unei corespondențe între valoarea măsurandului și o scală numerică absolută sau relativă. Este necesar ca această corespondență să fie ușor reproductibilă și transmisibilă. Din păcate măsurătorile sunt afectate de imperfecțiunea dispozitivelor de măsurare și în plus suferă influențele perturbatoare ale altor mărimi, diferite de măsurand.

Creșterea calității măsurătorilor se poate obține în mai multe moduri, dar cea mai modernă și fertilă abordare constă din *investirea senzorilor cu inteligență*. Evoluția sistemelor de comandă integrând tehnici de inteligență artificială au condus la necesitatea utilizării unui nou tip de senzor inteligent capabil să fie interfațat direct cu astfel de sisteme. Mergând mai departe pe această direcție și pentru a putea integra funcțiile cele mai evoluat ale conceptului de captor inteligent, s-a propus echiparea senzorului însuși, cu tehnici de inteligență artificială care să-i permită obținerea unor măsurători cât mai precise în condiții de imprecizie și incertitudine. De asemenea s-a urmărit distribuția inteligenței de la nivelul sistemului central spre senzorul inteligent, pentru desconggestionarea de sarcini a acestuia.

Modalitățile prin care se poate investi cu inteligență un senzor pot fi cuprinse într-un domeniu delimitat de două tipuri fundamentale de soluții:

- Soluții bazate pe *perfecționarea tehnologiilor*;
- Soluții bazate pe *perfecționarea prelucrării informațiilor*.

Primul referat elaborat pentru fundamentarea acestei teze [Băla98a] prezintă o trecere în revistă a principalelor soluții tehnologice de investire a senzorilor cu inteligență, în acest sens fiind de menționat mai ales tehnologiile de microprelucrare a siliciului. Din păcate aceste tehnologii sunt extrem de costisitoare și greu accesibi-

le. Singura șansă de realizare a unui senzor inteligent prin microprelucrări ar fi elaborarea unei structuri care să aibă o aplicabilitate extrem de largă, astfel încât realizarea sa practică să devină fezabilă. Din acest motiv, următorul referat [Băla99b], ca și soluția finală prezentată în teză, s-au orientat înspre elaborarea unei structuri de senzor inteligent care să fie în primul rând capabil de o valorificare superioară a datelor disponibile. Teza urmărește obținerea unei structuri fundamentale de senzor inteligent, care să poată fi utilizată într-o gamă cât mai extinsă de aplicații, indiferent de natura măsuranzilor și să poată fi implementată simplu, prin orice tehnologie software sau hardware. Astfel se vor putea realiza cu ușurință aplicațiile care să justifice eventuala sa integrare.

Definirea senzorilor inteligenți și inventarierea funcțiilor care pot fi considerate ca inteligente sunt deocamdată probleme deschise și fac obiectul capitolului 1.

0.2. Suportul teoretic și contribuțiile teoretice originale

Dificultatea obiectivului propus este provocată în principal de imprecizia și incertitudinea datelor care trebuiesc prelucrate. În timpul unei măsurători, mai ales dacă ea se realizează la distanță, avem un acces foarte limitat la condițiile concrete în care se desfășoară măsurătoarea (starea tehnică a senzorilor și a canalelor de măsură, condiții climatice, mărimi perturbatoare, etc.) Practic, pentru a face posibile anumite măsurători sau pentru a îmbunătăți calitatea lor, suntem constrânși la estimarea acestor condiții, doar pe baza datelor imperfecte pe care le avem la dispoziție.

Din aceste motive consider că singura abordare la care se poate apela întotdeauna în acest domeniu este cea de tip sistem expert. Pentru fundamentarea soluțiilor expert am apelat în principal la *logica fuzzy* și la *teoria posibilității*. Deoarece logica fuzzy a făcut deja obiectul unui număr suficient de mare de lucrări în ultimii ani, ea nu este decât evocată, în timp ce teoria posibilității este prezentată mai pe larg, în Anexa 2.

Pentru a extrage cât mai multe informații din datele disponibile s-a apelat la o tehnică des aplicată în ultimii ani, respectiv la tehnica *fuzionării datelor*, care face obiectul capitolului 2. Prin această tehnică, datele furnizate de la mai mulți senzori primari pot concura la realizarea unei singure estimări a măsurandului. În cazul în care fuzionarea este corect proiectată, această estimare are șanse de a fi superioară calitativ măsurilor furnizate de oricare dintre senzorii primari. Fuzionarea datelor poate fi aplicată în mai multe variante, în funcție de gradul de incertitudine al cunoștințelor despre sistem. În studiile de caz din capitolele 4 și 5 se propun două variante: o metodă originală de mediere ponderată neliniară, recomandată atunci când dispunem de fișa de etalonare a senzorilor, respectiv o fuzionare ponderată fuzzy, în cazul în care nu dispunem de informații precise referitoare la senzorii primari.

Cea mai importantă contribuție teoretică originală a tezei face obiectul capitolului 3 și constă din introducerea în structura senzorului inteligent a unui model intern al sistemului din care face parte măsurandul. Modelul intern este *determinist* și *structural*, oferind în primul rând o estimare a măsurandului, care este introdusă în mecanismul de fuzionare împreună cu datele senzorilor primari. Dar mai mult decât atât, în cazul în care este utilizat cu ingeniozitate, modelul oferă o gamă largă de posibilități „inteligente” de îmbunătățire a măsurărilor: estimarea unor mărimi perturbatoare, estimarea unor mărimi greu măsurabile, adaptarea senzorului la condițiile de măsură, auto-diagnosticarea și auto-configurarea, etc. Modelul acționează prin

intermediul fuzionării, care este condusă prin gradele de încredere acordate datelor provenite de la senzorii primari.

0.3. Contribuțiile aplicative originale

Structura de senzor inteligent descrisă, care poate fi considerată prin aspectele sale metodologice ca generând și o metodă de măsurare asociată, este aplicată în două studii de caz prezentate pe larg în capitolele 4 și 5. Este vorba despre estimarea vitezei unui vagon pe durata frânării ABS, caz în care roțile vagonului nu mai indică viteza acestuia, respectiv despre măsurarea temperaturii dintr-un cuptor de tratamente termice. Estimarea vitezei vagonului este completată de alte două aplicații originale: estimarea on-line a uzurilor frânei disc respectiv a bandajelor roților vagonului. Aplicațiile legate de frânarea vagonului au fost comunicate la conferințe internaționale, în Annecy (Franța) și Budapesta (Ungaria).

Avantajele aplicării noii metode de măsurare inteligentă, care poate fi definită ca fiind *adaptivă, cu fuziune a datelor și cu model intern*, sunt demonstrate prin simulări.

Pe lângă cele cinci capitole, teza mai cuprinde patru anexe.

În Anexa 1 se prezintă terminologia de bază utilizată în domeniul metrologiei.

În Anexa 2 sunt caracterizate diferitele varietăți ale imperfecțiunii datelor și informațiilor, respectiv impreciziile și incertitudinile, precum și modelările acestora cu ajutorul mulțimilor fuzzy și măsurilor de posibilitate și necesitate.

În Anexa 3 se face un studiu bibliografic asupra noțiunii de fuziune a datelor și informațiilor.

În Anexa 4 se prezintă elemente de teoria posibilității și fuziunea informației bazată pe această teorie.

11

Notă: *contribuțiile originale sunt evidențiate prin caractere îngroșate (bold), atât în cazul textului și bibliografiei cât și în cazul figurilor sau formulelor.*

Introducere în problematica senzorilor inteligenți

În acest capitol se definesc funcțiunile care conferă senzorilor inteligență, conform accepțiunii grupului de lucru CIAME (Comité Interprofessionnel pour l'Automatisation et la MEsure). Din studiul literaturii se constată că aceste funcții se pot grupa în patru categorii: măsurare, configurare, validare și comunicare. Am introdus ca element original al structurii unui senzor inteligent un modelul intern al procesului măsurat și al canalului de măsură. Scopul utilizării modelului este introducerea unei funcții noi, care urmează să fie utilizată în continuare în teză: estimarea evoluției în timp a măsurandului.

1. 1. Definirea senzorului inteligent

Dezvoltările tehnologice ale microelectronicii și ale structurilor microprogramate au contribuit la apariția conceptului de *senzor inteligent* SI [Foul91], [Foul93a], [Foul95], [Robe99], [Petr00]. Dotând canalul de măsură asociat senzorului cu un organ de calcul intern și cu un transmițător, și integrând o parte cât mai mare din acest ansamblu, vor rezulta performanțe metrologice și funcționale considerabil mărite față de cele obținute tradițional. Termenul *traductor inteligent* TI se folosește atunci când senzorul este intercalat în structura unei bucle de reglare automată [Dumi93], [Băla98a]. Termenii SI și TI sunt considerați de multe ori sinonimi.

În Referatul I pentru doctorat [Băla98a] am prezentat principalele tehnologii microelectronice cu aplicații în domeniul senzorilor inteligenți: tehnologiile planară, a straturilor subțiri, a straturilor groase, compatibilă și mai ales microprelucrările de suprafață și de volum.

Definirea precisă a conceptelor SI respectiv TI este însă mai puțin legată de tehnologie cât de funcționalitate, problema rămânând încă deschisă. O lungă serie de lucrări poate fi consultată în acest sens: [Abde90], [Alie94], [Abde95], [Robe99], etc.

Din studiul literaturii dedicate senzorilor inteligenți am constatat că cele mai multe încercări de sistematizare a domeniului se găsesc în literatura franceză. Se pot astfel menționa o serie de lucrări de doctorat care tratează subiecte ca: senzorii simbolici [Fou91], senzorii ultrasonici inteligenți [Maur92], senzorii fuzzy și simbolici de culoare [Beno91], [Beno93a], [Beno93b], [Beno94a], [Beno94b], arhitecturi de senzori inteligenți [Lutt97], modelarea fuzzy a incertitudinii senzorilor [Lass99], etc. Din acest motiv, în acest capitol introduc o serie de noțiuni propuse de echipa de instrumentație inteligentă CRAN de la Universitatea din Nancy [Robe93] a grupului de lucru CIAME [CIAM87] precum și de *Ghidul de exprimare a incertitudinii măsurătorilor* [GUI93].

Conform CIAME, arhitectura unui SI poate fi descrisă ca în fig. 1.1. Principalele sale componente sale sunt:

- unul sau mai mulți senzori primari (pentru măsurand și pentru mărimile de influență);
- părți de condiționare specifice;
- un organ de calcul intern (microcontroler, DSP), care permite tratarea locală și elaborarea unui semnal numeric;

- o interfață de comunicație permițând un schimb bilateral de informație prin intermediul unui mediu de comunicație;
- circuite de alimentare.

Tot în fig. 1.1 se prezintă și o comparație între două tipuri de canale de măsură specifice unui senzor analogic respectiv unui senzor numeric inteligent [Lutt97].

Specificitatea unui SI poate să fie rezumată la capacitatea sa internă de calcul, de tratare a datelor, asociată cu posibilități de comunicație. Aceste caracteristici tehnologice permit să se amelioreze funcția “măsură” în sistemele de automatizare.

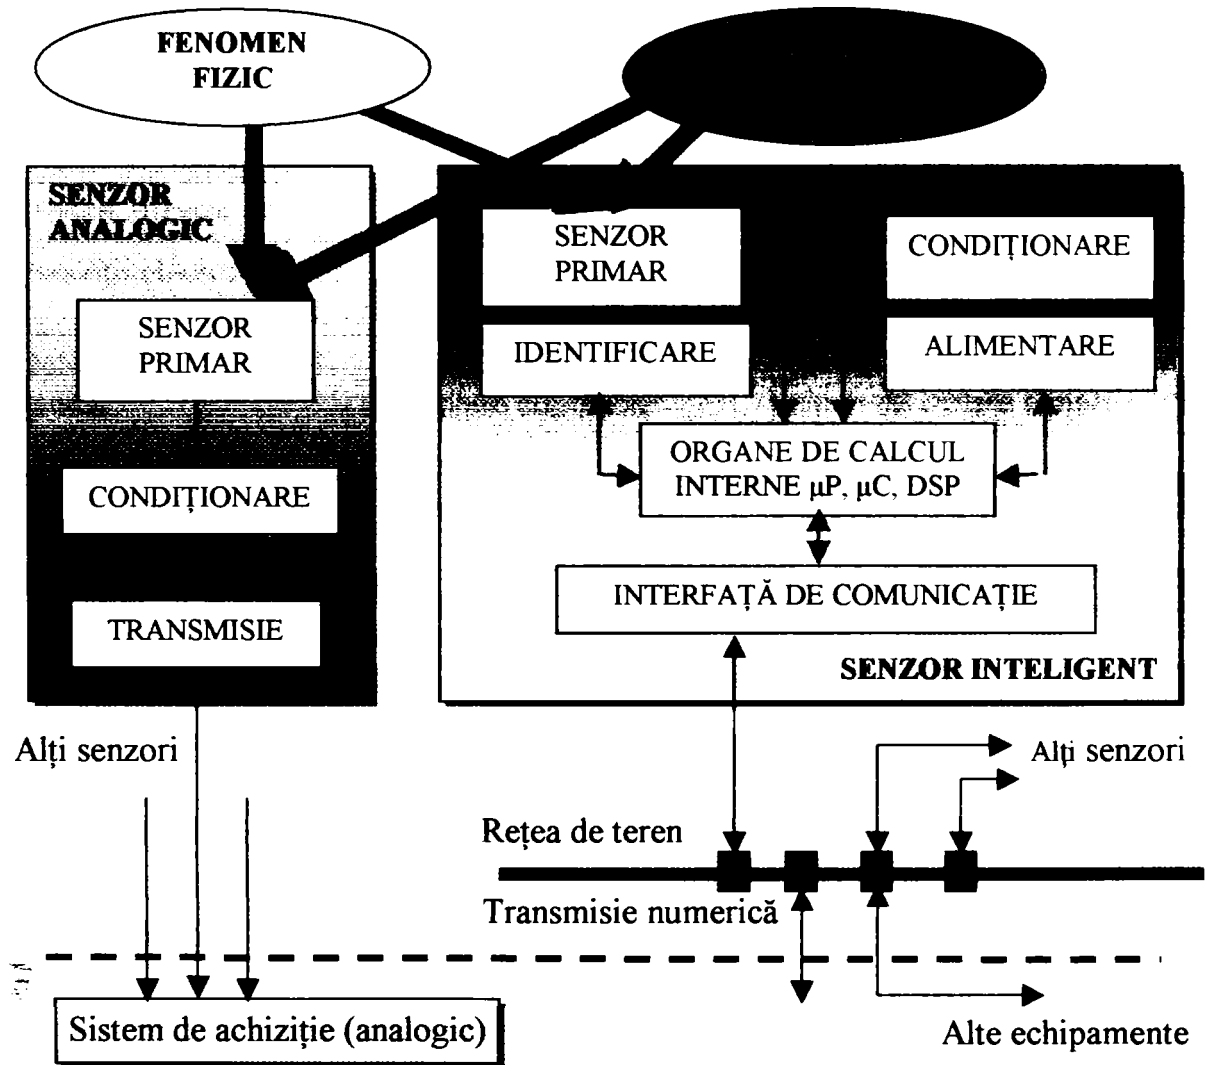


Figura 1.1. Arhitectura senzorului analogic și a celui numeric - inteligent

Principalele câștiguri aduse de SI, în termeni metrologici și funcționali sunt:

- creșterea exactității măsurilor prin compensarea locală a neliniarităților, a mărimilor de influență, a derivelor, etc.
- elaborarea de date direct exploatabile la nivelurile superioare; se permite astfel distribuirea unei părți de loc neglijabilă a puterii totale de calcul necesare;
- diminuarea costurilor prin simplificarea cablajelor, reducerea transmițătoarelor, convertizoarelor sau adaptoarelor intermediare;
- simplificarea mentenanței și configurării (auto-diagnostic, auto-calibrare, etc.);
- credibilitatea crescută a informațiilor prin auto-validare și auto-diagnosticare.

Trecerea de la măsurarea clasică la cea inteligentă rezultă din trecerea de la instrumentația analogică la cea numerică și din progresele făcute în microelectronică și software. Utilizarea tehnicilor numerice permite digitizarea semnalului aproape de măsurand pentru a diminua efectele perturbațiilor analogice. Tabelul de mai jos compară cele două modalități fundamentale de prelucrare a datelor [Lutt97].

Caracteristici	Senzori analogici	Senzori numerici
1. Perturbații		
Tensiunea de alimentare	Influență asupra preciziei	Risc de indisponibilitate
Îmbătrânirea componentelor	Influență asupra preciziei	Puțină influență fără risc de indisponibilitate
Mediul climatic	Problemă bine stăpânită	Problemă mai critică
Paraziții electromagnetici	Precauții clasice (filtrare, ecranare)	Precauții clasice (filtrare, ecranare), filtraj numeric
Defecte de izolare galvanică	Sensibili, dispozitive de izolare complexe	Sensibilitate medie și dispozitive de izolare simple
Defecțiuni tipice	Derive, erori, pierderi ale preciziei	Încetarea funcționării sau dispersie
Diagnosticare	Detecție dificilă a defectelor	Detecția ușoară a defectelor (cod de detecție)
2. Metrologie		
Precizia	Medie, din cauza derivei componentelor analogice	Poate fi excelentă, un compromis bun cu viteza
Zgomotul de cuantificare	Nu există	Există, poate limita rezoluția și precizia
3. Transmisie		
Împlicare	Dificilă	Foarte simplă
Transmisie simultană într-un mediu unic	Dificilă	Simplă
Debit de informații	Oferă încontinuu întreaga informație	Debitul poate să fie foarte ridicat
4. Diverse		
Stocarea informației	Aproape imposibilă	Foarte simplă
Consumul de energie	Legat de specificul măsurătorii	Inferior cazului analogic, variază cu viteza
Testabilitatea	Foarte simplă	Simplă
Mentenanță	Medie	Poate fi mult ușurată

1.2. Integrarea senzorilor inteligenți într-un sistem automat de producție

Un sistem automat de producție este constituit din suma mijloacelor tehnice (procesul tehnologic, sistemul de automatizare, operatorii, etc.) destinate elaborării unor produse conforme obiectivelor economice și tehnice.

Un sistem de automatizare a producției (SAP) este compus în același timp din elemente hardware și software:

- dispozitive hardware și software de prelucrare: senzori, elemente de acționare, reglatoare, automate programabile, etc.
- dispozitive de memorare: memorii, discuri, benzi, etc.
- dispozitive hardware și software de comunicație: linii, rețele, etc.

Un SAP poate să fie împărțit în mod funcțional în patru subsansambluri: sistemul de achiziție de date, din care face parte și setul de senzori, sistemul de decizie, sistemul de comunicație și sistemul de execuție (fig. 1.2). Dintre acestea, legate direct de SI sunt sistemul de achiziție a datelor și cel de comunicare.

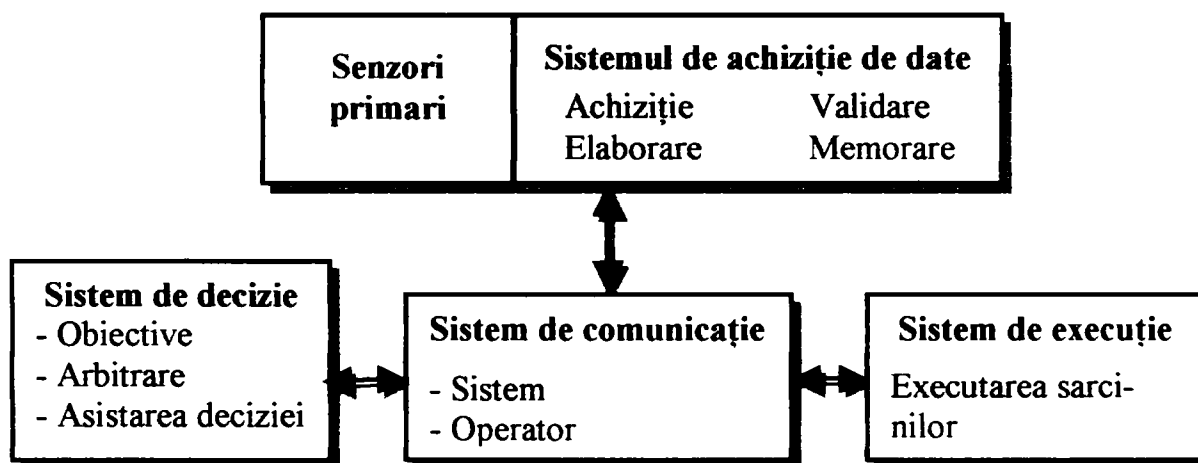


Figura 1.2. Descompunerea unui SAP în subsisteme

Sistemul de achiziționare a datelor colectează (prin intermediul senzorilor), validează și memorează informațiile necesare funcționării SAP-ului și generează baza de date validată, folosită de către sistemul de decizie.

În [Peti96] se prezintă în contextul industrial PRIAM (*Pre-normative Requirements for Intelligent Actionnement and Measurement*), un sistem de Acționare și de Măsurare Inteligent (AMI), ca o interfață între sistemul de producție și sistemele automatizate de Control-comandă, Mentenanță sau Gestiune Tehnică.

Creșterea inteligenței și integrarea în SAP produce nevoi de comunicație mai importante între senzori și mediu (automate, sisteme de menținere, elemente de acționare, etc.).

Nevoia de comunicare crește și pe plan calitativ deoarece tipurile de informații de transmis printr-un SI pot să fie variate (rezultatele măsurărilor, informații de stare, mesaje de serviciu, etc.). În plus SI este susceptibil de a primi informații sau cereri externe specificând un anumit tip de funcționare, sau un anumit tip de măsurare. Acesta permite descentralizarea tratamentelor și distribuirea inteligenței, prin coborârea unor funcții de prelucrare și decizie până la nivelul său. Alegerea sistemu-

lui de comunicație care se asociază acestor senzori este deci importantă. Rețelele locale industriale (de teren) vor fi instrumentele și suporturile care permit realizarea acestei funcții de comunicație, între senzori, elementele de acționare, etc.

1.3. Credibilitatea măsurii

Credibilitatea poate să fie definită ca și proprietatea unui sistem de a furniza informații având un grad de încredere impus. Ameliorarea disponibilității, securității și rentabilității instalațiilor industriale trece printr-o credibilitate crescută a informațiilor puse la dispoziția operatorilor în sistemele automatizate de producție și prin exploatarea optimă a acestor date [Maur94a], [Maur95], [Maur96].

În ceea ce privește senzorii, ei pot fi afectați de diferite defecte:

- defecte proprii sensorului (derivate, deteriorări, etc.);
- defecte datorate electronicii atașate (alimentare, deriva componentelor, etc.);
- defecte legate de condițiile de utilizare (efecte ale mărimilor de influență, depășirea domeniului măsurii, timp de răspuns, etc.);
- defecte de transmitere a semnalelor (paraziți).

Unul dintre beneficiile aduse de SI este contribuția la ameliorarea credibilității măsurilor efectuate. Această credibilitate este obținută :

- datorită funcțiilor interne vizând realizarea validării informației: autodiagnostic, autosupraveghere, autoadaptare, etc. (fig. 1.3);
- datorită informațiilor despre sistem și mediu obținute prin măsurare.

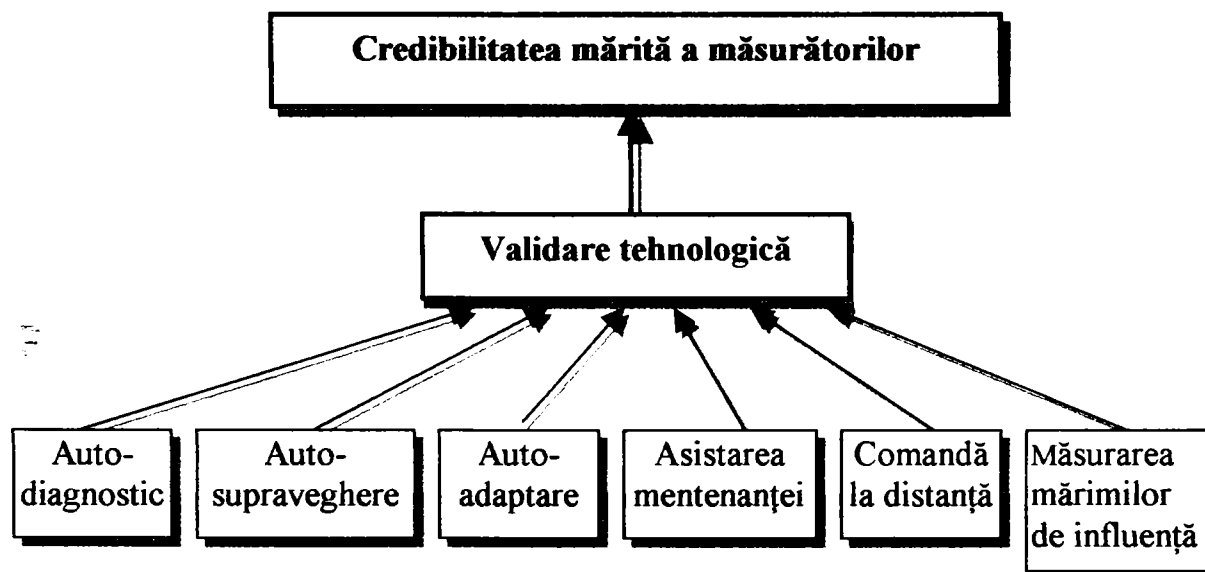


Fig. 1.3. Creșterea credibilității prin funcțiunile introduse de SI

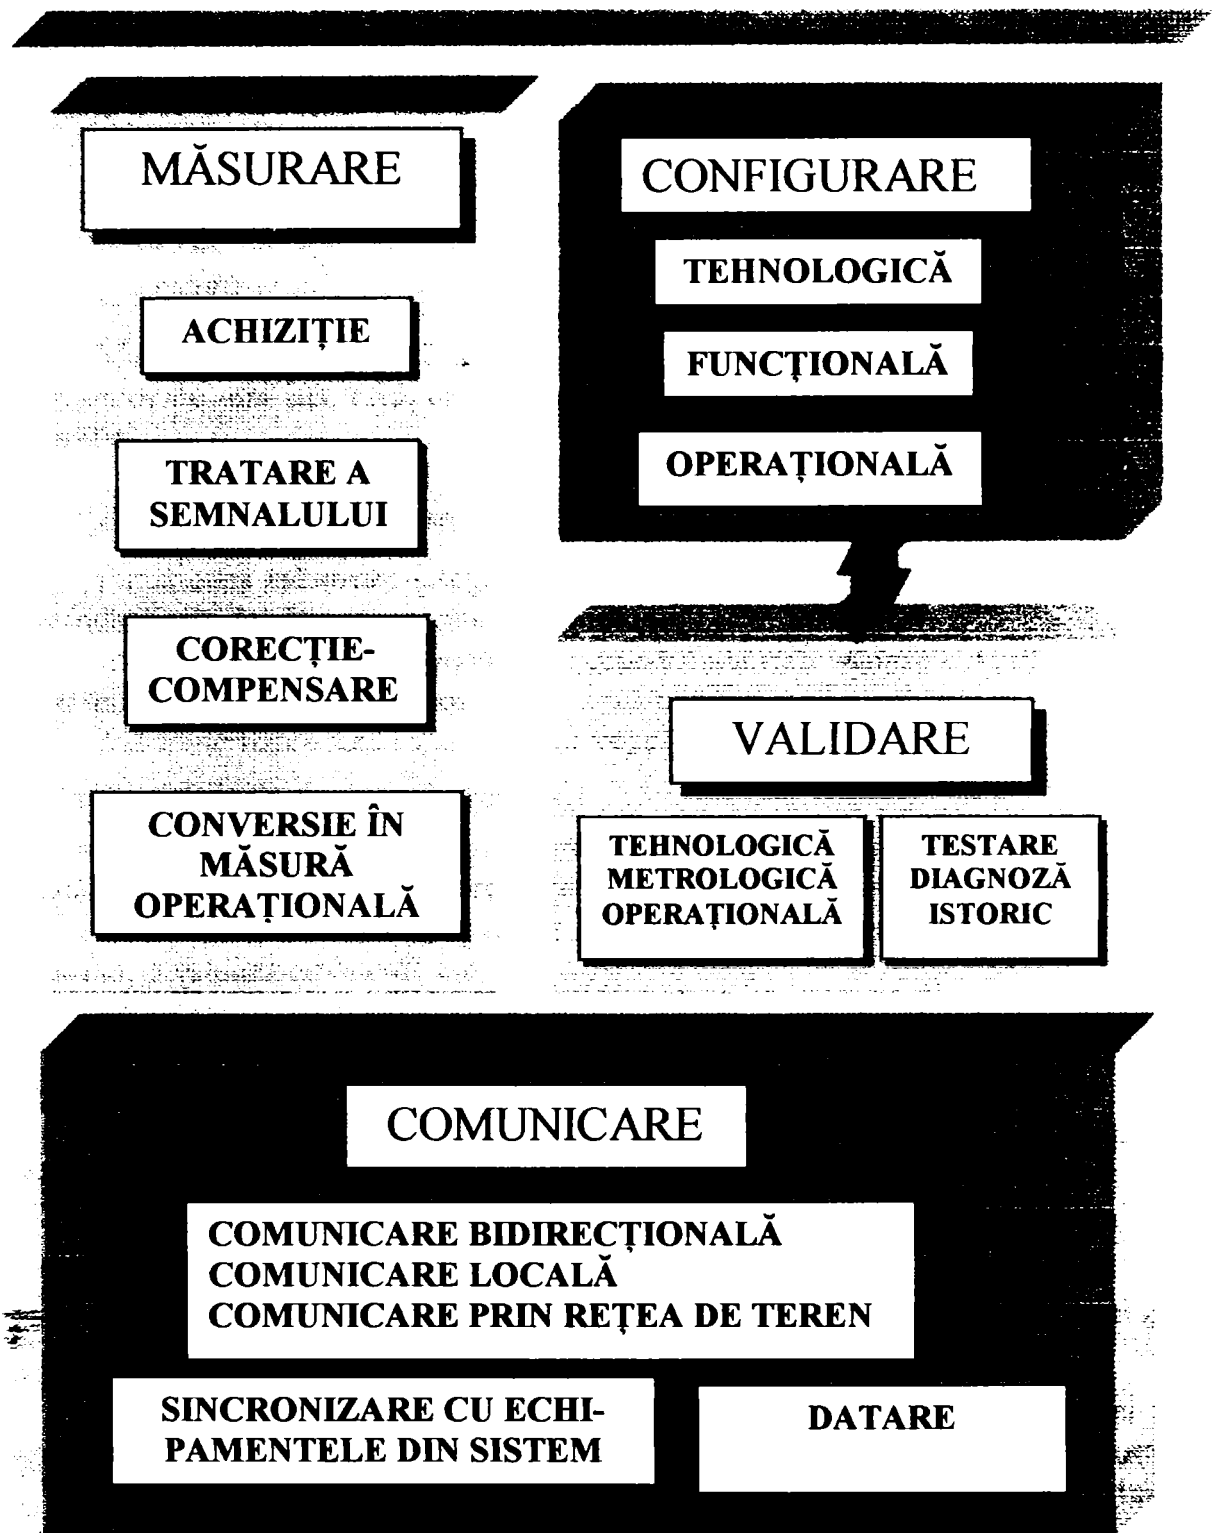


Figura 1.4. Funcțiunile interne ale unui senzor inteligent

1.4. Funcțiunile senzorului inteligent

Funcțiunile prezentate în continuare sunt extrase din modelul CIAME și provin de la grupul de lucru "Funcționalitatea senzorilor" [CIAM87], [Foul91], [Peti96], [Maur97]. Acest model se bazează pe descompunerea inițială a funcțiilor interne ale unui SI.

Pentru utilizator, SI poate să fie văzut ca o sursă de date metrologice ale căror conținut informațional constă din evoluția măsurii în timp și nivelul ei de încredere.

Fig. 1.4 prezintă funcțiunile esențiale oferite de către un SI:

- *măsurare*;
- *configurare*;
- *validare*;
- *comunicare*.

Mai multe exemplificări ale soluțiilor tehnice care permit implementarea funcțiunilor de mai sus, reieșite din literatura de specialitate, au fost menționate în [Băla98a].

a) Funcțiunea *măsurare*

Funcțiunea *măsurare* integrează aspectele metrologice și de tratare a semnalului îndeplinite de către un senzor inteligent.

În fig. 1.5 este descrisă ierarhia necesară elaborării *măsurii operaționale*, care este o măsură validă direct exploatabilă de către utilizator.

Mărimile fizice sunt repartizate în trei clase:

- mărimi principale sau măsuranzi;
- mărimi de influență care vor permite compensarea măsurii față de influențele fenomenelor fizice perturbatoare. Aceste mărimi sunt măsurate fie intern, fie obținute prin intermediul unui suport de comunicație (de exemplu: temperatura aparatului, presiunea ambiantă, etc.);
- variabile și mărimi de auto-control care permit să se testeze buna funcționare a senzorului în timpul măsurării.

Toate aceste mărimi pot să fie interne, locale sau la distanță.

- interne, adică produse de către senzor, în particular pentru variabilele de auto-control și toate variabilele intermediare localizate în senzor;
- locale, care caracterizează mediul fizic al senzorului;
- la distanță, care caracterizează mediul sistemului SI (de exemplu orologiul sistemului ca și toate informațiile emise de către oricare alt senzor).

Aceste informații participă la punerea la dispoziția utilizatorului a unei măsurii operaționale, obținută pornind de la *măsura calificată*. Ea este elaborată pornind de la *măsurile funcționale*, integrând *măsurii primare* reprezentative ale mărimilor principale, corectate eventual prin *măsurii auxiliare*, imagini ale mărimilor de influență, prin intermediul modelelor matematice care țin cont de diferite neliniarități care caracterizează interacțiunile măsuranzilor și ale sistemului de măsură.

În cadrul acestei lucrări, în structura SI s-a introdus ca soluție originală, modelul determinist structural al procesului măsurat și al canalului de măsură, denumit în continuare *model intern*. Această soluție este expusă în capitolul 3.

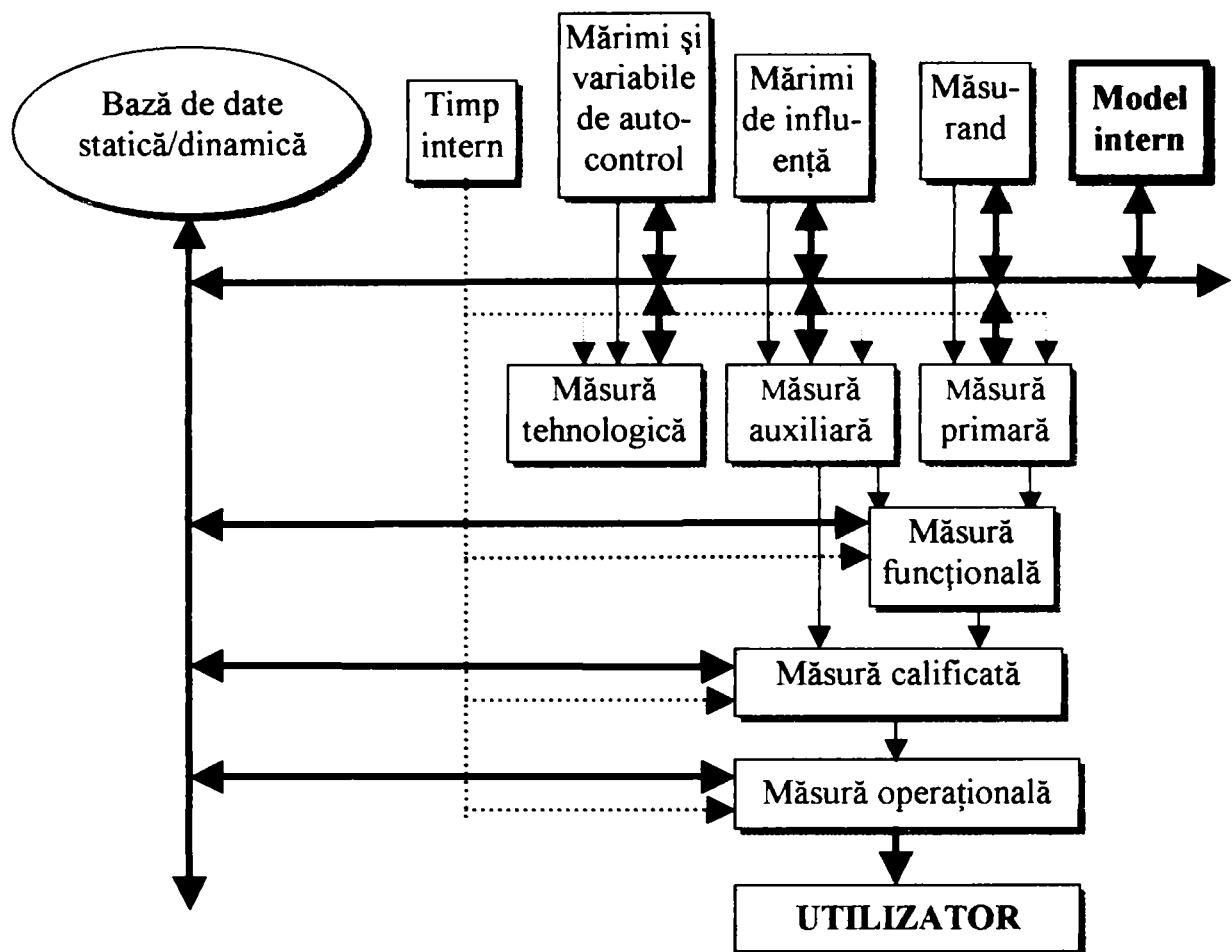


Figura 1.5. Ierarhia care conduce la măsura operațională

La această măsură funcțională se vor adăuga *măsură tehnologică* care permit garantarea bunei funcționări a instrumentului în momentul măsurării.

Între măsura validată și măsura operațională se face o conversie care constă din transcrierea datelor senzorului într-un domeniu dorit de utilizator.

Această măsură, furnizată de către senzorul inteligent prin intermediul unui suport de comunicație, trebuie să conțină și datarea, de unde rezultă necesitatea de a integra în SI o gestiune de timp sincronizabilă cu un orologiu extern.

În ultimii ani s-au realizat și *senzori simbolici*, a căror informații de ieșire nu sunt numerice ci simbolice [Perr00], [Fuol94a], [Foul94b], [Maur97], [Băla00b].

b) Funcțiunea *configurare*

Această funcțiune constă din adaptarea senzorului la condițiile impuse de către un regim de exploatare dat. SI poate beneficia de posibilitățile oferite de schimbul de informații cu operatorul, dar din punctul de vedere al inteligenței, importantă este mai ales auto-configurarea. Funcționalitatea configurare, este realizată de către constructor încă din faza de fabricație [Isak95] și include:

- *configurarea tehnologică* care este rezultatul unui ansamblu de acțiuni și validările lor, vizând integrarea SI în mediul său fizic de exploatare;
- *configurarea funcțională* care este rezultatul unei mulțimi de acțiuni și validările lor, care vizează să asigure măsurarea și comunicarea SI.

- *configurarea operațională* este rezultatul unui ansamblu de acțiuni și validarea lor, vizând dedicarea senzorului pentru o aplicație specifică.

Configurările funcțională și operațională inițiale pot să fie modificate în ipoteza unei exploatare degradate, rezultată dintr-o defecțiune detectată intern sau pentru o cât mai bună adaptare la condițiile de funcționare [Băla99a]. În acest caz, se poate vorbi despre *autoadaptare* și despre SI *adaptivi* sau TI *adaptive*.

c) Funcțiunea validare

După CIAME funcțiunea validare este indisociabilă de alte funcțiuni (fig. 1.6), pentru că ea este baza conceptului SI. Un efect al introducerii inteligenței în SI este legat chiar de creșterea credibilității măsurii.




Figura 1.6. Funcțiunea validare

Măsura funcțională trebuie să fie luată în considerare de către măsurile tehnologice care caracterizează buna funcționare a SI atât în termeni de *tehnologie*, de exemplu:

- măsura tensiunii de alimentare;
- temperatura circuitelor electronice;
- integritatea canalului de achiziție;
- verificarea bunei derulări a algoritmului;

cât și în termeni de *metrologie*, de exemplu:

- coerența măsurii față de plaja de măsură;
- respectarea condițiilor de temperatură a mediului ambiant;

Funcțiunea validare poate să fie completată prin:

- actualizarea sistematică a unui istoric stocat în SI;
- declanșarea procedurilor de reconfigurare, când este diagnosticată o defecțiune.

d) Funcțiunea comunicare

Funcțiunea comunicare trebuie să decodeze și să interpreteze ordinele și mesajele care parvin înspre SI și în consecință să declanșeze acțiunile adecvate [Foul94a], [Foul94b], [Jose95]. Ea are de asemenea sarcina să formeze informațiile de transmis de la SI înspre exterior.

Funcțiunea de comunicare pune între altele, probleme cum ar fi:

- protocoalele de comunicare aplicate;
- modalitatea de acces la variabile;
- dialogul cu operatorul, etc.

În contextul sistemului distribuit care favorizează comunicația dintre echipamente, se pune problema compatibilității între echipamente și a inter-operabilității. Pentru echipamentele pe care le putem caracteriza ca omogene soluția este de tip producător unic. Într-un mediu de echipamente eterogene, echipamentele diverșilor constructori trebuie să fie compatibile între ele. Sunt necesare echipamente capabile să dialogheze între ele și care pot să fie înlocuite cu echipamente care provin de la alți constructori, de același tip și asigurând aceleași servicii (sau cel puțin o mare parte dintre ele).

Comunicația poate să fie orientată și înspre mărimi simbolice [Pedr99].

e) Funcțiuni suplimentare

În completarea funcțiilor de mai sus, este oportună și integrarea funcțiilor de gestiune, care au sarcina să asigure gestionarea următoarelor elemente:

- baza de date;
- timpul intern, sincronizabil cu timpul exterior;
- siguranța în funcționare: disponibilitatea, integritatea, securitatea, fiabilitatea, mentenanța, credibilitatea;
- calitatea echipamentului, de exemplu, parametrii comunicării, etc.

1.5. Noi modalități de creștere a capacității de prelucrare a datelor

În general avantajele utilizării SI sunt următoarele:

- ameliorarea performanțelor metrologice (extinderea domeniului de măsură, creșterea preciziei, compensarea automată a derivelor și a perturbațiilor, etc.);
- posibilitatea auto-adaptării și auto-configurării în funcție de condițiile de măsurare;
- optimizarea costurilor de exploatare datorită auto-diagnozei;
- optimizarea costurilor de producție;
- validarea măsurii prin atribuirea unor grade de încredere;
- comunicarea cu mediul înconjurător (alți senzori, echipamente de conducere automată, etc.);
- descentralizarea operațiilor de condiționare și prelucrare a semnalelor produse de senzorii primari. Aceste operații sunt realizate la nivel local, doar rezultatele fiind comunicate înspre nivelele de decizie ale aplicațiilor

În lucrare se va urmări creșterea cantității și calității informației extrase în cadrul măsurătorilor prin mărirea numărului de senzori primari și agregarea lor prin fuzionare. Se obține astfel creșterea redundanței și prin urmare și a fiabilității. În plus performanțele metrologice cresc, deoarece se creează posibilitatea ca într-un anumit punct de măsură să se aleagă cel mai precis dintre senzorii primari.

Avantajul concentrării datelor și capacității de calcul la nivelul senzorului va fi pe deplin valorificat introducând o nouă funcțiune: *estimarea măsurandului și a mărimilor de influență*. Prin estimare, din datele primare pot fi obținute informații „ascunse”, referitoare la mărimile de influență sau caracteristicile de performanță care nu pot fi măsurate direct, dar joacă un rol important în procesul măsurat. Estimările vor fi realizate cu ajutorul modelelor interne.

Pentru exemplificare, în capitolul 4 se va demonstra posibilitatea estimării aderenței, mărime de influență esențială în cazul frânărilor, care nu poate fi măsurată direct. În același capitol se exemplifică estimarea on-line a uzurii frânei disc în cazul vagoanelor.

1.6. Concluziile capitolului 1

Noile tehnologii electronice, mai ales microtehnologiile, precum și utilizarea tehnicilor numerice în prelucrarea datelor, permit integrarea unei anumite inteligențe în interiorul senzorilor și traductoarelor și în consecință, ameliorarea caracteristicilor metrologice și a credibilității măsurilor. Noile funcțiuni integrate dau senzorilor inteligenți și traductoarelor inteligente un loc mai important în sistemele automatizate de producție. Se prezintă funcțiunile prin care dispozitivele de măsurare pot fi investite cu inteligență. Din studierea literaturii se constată că aceste funcțiuni se pot grupa în patru categorii: măsurare, configurare, validare și comunicare.

Se subliniază principalele diferențe dintre senzorul analogic clasic și cel numeric, care poate deveni inteligent. Utilizarea tehnicilor numerice permite pe lângă prelucrarea informației la nivelul senzorului și comunicarea bidirecțională a acestuia cu alte echipamente inteligente. Se facilitează astfel distribuirea informațiilor și a sarcinilor în interiorul sistemului.

Este propusă introducerea în structura senzorilor inteligenți a unui bloc conținând modelul intern determinist structural al procesului măsurat, al senzorilor primari și al canalului de măsură. Prin utilizarea modelului intern se introduce și o nouă funcțiune „inteligentă”, estimarea, care crește capacitatea de prelucrare a informației la nivelul senzorilor. Estimarea urmează să fie aplicată în cadrul soluțiilor originale propuse în teză.

Validarea și fuziunea senzorilor în condiții de incertitudine

În acest capitol se tratează două probleme esențiale ale senzorilor inteligenți: validarea și fuziunea mai multor senzori, cu scopul de a obține o măsură cu un grad de încredere mai mare decât al oricăruia dintre cele furnizate de senzorii primari componenți. Se trec în revistă mai multe tehnici de validare și fuziune și în final se propune o metodă originală de fuziune neliniară.

2.1. Reducerea imperfecțiunii prin validare și fuzionare

2.1.1. Obiectivele validării și fuzionării

Validarea și fuzionarea datelor sunt funcțiuni importante ale unui SI, prin care acesta poate opera în condiții de imprecizie și incertitudine [Goeb96].

Validarea constă din atribuirea unui grad de încredere fiecărei măsurători.

Fuziunea este o operație prin care un șir de date furnizate de către unul sau mai mulți senzori primari sunt înlocuite cu o singură valoare. În mod obișnuit datele obținute în urma unor măsurători ale aceluiași măsurand cu mai mulți senzori nu coincid, de unde apare necesitatea fuziunii. Rezultatul fuziunii prezintă un grad de încredere mai mare decât al fiecăruia dintre senzori luați în parte [Yage97a], [Yage97b].

Este preferabil să se culeagă date de la mai mulți senzori deoarece creșterea redundanței este benefică în cazul apariției unor defecțiuni. Astfel, putem fi siguri că există o valoare disponibilă a măsurii chiar dacă majoritatea senzorilor din structură se defectează – cu excepția unuia. Senzorii pot fi de același tip sau diferiți. Redundanța poate fi de asemenea creată folosind senzori indirecti (estimatori) care prezintă anumite relații funcționale ce înglobează cantitatea interesată.

Inerentele imperfecțiuni ale informațiilor furnizate de către senzori sunt concretizate prin imprecizie și incertitudine și sunt prezentate în Anexa 2. Printre metodele care modelează imprecizia și incertitudinea amintim teoria probabilității, logica fuzzy, teoria posibilității, rețelele neuronale, etc. (vezi Anexa 3) [Bouc95], [Bouc98], [Chat99].

Teoria probabilității este o teorie clasică, testată matematic și aplicativ. Axiomele sale fundamentale de aditivitate pentru evenimente disjuncte sunt clare și necontestate. Limitările teoriei probabilităților sunt acelea că evenimentele considerate sunt mutual exclusive și colectiv exhaustive [Dubo00a].

Logica fuzzy și teoria posibilității pe de altă parte se concentrează mai mult pe caracterul vag al datelor spre deosebire de probabilitatea unui eveniment [Dubo00b]. În logica fuzzy încrederea în datele observate este exprimată prin valoarea funcției de apartenență care este gradul de adevăr că datele sunt corecte. Acest punct de vedere diferă de cel al logicii clasice în care un eveniment este fie adevărat fie fals. Un eveniment poate fi parțial adevărat, gradul de adevăr fiind înglobat în valoarea funcției de apartenență .

O a treia metodă compatibilă cu incertitudinea o reprezintă tehnica rețelelor neuronale. Ele nu sunt instrumente tradiționale în sensul că nu cuantifică incertitudinea pe care o implică un proces sau un eveniment, dar pot fi folosite pentru a filtra incertitudinea. Aceasta se poate realiza mai întâi prin antrenarea rețelei neuronale după care rețeaua poate fi capabilă de a îndepărta incertitudinea atașată datelor. Dezavantajul rețelelor neuronale este lipsa lor de transparență, reprezentarea cunoștințelor fiind exclusiv internă.

În concluzie, în funcție de tipul incertitudinii încrederea se poate exprima fie în termeni de probabilitate fie în grade de apartenență (încredere).

Validarea și fuziunea sunt indisolubil legate, motiv pentru care de cele mai multe ori sunt tratate împreună. Aceste tehnici încearcă să atribuie o valoare de încredere sensorului luat în considerare. Fuzionarea ia în considerare încrederea citirii sensorului fie prin înlăturarea citirilor cu o încredere scăzută fie prin aplicarea unor reguli, sau a unor metode de mediere ponderată. Validarea senzorilor implică estimarea stării adevărate a sistemului care este apoi comparată cu datele măsurate de senzor.

O arhitectură fundamentală de validare-fuziune poate fi cea prezentată în fig. 2.1, caracterizată printr-o buclă de reacție, pe baza căreia se execută validarea. Validarea de acest tip se bazează pe compararea măsurilor furnizate de senzori cu măsura produsă prin fuziune.




Fig. 2.1. Arhitectură de validare și fuziune a senzorilor cu feedback

Reacția propusă a fost până în prezent evitată din cauza riscului de instabilizare generată de inerția senzorilor, pe durata regimurilor tranzitorii [Chab94]. Așa cum se va vedea în capitolele 4 și 5, acest risc poate fi evitat prin estimarea măsurandului cu ajutorul unui model intern.

În continuare în acest capitol se vor investiga mijloacele prin care arhitectura originală din fig. 2.1 poate fi concretizată.

Din cauza impreciziei și incertitudinii, datele care provin de la senzori trebuie validate mai ales în aplicațiile în care este în joc siguranța oamenilor sau în aplicațiile care implică costuri ridicate. **O aplicație din prima categorie o reprezintă estimarea vitezei vagonului pe durata frânării ABS pentru vehiculelor feroviare, care face obiectul capitolului 4. În această aplicație se utilizează atât senzori identici - cei fixați la fiecare osie cât și senzori diferiți – un accelerometru și chiar un senzor indirect – un model software al vehiculului. O aplicație ce implică costuri ridicate, măsurarea temperaturii în cuptoarele de tratamente termice, în care se utilizează mai mulți senzori diferiți și un model, este tratată în capitolul 5.**

2.1.2. Tehnici de validare și de fuziune

2.1.2.1. Fuziunea prin selectarea senzorilor

Fuziunea prin selectarea senzorilor poate fi ilustrată printr-o metodă propusă în [Koba99] și care înglobează principalele tendințe actuale. Metoda utilizează trei module: de evaluare, de selectare și de fuzionare. Semnalele senzorilor primari sunt folosite ca intrări în modulul de evaluare și în modulul de selectare. Mai întâi, în modulul de evaluare este evaluată ca încredere informația fiecărui senzor, luând în considerare caracteristicile senzorului, ca de exemplu: domeniul de sesizare și precizia. Apoi, în modulul de selectare sunt selectate, pe bază de reguli, gradele de încredere ale senzorilor. Regulele de selectare sunt determinate de experiența și cunoștințele unui expert uman. La formularea regulilor de selectare se folosește măsura de posibilitate. În final, în modulul de fuzionare, sistemul evaluează prin inferență fuzzy valoarea estimată a măsurii din informația selectată de la senzori, luând în considerare încrederea acestora.

Schema bloc corespunzătoare este prezentată în fig. 2.2. iar mai multe detalii despre metodă se găsesc în Anexa 2.

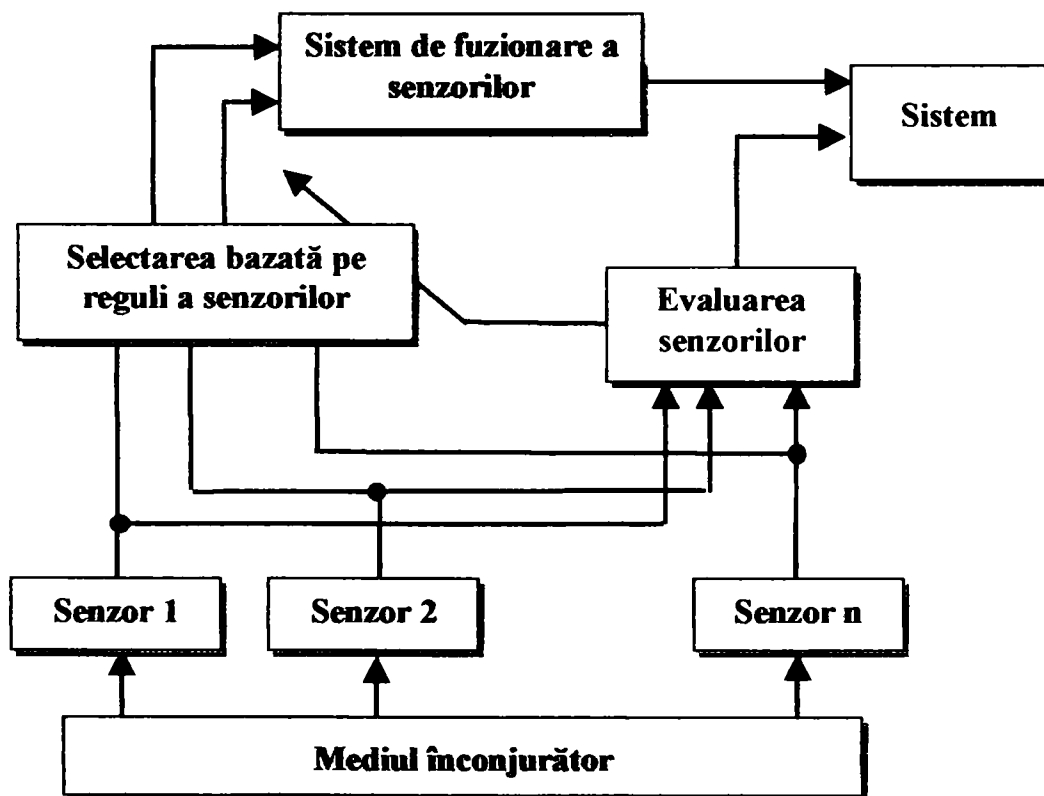


Fig. 2.2. Sistem de fuzionare cu selectare a senzorilor

Metoda este perfecționată față de o lucrare anterioară [Fuku92] prin înlocuirea fuziunii fuzzy cu o rețea neuronală recurentă pentru fuzionarea informației selectate de la senzori și inferarea ei. În mod special, rețelele neuronale recurente sunt foarte folosite pentru fuziunea sistemelor de senzori care inferează stările sistemului din

datele serie de timp. S-a folosit o rețea recurentă de tip Jordan care are trei straturi și reacție de la stratul de ieșire la stratul de intrare

Măsura fuzzy reprezintă ambiguitatea informației și a fost propusă de Sugeno în 1972. Ambiguitatea semnifică faptul că informația poate să aparțină la submulțimi diferite. Măsura fuzzy este definită ca o funcție:

$$\mu_{\omega_0} : S \rightarrow [0,1]$$

cu condițiile de graniță și monotonicitate exprimate de ecuațiile (2.1) și (2.2):

$$\mu_{\omega_0}(\Phi) = 0, \quad \mu_{\omega_0}(\Omega) = 1 \quad (2.1)$$

$$E \subset F \Rightarrow \mu_{\omega_0}(E) \leq \mu_{\omega_0}(F) \quad (2.2)$$

Măsura de posibilitate este un fel de măsură fuzzy și a fost propusă de către Zadeh în [Zade78]. Măsura de posibilitate Π este definită de ecuația (2.3):

$$\Pi(E) = \sup \{ \pi(\omega) \mid \omega \in E \} \quad (2.3)$$

unde E este o submulțime la care aparține informația și π este funcția distribuție de posibilitate care satisface ecuația (2.4):

$$\sup \{ \pi(\omega) \mid \omega \in \Omega \} = 1 \quad (2.4)$$

Fiecare informație a senzorului aparține unei submulțimi în care este împărțit domeniul de măsurare de către precizia cerută senzorului. Folosim precizia cerută a valorii inferate ca precizie impusă. Domeniul de măsurare S_i al senzorului i este împărțit în submulțimi de către precizia cerută a valorii inferate dy așa cum se prezintă în fig. 2.3.




Fig. 2.3. Împărțirea domeniului în funcție de precizia ieșirii

Presupunem că informația senzorului s_i este inclusă printre submulțimile S_{ik} și este exprimată cu ecuația (2.5):

$$S_{ik} = \{ s_i \mid (k-1)dy \leq s_i < kdy \} \quad (k = 1, 2, \dots, K) \quad (2.5)$$

Deoarece informația fiecărui senzor este afectată de eroare, nu este sigur faptul că aceasta aparține submulțimii S_{ik} . Se definește domeniul E prin ecuația (2.6):

$$E = \{ s_i \mid s_i - \frac{ds_i}{2} \leq s_i \leq s_i + \frac{ds_i}{2} \} \quad (2.6)$$

De aceea, încrederea în informația senzorului este determinată de relația dintre submulțimea S_{ik} și domeniul E. Adică, dacă domeniul E este inclus în submulțimea S_{ik} în întregime, senzorul are o încredere ridicată. Invers, dacă domeniul E nu este inclus în

submulțimea S_{ik} , încrederea este scăzută. Încrederea în informația senzorului se calculează cu ajutorul măsurii de posibilitate.

Submulțimea S_{ik} este transformată într-o mulțime Ω prin ecuația (5.7):

$$\Omega = \{\omega \mid 0 \leq \omega < 1\} \quad (2.7)$$

La fel domeniul E este transformat în domeniul E' exprimat prin relația (2.8):

$$E' = \left\{ \omega \mid \omega_i - \frac{ds_i/2}{dy} \leq \omega \leq \omega_i + \frac{ds_i/2}{dy} \right\} \quad (2.8)$$

unde ω_i este exprimat de ecuația (2.9):

$$\omega_i = \begin{cases} \frac{s_i - (k-1)dy}{dy} & (s_i \leq (k - \frac{1}{2})dy) \\ \frac{kdy - s_i}{dy} & (s_i > (k - \frac{1}{2})dy) \end{cases} \quad (2.9)$$

prevăzând că limita inferioară a mulțimii E' este 0 și limita superioară a acesteia este 1. Definim funcția distribuție de posibilitate prin ecuația (2.10), ca în fig.2.4.

$$\pi(\omega) = \begin{cases} \frac{dy}{ds_i} & (0 \leq \omega \leq \frac{ds_i}{dy}) \\ 1 & (\frac{ds_i}{dy} < \omega \leq 1) \end{cases} \quad (2.10)$$




Fig. 2.4. Distribuția de posibilitate a funcției $\pi(\omega)$

În consecință măsura de posibilitate λ_{s_i} a informației senzorului s_i este calculată cu ecuația (2.11)

$$\lambda_{s_i} = \sup \{\pi(\omega) \mid \omega \in E\} \quad (2.11)$$

Activarea senzorilor se face prin reguli expert de forma:

$$\begin{aligned} \text{DACĂ } & \lambda_{s_1} \text{ este } \{\text{Mic, Mediu, Mare}\}, \\ & \lambda_{s_2} \text{ este } \{\text{Mic, Mediu, Mare}\}, \\ & \dots \\ & \lambda_{s_i} \text{ este } \{\text{Mic, Mediu, Mare}\} \end{aligned} \quad (2.12)$$

ATUNCI senzorii folosiți sunt $\{1, 2, \dots, s\}$

unde termenii lingvistici “Mic”, “Mediu” și “Mare” descriu gradul de încredere.

Regulile de votare a senzorilor se bazează pe următoarele considerente:

- Dacă toate gradele de încredere sunt identice se folosește toată informația senzorilor;
- Dacă există o încredere “Mare”, se selectează senzorul respectiv;
- Dacă nu există încredere “Mare” se selectează senzorii cu încredere “Medie”.

Delimitarea mulțimilor fuzzy este apriorică:

$$\left\{ \begin{array}{l} \text{Mic: } \{0 \leq \lambda_{si} < 0,35\} \\ \text{Mediu: } \{0,35 \leq \lambda_{si} < 0,65\} \\ \text{Mare: } \{0,65 \leq \lambda_{si} < 1\} \end{array} \right. \quad (2.13)$$

Fuziunea propusă este obținută printr-o rețea neuronală recurentă de tip Jordan care are trei straturi și reacție de la stratul de ieșire la stratul de intrare.

Se poate aprecia că fuziunea prin selectarea senzorilor [Kobe99] este interesantă mai ales prin modalitatea de stabilire a gradelor de încredere în senzori, dar nu este recomandabilă pentru implementări hardware, mai ales din cauza utilizării rețelei neuronale.

Aguilar și Crespo [Agui92] urmăresc egalitatea valorilor furnizate de către senzori. Caracteristicile senzorului sunt extrase prin crearea unei distribuții de posibilitate folosind metoda histogramei. Presupunând că există doi senzori care măsoară aceeași cantitate, se obțin patru valori de încredere, două pentru senzorii individuali și două pentru perechile de combinații. Valorile individuale de încredere sunt obținute prin compararea comportării curente a senzorului cu valorile din trecut. Valorile de încredere pereche sunt obținute prin compararea celor doi senzori și evaluarea ratei lor de coincidență.

Regulile sunt proiectate astfel:

DACĂ senzorul 1 și senzorul 2 sunt similari **ATUNCI** încrederea este mare

DACĂ senzorul 1 și senzorul 2 sunt diferiți **ATUNCI** încrederea este mică

etc. (2.14)

Prin fuziune se creează o singură valoare a măsurătorii care are o încredere ce se obține prin combinarea încrederilor și ponderilor fiecărei măsurători:

$$\sigma_f = \sqrt{w_1 \sigma_1^2 + w_2 \sigma_2^2 + \dots + w_n \sigma_n^2} \quad (2.15)$$

unde

σ_f este valoarea încrederii fuzionate;

σ_i sunt încrederile valorilor obținute de la senzorii primari;

w_i sunt ponderile pentru fiecare valoare de încredere ($0 < w_i < 1$, $w_1 + \dots + w_n = 1$).

Spre deosebire de această abordare destul de laborioasă, în [Pala94] se folosește logica fuzzy. Se pot crede ambii senzori sau nici unul sau unul dintre cei doi senzori. Această situație se prezintă grafic în Fig. 2.5.

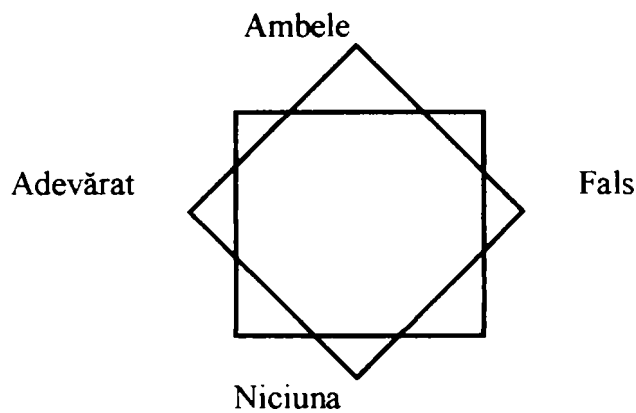


Fig. 2.5. Latticea celor patru valori de adevăr

Fiecărei citiri a senzorilor îi este alocată una dintre valorile mulțimii {„Adevărat”, „Fals”, „Nici una”, „Ambele”}. Logica cu valori fuzzy adaugă grade de încredere sau de neîncredere celor patru clasificări. Astfel, fiecare colț al laticii presupune o suprafață cu două dimensiuni a gradelor de apartenență așa cum se prezintă în fig. 2.6, desemnând grade de încredere sau de neîncredere. Astfel, [0,0] semnifică ignoranța completă, [1,1] inconsistență completă, [1,0] încredere completă și [0,1] neîncredere completă.

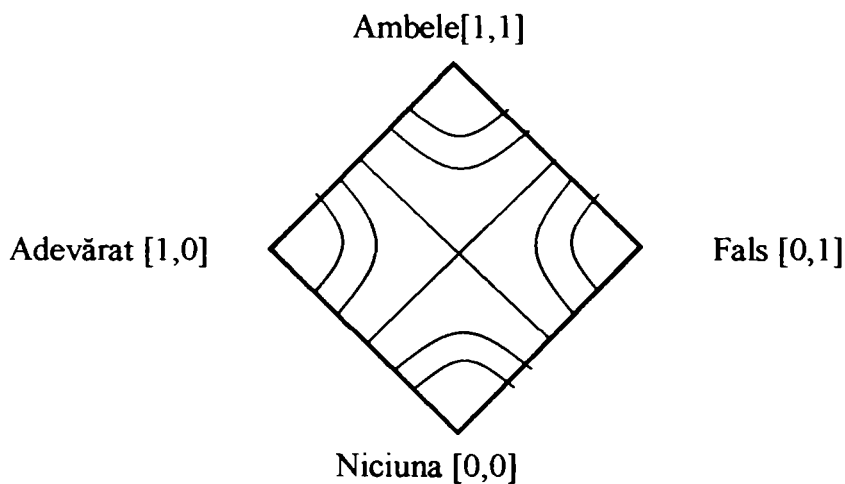


Fig. 2.6. Latticea valorilor de adevăr fuzzy

Aria din interiorul laticii se referă la o regiune fuzzy. Distanța de la colțuri este o măsură pentru valorile fuzzy. Centrul [0.5, 0.5] este punctul cel mai fuzzy dintre toate.

Ponderea unui punct poate fi calculată fie *liniar*:

$$w = 1 - d\sqrt{2} \quad \text{dacă } 0 \leq d \leq \frac{1}{\sqrt{2}} \quad (2.16)$$

fie *neliniar*:

$$w = \begin{cases} 1 & \text{dacă } d = 0 \\ 1 - 2(d\sqrt{2})^2 & \text{dacă } d \leq \frac{1}{2\sqrt{2}} \\ 2(1 - d\sqrt{2})^2 & \text{dacă } d \leq \frac{1}{\sqrt{2}} \\ 0 & \text{dacă } d = \frac{1}{\sqrt{2}} \end{cases} \quad (2.17)$$

Algoritmul de fuziune realizează suma ponderată a citirilor de date care cad în fiecare dintre cele patru cadrane. Datele care au cea mai mare valoare a gradului de apartenență dintre cele patru valori calculate sunt folosite ca și valori cu cea mai mare valoare de adevăr. Fiecărei date de intrare îi vor fi alocate patru valori și apoi aleasă una dintre ele, corespunzător unui criteriu de adevăr. Dacă una dintre celelalte date de intrare ia cea mai mare evaluare, aceasta va fi luată în considerare. În cazul "ambele", acestea vor fi fuzionate cu algoritmul explicat mai sus sau mai simplu, prin media ponderată Fukuda [Fuku92]:

$$z_f = \frac{\sum_i \mu_i z_i}{\sum_i \mu_i} \quad (2.18)$$

unde:

- z_f este valoarea fuzionată a senzorului
- z_i sunt citirile obținute de senzori
- μ_i sunt ponderile valorilor de încredere în fuziunea finală

Dacă nici una dintre citiri nu ia cea mai mare valoare, datele sunt considerate fără încredere și se apelează la datele anterioare.

Metoda prezintă anumite dezavantaje în cazul sistemelor la care este inacceptabil să nu avem rezultate. Un alt dezavantaj este dificultatea extensiei la mai mulți senzori.

Fukuda ia în considerare pentru inferența fuzzy [Fuku92] specificațiile senzorilor ca de exemplu precizia care este o funcție de domeniu. În plus, algoritmul trebuie să ia în considerare condițiile de mediu și efectele pe care acestea le au asupra senzorilor. Acestea pot fi temperatura, impactul umidității asupra preciziei senzorului, scăderea preciziei cauzate de ceață, ploaie, zăpadă, praf, schimbarea luminii zilei, etc. Gradul de încredere al măsurii se poate calcula fie prin reguli fuzzy fie prin mediere ponderată.

Odeberg [Odeb93], [Odeb94] descrie cum fiecărui sensor îi poate fi atribuită o „opinie” exprimată sub forma unor funcții de apartenență fuzzy.

Fiecare senzor formează o opinie μ_x folosind o funcție simplă triunghiulară.

$$\mu_x = \begin{cases} 1 - \frac{|z - m|}{2\sigma} & |z - m| < 2\sigma \\ 0 & |z - m| > 2\sigma \end{cases}$$

unde z este măsura, m media iar σ deviația standard a unui senzor specific.

Opiniile locale ale fiecărui senzor sunt apoi fuzionate într-o opinie globală. Aceasta se obține luând în considerare distanțele dintre opiniile fuzzy.

Fuziunea este realizată folosind (de exemplu) dualitatea mediei armonice.

$$f(\mu_x, \mu_y) = \frac{\mu_x + \mu_y - 2\mu_x\mu_y}{2 - (\mu_x + \mu_y)} \quad (2.20)$$

care este un operator de mediere cu proprietatea:

$$\min(\mu_x, \mu_y) \leq f(\mu_x, \mu_y) \leq \max(\mu_x, \mu_y) \quad (2.21)$$

Metoda suferă de mai multe neajunsuri. În primul rând se pot fuziona numai doi senzori în același timp. În plus determinarea parametrilor pentru funcția de fuziune nu este transparentă, trebuie ales un “compromis rezonabil” între extreme. În fine manipulează foarte slab situația în care senzorii se defectează.

În general, metodele bazate pe selectarea senzorilor reușesc să elimine citirile greșite [Smol02], dar nu pot depăși faptul că o citire votată, nu este niciodată corectă.

2.1.2.2. Fuziunea fuzzy și posibilistică

Efectuarea unei fuziuni multisenzor care să conserve toate caracteristicile obiectelor observate trebuie să permită accesul la incertitudinea și imprecizia proprie fiecărui obiect și fiecărui senzor. În plus trebuie să putem dispune în orice moment de informațiile referitoare la fiabilitatea fiecărui senzor. Pentru a putea construi o estimare corectă este necesar să folosim cunoștințele disponibile despre parametrii măsurătorii, care trebuie ponderați în funcție de influențele lor și de importanța lor reală [Dubo94c]. Teoria fuzzy și teoria posibilității permit atingerea acestor deziderate, așa cum s-a arătat într-o serie de lucrări recente [Prec95], [Prei97], [Gruy99], [Calu00], [Bara01], [Bouk01]. În Anexa 4 se prezintă bazele teoriei posibilităților, mai puțin cunoscută decât cea fuzzy, precum și fuziunea posibilistică a informației.

Fiecare senzor este reprezentat printr-un model fuzzy sau printr-o distribuție de posibilitate. Această estimare construită agregând diferite măsuri asociate fiecărui senzor trebuie să verifice următoarele proprietăți [Piat96]:

- *Închiderea*: rezultatul operației trebuie să rămână în același cadru teoretic;
- *Comutativitatea*: sursele de informație sunt interschimbabile;
- *Asociativitatea*: se pot adăuga noi măsuri fără recalcularea agregării anterioare. Se permit astfel proceduri incrementale de revizuire a operatorilor de fuziune.
- *Idempotența*: fuziunea unor măsuri identice produce aceeași măsură.

Operatorii fuzzy și posibiliști

Agregările din familia fuzzy se bazează pe două tipuri de operatori: *conjunctivi* (norme t) și *disjunctivi* (conorme t sau norme s) care generalizează operațiile de intersecție și reuniune (vezi Anexa 4). Între normele t și conormele t se pot construi o mare varietate de *operatori de mediere* care permit diverse tipuri de fuziune [Dubo91], [Band95], [Fodo00].

În continuare se prezintă o listă ne-exhaustivă a operatorilor care permit să se ia în considerare imprecizia, incertitudinea și fiabilitatea măsurilor care trebuiesc fuzionate.

a) Operatori de mediere

Operatorii de mediere sunt numiți și operatori de compromis între operatorul de conjuncție și cel de disjuncție. Prezentăm în continuare operatorii cei mai obișnuiți aplicați la două distribuții de posibilitate π_1 și π_2 .

$$m(\pi_1, \pi_2) = \left(\frac{\pi_1^\beta + \pi_2^\beta}{2} \right)^{\frac{1}{\beta}} \quad (2.22)$$

cu

$$m(\pi_1, \pi_2) = \min(\pi_1, \pi_2) \quad \text{pentru } \beta = -\infty$$

$$m(\pi_1, \pi_2) = \frac{2 \cdot \pi_1 \cdot \pi_2}{\pi_1 + \pi_2} \quad \text{pentru } \beta = -1 \text{ (media armonică)}$$

$$m(\pi_1, \pi_2) = \sqrt{\pi_1 \cdot \pi_2} \quad \text{pentru } \beta = 0 \text{ (media geometrică)}$$

$$m(\pi_1, \pi_2) = \frac{\pi_1 + \pi_2}{2} \quad \text{pentru } \beta = +1 \text{ (media aritmetică)}$$

$$m(\pi_1, \pi_2) = \max(\pi_1, \pi_2) \quad \text{pentru } \beta = +\infty$$

Operatorul generalizat este:

$$m(\pi_1, \pi_2, \dots, \pi_n) = \left(\frac{1}{n} \sum_{i=1}^n \pi_i^\beta \right)^{\frac{1}{\beta}} \quad (2.23)$$

b) Operatorii OWA (Ordered Weighted Averaging)

Operatorii OWA propuși în [Yage88], [Yage94], [Yage98a], [Yage98b], [Lars99] sunt un caz particular al operatorilor de mediere propuși mai sus:

$$m_{w_1, w_2, \dots, w_n}(\pi_1, \pi_2, \dots, \pi_n) = \left(\sum_{i=1}^n w_i \cdot \pi_i^\beta \right)^\beta \quad (2.24)$$

cu constrângerile $\sum_{i=1}^n w_i = 1$ și $\beta = 1$

Vectorul W este un vector de ponderi care pot fi interpretate ca grade de fiabilitate ale surselor de fuzionat. Yager a propus să se ordoneze crescător argumentele $\pi_i(\omega)$ ceea ce face ca vectorul de ponderi va fi asociat pozițiilor elementelor și nu elementelor.

În acest caz dacă avem un vector de ponderi $W = [1 \ 0 \ 0 \ \dots \ 0]$ atunci regăsim operatorul disjunctiv, dacă $W = [0 \ 0 \ 0 \ \dots \ 1]$ atunci vom avea operatorul conjunctiv și dacă $W = [1/n \ \dots \ 1/n]$ atunci obținem media aritmetică clasică. *Acești operatori sunt bine adaptați pentru a cuantifica mărimi lingvistice.*

Plasarea operatorilor de mediere OWA în contextul altor operatori de mediere este ilustrată în fig. 2.7.

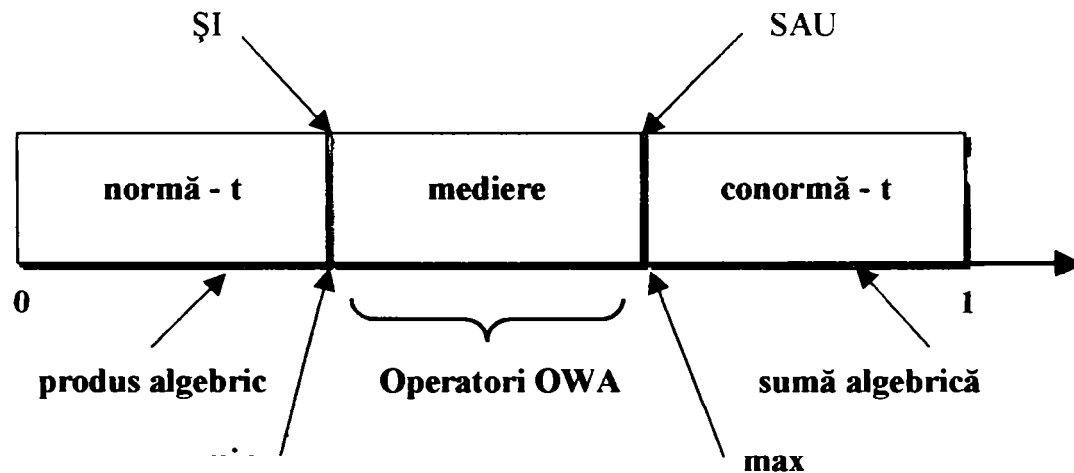


Fig. 2.7. Operatori OWA în contextul operatorilor de agregare fuzzy.

c) Combinarea ponderată

Este interesant ca în operația de fuziune să se poată cuantifica și utiliza și fiabilitatea sau importanța unei informații sau a unei măsuri. Acestor mărimi li se poate asocia un număr real α_i cuprins în $[0,1]$. În cadrul teoriei posibilităților, putem utiliza această fiabilitate și distribuțiile de posibilitate π_i asociate unei transformări t permițând construcția unei noi distribuții π_i' [Gruy99]:

$$\forall \omega \in \Omega' \quad \pi_i'(\omega) = t(\pi_i(\omega), \alpha_i)$$

Această transformare verifică următoarele constrângeri:

1. Relația de ordine între distribuții trebuie să fie conservată:

$$\forall (\omega_1, \omega_2) \in \Omega' \times \Omega' \quad \pi_i(\omega_1) \leq \pi_i(\omega_2) \Rightarrow \pi_i'(\omega_1) \leq \pi_i'(\omega_2)$$

2. Dacă fiabilitatea unei măsuri fuzzy este completă ($\alpha_i = 1$) atunci distribuția rămâne neschimbată:

$$\forall \omega \in \Omega' \quad t(\pi_i(\omega), 1) = \pi_i(\omega) = \pi_i'(\omega)$$

3. Dacă fiabilitatea unei măsuri este nulă ($\alpha_i = 0$) atunci distribuția rezultantă nu trebuie să modifice rezultatul fuziunii.

4. Variația rezultatului fuziunii trebuie să fie o funcție continuă față de indicii α_i .

Dacă se impune $\max_{i \in \{1, \dots, n\}} \alpha_i = 1$ și dacă se fuzionează măsurile fuzzy într-un mod conjunctiv, atunci Yager a propus ca soluție:

$$\forall \omega \in \Omega' \quad \pi_i'(\omega) = t(\pi_i(\omega), \alpha_i) = \max(\pi_i(\omega), (1 - \alpha_i)) \quad (2.25)$$

În cazul disjunctiv, fuziunea este obținută cu operatorul următor:

$$\forall \omega \in \Omega' \quad \pi_i'(\omega) = t(\pi_i(\omega), \alpha_i) = \min(\pi_i(\omega), \alpha_i) \quad (2.26)$$

Avantajul acestor abordări este acela că se poate lua în considerare fiabilitatea unei măsuri sau a unei surse de informație. Totuși alegerea unei transformări rămâne discutabilă și empirică.

d) Combinarea adaptivă generalizată

Am văzut că cea mai mare parte a operatorilor de fuziune lucrează fie în mod conjunctiv, fie disjunctiv. Modul conjunctiv este recomandabil atunci când distribuțiile de posibilitate sunt în acord. În cazul datelor contradictorii rezultatul va fi însă denaturat. Din contră, modul disjunctiv este recomandabil la fuziunea datelor aflate în conflict. În [Dubo94a] și [Dubo94b] s-a propus o abordare în cadrul teoriei posibilităților pentru a utiliza aceste două moduri într-un ansamblu al unui operator de combinare adaptivă. În Anexa 4 se prezintă pe larg modurile de combinare conjunctiv disjunctiv și adaptiv.

Acești operatori modifică în mod continuu strategiile de fuziune în funcție de nivelul de contradicție al datelor fuzionate. Strategia folosită va fi deci mai mult sau mai puțin conjunctivă sau disjunctivă în funcție de distribuțiile de posibilitate tratate.

Pentru combinarea a două distribuții de posibilitate, este necesar să se determine și să se cuantifice gradul lor de concordanță. Pentru aceasta se pot defini noțiunile tradiționale de indici de conflict ca de exemplu înălțimea intersecției:

$$h(\pi_1, \pi_2) = \sup_{\omega \in \Omega'} (\min(\pi_1(\omega), \pi_2(\omega))) \quad (2.27)$$

Sau încă indicele Jacquard care reprezintă câtul ariilor distribuțiilor corespunzătoare disjuncției și conjuncției între $\pi_1(\omega)$ și $\pi_2(\omega)$:

$$j(\pi_1, \pi_2) = \frac{\int_{\omega \in \Omega'} \min(\pi_1(\omega), \pi_2(\omega)) d\omega}{\int_{\omega \in \Omega'} \max(\pi_1(\omega), \pi_2(\omega)) d\omega} \quad (2.28)$$

atunci când $h = j = 0$ nu există nici o concordanță între distribuții.

e) Combinarea a două distribuții

Cei patru operatori propuși de Dubois și Prade sunt următorii:

- Primul operator permite o combinare cu trecere continuă de la modul conjunctiv la modul disjunctiv. Cu acest operator, se presupune că cel puțin una dintre distribuții este total fiabilă și suntem siguri că soluția aparține suportului $\max(\pi_1, \pi_2)$. Acest operator este cel mai mult utilizat:

$$\pi = \max \left[\frac{\pi_T}{h(\pi_1, \pi_2)}, \min(\max(\pi_1, \pi_2), 1 - h(\pi_1, \pi_2)) \right] \quad (2.29)$$

unde $\pi_T = t(\pi_1(\omega), \pi_2(\omega))$, t fiind o t -normă oarecare.

- Ceilalți trei operatori au fost propuși pentru cazul în care ar fi posibil ca nici o distribuție să nu fie total fiabilă și în acest caz soluția poate să aparțină la oricare regiune a lui Ω' :

$$\pi = \max \left[\frac{\pi_T}{h(\pi_1, \pi_2)}, 1 - h(\pi_1, \pi_2) \right] \quad (2.30)$$

$$\pi = \min \left[1, \frac{\pi_T}{h(\pi_1, \pi_2)} + 1 - h(\pi_1, \pi_2) \right] \quad (2.31)$$

$$\pi = \pi_T + 1 - h(\pi_1, \pi_2) \quad (2.32)$$

Aceste trei reguli au ca punct comun faptul că cu cât distribuțiile sunt mai contradictorii, încrederea se reflectă cu atât mai mult în Ω' . Atunci când contradicția este totală ($h=0$) distribuția rezultantă va fi 1 peste tot, ceea ce corespunde ignoranței totale. Se poate de asemenea remarca faptul că toate aceste reguli se focalizează pe porțiunile

de consens. Astfel, chiar dacă avem o foarte slabă acoperire a două distribuții, vom avea totuși generarea unui vârf unitar la intersecția distribuțiilor.

f) Combinarea generalizată a n distribuții

Agregarea unui ansamblu de măsuri sau distribuții poate să fie efectuată fie în serie fie în paralel. Combinarea serie utilizează distribuțiile de posibilitate două câte două, ceea ce o face neasociativă. Combinarea în paralel se obține ușor printr-o generalizare a regulii (2.28):

$$\pi = \max \left[\frac{\pi_{\wedge}}{h}, \min(\pi_{\vee}, 1 - h) \right] \quad (2.33)$$

cu

$$\pi_{\wedge} = \min[\pi_1(\omega), \dots, \pi_n(\omega)]$$

$$\pi_{\vee} = \max[\pi_1(\omega), \dots, \pi_n(\omega)]$$

$$h = \sup_{\omega \in \Omega} \pi_{\wedge}$$

Acest indice de consens cuantifică situația globală a tuturor surselor de informații. Dacă indicele este ridicat, atunci datele sunt în concordanță. Rezultatul obținut poate să fie considerat ca foarte robust pentru că el reflectă opinia unei largi majorități de măsuri. Din păcate, cu cât datele sunt mai numeroase cu atât mai puțin este verificată această concordanță. Într-adevăr, este mult mai dificil să se găsească un suport comun pentru un număr mare de distribuții. Astfel trei distribuții pot să reprezinte același obiect, având un suport comun două câte două și totuși indicele lor de concordanță să fie nul. Regula de combinare va fi de tip disjunctiv:

$$\pi = \max[\pi_1(\omega), \dots, \pi_n(\omega)]$$

În ciuda faptului că acest operator nu ia în calcul fiabilitatea surselor de informații, se remarcă faptul că această formulare paralelă a combinării este asociativă.

g) Fuziunea prin prioritate

Pentru a putea lua în calcul fiabilitatea surselor de informații a fost propusă o soluție în [Roux96]. Se pornește de la prezumția că există surse mai puțin fiabile ca altele și că aceste surse nu trebuie folosite într-un proces de fuziune dacă ele intră în conflict cu alte surse socotite mai fiabile. Aceasta revine la a crea mai multe grupuri ierarhizate de surse. Un prim grup K_1 conține sursele cele mai fiabile, apoi un grup K_2 pe cele cu fiabilitate puțin inferioară și așa mai departe. Fuziunea propusă se efectuează în doi timpi, primul corespunde unei fuziuni interne la fiecare grup iar al doilea la fuziunea informațiilor fiecărui grup. În fiecare grup, metoda de fuziune folosită poate să meargă de la modul conjunctiv la modul disjunctiv trecând prin fuziunea adaptivă. Pentru fuziunea intergrupuri, avem o partiție K_1, K_2, \dots, K_n de K surse astfel că sursele S_j reunite în grupul $K_i = \{S_1, S_2, \dots, S_p\}$ sunt considerate de fiabilitate identică. Astfel

grupul K_i adună sursele mai fiabile decât cele din grupul K_j ($i > j$). Principiul de fuziune prin prioritate este de a ajusta rezultatul obținut pentru grupul K_1 cu cel din grupul K_2 dacă nu sunt în contradicție. Procedeeul se reiterează până la ultimul grup K_n . Gradul de consens intergrup folosit este înălțimea intersecției.

$$h(\pi_{K_1}, \pi_{K_2}) = \max_{\omega \in \Omega} (\min(\pi_{K_1}(\omega), \pi_{K_2}(\omega))) \quad (2.34)$$

Și regula de fuziune prin prioritate pentru $n = 2$ grupe este următoarea:

$$\forall \omega \in \Omega \quad \pi_{\text{prio}}^{K_1, K_2}(\omega) = \min(\pi_{K_1}(\omega), \max(\pi_{K_2}(\omega), 1 - h(\pi_{K_1}(\omega), \pi_{K_2}(\omega)))) \quad (2.35)$$

Această metodă de fuziune permite să se atribuie ponderi mai mari unor surse față de altele. Informațiile surselor mai fiabile sunt întotdeauna privilegiate și părerile surselor mai puțin fiabile nu sunt luate în considerare. Această metodă nu este utilă decât dacă anumite surse sunt întotdeauna mai exacte decât altele.

h) Regula progresivă

Regula progresivă este o reformulare a regulii generalizate a lui Dubois și Prade [Dubo94b] care folosește două valori n (optimiste) și m (pesimiste) între care se presupune că se găsește mulțimea surselor fiabile. Prima mărime reprezintă numărul maxim de distribuții cu o intersecție nenulă a suportului lor, a doua mărime reprezintă numărul maxim de distribuții ale căror înălțime este maximă. Aceasta permite să se delimiteze influența conflictului.

$$\pi(\omega) = \max \left[\frac{\pi_{(n)}(\omega)}{h(n)}, \min(\pi_{(m)}(\omega), 1 - h(n)) \right] \quad (2.36)$$

cu

$$m = \sup \{ |J|, h(J) = 1 \} \quad \text{estimare pesimistă}$$

$$n = \sup \{ |J|, h(J) > 0 \} \quad \text{estimare optimistă}$$

și

$$h(n) = \max(h(J), |J| = n)$$

$$h(J) = \sup_{\omega \in \Omega} \left(\min_{i \in J} (\pi_i(\omega)) \right)$$

$$\pi_{(k)}(\omega) = \max_{K \subseteq N, |K|=k} \left(\min_{i \in J} (\pi_i(\omega)) \right)$$

Idea este atunci de a substitui lui $\pi_{(m)}$ și $\pi_{(n)}$ distribuțiile de posibilitate $\pi_{(m)}$ și $\pi_{(n)}$ astfel ca:

$$\pi_{(m)}' = \alpha_1 \cdot \pi_{(m-1)} + \alpha_2 \cdot \pi_{(m)} + \alpha_3 \cdot \pi_{(m+1)} \quad (\text{respectiv pentru } n)$$

sau

$$\sum_{i=1}^l \alpha_i = 1 \quad \text{și } \alpha_i \geq 0$$

În această alternativă, valorile lui n și m sunt repuse în cauză și se tolerează existența unei erori asupra valorii găsite a lui m și n , se presupune atunci că valoarea lui m (respectiv a lui n) variază între trei valori, de știut $m-1$, m și $m+1$. Cele trei valori pot să fie agregate fie printr-un indice de similaritate fie printr-un operator OWA [Yage94]. Aceea dă ecuația următoare:

$$\pi(\omega) = \sup \left[\frac{\pi_{(n)}'(\omega)}{h(n)}, \min \left(\pi_{(m)}'(\omega), 1 - h(n) \right) \right] \quad (2.37)$$

Realizarea unui efect de progresivitate implică faptul ca parametrii α_1 , α_2 și α_3 să fie funcție de distanța în raport cu zona de consens. Pentru aceasta, se introduce o distanță d_0 care permite rejecția unei distribuții eronate. Această distanță este calculată în raport cu o extremitate a suportului zonei de concordanță.

Această soluție permite să se obțină o regulă de fuziune luând în calcul progresiv conflictul unei distribuții în raport cu altele și ea este robustă în raport cu forma distribuțiilor în concordanță, ceea ce nu este cazul regulii de combinare adaptivă.

i) Alți operatori

Pe lângă operatorii descriși mai sus în literatură se oferă multe alte opțiuni, dintre care se pot menționa:

- CIVB (*Contextual Independent Variable Behavior*) [Bloc96], metodă bazată pe doi operatori neasociativi care aproximează la limită reuniunea și intersecția fuzzy.
- CD (*Contextual Dependent*) [Bord96] care utilizează pe lângă valorile de apartenență și informații contextuale, prin operatorii ADAPT1 și ADAPT2. Ei determină în funcție de diferența locală dintre valorile de apartenență sau de gradul de încredere al funcției de apartenență selectarea celui mai potrivit operator dintre reuniune, intersecție sau mediere.
- Integralele Sugeno și măsurile fuzzy de tip Sugeno;
- Sumele simetrice.

2.1.2.3. Fuziunea informațiilor complementare

În cazurile în care nu se dispune de modele matematice analitice sau bazate pe reguli ci numai de exemple exprimate lingvistic (produse de experți, senzori fuzzy simbolici, etc.) se poate realiza totuși așa numita *fuziune a informației complementare* [Maur94b],[Maur96a].

Senzorii multipli produc informații complementare și redundante care pot ajuta la rezolvarea unor situații complexe și realizează o descriere mai bogată a mediului. Problema este cum să obținem din măsurătorile de bază noi informații. Pentru aceasta în primul rând trebuie să știm:

- ce fel de informație se obține din senzorii primari;
- ce tip de informație se dorește pentru rezultat;
- cum să se lege informația de bază de informația rezultantă.

De fapt procesul de fuzionare contribuie la rezolvarea ultimului aspect, determinând metoda care trebuie folosită pentru combinarea informației complementare corespunzător cu nivelul de cunoștințe pe care-l avem la dispoziție. Dacă cunoaștem o relație analitică între informația de intrare și cea de ieșire (adică un nivel înalt de cunoștințe) se pot folosi metode statistice. Când avem numai perechi de date numerice intrare-ieșire metodele neuronale sunt eficiente pentru aproximarea relației dintre ele. În situațiile în care sunt implicate în procesul de agregare cunoștințe lingvistice, se impune de obicei apelarea la mulțimile fuzzy. Toate abordările sunt rezumate în Tabelul 1 [Maur94b]:

Tabelul 1: diferite aspecte ale problemei fuziunii

Intrări	Ieșiri	Relație	Metodă
numerice	numerice	numerice	statistice
numerice	lingvistice	lingvistice	reguli (simbolice)
lingvistice	lingvistice	lingvistice	reguli (simbolice)
lingvistice	numerice	lingvistice	reguli (numerice sau simbolice)
numerice	numerice	exemple	interpolare (metode neuronale)
numerice	lingvistice	exemple	interpolare (partiție fuzzy)
<i>lingvistice</i>	<i>lingvistice</i>	<i>exemple</i>	<i>interpolare lingvistică (fuzzy)</i>

Există un interes deosebit pentru cazurile în care intrările și ieșirile sunt ambele de natură lingvistică (ultima linie din tabel). Această situație apare adesea când ieșirea este o trăsătură abstractă nemăsurabilă (de exemplu confort, pericol, formă, etc.) și când intrările chiar cele care corespund unei mărimi fizice sunt de asemenea exprimate în manieră lingvistică. Aceasta se întâmplă când ele sunt date de către un operator uman sau de către o componentă inteligentă (de exemplu un senzor fuzzy) care a realizat o prelucrare a informației numerice pentru a da o informație mai concisă și relevantă unității centrale.

2.1.2.4. Fuziunea bazată pe produs și sumă probabilistică

O metodă de fuziune extrem de interesantă este propusă în [Hiro91]. Se apelează la produsul și la suma probabilistică, operatori introduși în teoria probabilităților dar care au fost preluați și de logica fuzzy.

Așa cum se observă în fig.2.8 citirile unor senzori distribuiți sunt însumate neliniar obținând informația agregată.




Fig. 2.8. Schema de bază a fuziunii prin produs și sumă probabilistică

Cei n senzori generează valori numerice în intervalul unitate, $x_1, x_2, \dots, x_n \in [0, 1]$, sau mai concis $x \in [0, 1]^n$. Modelul generic propus se bazează pe două operații neliniare: produsul și suma probabilistică. Valorile x_1, x_2, \dots, x_n sunt ponderate local cu coeficienții $(w_1, w_2, \dots, w_n) \in [0, 1]$, iar apoi rezultatele parțiale sunt însumate prin aplicarea sumei probabilistice. Aceasta se va nota cu s și este definită conform relației:

$$a \text{ s } b = a + b - ab \quad (2.38)$$

$a, b \in [0, 1]$. Astfel în general pentru cazul a n -senzori avem:

$$y = (w_1 \cdot x_1) \text{ s } (w_2 \cdot x_2) \text{ s } \dots \text{ s } (w_n \cdot x_n) \quad (2.39)$$

Deoarece suma probabilistică este asociativă (2.39) se mai poate scrie astfel:

$$y(x) = \sum_{i=1}^n (w_i \cdot x_i) = w \text{ s } x \quad (2.40)$$

unde însumarea este luată peste toți senzorii. w și x desemnează vectori ai ponderărilor și citirilor senzorilor.

Există o analogie evidentă între unitatea de agregare și un neuron simplu cu n semnale de intrare [Pedr93]. Nodul de însumare simplu este înlocuit cu o transformare s neliniară de aceea nu este nevoie să se încorporeze o funcție neliniară (ca de exemplu una logică) prezentă de obicei într-un neuron. Compatibilitatea cu rețelele neuronale reprezintă un avantaj esențial al acestei metode, deoarece îi conferă capacitatea de a învăța din exemple.

2.2. O metodă originală de fuziune prin mediere ponderată neliniară

2.2.1. O arhitectură fundamentală de fuziune prin mediere ponderată

Metodele de fuziune trecute în revistă până acum au în comun faptul că nu sunt compatibile cu implementările hardware deoarece necesită operații logice relativ sofisticate. Întrucât obiectul acestei lucrări constă în identificarea unor soluții de senzori inteligenți de largă aplicabilitate, ușor de implementat chiar în variante de integrare ASIC, este necesară alegerea unei variante fundamentale, care să includă totuși trăsăturile care fac posibilă funcționarea în condiții de imprecizie și incertitudine.

Procedeul matematic fundamental care se identifică în fuziunile multisenzor este *medierea ponderată* [Guu02]. Ea este relativ ușor de implementat în oricare dintre tehnologiile software sau chiar hardware posibile [Gree97].

Medierea în sine atenuează efectele unor citiri aberante, dar pentru a obține fuziuni performante, în spiritul celor de tip fuzzy sau posibilistic este esențial ca să știm care dintre senzori lucrează mai bine decât altul și în ce grad. **Aceasta se poate obține identificând ponderile sumei cu gradele de încredere ale fiecărui senzor. Schema bloc care materializează metoda propusă este prezentată în fig. 2.9 care detaliază idea prezentată în figura 2.1.**

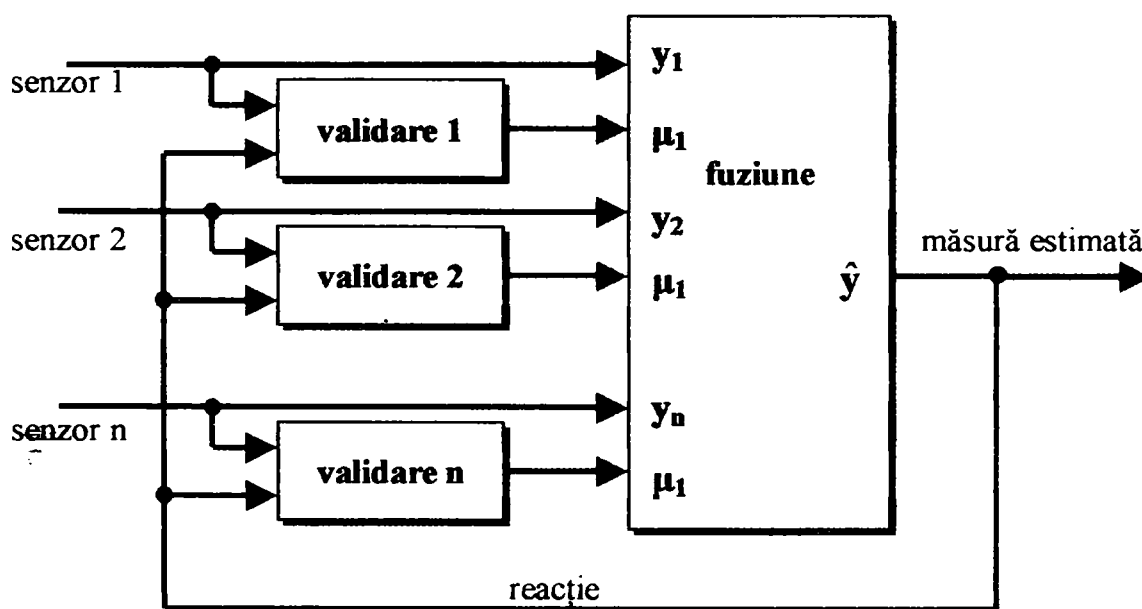


Fig. 2.9. Arhitectură de validare și fuziune cu medie ponderată

Valoarea estimată a măsurii, utilizând media ponderată Fukuda (2.18) este:

$$\hat{y} = \frac{\sum_i \mu_i \cdot y_i}{\sum_i \mu_i} \quad (2.42)$$

cu următoarele notații:

- y_i = măsura senzorului i ;
- μ_i = gradul de încredere al senzorului i ;
- \hat{y} = măsura estimată de către SI.

De cele mai multe ori media ponderată este aplicată respectând condiția de ortogonalitate

$$\sum_i \mu_i(y_i) = 1 \quad (2.42)$$

În continuare această metodă se va completa prin includerea modalității de calcul a gradelor de încredere în care intervin atât valoarea măsurii senzorului primar curent cât și măsura estimată globală de la ieșirea senzorului inteligent:

$$\hat{y} = \frac{\sum_i \mu_i(y_i, \hat{y}) \cdot y_i}{\sum_i \mu_i(y_i, \hat{y})} \quad (2.43)$$

În plus, se renunță la condiția de ortogonalitate (2.39).

Rolul esențial în această variantă de fuzionare îl joacă blocurile de validare, care calculează gradele de încredere, prin care fuzionarea poate fi pe deplin controlată. De exemplu, în cazul în care se constată că unul dintre senzori este defect, ponderea lui poate fi anulată.

Validarea se realizează în esență, pentru fiecare senzor în parte, pornind de la eroarea măsurii senzorului, definită ca $y_i - \hat{y}$.

Principalul obstacol din calea acestui procedeu apare la începutul măsurătorii și pe durata regimurilor tranzitorii. Comportarea dinamică a oricărui sistem nu este ideală, și cu atât mai puțin a celor n senzori primari, care, în funcție de principiul de funcționare, pot prezenta inerții importante. Erorile de urmărire astfel produse pot compromite comportarea algoritmului.

Împotriva acestui dezavantaj se vor lua două măsuri alternative:

- **utilizarea a cel puțin unui senzor de mare viteză, cu inerție redusă. Pe durata regimurilor tranzitorii, gradele de încredere a senzorilor cu inerție mare vor fi anulate;**
- **în cazul în care nici un senzor de acest fel nu este disponibil, se va apela la un model funcțional al procesului măsurat, care va estima în timp real evoluția măsurandului. Această soluție este detaliată în capitolul 3.**

Arhitectura de mai sus, ca și metoda de măsurare asociată, vor fi denumite în continuare „cu fuziune cu medie ponderată neliniară”.

2.2.2. Grade de încredere neliniare

Modalitatea prin care SI poate fi adaptat la condițiile de măsurare, în condițiile metodei FMPN, este dependentă în totalitate de modul de calcul al gradelor de încredere μ_i . Acest calcul trebuie astfel proiectat încât să țină seama de imprecizia și incertitudinea care caracterizează măsurătoarea.

În principiu nici un mod de calcul nu poate fi exclus. Cazurile extreme posibile sunt:

a) Senzori primari etalonati și incertitudine minimă

În cazul în care dispunem de informații detaliate despre senzorii primari, gradele lor de încredere pot fi modificate în cursul fuzionării pe baza informațiilor disponibile.

De exemplu, atunci când sunt disponibile diagrame de etalonare ale senzoriilor primari de forma celei din fig. 3.7, fuziunea poate fi realizată astfel încât gradele de încredere în senzorii primari să fie invers proporționale cu eroarea rezultată din diagrame. În acest caz imprecizia din proces este datorată doar impreciziei etalonării. O exemplificare a acestei variante este prezentată în §5.3.

b) Senzori primari ne-etalonati și incertitudine maximă

În cazul în care precizia senzorilor primari este necunoscută iar incertitudinea din sistem este importantă, se poate apela la calcularea gradelor de încredere cu controlere de tip fuzzy-expert, ca și în situația prezentată în §4.1.3.5. Acesta este și unul dintre motivele care împiedică menținerea condiției (2.42), care ar îngreuna mult elaborarea euristică a regulilor.

Fuziunea ponderată fuzzy, în care fuziunea propriu-zisă este suma ponderată iar gradele de încredere sunt determinate prin metode fuzzy poate fi simbolizată prin formula

$$\hat{y} = \frac{\sum_i \mu_i(\text{fuzzy}(y_i, \hat{y})) \cdot y_i}{\sum_i \mu_i(\text{fuzzy}(y_i, \hat{y}))} \quad (2.44)$$

Pe de altă parte, apropierea acestei metode de cea prezentată în §2.1.2.3 îi conferă și ei același avantaj major: capacitatea de a învăța din exemple, în cazul în care este implementată printr-o rețea neuronală.

Compatibilitatea cu rețelele neuronale devine evidentă dacă se operează normalizarea măsurilor de intrare (de la senzori) și de ieșire.

Reprezentarea analitică a gradelor de încredere neliniare din (2.44) se poate realiza doar prin precizarea controlerului fuzzy care implementează calculul, respectiv prin baza sa de reguli.

Fuziunea fuzzy poate fi implementată în mediul Matlab fie prin interfața grafică FIS (*Fuzzy Inference System*) din componența toolkit-ului *Fuzzy Logic*, fie așa ca în fig. 5.12b, prin metoda fuzzy-interpolativă [Băla01a], pe bază de tabele de căutare cu interpolare liniară.

2.3. Concluziile capitolului 2

În acest capitol se realizează două obiective:

- a) schițarea unui studiu bibliografic referitor la unul dintre principalele subiecte de interes ale tezei: fuziunea datelor și informațiilor;
- b) propunerea unei metode originale de fuziune.

Principalele curente prezente în domeniul fuziunii datelor și informațiilor au fost identificate ca fiind:

- selectarea senzorilor prin diferite operații logice;
- fuziunea fuzzy sau posibilistică;
- fuziunile compatibile cu tehnica rețelelor neuronale.

Soluția originală propusă, care urmează să fie dezvoltată și exemplificată în capitolele următoare, prezintă următoarele particularități:

- **fuziunea se realizează prin mediere ponderată neortogonală a măsurilor senzorilor primari;**
- **ponderile sumei sunt identice cu gradele de încredere ale senzorilor;**
- **calculul gradelor de încredere se bazează pe analizarea erorilor care apar între măsurile senzorilor și estimarea globală de la ieșirea blocului de fuziune;**
- **evitarea riscului de instabilizare care apar pe durata regimurilor tranzitorii se obține prin utilizarea unui senzor cu inerție foarte mică sau prin introducerea unui model funcțional al procesului măsurat.**

Principalele avantaje ale metodei propuse sunt:

- **posibilitatea operării cu date imperfecte: imprecise și incerte;**
- **performanțe metrologice și de fiabilitate superioare;**
- **posibilități largi de implementare software dar și hardware;**
- **compatibilitatea cu rețelele neuronale.**

O nouă structură de senzor inteligent adaptiv cu model intern

În acest capitol se prezintă succint unele noțiuni de bază referitoare la modelele interne și la principalele lor aplicații: reglarea adaptivă și identificarea automată a proceselor. Este propusă o structură originală de senzor inteligent adaptiv cu model intern, SIAMI. Ea face apel atât la tehnica modelului intern cât și la cea a fuziunii datelor prezentată în capitolul 2. Dintre posibilele tipuri de modele interne se pot utiliza fie modelele deterministe fie modelele fuzzy, în cazul în care construirea modelelor deterministe nu este posibilă din lipsa cunoștințelor referitoare la structura procesului modelat.

3.1 Metode de reglare și identificare bazate pe modele interne

Una dintre posibilitățile de introducere a inteligenței artificiale în funcționarea senzorilor constă din *înglobarea în structura lor a unor modele ale proceselor în care ei urmează să fie utilizați*. Pentru că aceste modele sunt plasate chiar în structura reglatoarelor sau a senzorilor ele pot fi denumite *modele interne*. În secțiunea §3.1 se prezintă pe scurt ideile de bază care fundamentează utilizarea modelelor interne în reglarea și identificarea sistemelor. Scopul prezentării este de a pregăti introducerea tehnicilor bazate pe modele interne în domeniul senzorilor inteligenți, în §3.2, printr-o structură originală.

3.1.1 Sisteme de reglare adaptive cu model intern

Utilizarea modelelor de referință interne a fost inițiată în contextul sistemelor de reglare adaptivă [Dumi80],[Dumi93]. Metoda este extrem de răspândită, mai ales în ultimii ani și poate fi regăsită în mai multe variante.

În varianta prezentată în fig. 3.1 funcționarea dorită a procesului neliniar este simulată prin intermediul modelului de referință, care conduce un corector adaptiv ce modifică parametri regulatorului pe baza unei legi de corecție adaptivă având ca intrare diferența dintre ieșirea y a procesului și cea ale modelului de referință y_M , diferență denumită în continuare *eroare de adaptare*.

Corectorul adaptiv trebuie să determine modificarea parametrilor regulatorului astfel încât ieșirea procesului real să fie cât mai apropiată de ieșirea modelului de referință. Acțiunea de adaptare constă în esență din urmărirea modelului.

Prin acțiunea corectorului adaptiv care are funcția de transfer $C(s)$, se realizează un algoritm de reglare cu structură variabilă, depinzând de evoluția erorii de adaptare ε .

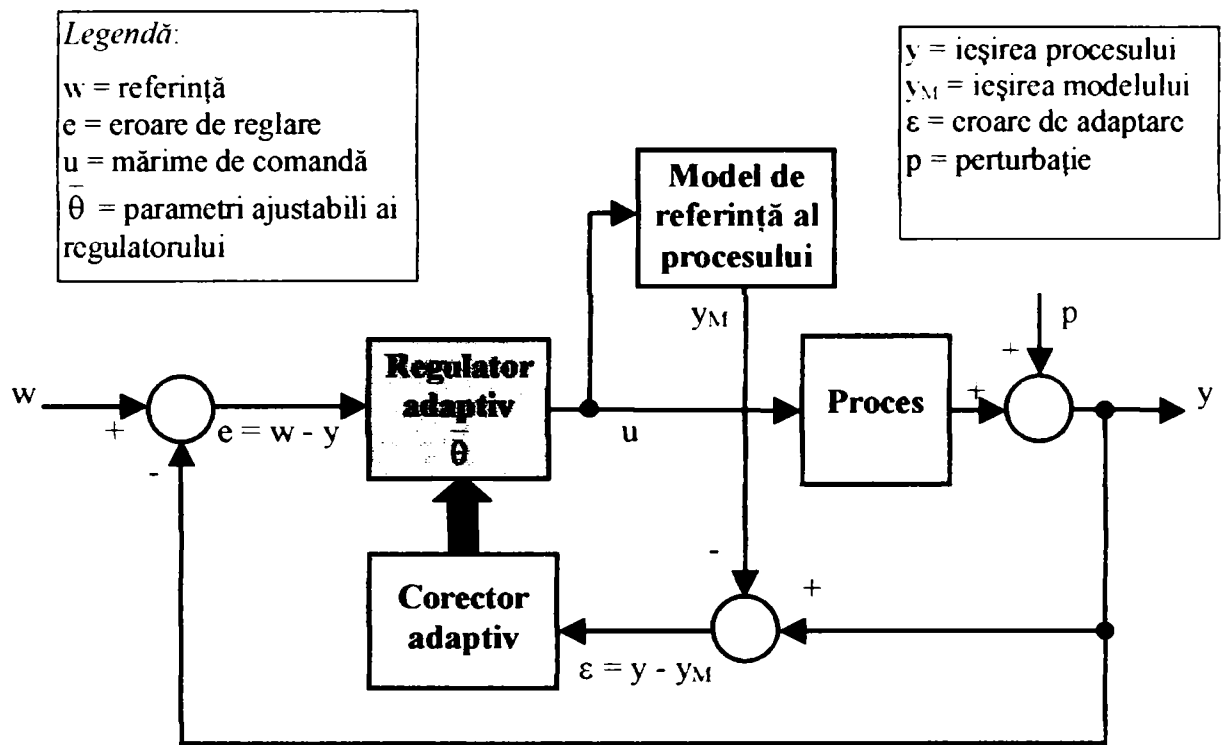


Fig. 3.1 Sistem de reglare automată adaptivă cu model de referință

Ecuțiile care modelează comportarea sistemului de reglare adaptivă cu model intern pentru cazul cu timp continuu cu parametri constanți pe subintervale de timp, sunt pentru fiecare subinterval de forma:

$$\left\{ \begin{array}{l} U(s) = \frac{R_A(C(s))}{1 + G(s) \cdot R_A(C(s))} \cdot W(s) - \frac{R_A(C(s))}{1 + G(s) \cdot R_A(C(s))} \cdot P(s) \\ Y(s) = \frac{G(s) \cdot R_A(C(s))}{1 + G(s) \cdot R_A(C(s))} \cdot W(s) + \frac{1}{1 + G(s) \cdot R_A(C(s))} \cdot P(s) \\ \varepsilon(s) = (G(s) - M(s)) \cdot U(s) + P(s) \end{array} \right. \quad (3.1)$$

Notățiile folosite în sistemul de ecuații sunt: $G(s)$ funcția de transfer a procesului, $R_A(s)$ funcția de transfer a regulatorului adaptiv, $C(s)$ funcția de transfer a corectorului adaptiv, $W(s)$ imaginea Laplace a referinței, $U(s)$ imaginea Laplace a comenzii, $Y(s)$ imaginea Laplace a ieșirii și $P(s)$ imaginea Laplace a perturbației aditive, $M(s)$ funcția de transfer a modelului procesului. Aceste ecuații sunt valabile și în cazul cu timp discret.

Problema centrală a acestor sisteme este proiectarea legii de corecție a corectorului adaptiv $C(s)$. Există mai multe metode de analiză și sinteză utilizabile în acest sens, dintre care cea mai des utilizată este metoda gradientului.

Se alege o funcție criteriu $J(\bar{\theta})$ unde $\bar{\theta}$ este vectorul parametrilor ajustabili ai regulatorului. $J(\bar{\theta})$ se alege ca o funcție a erorii de adaptare $\varepsilon = \bar{y} - \bar{y}_M$, de exemplu:

$$J(\bar{\theta}) = \frac{1}{2} \bar{\varepsilon}^2 \quad (3.2)$$

sau

$$J(\bar{\theta}) = |\bar{\varepsilon}| \quad (3.3)$$

Evident, cu cât valoarea lui J este mai mică, cu atât eroarea ε este și ea mai mică. Acest fapt induce principiul minimizării.

În continuare, în spiritul principiului minimizării lui J , parametrii evoluează în timp în sensul negativ al gradientului lui J în raport cu θ :

$$\frac{d\theta}{dt} = -\gamma \cdot \frac{dJ}{d\theta} \quad (3.4)$$

unde γ este o constantă pozitivă ce caracterizează viteza de adaptare

O condiție de aplicabilitate a acestei metode este ca parametrii să varieze mult mai lent decât alte variabile din sistem.

Simplitatea sintezei corectorului și robustețea deosebită constituie avantajele principale ale metodei. Dezavantajele sunt legate de faptul că poate fi aplicată numai proceselor stabile [Said96] precum și de viteza de convergență și precizia relativ scăzute față de principala metodă alternativă, metoda Gauss-Newton [Frio95].

O metodă care combină avantajele metodelor gradientului și Gauss-Newton este metoda Marquardt [Frio95].

3.1.2 Variante ale reglării adaptive cu model intern

Metoda modelului intern oferă posibilități numeroase de sinteză a unor sisteme de reglare adaptive având diverse topologii și caracteristici. În fig. 3.2 prezintă varianta sa cea mai simplă, aplicabilă pentru procese liniare, pentru cazul în care corecția adaptivă se identifică cu eroarea de adaptare $C(s) = \varepsilon(s)$, așa cum se regăsește ea în [Said96].

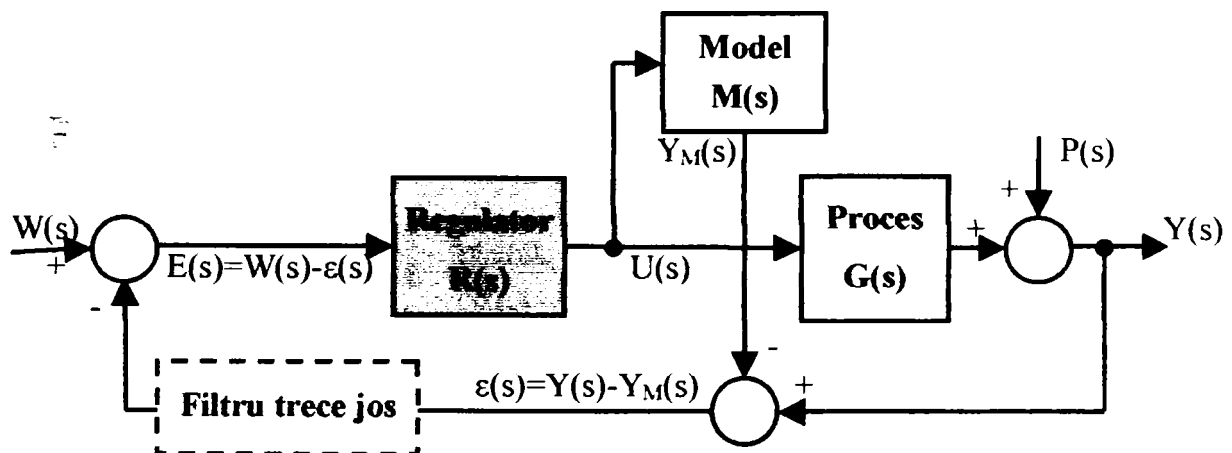


Fig. 3.2. Varianta cea mai simplă a reglării cu model intern

Ecuatiile care modelează sistemul pentru cazul cu timp continuu sunt:

$$\begin{cases} U(s) = \frac{R(s)}{1 + R(s) \cdot (G(s) - M(s))} \cdot W(s) - \frac{R(s)}{1 + R(s) \cdot (G(s) - M(s))} \cdot P(s) \\ Y(s) = \frac{R(s) \cdot G(s)}{1 + R(s) \cdot (G(s) - M(s))} \cdot W(s) + \frac{1 - R(s) \cdot M(s)}{1 + R(s) \cdot (G(s) - M(s))} \cdot P(s) \\ \varepsilon(s) = (G(s) - M(s)) \cdot U(s) + P(s) \end{cases} \quad (3.5)$$

Dacă modelul $M(s)$ ar reprezenta perfect procesul $G(s)$ atunci:

$$\varepsilon(s) = P(s) \quad (3.6)$$

și mărimea de reacție ar fi identică cu perturbația, nefiind afectată de acțiunea de reglare. În această situație nu se mai pun probleme de stabilitate legate de reacție. Sistemul se comportă ca și cum ar fi în buclă deschisă, stabilitatea sa implicând stabilitatea procesului și a corectorului. În acest caz ieșirea are forma

$$Y(s) = R(s) \cdot G(s) \cdot W(s) + (1 - R(s) \cdot M(s)) \cdot P(s) \quad (3.7)$$

Dacă referința este constantă eroarea statică poate fi anulată teoretic prin condiția

$$R(0) = M(0)^{-1} = G(0)^{-1} \quad (3.8)$$

În regim dinamic erorile de modelare cauzează erori de reglare și chiar instabilitate, dar popularitatea metodei modelului intern demonstrează fezabilitatea ei. O posibilitate de reducere a riscului instabilizării provocate de diferențele dintre model și procesul real constă din introducerea unui filtru trece jos pe calea de reacție, ca în fig. 3.2.

În fig. 3.3 se prezintă o variantă echivalentă celei din fig. 3.2, dar având modelul plasat în buclă închisă.

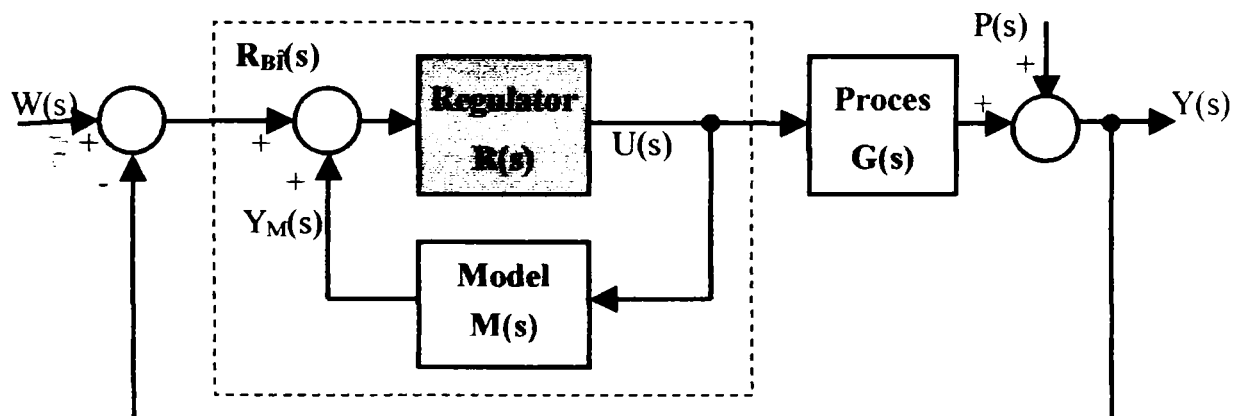


Fig. 3.3. Reglarea cu model intern în buclă închisă

În acest caz regulatorul în buclă închisă va avea funcția de transfer

$$R_{BI}(s) = \frac{R(s)}{1 - R(s) \cdot M(s)} \quad (3.9)$$

De la structura cu model intern în buclă închisă se poate ajunge la o altă variantă posibilă de reglare cu model intern în care modelul este prezent atât în paralel cu procesul cât și în regulator.

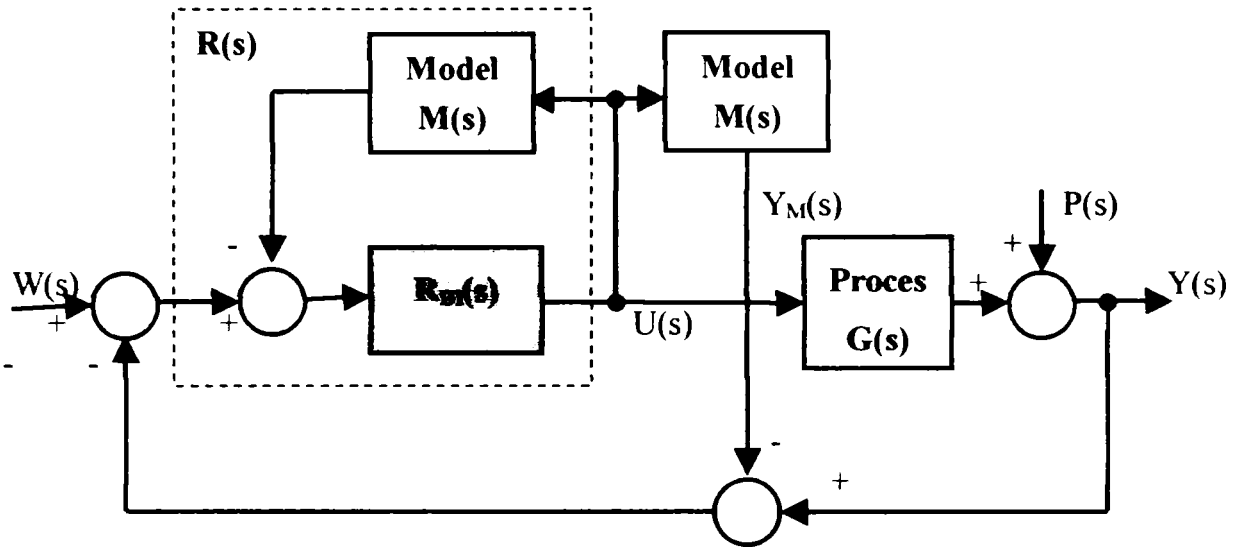


Fig. 3.4. Structură de reglare cu model intern

În acest caz regulatorul va avea funcția de transfer

$$R(s) = \frac{R_{BI}(s)}{1 + R_{BI}(s) \cdot M(s)} \quad (3.10)$$

Când în componența regulatorului în buclă închisă $R_{BI}(s)$ există un integrator, în regim staționar regulatorul $R(s)$ se identifică cu $M^{-1}(s)$.

Deși echivalente din punctul de vedere al transferului intrare-ieșire, variantele din figurile 3.2, 3.3 și 3.4 au comportamente diferențiate în funcție de stabilitatea procesului [Said96].

3.1.3 Identificarea proceselor prin metoda modelului intern

Metoda modelului intern poate fi reorientată în sensul identificării procesului: *în loc ca procesul să urmărească automat modelul de referință, modelul va urmări automat evoluția procesului*. Schema bloc a procedurii este prezentată în fig. 3.4.

Avantajul acestei abordări a modelării este acela că oferă premisa *identificării on-line* a întregului set de parametri interni ai procesului, cu condiția ca modelul să fie *determinist*, adică să respecte legăturile funcționale dintre parametrii procesului.

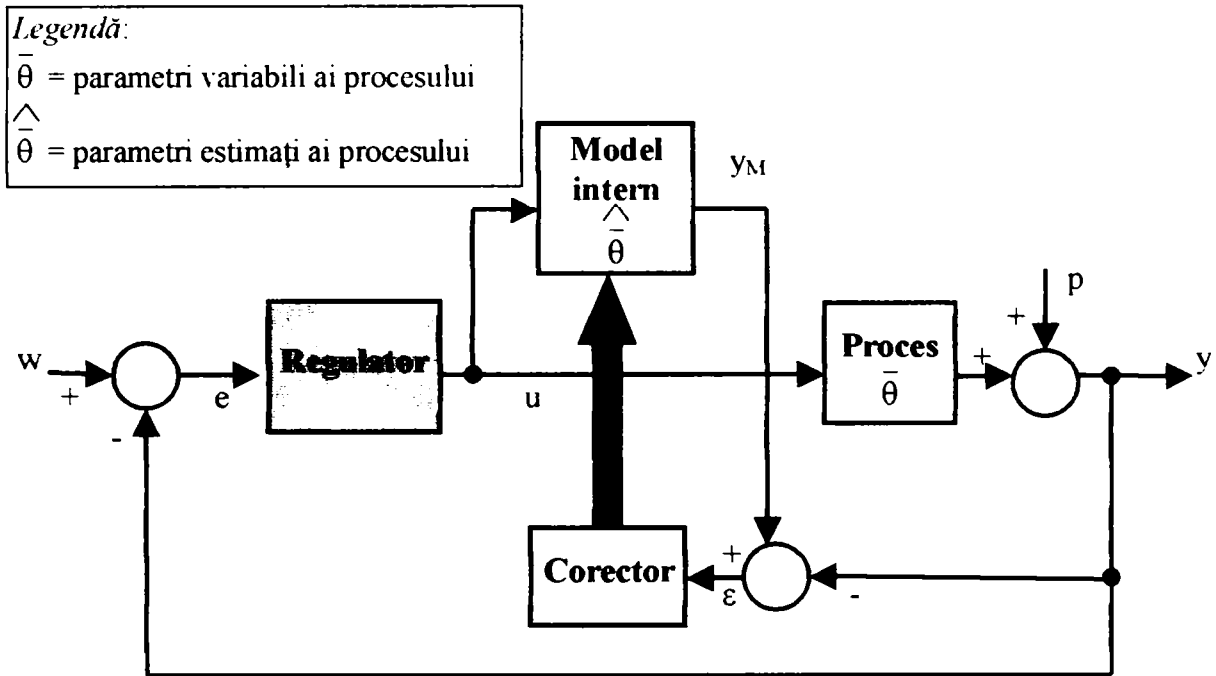


Fig. 3.5 Identificarea unui proces prin metoda modelului intern

Principala dificultate a acestei metode apare la proiectarea corectorului, atunci când nu dispunem de informații precise referitoare la modul de acțiune a parametrilor asupra procesului. În acest caz se ridică problema convergenței algoritmului de corecție pe domeniul de funcționare al sistemului (în sensul relației 3.4) precum și problema stabilității acțiunii corectoare. Bucla de reacție dintre corector și modelul intern poate ea însăși genera instabilitate. Stabilitatea identificării cu model intern poate fi studiată doar în cazuri concrete, în care se cunoaște precis legea de corecție adaptivă.

Ecuțiile care modelează structura din fig. 3.5 sunt:

$$\left\{ \begin{array}{l} U(s) = \frac{R(s)}{1 + R(s) \cdot G(s)} \cdot W(s) - \frac{R(s)}{1 + R(s) \cdot G(s)} \cdot P(s) \\ Y(s) = \frac{R(s) \cdot G(s)}{1 + R(s) \cdot G(s)} \cdot W(s) + \frac{P(s)}{1 + R(s) \cdot G(s)} \\ \varepsilon(s) = (M(C(s)) - G(s)) \cdot U(s) - P(s) \end{array} \right. \quad (3.11)$$

3.1.4 Soluții de modelare

Modelele utilizabile în conducerea automată și care urmează să fie utilizate în compunerea senzorilor inteligenți trebuie adaptate aplicației și resurselor disponibile.

În lucrarea de față se vor utiliza *modele deterministe structurale cu timp continuu, programate în SIMULINK – MATLAB*. Avantajul lor principal este transparența față de raționamentul uman și apropierea de natura fizică, continuă, a proceselor modelate. În plus reprezentarea prin scheme bloc este cea mai adecvată sistemelor complicate, cu multe interconexiuni între module.

Implementările se obțin de regulă cu modele în timp discret, compatibile cu procesoarele utilizate atât în ceea ce privește limbajul de programare cât și capacitatea de memorie și de calcul.

Modelele deterministe au avantajul că nu necesită capacități mari de memorare, relațiile funcționale ale modelului dezvoltându-se în timp, prin integrarea numerică a ecuațiilor. Atunci când nu dispunem de un model analitic sau când modelul este foarte complicat se poate apela la o soluție extrem de eficientă: modelarea prin rețele de interpolare [Drag01b]. În principiu orice dependență funcțională poate fi aproximată cu ajutorul rețelelor interpolative, cu o anumită precizie, care depinde de numărul nodurilor de interpolare.

În mediul MATLAB rețelele interpolative se pot implementa cu ajutorul tabelor de căutare multi-dimensionale. În limbajele de nivel înalt implementările se pot realiza prin intermediul ariilor multidimensionale. Ariile multidimensionale pot fi implementate și în cazul sistemelor de nivelul microprocesoarelor sau microcontrolerelor. Sisteme interpolative cu interpolare liniară pot fi implementate chiar și în tehnologii analogice [Băla02a].

În oricare dintre variante problema principală a modelării este realizarea unei concordanțe cât mai bune între model și proces, în regim staționar cât și în regim dinamic. În cazul proceselor liniare simple, identificabile cu precizie, modelarea nu ridică probleme. În cazul în care caracteristica intrare-ieșire a procesului este bijectivă se pot construi modele inverse cu scopul asigurării condiției (3.8) teoretic sub forma:

$$M(s) = G^{-1}(s) \quad (3.12)$$

iar practic sub o formă modificată, corespunzătoare posibilității de realizare fizică aproximativă a lui $G^{-1}(s)$.

În cazul proceselor neliniare singura cale posibilă de asigurare a unui nivel impus al preciziei constă din ajustarea automată a parametrilor modelului astfel încât eroarea de adaptare ε să fie minimizată.

În [Bouk97] se propune o variantă de conducere pe bază de model de referință cu model intern de tip fuzzy. Soluția este recomandabilă atunci când nu se dispune de un model determinist al procesului, dar există totuși informații calitative, de tip expert, referitoare la intercondiționările funcționale dintre parametrii modelului.

Modelele fuzzy des întâlnite în literatură pot fi clasificate în trei categorii:

- a) Modelele lingvistice, introduse de Lotfi A. Zadeh în [Zade75].
- b) Modele cu relații fuzzy introduse de W. Pedricz și E. Czogala în [Pedr81].
- c) Modele Takagi-Sugeno introduse în [Taka85].

În [Bouk97] varianta aleasă este c, cea mai avantajoasă din punct de vedere al implementării. În aceeași lucrare se propune și o metodă de inversare a modelelor de tip Takagi-Sugeno. Deoarece controlerul fuzzy obținut nu corespunde exact modelului invers al sistemului, tehnica folosită se numește pseudo-inversiune.

Considerând o regulă de forma:

„Dacă procesul este în starea \bar{x}_i și se aplică comanda \bar{u}_j atunci ieșirea este $\bar{y}_{(i,j)}$ ”

ea va avea inversa de forma:

„Dacă procesul este în starea \bar{x}_i și dorim ieșirea $\bar{y}_{(i,j)}$ atunci se aplică comanda \bar{u}_j ”

Trebuie evidențiat faptul că pentru a nu rezulta reguli contradictorii funcția $\bar{y}_{(i,j)}$ trebuie să fie bijectivă.

Modelele fuzzy se pot aplica atunci când nu este necesară sau posibilă modelarea precisă a procesului. Când nici modelarea fuzzy nu este productivă se poate apela la rețelele neuronale sau la alte metode de învățare artificială.

3.2 Un senzor inteligent cu fuziunea datelor și model intern

3.2.1 Senzor inteligent adaptiv cu model intern

Deseori măsurătorile asupra proceselor conduse automat sunt afectate de erori, având diferite cauze: imprecizii sau derive în timp ale valorilor componentelor electronice din echipamente, sensibilități limitate, perturbații externe, etc. Incertitudinea introdusă astfel se numește *incertitudine de ordin 1* [Gupt88].

Mai mult decât atât, procesele și măsurătorile aferente lor sunt de regulă afectate de *incertitudini de ordin 2* care țin chiar de cunoașterea insuficientă a procesului sau echipamentelor de conducere, care pot avea chiar prin natura lor un caracter vag.

Un astfel de caz apare de exemplu la măsurarea temperaturii aerului din interiorul unei incinte condiționate. Circulația aerului, inerțiile termice, influențele pereților și alți factori creează distribuții complexe și nerepetitive ale temperaturii aerului atât în spațiu cât și în timp. Măsurarea temperaturii va fi în consecință influențată de poziția senzorului, fără a se putea defini în mod fundamentat o poziție optimă.

Pentru măsurări în condiții de incertitudine una dintre căile posibile este extragerea unei cantități cât mai mari de informație din datele disponibile. În acest scop, în continuare se va apela la două tehnici diferite dar care pot conlucra eficient: *fuzionarea datelor și modelul intern*.

Prin fuzionarea datelor se obțin în principal două avantaje:

- extinderea domeniului de măsură;
- creșterea fiabilității;

În plus, prin analogie cu sistemele de reglare adaptive cu model de intern, în această lucrare se propune, ca o soluție originală, introducerea în structura senzorului a unui model al procesului măsurat (vezi modelul intern din fig. 3.6), care poate să includă și particularitățile importante ale senzorilor primari și ale canalului de măsurare: întâzieri, etc. În acest model se includ toate cunoștințele apriorice disponibile, teoretice și/sau experimentale.

Introducerea modelului intern al procesului fizic la care este conectat senzorul poate sta la baza unor acțiuni vizând mai multe obiective care pot fi grupate în următoarele categorii:

- îmbunătățirea funcționării sensorului:
 - creșterea preciziei,
 - scăderea timpului de răspuns,
 - rejectarea perturbațiilor, etc.;
- validarea măsurătorilor;
- diagnosticarea funcționării și a stării tehnice a sensorului.
- estimarea mărimilor fizice sau indicilor de performanță sintetici ai procesului, care nu sunt măsurabili sau sunt greu accesibili;
- adaptarea la condițiile de măsurare și la starea tehnică cu ajutorul estimărilor.

Rezultă o structură originală de *senzor inteligent adaptiv cu model intern* SIAMI. Se au în vedere structuri complexe de senzori, în care există cât mai mulți senzori lucrând în redundanță, la care rezultatul final al măsurătorii se obține prin fuzionarea informațiilor primare. **Modelul intern va acționa asupra rezultatului final al măsurătorii sau estimării prin intermediul mecanismului de fuzionare.** Schema bloc SIAMI este reprezentată în fig. 3.6.

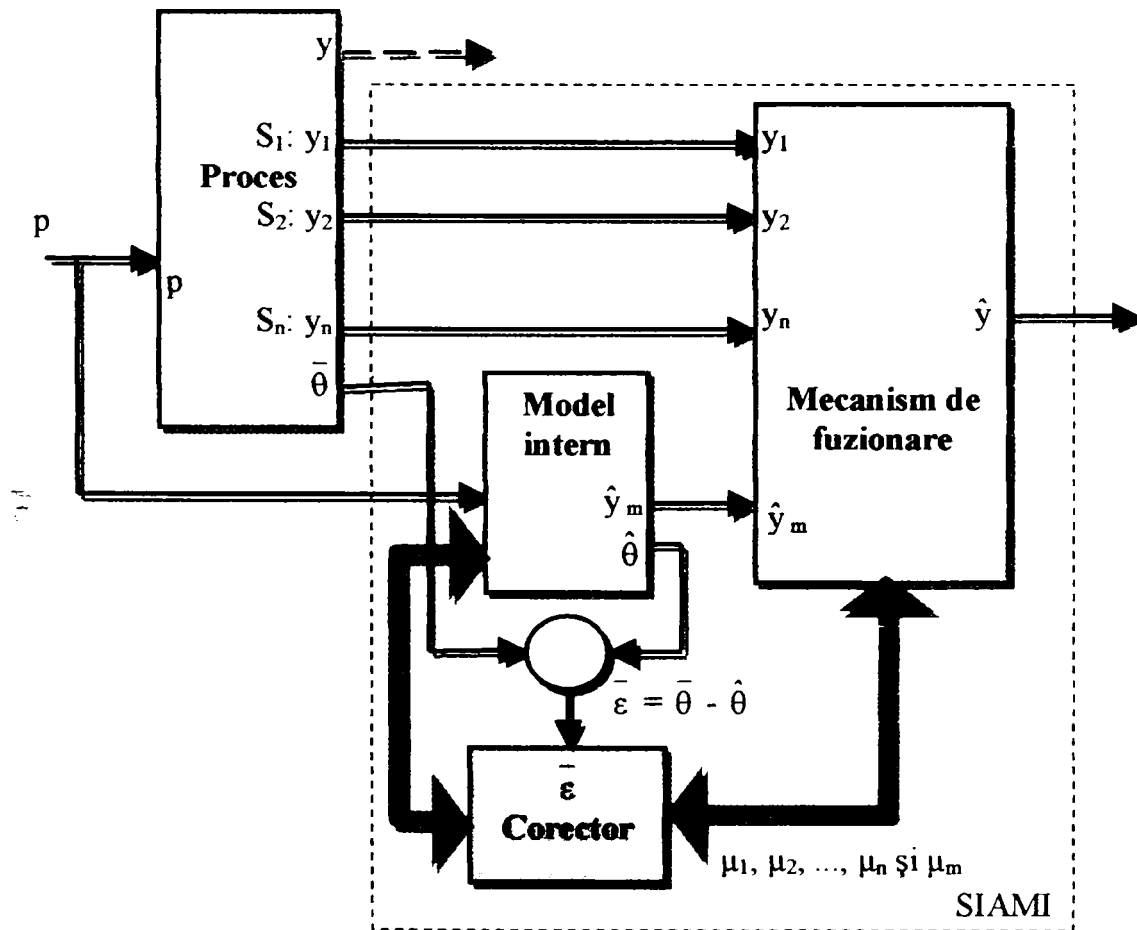


Fig. 3.6. Structura SIAMI

▪ **Procesul** – este caracterizat de incertitudinea referitoare la mărimea de ieșire și la măsurarea ei. Procesul include n senzori primari S_1, S_2, \dots, S_n care măsoară în paralel variabila de ieșire din proces y . Din cauza incertitudinii care afectează procesul nu avem acces la ieșirea y , care trebuie estimată.

Intrări: mărimea de intrare p ;

Ieșiri: mărimea de ieșire y (neaccesibilă); semnalele celor n senzori y_1, y_2, \dots, y_n ;

Mărimi de stare: vectorul mărimilor de stare $\bar{\theta}$ (menționați în relațiile 3.2, 3.3 și 3.4).

Elementele componente ale SIAMI sunt:

▪ **Modelul intern** – reprezintă totalitatea cunoștințelor deterministe despre proces.

Intrări: mărimea de intrare în proces p ;

Ieșiri: estimata modelului \hat{y}_m ;

Mărimi de stare: estimarea vectorului mărimilor de stare $\hat{\theta}$.

▪ **Mecanismul de fuzionare** – calculează estimata ieșirii procesului \hat{y} pe baza unor grade de încredere în fiecare dintre senzorii primari. $\mu_1, \mu_2, \dots, \mu_n$ precum și a gradului de încredere în model μ_m . Se pot utiliza diferite legi de agregare, inclusiv fuziunea fuzzy.

Intrări: semnalele celor n senzori y_1, y_2, \dots, y_n și estimata modelului \hat{y}_m ;

Ieșiri: estimata mărimii de ieșire \hat{y} ;

Mărimi de stare: gradele de încredere în senzorii primari și în model $\mu_1, \mu_2, \dots, \mu_n$ și μ_m .

▪ **Corectorul** – îndeplinește două funcții fundamentale:

a) **adaptarea on line a modelului intern al procesului, astfel ca acesta să urmărească cât mai fidel evoluția parametrilor funcționali ai procesului real,**

b) **validarea senzorilor primari și a modelului (calculul gradelor lor de încredere) se face pe baza datelor tehnice ale senzorilor primari (domeniul de funcționare, precizii, perturbații, viteza de răspuns, etc.). Justificarea cumulării validării cu corecția rezidă în aceea că în corector sunt centralizate deja o serie de date referitoare la sistem, necesare adaptării. Aceleași date pot fi utilizate și la validare și la gestionarea fuzionării.**

La stabilirea gradelor de încredere se au în vedere mai multe obiective:

- **asigurarea unei precizii maxime pe un domeniu cât mai mare de funcționare a senzorului inteligent. Pentru aceasta se vor atribui valori maxime de încredere pentru acei senzori care în punctul de măsură au precizie maximă,**

- **asigurarea unei viteze de răspuns cât mai bună pentru senzor. Compensarea inerției senzorilor primari pe durata regimurilor tranzitorii poate fi obținută prin utilizarea mărimii estimate de către model \hat{y}_m ,**

- **asigurarea unei fiabilități sporite prin diagnosticarea senzorilor primari, ale căror indicații sunt comparate cu \hat{y}_m . Gradul de încredere în senzorii care nu funcționează corect conform criteriilor diagnozei este anulat.**

Stabilirea legilor de adaptare a modelului și a gradelor de încredere în măsurile care participă la fuziune, cade în sarcina corectorului din componența SIAMI. Adaptarea modelului intern și fuziunea informației disponibile sunt afectate la rândul lor de incertitudine, din cauza diversității proceselor și a mecanismelor de neliniaritate și variație în timp. De aceea este dificilă identificarea unei soluții general aplicabile în cazul corectorului. *Singura abordare posibilă în fiecare caz este cea euristică.* În această situație, o cale posibilă și recomandabilă este alegerea unui corector adaptiv fuzzy. Pentru facilitarea implementărilor este recomandabilă varianta fuzzy-interpolativă [Băla01a], bazată pe echivalențele posibile dintre controlerile Takagi-Sugeno și cele interpolative cu interpolare liniară.

Așa cum s-a arătat în cap. 2, în funcție de ponderea incertitudinii prezente în cunoștințele despre proces, fuzionarea poate la rândul ei să includă o cantitate variabilă de incertitudine. În cazul fuziunii fuzzy se pot distinge trei niveluri de fuzzycitate:

- *fuziunea non-fuzzy*, cazul tipic fiind cel al sumei ponderate. Considerând notațiile de mai sus și cazul unor ponderi neliniare, dependente de valorile măsurate (§5.3),

$$y = \frac{\sum_i \mu_i(y_i) \cdot y_i}{\sum_i \mu_i(y_i)} \quad (3.13)$$

- *fuziunea ponderată fuzzy*, în care fuziunea propriu-zisă este suma ponderată dar gradele de încredere sunt determinate prin metode fuzzy:

$$y = \frac{\sum_i \mu_i(\text{fuzzy}(y_i)) \cdot y_i}{\sum_i \mu_i(\text{fuzzy}(y_i))} \quad (3.14)$$

- *fuziunea fuzzy propriuzisă* (cap.2).

Cele trei tipuri de fuziune vor fi exemplificate în capitolele 4 și 5.

3.2.2 Modelul matematic al SIAMI

Din cauza complexității și neliniarității structurale a SIAMI, modelarea în frecvență (prin funcții de transfer) trebuie înlocuită cu modelarea în timp, prin ecuații diferențiale neliniare, care urmează să fie integrate fie în cadrul unor simulări, fie în timp real, în cazul aplicațiilor. Din aceleași motive, singura reprezentare precisă a modelelor este sursa programului prin care ele sunt implementate, respectiv a blocurilor funcționale în cazul implementărilor Simulink [Băla02f].

Modelul trebuie să țină cont de cele două prelucrări fundamentale ale semnalului măsurat y : prelucrarea la nivel de senzori și fuzionarea.

Senzorii primari introduc diferite erori, conform principiilor lor de funcționare, a particularităților constructive, a influenței factorilor de mediu și a stării lor tehnice.

$$y_i(t) = S_i(y(t)) \quad (3.15)$$

Funcțiile de intrare-ieșire ale senzorilor $S_i(y(t))$ pot fi determinate doar experimental, prin etalonarea senzorilor. O diagramă de etalonare este prezentată în fig. 3.7.




Fig. 3.7. Diagramă de etalonare a unui senzor

Indicațiile $y_i(t)$ sunt ponderate prin gradele de încredere aferente fiecărui senzor $\mu_i(y(t))$, rezultând n termeni de forma $\mu_i(y(t)) \cdot y_i(t)$, care sunt agregați prin mecanismul de fuzionare, împreună cu termenul corespunzător modelului intern $\mu_m(y(t)) \cdot y_m(t)$:

$$\hat{y} = \text{Fuz}(\mu_1(y(t)) \cdot y_1(t), \mu_m(y(t)) \cdot y_m(t)) \quad (3.16)$$

Fuzionarea este ortonormată atunci când gradele de încredere respectă relația:

$$\mu_m(y(t)) + \sum_{i=1}^n \mu_i(y(t)) = 1 \quad (3.17)$$

3.3 Concluziile capitolului 3

În acest capitol se prezintă succint ideile care fundamentează teoretic utilizarea modelelor interne. Se menționează principalele lor aplicații cunoscute:

- reglarea adaptivă;
- identificarea automată a proceselor.

Lucrarea propune o structură originală de senzor inteligent adaptiv cu model intern, SIAMI. Ea face apel atât la tehnica modelului intern cât și la aceea a fuziunii datelor, prezentată în capitolul anterior.

Prin tehnica SIAMI se pot dezvolta structuri complexe de măsurare inteligentă prin fuzionarea mai multor senzori primari lucrând în redundanță. Modelul intern participă la fuziune prin estimarea sa, care este introdusă la intrarea blocului de fuziune, împreună cu măsurile senzorilor primari. Pe lângă aceasta, modelul intern asistă validarea măsurilor senzorilor primari. Validarea este realizată de către un corector de tip fuzzy-interpolativ cu reguli euristice, care are și rolul adaptării modelului intern.

Dintre posibilele tipuri de modele interne se propun pentru a fi aplicate în SIAMI fie modelele în timp deterministe și structurale, fie modelele fuzzy, în cazul în care aplicarea primelor nu este posibilă. Având în vedere complexitatea sistemelor modelate precum și neliniaritatea lor, reprezentările matematice analitice nu sunt posibile, singura reprezentare precisă a modelelor fiind sursa programului prin care ele sunt implementate, adică modulele Simulink în cazul lucrării de față.

Structura SIAMI, relativ complicată, este necesară în cazurile în care procesul măsurat este complex, neliniar, puternic variabil în timp, atunci când mărimile de ieșire sunt greu măsurabile sau atunci când fiabilitatea măsurătorii este critică.

Senzor inteligent cu model intern al vitezei unui vagon

În acest capitol se propun aplicații ale senzorului cu fuziunea datelor și model intern în cazuri în care mărimile măsurate sunt afectate de incertitudini fundamentale. Se prezintă în primul rând un senzor inteligent al vitezei unui vagon, SIVV, care este capabil să estimeze viteza vagonului chiar și pe durata regimului de alunecare care apare în timpul frânelor puternice, în care roțile patinează față de șină. Pe lângă traductorul de turație al roții SIVV include și un accelerometru precum și un model al instalației ABS, care conduce operația de fuzionare fuzzy. SIVV efectuează în același timp și estimarea aderenței dintre roată și șină. Se mai prezintă și o aplicație originală a SIVV, prin care acesta, cu ajutorul unui bloc suplimentar, poate estima on-line uzura elementelor de fricțiune ale unei frâne disc.

4.1. Un senzor inteligent al vitezei unui vagon pe durata frânării ABS

4.1.1. Frânarea ABS, un proces afectat de incertitudine

Fenomenul care creează principalele probleme la frânarea vagoanelor este alunecarea instalată între roată și șină atunci când forța de frânare depășește forța de reacție a șinei, care depinde de coeficientul de aderență (frecare) dintre roată și șină. Dacă în timpul alunecării forța de frânare nu este imediat scăzută, viteza unghiulară a roții va scădea până la blocarea totală, roata ajungând să patineze pe șină. Patinarea produce uzuri rapide, deformări ale bandajelor roților care în continuare vor produce vibrații, dar mai ales afectează siguranța circulației prin creșterea distanței de frânare. Alunecarea roții se definește prin relația:

$$s = (v_{\text{car}} - v_w) / v_{\text{car}} \quad (4.1)$$

unde: s este alunecarea, cuprinsă între 0 (roată nefrânată) și 1 (roată blocată), v_{car} este viteza vagonului iar v_w viteza roții [Boite86a]. În cazul vagoanelor, care nu au roți motoare, $v_w \in [0, v_{\text{car}}]$. În cazul locomotivelor sau automobilelor, când forța de tracțiune depășește reacția șinei respectiv a șoselei, apare fenomenul de patinare (*skid*) în timpul căruia $v_w > v_{\text{car}}$.

Modelul matematic al roții în regim de alunecare, dacă nu se consideră efectele dinamice (mai ales cabrările boghiurilor și vagonului) și dacă pe osie sunt montate N_d de frână, este [Băla01b]*:

$$J_i \cdot \frac{1}{r_{wi}} \cdot \frac{dv_{wi}}{dt} = f_i(s_i) \cdot \frac{Q_i}{N_d} \cdot g \cdot r_{wi} - \mu_i(s_i) \cdot F_{di}(t) \cdot r_{di} \quad (4.2)$$

unde: J_i = momentul de inerție al roții, f_i = coeficientul de frecare roată-șină, r_{wi} = raza roții, Q_i = sarcina pe osie, g = accelerația gravitațională, μ_i = coeficientul de frecare disc-garnitură, F_{di} = forța de frânare aplicată discului iar r_{di} = raza echivalentă a discului.

* lucrare prezentată la a 9-a Conferință Internațională asupra Boghiurilor și Materialului Rulant, Budapesta, Ungaria, 2001

Coeficientul de frecare f este puternic dependent de alunecarea s [Boite86a]. Pe lângă dependența de s , f este influențat de geometria, curățenia și uzura sistemului roată-șină precum și de factorii meteorologici. Experimental se constată și existența unor variații aleatorii ale aderenței chiar pe distanță de câțiva metri. În fig. 4.1 se prezintă o dependență $f(s)$ tipică. Aceeași alură a dependenței aderență-alunecare poate fi găsită și în cazul automobilelor [Altr96], [Klei96].




Fig. 4.1. O dependență tipică aderență-alunecare [Boite86a].

În principiu aderența scade cu creșterea alunecării, valoarea sa maximă f_A manifestându-se pentru $s = 0$, în momentul în care se produce inițierea alunecării, fenomen brusc (*creepage*) în care un rol îl joacă și elasticitatea roții. Pentru $s = 0,15 \dots 0,2$ există însă o regiune în care aderența crește cu creșterea alunecării. Astfel f atinge un maxim relativ f_B , pentru o alunecare optimă s_{Opt} . De cele mai multe ori între f_B și f_A există inegalitatea $f_B < f_A$. Există și situații în care $f_B > f_A$ [Boite86a]. În continuare vom neglija acest fenomen, nerevelator pentru funcționarea frânei. Cu toate că această caracteristică a fost determinată în regim staționar ea este folosită și în regim dinamic, adică atunci când s variază în raport cu timpul.

Datorită creșterii aderenței cu alunecarea, în porțiunea $s_B - s_{Opt}$ apare un efect de autostabilizare a alunecării, care favorizează reglarea sa cu precizie, prin modificarea adecvată a forței de frecare aplicate roții. Scopul acțiunii sistemelor de frânare ABS (*Antilock-Braking System*) este tocmai menținerea alunecării fiecărei roți în domeniul controlabil dintre s_B și s_{Opt} , cât mai aproape de s_{Opt} , care este de regulă cuprins între 0,15 și 0,25, atât pentru vagoane [Boite86b], [Auma86] cât și pentru automobile [Altr96], [Klei96]. Scopul este atins prin modificarea forței de frânare. În cazul frânelor disc pneumatice reglarea forței de frânare este obținută cu ajutorul valvelor cu acțiune continuă cu trei poziții (admisie, evacuare și reținere).

Când alunecarea depășește acest domeniu, controlul asupra roții este greu de menținut și roata se blochează rapid. Dacă forța de frânare scade, deblocarea roții se produce rapid, controlul asupra alunecării fiind greu de restabilit.

Principala dificultate a frânării ABS este produsă de caracterul incert al coeficientului de frecare efectiv dintre roată și șină. Acesta este diferit de coeficientul de frecare măsurat în condiții de laborator, fiind puternic influențat de către o serie întreagă de factori naturali și tehnici [Diet90]:

- 1) condiții de vreme ca temperatura ambiantă, ploaia, zăpada, ceața etc.
- 2) condițiile în punctul de contact dintre roată și șină; forța de aderență descrește în prezența uleiului, grăsimii, noroiului sau a altor substanțe străine;

- 3) variația pantei și curbura șinei;
- 4) mărirea instantanee a alunecării roții;
- 5) viteza unghiulară și accelerația unghiulară a roților;
- 6) dinamica vagonului: de exemplu, în timpul frânării, din cauza inerției se produce cabrarea întregului vagon, fenomen prin care boghiul anterior este mai încărcat decât cel posterior; cabrarea se manifestă și în cazul fiecărui boghiu în parte, roțile anterioare fiind mai încărcate decât cele posterioare;
- 7) tipul de material folosit la calea ferată și roți;
- 8) uzura roților și a șinelor.

Efectul produs prin cumulara acestor factori constă din variații puternice, rapide și aleatorii ale coeficientului de frecare efectivă dintre roată și șină. Este dificil să se cuantifice și să se măsoare precis efectul tuturor acestor factori [ICPV].

În continuare fenomenele complexe care creează și influențează reacția șinei asupra roții vor fi denumite generic *aderență* iar coeficientul efectiv de frecare roată-șină se va denumi *coeficient de aderență* și notat f .

În fig. 4.2 se prezintă orientativ, doar efectul umidității asupra aderenței.

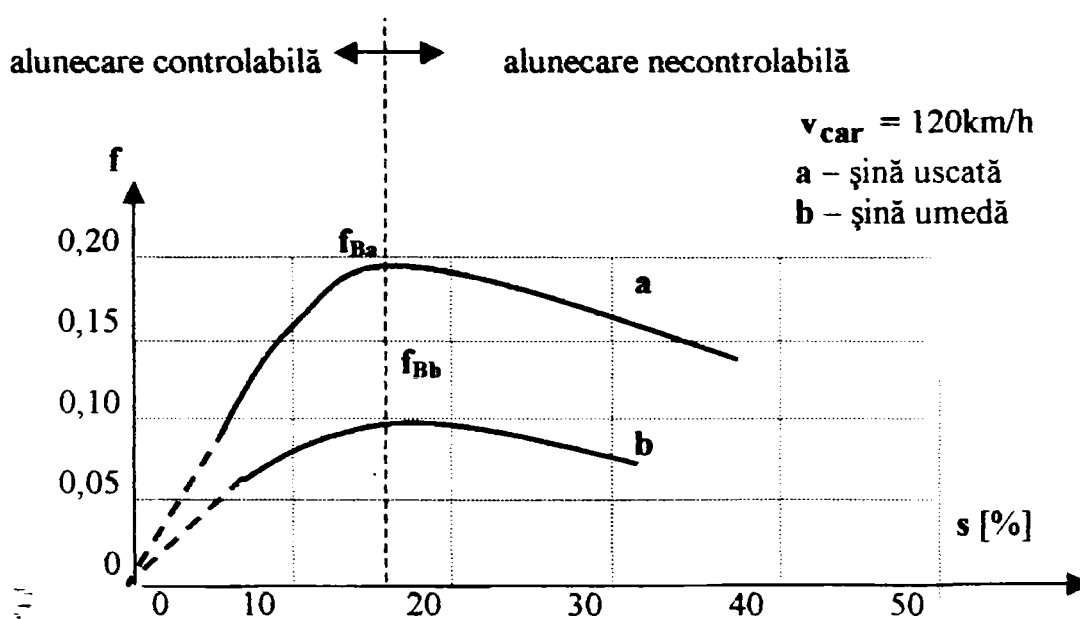


Fig. 4.2. Efectul umidității asupra aderenței [Boite86a].

Întrucât regulatorul ABS trebuie să adapteze forța de frânare la coeficientul de aderență disponibil, incertitudinea care marchează variațiile aderenței se va răsfrânge asupra întregului sistem [Naka95]. De aceea se impune ca fiecare osie să dispună de propriul său traductor de turație și de propriul regulator [UIC].

O dificultate suplimentară în reglarea ABS este provocată de lipsa unui traductor valid al vitezei vagonului în momentele în care toate roțile alunecă. Senzorii de viteză ai roților cu care se măsoară viteza vagonului sunt montați pe osie, de obicei pe capetele acestora. În timpul alunecării ei nu mai indică v_{car} ci v_w [Auma86]. De aceea în timpul frânărilor puternice nu se mai dispune de informații referitoare la viteza vagonului și prin urmare nu se mai poate calcula alunecarea s . Pentru a putea calcula în timp real alunecarea s trebuie să se dispună de o estimare a vitezei vagonului, notată în continuare \hat{v}_{car} . Măsurarea directă a v_{car} ar putea fi

obținută cu traductoare suplimentare, de exemplu prin radare sau sonare Doppler (montate de-a lungul liniei) sau prin integrarea ieșirii unui accelerometru. Traductoarele suplimentare sunt însă de regulă evitate atât din cauza costurilor ridicate cât și din motive de siguranță a circulației [Băla00a].

Metoda tipică de obținere a \hat{v}_{car} constă din aproximarea decelerației vagonului ca o constantă în timp. În cazul frânelor Knorr decelerația este determinată offline, experimental (vezi fig. 4.3) [Knor90]. Această estimare este evident imprecisă. Pentru a se evita acumularea erorilor de calculare a alunecării, care ar putea produce oscilații nedorite ale forței de frânare, una dintre osiile vagonului trebuie să fie subfrânată, astfel că ea păstrează mai ușor contactul roată-șină, sau, în cazul producerii alunecării, ea iese mai ușor din acest regim. Când se ajunge la situația $v_w > \hat{v}_{car}$ estimarea trebuie actualizată la valoarea v_w a traductorului de viteză [Auma86] și [Knor94]. În fig. 4.3 se reprezintă variații tipice ale vitezelor a două roți ale unui boghiu în regim de alunecare v_{w1} și v_{w2} . Se observă că estimarea vitezei vagonului prin metoda decelerării constante este corectă doar în momentele marcate cu pătrat.





Fig. 4.3. Evoluția vitezelor roților în timpul alunecării

4.1.2. Introducerea unui accelerometru

În [Klei96], în cazul unui automobil experimental, \hat{v}_{car} este evaluată cu ajutorul unui controler fuzzy, care are la intrare semnalele celor patru traductoare de viteză ale fiecărei roți v_{wi} , ($i = 1 \dots 4$) și al unui accelerometru (vezi fig. 4.4). Semnalul furnizat de accelerometru (care este de preferat să fie instalat în zona centrului de greutate al automobilului pentru evitarea erorilor introduse de tangaj și ruliu), este integrat, furnizând o evaluare a vitezei vehiculului \hat{v}_{car_a} , chiar și atunci când roțile sunt în regim de alunecare, conform relației (4.3). Viteza inițială de la care începe alunecarea roților $v_{car}(0)$ se poate determina ca fiind ultima indicație a senzorilor de viteză ai roților înaintea instalării alunecării.

Controlerul evaluează viteza vehiculului printr-o însumare ponderată a celor cinci intrări, ponderile fiind reprezentate de gradele de încredere ale fiecărei intrări. Pentru evitarea problemelor ridicate de integrarea analogică, mai ales a saturării, integrarea se va realiza digital, pe un domeniu suficient de larg.



$$\hat{v}_{\text{car}_a} = \int_0^t a dt + v_{\text{car}}(0) \quad (4.3)$$

CG = centru de greutate

Fig. 4.4. Instalarea unui accelerometru

În cazul automobilului existența roților motoare impune utilizarea informațiilor provenite de la traductoarele roților. În timpul demarajelor, când roțile motoare patinează, viteza lor tangențială ajunge să depășească viteza vehiculului. Pentru vagoane, care nu au roți motoare și la care se pune doar problema frânării, o simplă operație $\max(v_{w_i})$, ($i = 1 \dots 4$), este suficientă pentru a identifica care dintre senzori are cel mai înalt nivel de încredere. Doar indicația acestui senzor va fi utilizată în cele ce urmează (vezi fig. 4.5).

Precizia tandemului accelerometru-integrator este însă critică, mai ales pentru accelerații mici, când zgomotul și offsetul circuitelor analogice care determină factorul de scalare al semnalului de accelerație pot altera rezultatul.

Rezultă că nici unul dintre cei doi senzori candidați: senzorul de viteză al osiei respectiv accelerometru, nu poate acoperi toate regimurile posibile de funcționare ale regulatorului ABS. Cei doi senzori au caracteristici complementare: pentru accelerații mici ale vehiculului este de preferat senzorul de viteză, în timp ce pentru accelerații mari este preferabil accelerometru.

4.1.3. Structura și funcționarea senzorului inteligent

4.1.3.1. Fuzionarea fuzzy asistată de un model intern

O cale principală de eliminare a impedimentului de mai sus, prin care se obține o evaluare cu un grad uniform de încredere în toate regimurile de funcționare posibile, constă din fuzionarea celor două semnale, $\max(v_{w_i})$ respectiv \hat{v}_{car_a} într-un singur estimator al mărimii \hat{v}_{car} .

Deși reticente la început, în ultimii ani administrațiile de căi ferate au devenit mai deschise față de tehnicile fuzzy [Voge93]. De aceea, în continuare (vezi fig. 4.5) se propune o soluție originală [Băla02b]* constând din fuzionarea fuzzy a informațiilor furnizate de următoarele trei mărimi:

- a) $\max(v_{w_i})$;
- b) \hat{v}_{car_a} ;
- c) $\hat{v}_{\text{car}_{\text{model}}}$, estimata vitezei vagonului obținută cu ajutorul unui model intern al instalației de frânare ABS, care are ca intrare principală presiunea P din cilindrul de frână.

* lucrare prezentată la a 9-a Conferință Internațională asupra Prelucrării Informației și Gestionării Incertitudinii în Sistemele bazate pe Cunoștințe, Annecy, Franța, 2002.

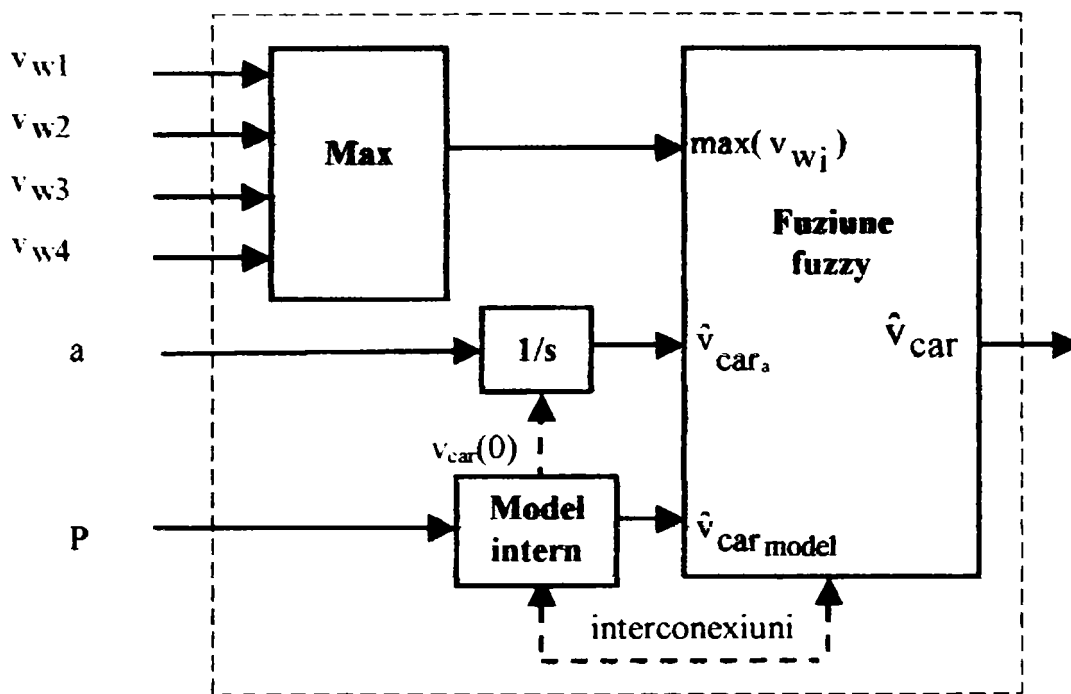


Fig. 4.5. Schema bloc a senzorului cu model intern

Rolul **modelului intern** (vezi §3.2) introdus prin această metodă este complex:

- identificarea regimului de funcționare a frânei ABS, inclusiv $v_{car}(0)$;
- calcularea gradelor de încredere în senzorii primari, în funcție de regimul de funcționare;
- calcularea unei estimări $\hat{v}_{car\ model}$ care să poată interveni direct în fuziunea fuzzy atunci când încrederea în senzorii primari este scăzută și care în același timp poate să asiste diagnosticarea on-line a senzorilor primari;
- estimarea on-line a aderenței roată-șină în vederea adaptării regulatorului ABS la variațiile ei;
- asistarea coordonării întregului ansamblu.

Elementul central al senzorului rezultat este **blocul de fuzionare fuzzy**. Principalele funcții ale acestui bloc sunt:

- realizarea fuzionării fuzzy a trei mărimi: $\max(v_{w_j})$ (maximumul dintre indicațiile celor patru traductoare de viteză ale osiilor), \hat{v}_{car_a} (ieșirea accelerometrului integrată) și $\hat{v}_{car\ model}$ (ieșirea modelului intern);
- adaptarea fuzionării la regimurile de funcționare posibile și la eventualele disfuncționalități diagnosticate cu ajutorul modelului intern. Prin anularea de către acesta a încrederii în elementele diagnosticate ca fiind defecte se obține de fapt o modificare adaptivă a structurii ansamblului.

După cum s-a precizat, senzorul propus reprezintă ansamblul obținut prin fuzionarea fuzzy a mai multor senzori primari și a unui model intern al întregului sistem. Astfel devin posibile adaptarea și autodiagnoza, întrunind elementele care permit încadrarea sa în categoria senzorilor inteligenți (*smart sensors*) [Robe 93].

Această structură denumită în continuare *senzor inteligent al vitezei vagonului* (SIVV), are o natură hibridă: de *senzor* în momentele în care gradul de încredere în oricare dintre senzorii primari este maxim, respectiv de *estimator*, în momentele în care, dimpotrivă, încrederea în toți senzorii primari este redusă, ponderea modelului intern crește. Între cele două situații extreme există un domeniu continuu în care SIVV evoluează între cele două funcții, dependent de regimul de funcționare a frânei și de starea sa tehnică. În acest fel se pot furniza în mod continuu regulatorului ABS informațiile necesare pentru ca acesta să poată calcula cu precizie alunecarea roților și să poată adapta cât mai bine forța de frânare la condițiile existente. Pentru aceasta senzorul complex furnizează regulatorului ABS și o estimare a coeficientului de aderență roată-șină obținută prin metoda modelului intern. Schema bloc a SIVV este prezentată în fig. 4.6. Detalii despre estimarea coeficientului de aderență apar în §4.1.3.4.

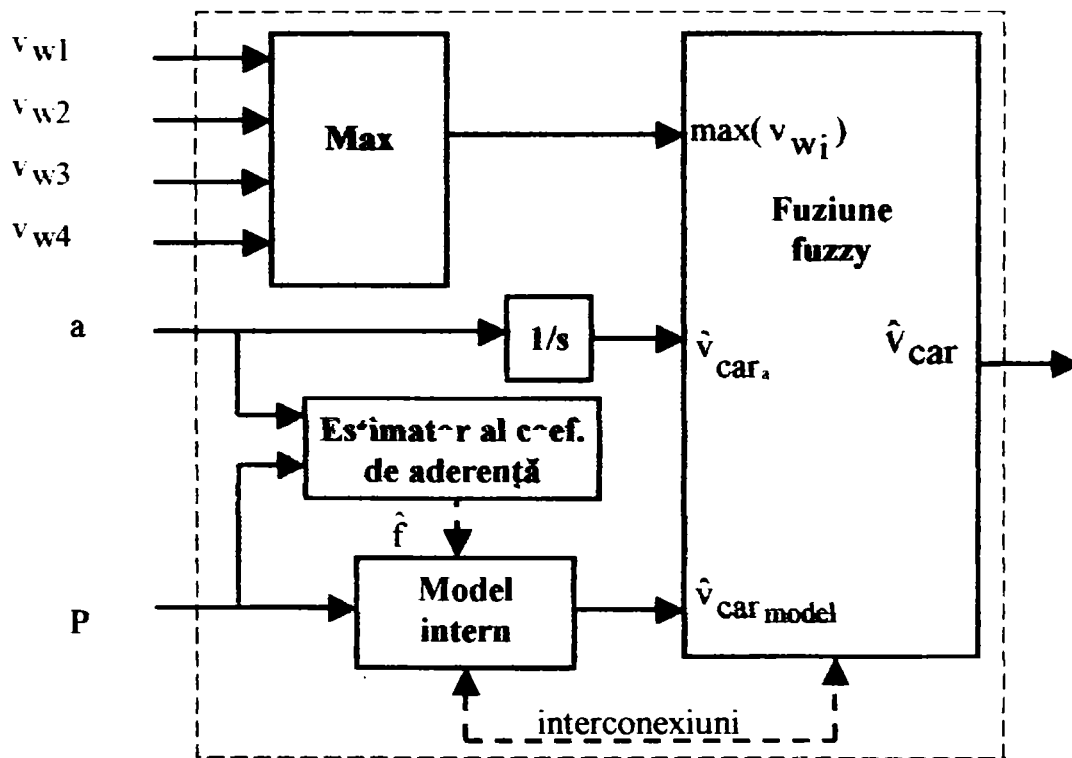


Fig. 4.6. Schema bloc a SIVV, cu estimarea aderenței

Efectele vizate prin realizarea acestei arhitecturi relativ complexe sunt:

- obținerea unei estimări cât mai precise a vitezei vagonului pentru toate regimurile de frânare posibile, rezultând creșterea calității frânării;
- creșterea capacității de autoadaptare a regulatorului frânei ABS care primește din partea senzorului SIVV o estimare a coeficientului de aderență roată-șină, rezultând o îmbunătățire suplimentară a calității frânării;
- creșterea siguranței circulației datorită creșterii redundanței rezultată prin utilizarea unui număr sporit de senzori diverși și complementari ca principiu de funcționare care măsoară aceeași mărime v_{car} , reducând astfel incertitudinea asociată fiecărui senzor luat separat [Many94]. În plus se creează premisele unei diagnosticări automate a senzorilor.

În continuare se precizează funcționarea blocurilor componente ale SIVV.

4.1.3.2. Modelul funcțional al frânei ABS

Modelul, scris în Simulink (Matlab), este preluat din [Băla01a] și [Băla01b]. Principala sa mărime de intrare este presiunea din cilindrul de frână, adică mărimea care produce forța de frecare. Modelul furnizează la ieșire estimări ale majorității parametrilor care caracterizează funcționarea instalației de frânare: viteza și decelerația vagonului, poziția curentă, forța de frânare, alunecarea roților, coeficientul de aderență, etc. Ansamblul modelului este prezentat în fig. 4.7 iar mărimile de intrare, stare și ieșire sunt detaliate în Anexa 2.

În principal modelul include ecuația de mișcare cu parametri fizici variabili în timp ai vagonului și ecuația forței de frânare. În acestea sunt folosiți parametrii instalației de frânare precum și dependența neliniară a coeficientului de frecare dintre disc și garnitura de fricțiune cu viteza relativă dintre ele [Vădă96]. Astfel:

Ecuatia de mișcare a vagonului este:

$$M \cdot \frac{dv_{\text{car}}}{dt} = F_{\text{tr}}(t) - F_a(v_{\text{car}}) - F_{\text{fr}}(t) - F_{\text{tt}}(t) \quad (4.4a)$$

unde: M = masa vagonului [kg], v_{car} = viteza vagonului [m/s], F_{tr} = forța de tracțiune [N], F_a = rezistența la înaintare [N] și F_{fr} = forța de frânare [N]. F_{tt} = forța produsă de înclinarea traseului j [%] este:

$$F_{\text{tt}}(t) = M \cdot g \cdot \sin(\arctg(j)) \quad (4.4b)$$

Forța totală de frânare F_{fr} este egală cu suma forțelor de frecare aplicate tuturor discurilor de frână ale vagonului. Dacă considerăm că forța de frânare se împarte egal pe cele N_w osii ale vagonului și fiecare osie are N_d discuri de frână,

$$F_{\text{fr}}(t) = \sum_{i=1}^{N_w \cdot N_d} F_{\text{di}}(t) = N_w \cdot N_d \cdot F_{\text{di}} \quad (4.4c)$$

Forța de frânare la nivelul discului, care apare și în modelul roții (5.2) este:

$$F_{\text{di}}(t) = F_{\text{cil } i}(t) \cdot \lambda_i \cdot \eta_i \quad (4.4d)$$

fiind produsă de cilindrul de frână. Forța realizată la tija cilindrului de frână este

$$F_{\text{cil } i}(t) = P_i(t) \cdot S_{\text{cil } i} - F_{\text{ri}} \quad (4.4e)$$

cu: P_i = presiunea din cilindrul de frână, S_{cil} = suprafața activă a cilindrului, F_{ri} = forța de rapel, λ_i = amplificarea și η_i = randamentul timoneriei de frână. Presiunea poate varia continuu datorită valvelor cu acțiune continuă conduse tripozițional: *admisie* ($\uparrow P$), *evacuare* ($\downarrow P$) și *menținere a presiunii* ($=P$). Comandat de o astfel de valvă, cilindrul poate modifica continuu forța de frânare.

Prin implementarea acestui model matematic se poate obține un sistem care având la intrare presiunea din cilindru de frână real al vagonului P, oferă la ieșire estimări ale tuturor mărimi lor de stare: viteza vagonului v_{car} , accelerația vagonului a_{car} , spațiul parcurs x_{car} , alunecarea roții s , etc.

În detaliu, modelul implementat este structurat în șapte module: *Regulator ABS*, *Cilindru de frână*, *Boghiu*, *Roată*, *Disc-garnitură*, *Roată-șină*, și *Vagon*. Modulul *Roată* este inclus în modulul *Boghiu* [Băla01a].

Arhitectura modelului este prezentată în fig. 4.7.

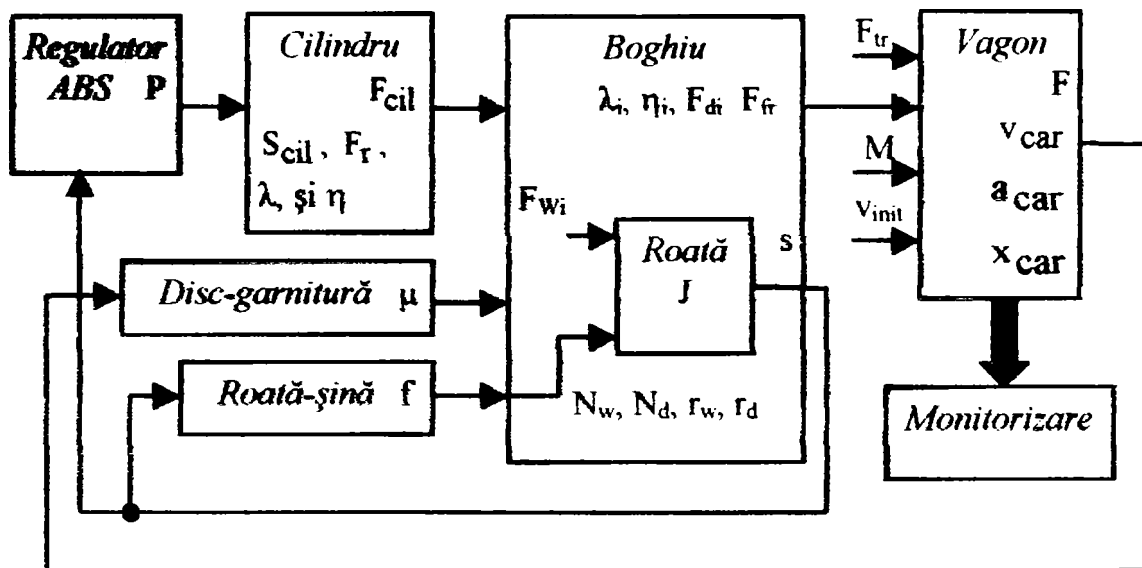


Fig 4.7. Modelul vagonului

Este de menționat că modelul vagonului este utilizat în cadrul simulărilor în trei variante diferite, redate în fig. 4.8 prin modulele: *Vagonul real*, *Model I* (estimarea alunecării) și *Model II* (estimarea aderenței).

4.1.3.3. Implementarea modelului vagonului în SIMULINK

Implementarea SIVV în SIMULINK este ilustrată în figurile următoare. Fișierul rezultat este de 170kB.

În fig. 4.8 este prezentată fereastra principală a aplicației. Modulele *Vagon real* și *Accelerometru* realizează platforma de simulare a vagonului frânat, pe care se testează SIVV. Modulul *Monitorizare* ține de asemenea de platforma de simulare.

◆ Modulul *Accelerometru* (fig. 4.9) este destinat simulării accelerometrului, având la intrare accelerația reală și la ieșire accelerația măsurată și integrala ei. În componența modulului intră un filtru de ordin I cu constanta de timp de 0,01s, un generator de zgomot alb de bandă limitată și un generator de offset care are rolul de a simula offset-ul amplificatorului electronic care condiționează semnalul accelerometrului.

◆ Modulul *Monitorizare* (fig. 4.10a) este nefuncțional. El centralizează parametrii simulării pe care îi afișează cu osciloscoape și display-uri.

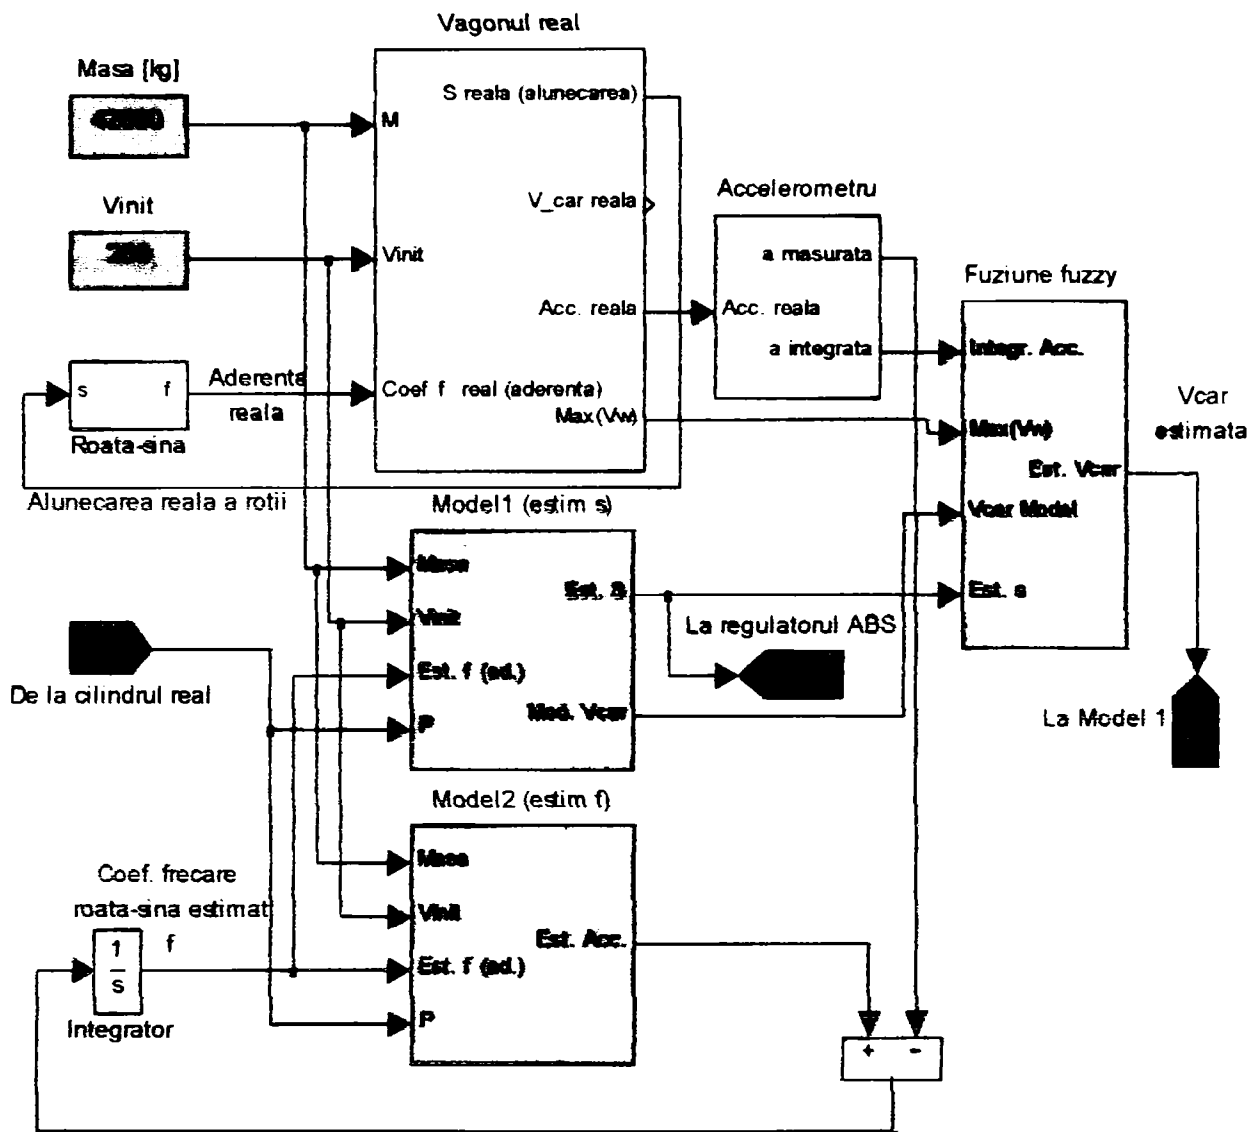


Fig. 4.8. Fereastra principală a platformei de simulare pentru testarea SIVV

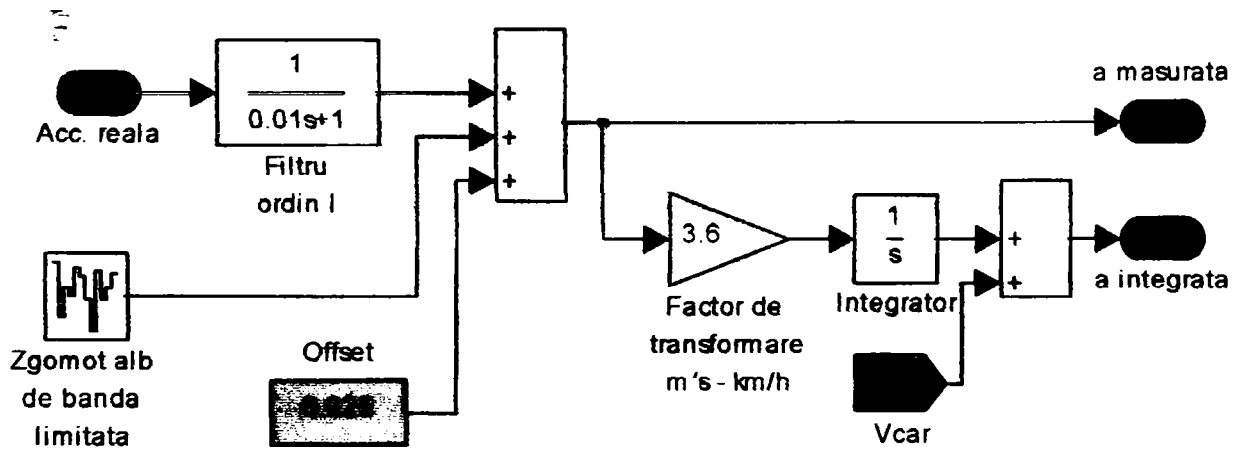


Fig. 4.9. Modulul Accelerometru

Principalele blocuri din componența platformei de simulare sunt date în fig. 4.10 a...f.

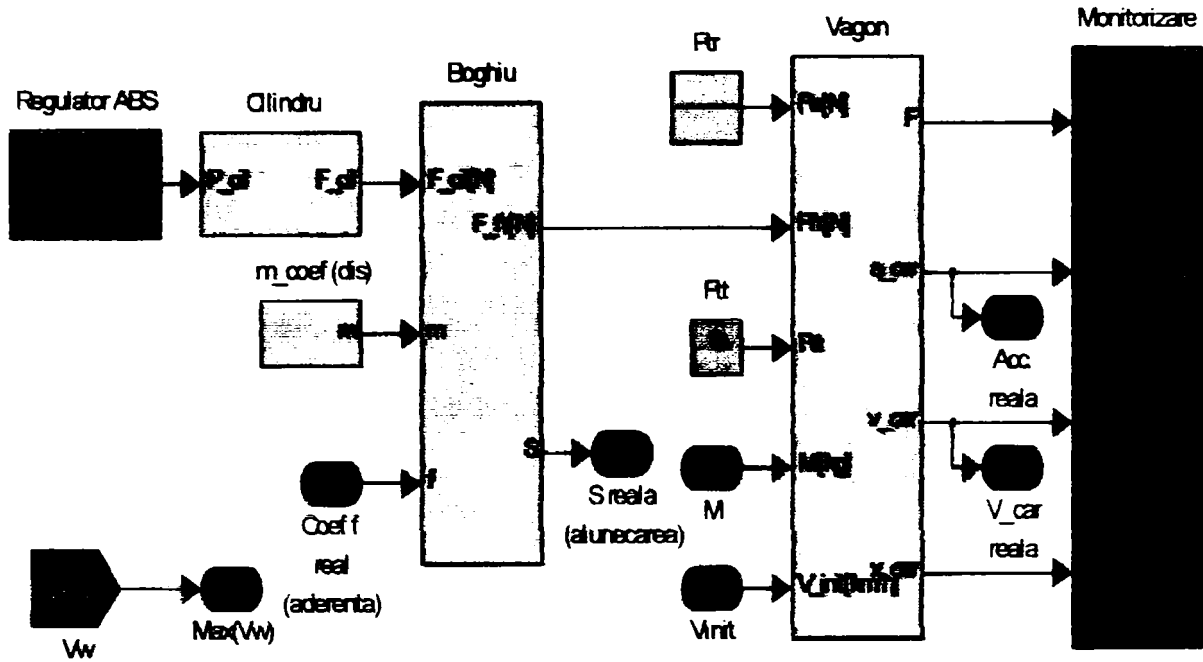


Figura 4.10a. Blocul *Vagonul real*

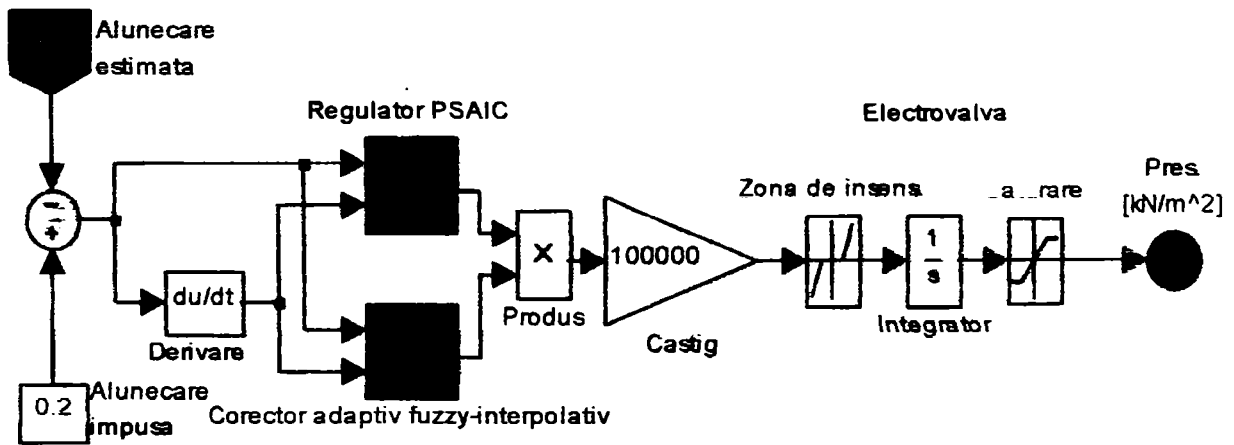


Figura 4.10b. Blocul *Regulator ABS* (de tip FSAIC), incluzând și electrovalva

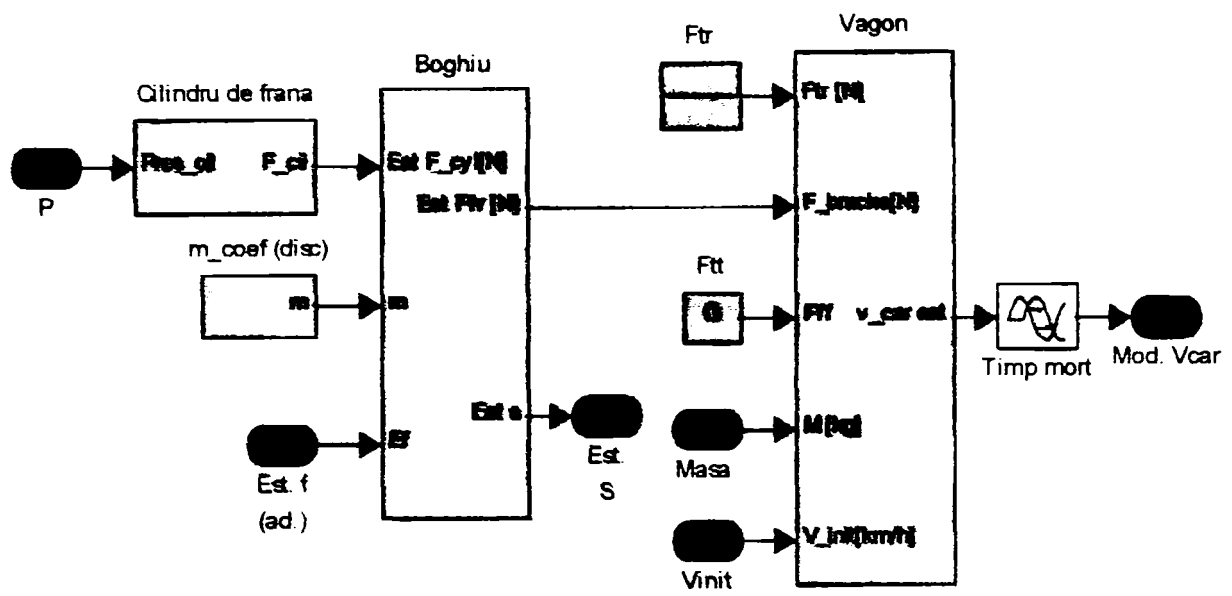


Fig. 4.10c. Blocul *Model 1* (pentru estimarea alunecării s)

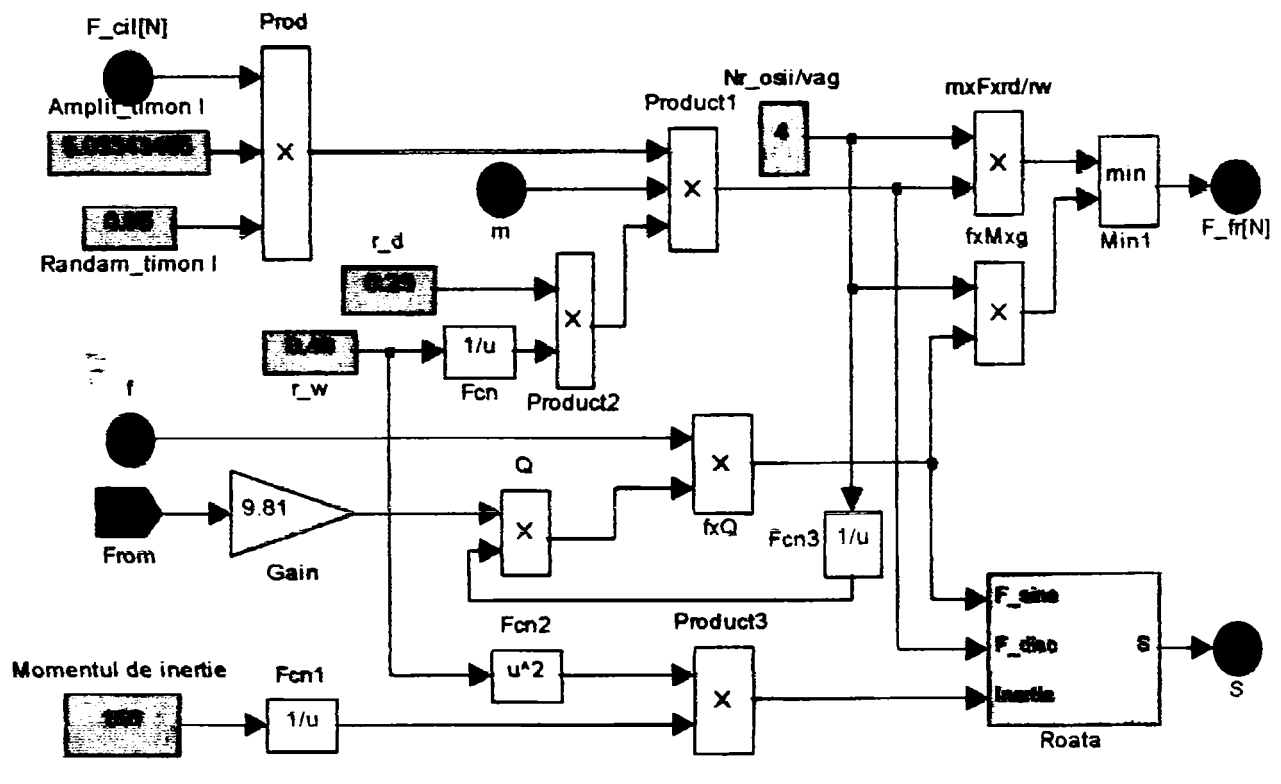


Fig. 4.10d. Blocul *Boghiu*

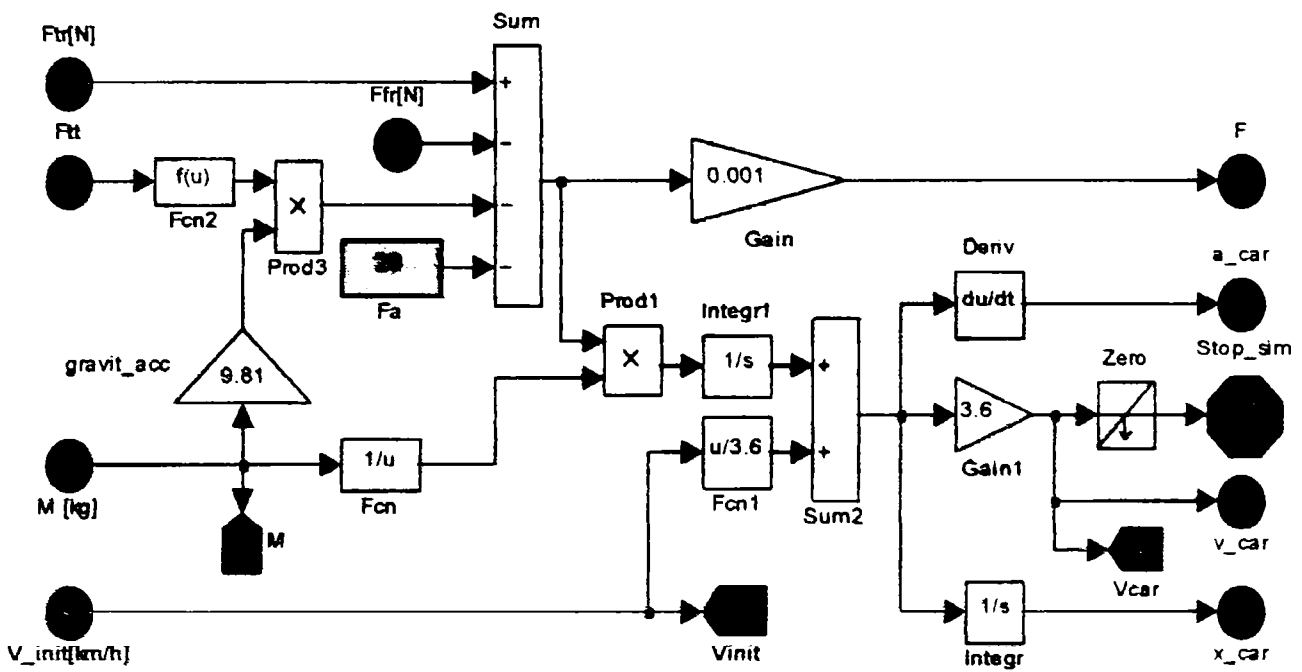


Figura 4.10e. Blocul *Vagon*

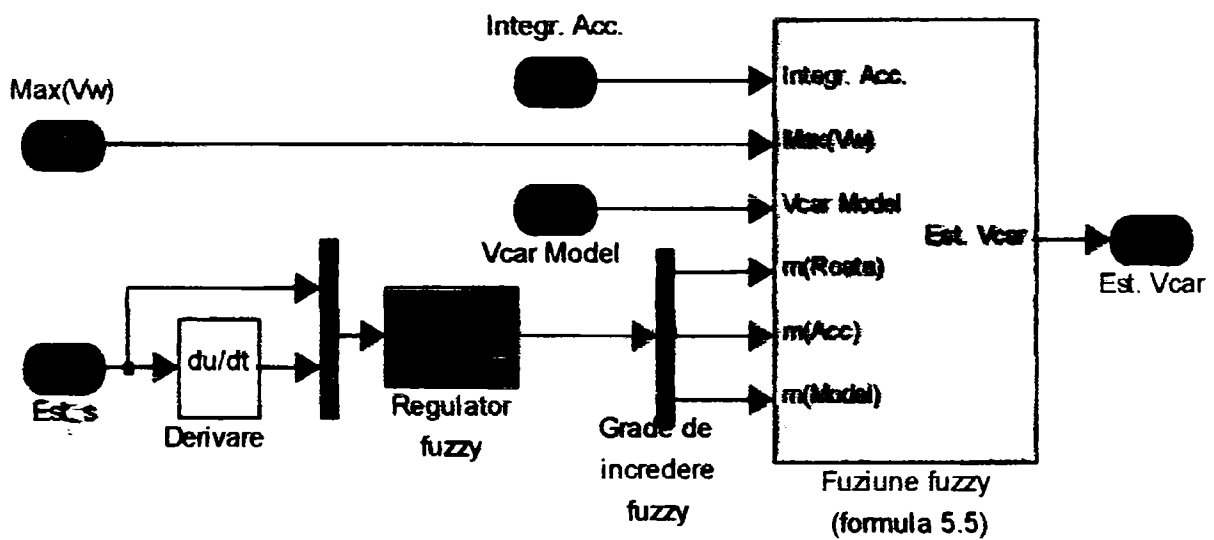


Figura 4.10f. Blocul *Fuziune fuzzy*

În continuare sunt detaliate cele 7 module care intervin direct în componența SIVV.

◆ Modulul *Vagon* (fig. 4.10e) realizează ecuația (4.4a). Modulul este prezent în fig. 4.10a în variantele *Vagon real*, *Model I* și *Model II*. Ultimele două diferă de prima în principal de prin lipsa modulului *Regulator* (fig. 4.10c).

Intrări: forța de frânare F_{fr} , forța de tracțiune F_{tr} , masa M și viteza inițială v_{init} . În această lucrare influența înclinării traseului j și a rezistenței la înaintare F_a nu sunt luate în considerare.

Ieșiri: forța totală $F = F_{tr} - F_{fr}$, accelerația a_{car} , viteza v_{car} , poziția x_{car} .

◆ Modulul *Regulator ABS* conține regulatorul de presiune care comandă electrovalva cilindrului de frână. Acest regulator, de tip FSAIC a fost introdus în [Băla01a]. Implementarea sa în SIMULINK este redată în fig. 4.10b. Modulul *Regulator ABS* este inclus în modulul *Vagon Real* din fig. 4.10a.

Intrări: accelerația a_{car} , viteza v_{car} , poziția x , alunecarea estimată \hat{s} , etc., în funcție de legea de reglare aleasă. În varianta FSAIC prezentată în fig. 4.10b, adoptată pentru simulările din această lucrare, intrarea utilizată este alunecarea estimată \hat{s} (explicată în fig. 4.11).

Ieșire: presiunea de aer P .

◆ Modulul *Cilindru de frână* conține ecuația de funcționare a cilindrului de frână (4.4e). Parametrul τ reprezintă timpul de umplere al cilindrului.

Intrare: presiunea de aer P .

Ieșire: forța dezvoltată de cilindru F_{cil} .

◆ Modulul *Boghiu* conține ecuația de funcționare a timoneriei și a frânei disc, prin care forța de frânare realizată de cilindru este transmisă la disc (4.4d), cu următorii parametri: amplificarea λ și randamentul timoneriei de frână η , obținându-se forța de frânare pe disc F_{dis} . În continuare cu (4.4.c) se calculează forța totală de frânare F_{fr} . Alți parametri prezenți în acest modul sunt raza roții r_w și raza de frânare r_d . Implementarea sa în SIMULINK este redată în fig. 4.10d.

Intrări: forța realizată de cilindrul de frână F_{cil} , coeficienții de frecare dintre garniturile de frecare și disc μ respectiv dintre roată și șină f .

Ieșire: forța totală de frânare F_{fr} a vagonului.

◆ Modulul *Roată* este inclus în modulul *Boghiu* și conține ecuația de mișcare a roții (4.2).

Intrări: momentul de inerție al roții J , F_{dis} , r_w și r_d .

Ieșire: alunecarea roții s .

◆ Modulul *Disc-garnitură* modelează frecarea dintre componentele frânei (apare sub denumirea m_coeff (disc) în fig. 4.10 a și c).

Intrare: viteza vagonului v_{car} .

Ieșire: coeficientul de frecare disc-garnitură μ .

◆ Modulul *Roată-șină* (fig. 4.8) modelează aderența roată-șină.

Intrare: alunecarea s .

Ieșire: coeficientul de aderență f .

Modelul este validat chiar prin modul său de ajustare, și anume pornind de la rezultatele unor teste standard: determinarea distanței de frânare pentru diferite viteze inițiale, cu presiune constantă în cilindrul de frână [Băla01a]. **În lucrare se utilizează o variantă Simulink (fig. 4.9) dar modelul poate fi realizat în orice alt mediu software.**

4.1.3.4. Estimatorul coeficientului de aderență

Așa cum s-a prezentat, performanțele frânelor ABS sunt afectate de incertitudinea care caracterizează evoluția în timp a aderenței. Măsurări precise ale coeficientului de frecare roată-șină pot fi făcute static, off-line, dar această abordare este total neproductivă, deoarece aderența prezintă notabile variații aleatorii. În [Hami98] se prezintă și o metodă de măsurare a coeficientului de aderență aplicabilă în studiul experimental al vagoanelor: metoda M-ABS. Metoda presupune instalarea unor timbre tensometrice direct pe osii. În condiții de exploatare a vagonului fiabilitatea echipamentului de frânare trebuie să fie cât mai ridicată, ceea ce exclude utilizarea tensometriei rezistive și în plus așa cum s-a arătat și în §4.1.1.1, aderența este puternic influențată de dinamica vagonului [Dobr95] [Roth98].

Modelul de la paragraful anterior prezintă avantajul de a putea fi orientat înspre diferite obiective. În cele ce urmează el este utilizat în scopul evaluării on-line a coeficientului de aderență roată-șină \hat{f} , conform schemei bloc ilustrate în fig. 4.11.

Un model intern al vagonului și al instalației sale de frânare, identic cu cel utilizat în §4.1.3.1, este inclus într-o buclă de urmărire a accelerației vagonului a_{car} (măsurată de accelerometru). Mărimea de reacție este accelerația estimată de model \hat{a}_{car} , care este comparată cu a_{car} . Semnalele de intrare în model sunt presiunea din cilindrul de frână P , mărime care determină în proces valoarea decelerației prin intermediul forței de frânare și coeficientul de aderență estimat \hat{f} , furnizat de către modulul de estimare a coeficientului de aderență. Prin acțiunea modulului de estimare a coeficientului de aderență \hat{f} va fi modificată astfel încât să minimizeze eroarea de urmărire a accelerației $\varepsilon = a_{car} - \hat{a}_{car}$ [Băla02b].

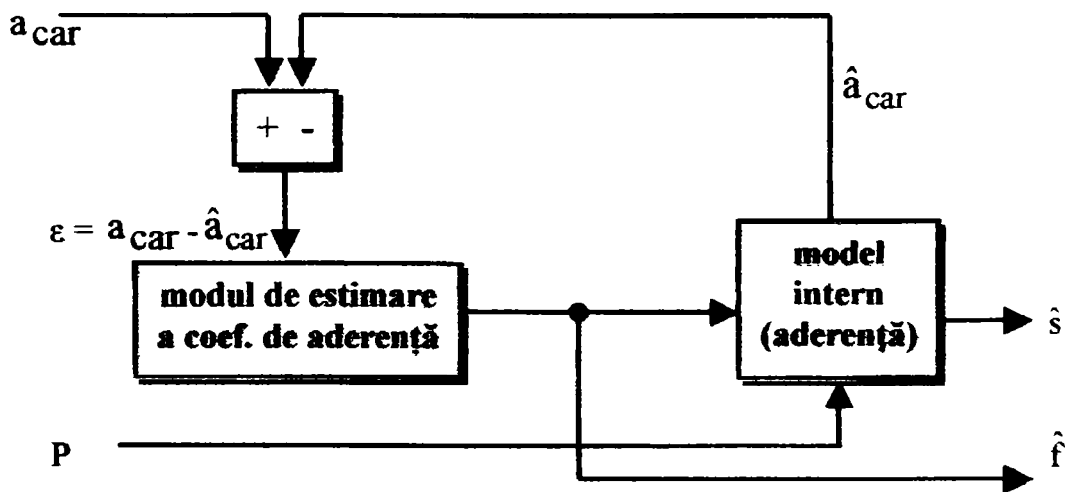


Fig. 4.11. Estimatorul coeficientului de aderență

Estimatorul utilizează ca mărime de intrare presiunea din cilindrul de frână P deoarece pentru măsurarea forței de frânare nu există traductor. Folosirea mărimii P ca mărime de intrare este facilitată de disponibilitatea măsurii acestei mărimi folosite și la comanda regulatorului. Unul dintre avantajele utilizării modelului intern este posibilitatea estimării forței de frânare prin formula (4.4c).

4.1.3.5. Fuziunea fuzzy

Blocul din platforma de simulare care realizează fuziunea fuzzy a celor trei evaluări diferite ale vitezei vagonului de care dispunem operează cu ajutorul a trei grade de încredere: μ_w pentru maximul semnalelor provenite de la cei patru senzori ai roților, μ_a pentru semnalul integrat al accelerometrului și μ_{model} pentru evaluarea efectuată de către modelul funcțional. Blocul Simulink *Fuziune fuzzy* este prezentat în fig. 4.10f.

În cele ce urmează algoritmul de fuziune fuzzy va fi asimilat cu un controler MIMO fuzzy-interpolativ, înțelegând prin aceasta o structură fuzzyficare/inferență/defuzzyficare [Băla01a]. Acest controler poate fi implementat cu un tabel de căutare 3D cu interpolare liniară. La proiectarea bazei de reguli se va apela însă la latura lingvistică a controlerului, fundamentarea regulilor fiind euristică [Delg98], [Cheo00].

Esențială în proiectarea bazei de reguli este definirea informației apriorice referitoare la precizia celor trei surse de informații referitoare la viteza vagonului. Dispunând de evaluarea alunecării s , o vom utiliza ca principală mărime de stare în acest proces. Derivata ei este notată cs . **Nucleul bazei de reguli este constituit din următoarele trei reguli:**

R1: DACĂ s este zero ATUNCI μ_w este mare & μ_a este zero & μ_{model} este zero

R2: DACĂ s nu este zero & cs este mare ATUNCI μ_w este zero & μ_a este mare & μ_{model} este mic

R3: DACĂ s este mic & cs este mic ATUNCI μ_w este zero & μ_a este zero & μ_{model} este mare

≡ Efectele celor trei reguli sunt evidente, ele materializând modul de funcționare descris anterior:

R1: selectează în lipsa alunecării senzorii roților (agregați prin operația *max*);

R2: accentuează ponderea accelerometrului când alunecarea este prezentă și are variații mari;

R3: accentuează ponderea modelului atunci când alunecarea s-a stabilizat și indicațiile accelerometrului încep să fie tot mai afectate de offset, iar accelerația vagonului nu mai prezintă variații importante

În continuare este prezentat un exemplu de implementare a regulilor de mai sus, pentru cazul calculului lui μ_{ACC} prin intermediul unui tabel de căutare (*look-up table*). Intrările în tabel sunt alunecarea s pe rânduri și accelerația a pe coloane. Tabelul este normat, valorile numerice înscrise în el fiind cuprinse între 0 (grad de încredere nul) și 1 (grad de încredere maxim).

$$\left\{ \begin{array}{l} \text{row}(s): [0 \ 0.1 \ 0.2] \\ \text{column}(a): [0 \ 0.005 \ 0.1] \\ \text{table}(\mu_{ACC}): [0 \ 0 \ 0; 0 \ 0.2 \ 1; 0 \ 0.2 \ 1] \end{array} \right. \quad (4.6)$$

Caracteristica de transfer rezultată este prezentată în fig. 4.12.

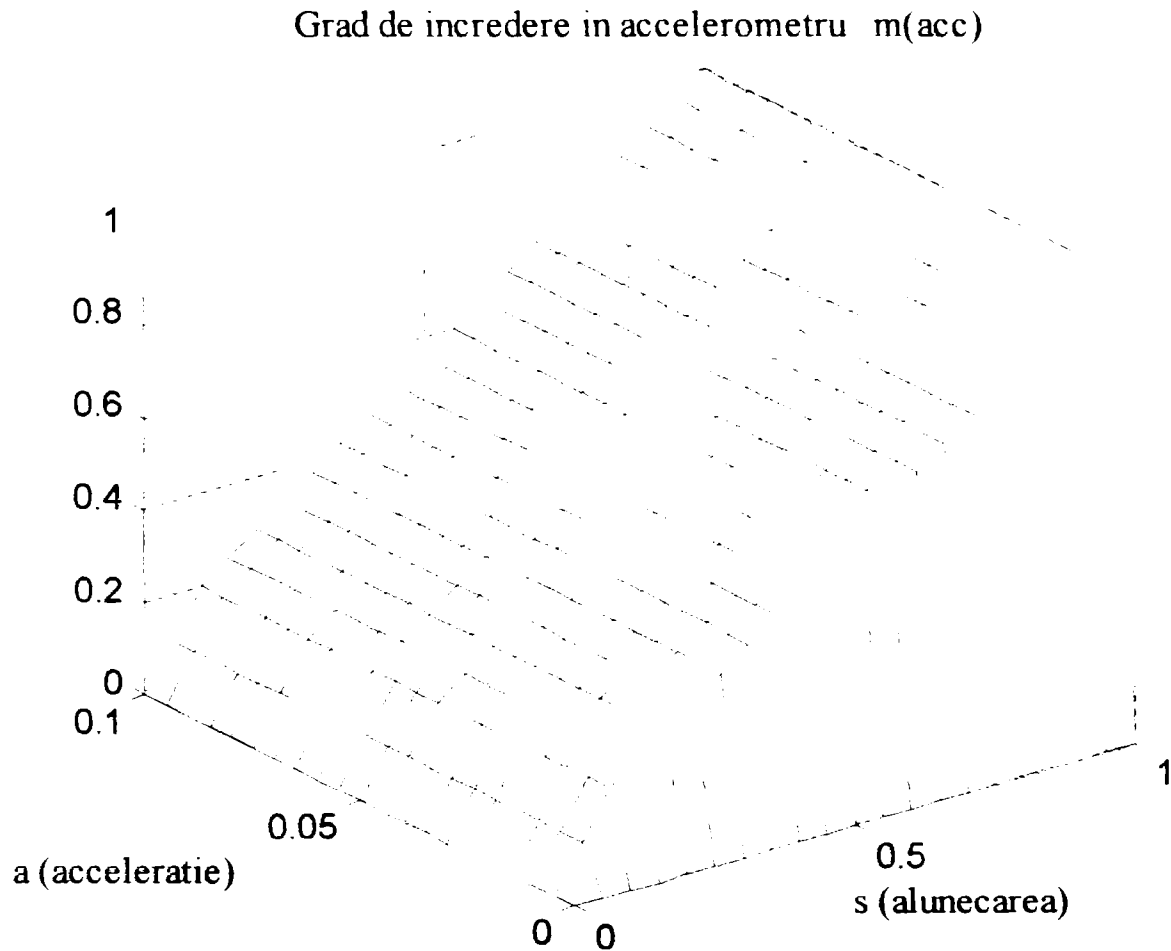


Fig. 4.12. Reprezentarea grafică a caracteristicii de transfer $\mu_{acc}(s, a)$

Simulările efectuate în condițiile de mai sus evidențiază o prestație foarte precisă a SIVV, diferențele dintre valoarea estimată a vitezei vagonului și cea efectivă fiind ne semnificative, așa cum se observă în fig. 4.13 și 4.14, în care viteza estimată se confundă practic cu cea efectivă (graficul de culoare neagră).

În acest caz nu se justifică complicarea fuziunii fuzzy prin înlocuirea variantei liniare cu forme mai complicate ale funcțiilor de apartenență.

4.1.3.6. Descrierea funcționării SIVV

Având în vedere că fiecare osie este frânată în mod independent, este necesar ca fiecare regulator ABS să dispună de propriul său SIVV. **Conform figurilor de principiu 4.5 și 4.6 funcționarea senzorului SIVV este următoarea**

▪ Blocul de fuziune fuzzy execută permanent fuzionarea măsurătorii $\max(v_{wi})$, a semnalului integrat al accelerometrului \hat{v}_{car_a} și a estimării produse de modelul intern $\hat{v}_{car_{model}}$. Controlerul fuzzy detaliat în §4.1.3.5 calculează gradele de încredere ale fiecărui termen, respectiv μ_w , μ_a și μ_{model} . Pentru fuzionare pot fi utilizate mai multe variante. Cea mai simplă variantă de fuziune este dată de suma ponderată a celor trei semnale:

$$\hat{v}_{car}(t) = \frac{\mu_w(t) \cdot \max(v_{wi})(t) + \mu_a(t) \cdot \hat{v}_{car_a}(t) + \mu_{model}(t) \cdot \hat{v}_{car_{model}}(t)}{\mu_w(t) + \mu_a(t) + \mu_{model}(t)} \quad (4.5)$$

Pentru funcțiile de apartenență ale gradelor de încredere μ_w , μ_a și μ_{model} s-au considerat variații triunghiulare normate. Este posibilă și utilizarea altor tipuri de funcții de apartenență.

▪ Cei patru senzori de viteză ai roților indică viteza reală a vagonului v_{car} numai atunci când indicațiile lor au valori foarte apropiate și atunci când accelerația roților este foarte apropiată de accelerația măsurată de accelerometru. În acest caz

$$\mu_w = 1, \mu_a = 0 \text{ și } \mu_{model} = 0 \quad (4.6a)$$

▪ Când unul sau mai mulți senzori de roată își modifică semnificativ indicația față de ceilalți și/sau accelerația roților diferă semnificativ de indicația accelerometrului, se sesizează inițierea regimului de alunecare a roților; începând din acest moment ponderea alocată roților se anulează, singurele elemente credibile rămânând accelerometrul și modelul:

$$\mu_w = 0, \mu_a \neq 0 \text{ și } \mu_{model} \neq 0 \quad (4.6b)$$

▪ Modelul intern este adaptat on-line față de variațiile coeficientului de aderență real al sistemului roată-șină cu ajutorul coeficientului aderenței estimate prin estimatorul cu model intern \hat{f} . Adaptarea constă din aplicarea lui \hat{f} la intrarea modelului intern, care poate astfel estima \hat{v}_{car} ținând cont de aderența reală.

▪ Controlerul care conduce blocul de fuziune fuzzy urmărește și diferențele dintre estimările implicate în fuziune, între care nu trebuie să existe diferențe majore; în cazul constatării unor diferențe anormale între estimări, ponderea elementelor suspectate de a fi defecte este anulată.

▪ Atunci când accelerația măsurată de accelerometru este mare, ponderea ei în fuziune va fi de asemenea mare.

▪ Atunci când accelerația măsurată de accelerometru este mică dar roțile sunt totuși în regim de alunecare, ponderea maximă va fi alocată modelului.

4.1.3.7. Autodiagnosticarea prin intermediul fuzionării fuzzy

Structura relativ complexă a sensorului inteligent SIVV are printre avantajele faptul că oferă un mare volum de informații referitoare la procesul măsurat (instalația de frână a vagonului), informații care nu ar fi fost accesibile fără centralizarea și prelucrarea lor asistată de modelul intern.

Apare astfel posibilitatea efectuării unei diagnosticări on-line a fiecăruia dintre senzorii primari (senzorii roților și accelerometrului), a testării modelului intern și posibilitatea autoadaptării structurale, cu scopul înlăturării sau reducerii impactului defectării componentelor individuale.

În acest sens se poate introduce în structura controlerului fuziunii fuzzy un set de reguli suplimentare, care au ca scop analizarea posibilelor diferențe dintre indicațiile senzorilor primari v_{w_j} și $\max(v_{w_j})$, \hat{v}_{car_a} și \hat{v}_{car_model} și intervenția asupra μ_w , μ_a și μ_{model} când apar neconcordanțe.

Două astfel de reguli, aplicabile fiecărui senzor în parte sunt:

$$\left\{ \begin{array}{l} \text{DACĂ } v_{w_j} > \hat{v}_{car_model} \text{ ATUNCI } \mu_{model} \text{ este } zero \text{ (roțile în regim de alunecare} \\ \text{trebuie să aibă viteza mai mică decât a vagonului, deci și decât a estimărilor)} \\ \text{DACĂ } v_{w_j} > \hat{v}_{car_a} \text{ ATUNCI } \mu_a \text{ este } zero \text{ (aceeași justificare)} \end{array} \right. \quad (4.7)$$

Identificarea momentului în care se instalează alunecarea la una dintre roți (roata j) se poate obține prin compararea semnalului sensorului roții respective cu $\max(v_{w_j})$ și \hat{v}_{car_model} :

$$\text{DACĂ } v_{w_j} < \max(v_{w_j}) \text{ ȘI } v_{w_j} < \hat{v}_{car_model} \text{ ATUNCI } s \neq 0 \quad (4.8)$$

4.1.3.8. Autoadaptarea prin intermediul fuzionării fuzzy

Deoarece SIVV oferă o estimare a coeficientului de aderență al sistemului roată-șină, devine posibilă oferirea acestei informații regulatorului frânei ABS, în vederea adaptării lui la starea traseului. Întrucât aderența prezintă variații aleatorii rapide, este de dorit ca datele referitoare la aderență să fie filtrate, realizându-se clasificarea calității aderenței în câteva categorii, semnificative pentru adaptare. În [Băla99b] s-a propus o metodă de identificare a calității aderenței pornind de la presiunea P din cilindrul de frână din momentul în care apare alunecarea. Cu cât P este mai mare coeficientul aderenței este mai mare. În lucrarea pentru caracterizarea aderenței unui drum au fost folosite următoarele etichete lingvistice: drum *uscat*, drum *ud* și *zăpadă*. În cazul vagonului de călători se pot utiliza termeni lingvistici asemănători.

Avantajul unui astfel de demers este legat de adaptarea regulatorului frânei ABS [Băla97] care poate fi realizată în mod stabil pe durate mari de timp, în funcție de categoria de aderență identificată, filtrând astfel variațiile aleatorii ale aderenței reale.

4.1.4. Rezultate obținute prin simulare

Următoarele simulări ilustrează comportarea unei frâne ABS care utilizează SIVV. Pentru o cât mai bună veridicitate a rezultatelor se includ o serie de particularități ale unei implementări reale:

- Accelerometrul este afectat de zgomotul alb; blocul specific SIMULINK (fig. 4.9) are următorii parametri: puterea zgomotului este de 0,0005W iar timpul de eșantionare de 0,25s.
- Accelerometrul este afectat de un semnal de offset echivalent cu $0,025\text{m/s}^2$ (fig. 4.9)
- Întârzierile care apar la prelucrarea datelor referitoare la accelerometru sunt modelate printr-un element de întârziere de ordin I cu constanta de timp 0,01s (fig. 4.9).
- Întârzierile produse de modelele funcționale *Model 1* (fig. 4.9.c) și *Model 2* sunt modelate prin timpi morți cu valoarea de 0,025s.
- Regulatorul de frânare ABS – FSAIC de tip fuzzy-interpolativ [Băla01a], [Băla02a] este ușor dezacordat prin scoaterea din funcțiune a corectorului adaptiv fuzzy-interpolativ. Acest mod de funcționare se evidențiază în fig. 4.9.b prin aceea că tabelul de căutare al corectorului conține doar valoarea 1. Dezacordarea determină un anumit nivel de oscilații ale alunecării, comparabil cu cele întâlnite în cazul frânelor ABS uzuale. În acest fel poate fi testată convingător funcționarea estimatorului coeficientului de aderență, având în vedere că și variațiile alunecării produc variații ale aderenței. Acest regulator se distinge prin aceea că acționează direct asupra alunecării roții. Reacția în alunecare se obține de asemenea cu ajutorul modelului funcțional, care poate furniza la ieșire și alunecarea, care este utilizată ca mărime de stare (ca în fig. 4.11). În același timp caracteristica de comandă a acestui regulator este extrem de netedă, fără comutări bruște ale regulilor de conducere, garantând un răspuns în viteză al roții de asemenea foarte neted, după cum se poate observa în fig. 4.13.

În industria constructoare de vagoane frânele se testează conform anumitor metode specifice, standardizate. În cazul Europei, organizația de standardizare se numește U.I.C. (franc. *Union Internationale des Chemins de Fer*) la care și România este parte activă. Două dintre testele uzuale recomandate de U.I.C. sunt măsurarea distanței de frânare rezultată în urma unei frânări totale și frânarea pe porțiuni de șină udate cu soluție de detergent. Vagonul este lansat cu ajutorul unei locomotive sau de pe un plan înclinat (cocoașă), de la viteza inițială dorită, în funcție de tipul vagonului. Având în vedere construcția frânei, la deconectarea conductei de aer a vagonului de la cea a trenului se produce automat o frânare totală, de avarie, cu forța maximă de frânare.

Următoarele simulări reproduc o frânare pe o porțiune de șină udată cu soluție de detergent. După 20s de frânare se ajunge pe șină uscată, care durează până la oprirea vagonului. Coeficientul de frecare roată-șină al porțiunii udate cu soluție de detergent este de 50% din cel corespunzător șinei uscate, conform fig. 4.2.

Prima simulare prezentată ilustrează funcționarea estimatorului aderenței.




Fig. 4.13. Funcționarea estimatorului aderenței, în cazul unei frânări de la 200km/h

Pe lângă comportarea estimatorului cu model intern al coeficientului de aderență, în fig. 4.13 se prezintă și evoluția vitezelor unei roți în cursul frânării și a vitezei vagonului. Pe prima perioadă a frânării (timp de 20s) coeficientul de aderență fiind mic, apare blocarea roților. Apoi coeficientul de frecare se dublează, reacția șinei depășește forța de frânare și alunecarea roții dispăre. În această perioadă se observă creșterea coeficientului de aderență datorată scăderii vitezei vagonului.

Cel mai dificil regim pentru estimatorul coeficientului de aderență se dovedește a fi cel în care alunecarea roții oscilează, aproximativ în primele 10s ale simulării, dar după amortizarea acestor oscilații, precizia estimării crește.

A doua simulare prezintă funcționarea unui sistem de frânare ABS dotat cu SIVV, cu scopul de a compara mărimea reală v_{car} cu estimările sale.

După cum se observă însă în fig. 4.14, pentru o frânare de la 250km/h, erorile de estimare ale aderenței nu au o influență puternică asupra comportării SIVV. Diferențele dintre \hat{v}_{car} și v_{car} sunt abia vizibile la scara diagramei din fig. 4.14. De aceea ele sunt detaliate în fig. 4.15. Și în acest caz coeficientul de aderență se dublează după $t=20s$, dar alunecarea dispăre doar la $t=35s$ deoarece frânarea se face de la o viteză inițială superioară celei din simularea anterioară.




Fig. 4.14. Evoluția vitezelor implicate în fuzionarea fuzzy

Se remarcă cumulara în timp a offset-ului, care afectează viteza estimată prin integrarea semnalului accelerometrului.




Fig. 4.15. Detaliu al figurii 4.14

4.2 Estimarea on-line a uzurii frânei disc

După cum s-a văzut în cele de mai sus, prin tehnica modelului intern, SIVV concentrează suma cunoștințelor referitoare la procesul măsurat, respectiv la echipamentul de frânare al vagonului. Această bază de cunoștințe oferă posibilitatea estimării unor parametri ai proceselor sau unor indici de performanță, care sunt greu sau imposibil de măsurat on-line.

Un exemplu în acest sens îl reprezintă estimarea on-line a uzurii discurilor și garniturilor de fricțiune din compunerea frânelor cu disc ale vagoanelor. Uzura frânei se măsoară în mod curent manual, în cadrul programelor de întreținere a vagoanelor. Măsurarea ei în timpul exploatării este imposibilă din cauza particularităților constructive și a poziției. Uzura este însă puternic dependentă de regimurile de frânare, mai ales de vitezele de la care se frânează și de forța de frânare, factori aleatorii care nu permit optimizarea operațiilor de întreținere și în același timp reducerea riscurilor de defecțiune a frânelor din cauza uzurilor accentuate.

În [Băla02d] și [Băla02f] este prezentată o metodă originală de evaluare a uzurii frânei cu disc din vagoane, bazată pe utilizarea unui SIVV. Prin această metodă SIVV este adaptat pentru estimarea on-line a intensității de uzare a frânei disc. Modulul suplimentar de estimare a uzurii, are trei intrări, oferite de către SIVV: viteza relativă dintre disc și garnitura de fricțiune, forța de frânare și distanța parcursă în regim de frânare.

Cunoștințele referitoare la uzura frânelor sunt obținute experimental, în condiții de laborator, fiind reprezentate prin *curbe de uzură* de tipul celor prezentate în fig. 4.16.

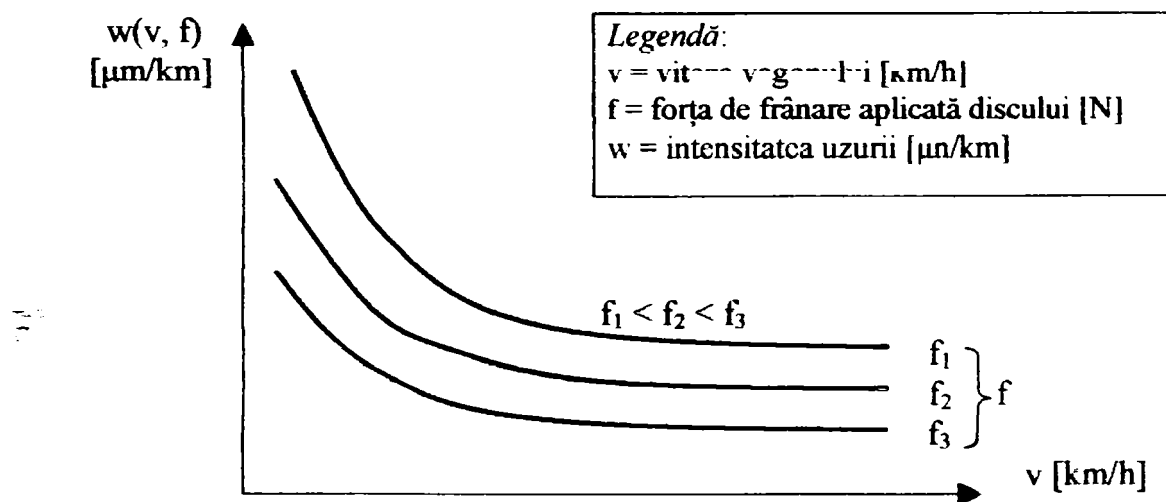


Fig. 4.16. Dependența intensității uzurii de viteza și de forța de frânare

Problema pe care o rezolvă introducerea SIVV în compunerea echipamentului de comandă al frânei este calcularea permanentă a uzurii prin integrarea numerică a intensității de uzare $w(v, f)$, pentru condițiile concrete, variabile în timp, în care se produc frânările reale.

Uzura u_i produsă în decursul unei frânări i desfășurată pe distanța de frânare D_i poate fi estimată prin integrala intensității de uzare w cu poziția curentă x redusă la diametrul de frânare a discului:

$$\hat{u}_i = \int_0^{D_i} w(v(x), f(x)) \cdot dx \quad (4.9)$$

Pentru a se ajunge la o integrare în timp, conform metodei propusă în [Băla02b], se face o schimbare de variabilă, de la poziția x la timpul t :

$$\hat{u}_i = \int_0^{T_i} w(v(t), f(t)) \cdot v(t) \cdot dt \quad (4.10)$$

unde T_i este durata frânării i .

Uzura totală estimată a discului, după N acțiuni de frânare, este

$$\hat{u} = \sum_{i=1}^N \hat{u}_i \quad (4.11)$$

Exemplificarea metodei se poate obține prin modul SIMULINK prezentat în fig. 4.17, care este încadrat în componenta SIVV, prin conectarea intrărilor f , v și x la ieșirile corespunzătoare ale SIVV. Încadrat în echipamentul de frânare al vagonului, SIVV primește la intrare parametri reali ai frânării, oferind la ieșire estimarea on-line a uzurii. Structura astfel obținută permite estimarea uzurii chiar și în timpul regimului de alunecare care apare la frânări puternice, ceea ce îmbunătățește precizia estimării.

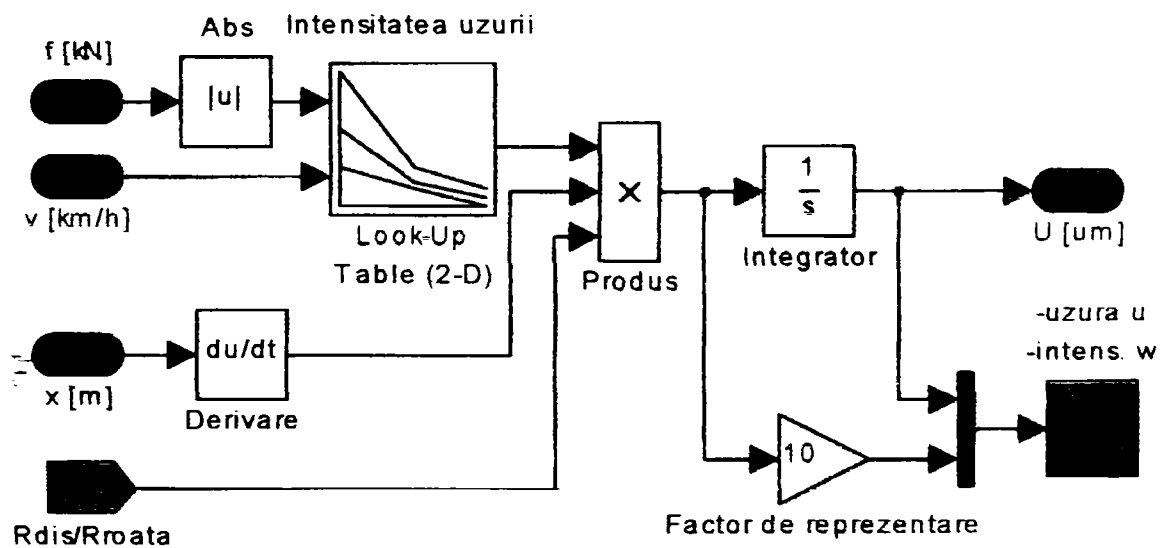


Fig. 4.17. Modul pentru estimarea uzurii discului de frână a unei roți

Curbele din fig. 4.16 sunt reprezentate printr-un tabel de căutare bi-dimensional cu interpolare liniară (*look-up-table 2-D*), având ca intrări v și f și ca ieșire w .

Rezultatele obținute în urma simulării unei frânări de la 200 de km/h sunt prezentate în fig. 4.18. Se poate remarca variația în timp a intensității de uzare, care nu ar putea fi calculată și integrată în timp altfel decât cu ajutorul modelului intern.




Fig. 4.18. Estimarea uzurii frânei disc cu ajutorul SIVV

4.3. Avantajele SIVV

Avantajele SIVV sunt următoarele:

- realizarea unei platforme flexibile de studiu al frânării vagoanelor, care pe lângă simularea procesului și a diferiților algoritmi de reglare oferă posibilitatea studierii unor parametri greu măsurabili: aderența roată-șină, coeficientul nelinier de frecare disc-garnitură de frecare, alunecarea roților, etc.
- creșterea preciziei estimării referitoare la viteza vagonului și prin urmare și a calității reglării ABS, prin selectarea celei mai bune estimări într-un regim de funcționare dat;
- posibilitatea adaptării frânei ABS la variațiile aderenței roată-șină;
- creșterea redundanței estimării vitezei prin apelarea la un accelerometru și la un model intern, ceea ce produce și creșterea fiabilității;
- creșterea fiabilității frânei prin diagnosticare on-line și prin autoadaptare;

- SIVV reprezintă un pas înainte în realizarea unui regulator ABS funcționând cu reacție în alunecare, cu o caracteristică netedă de comandă, care are potențialul de a depăși performanțele actualelor regulatoare.

4.4. Concluziile capitolului 4

În acest capitol se propune ca o aplicație a tehnicii senzorilor inteligenți cu fuziune și model intern, o soluție originală de senzor inteligent al vitezei vagonului SIVV. Rolul său principal este acela de a oferi regulatoarelor frânelor ABS cu care sunt dotate fiecare dintre osiile unui vagon, o informație cât mai precisă referitoare la viteza momentană a vagonului, inclusiv atunci când toate roțile sunt în regim de alunecare iar senzorii de viteză ai osiilor nu mai indică viteza vagonului ci viteza momentană a fiecărei roți. Fiecare regulator de frânare ABS trebuie să dispună de propriul său SIVV.

SIVV funcționează prin fuzionarea fuzzy a datelor numerice provenite de la trei surse diferite de informații referitoare la viteza vagonului: senzorii de viteză ai roților agregați prin operația *max*, un accelerometru a cărui indicație este integrată și un model intern al sistemului de frânare al vagonului, care poate fi implementat prin intermediul unui micro-controler sau al unui DSP. Pe lângă modelul intern necesar pentru estimarea vitezei, SIVV mai include un al doilea model intern, care are rolul estimării on-line a aderenței roat-șină, mărime de influență esențială pentru adaptarea regulatorului frânei ABS.

SIVV are și posibilitatea comparării între măsurile oferite de senzorii primari și estimarea modelului, cu scopul efectuării unei diagnoze on-line. Pe baza diagnozei, fuzionarea fuzzy poate fi adaptată astfel încât efectele defectării oricărui dintre senzorii primari să fie cât mai mic.

Determinarea parametrilor greu măsurabili cu ajutorul SIVV este ilustrată printr-o metodă originală de estimare on-line a uzurii elementelor frânelor cu disc de pe vagoane. SIVV este conectat la parametrii reali de frânare a vagonului: presiunea din cilindrul de frână, masa frânată, etc. Uzura frânei se obține integrând în timp real ecuația neliniară care leagă intensitatea de uzură de viteza vagonului și de forța de frânare aplicată discului. Ea reflectă influențele majore ale regimului de exploatare a vagoanelor și a stilului personal în care este condus trenul.

Dependențele neliniare n-dimensionale de tipul celei a intensității de uzură pot fi implementate prin tabele de căutare (look-up tables) multidimensionale.

Validarea considerentelor teoretice care stau la baza SIVV și a evaluării on-line a uzurii frânei disc a fost realizată prin simulări originale, dezvoltate în MATLAB-SIMULINK. Rezultatele obținute au fost prezentate la două sesiuni internaționale (Annecy - Franța și Budapesta – Ungaria).

Prin aplicarea SIVV în construcția vagoanelor de cale ferată se poate obține creșterea performanțelor tehnico-economice ale vagoanelor, precum și creșterea siguranței circulației.

Pentru definitivarea acestei soluții se impune în continuare trecerea la realizarea practică a unui prototip și efectuarea de studii experimentale.

Senzor inteligent cu model intern al temperaturii din cuptoare

Se propune aplicarea senzorului cu fuziunea datelor și model intern la măsurarea temperaturii unui cuptor pentru tratamente termice. Se studiază o structură originală de senzor inteligent de temperatură pentru cuptoare SITC, care utilizează trei senzori primari: o rezistență de platină, un termocuplu și un pirometru de radiație precum și un model al comportării termice a cuptorului. Prin simulări se demonstrează creșterea preciziei estimării temperaturii, datorată fuziunii datelor oferite de senzorii primari. Fuziunea este ilustrată atât într-o variantă originală de mare precizie, aplicabilă atunci când dispunem de senzori etalonați, cât și într-o variantă fuzzy, aplicabilă atunci când precizia senzorilor primari este incertă. Rezultă și o creștere a fiabilității prin creșterea redundanței.

5.1. Aplicarea fuziunii asistată de model intern în cazul măsurării temperaturii în cuptoare

5.1.1. Structura unui senzor inteligent de temperatură pentru cuptoare

Măsurarea temperaturii are o mare importanță în cazul cuptoarelor pentru tratamente termice sau metalurgice. Erorile provocate de inerția termică sau de defectarea senzorilor pot produce importante pierderi având în vedere costurile ridicate ale acestor tehnologii și ale pieselor prelucrate [Șand82],[Albu02].

Pentru evitarea riscurilor menționate se poate apela la fuziunea asistată de model intern, prin care se realizează un senzor original, inteligent, al temperaturii din cuptoare, SITC. Din studiul literaturii de specialitate rezultă că fuziunea senzorilor nu a mai fost aplicată în măsurarea temperaturilor în cuptoare.

☞ SITC include trei senzori primari de temperatură:

- un senzor de temperatură cu rezistență de platină TR;
- un senzor de temperatură cu termocuplu TC;
- un pirometru cu radiație TP;

Pe lângă cei trei senzori primari SITC mai conține și un model intern al comportării termice a cuptorului precum și un bloc de fuziune a datelor. Schema bloc este prezentată în fig. 4.17.

Mărimile care apar în schema bloc sunt: valoarea impusă a puterii de încălzire P , indicația termocuplului θ_{TC} , indicația rezistenței de platină θ_{TR} , indicația pirometrului cu radiație θ_{TP} , temperatura din cuptor estimată de modelul intern θ_{MOD} și estimarea finală produsă de senzorul inteligent θ_{EST} .

Componentele aplicației sunt prezentate în continuare.

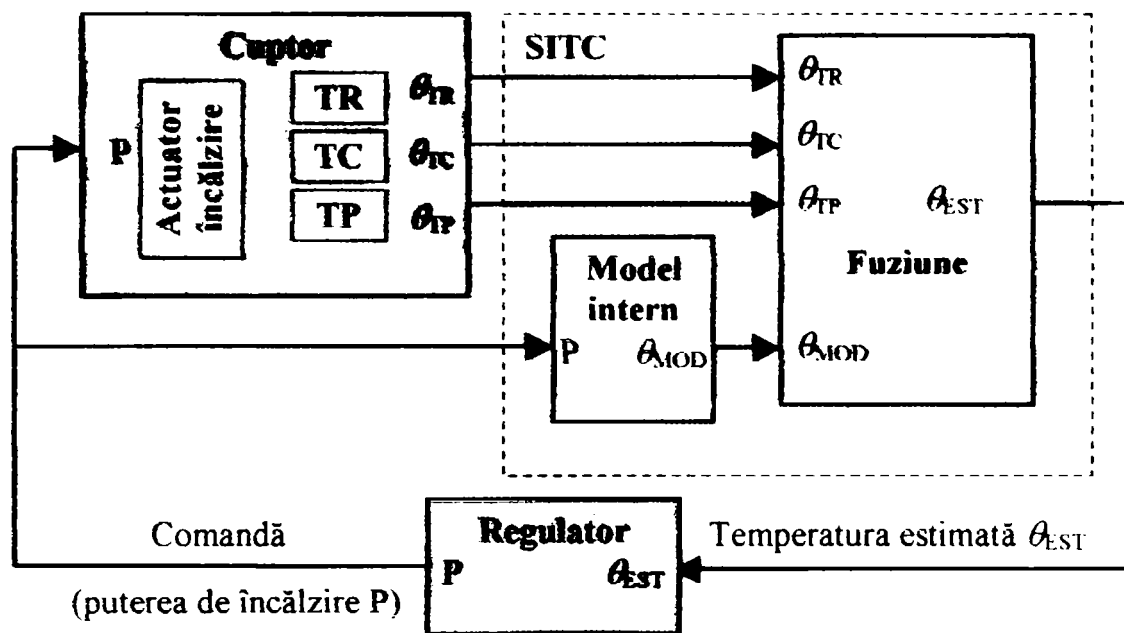


Fig. 5.1. Schema bloc a unui cuptor cu senzor inteligent de temperatură

a) **Cuptorul** include un actuator pentru încălzire și cei trei senzori de temperatură. Comandarea actuatorului încălzirii se face prin valoarea impusă a puterii P . Senzorii primari de temperatură sunt:

- **TR** senzorul de temperatură cu rezistență cu platină reprezintă etalonul pentru interpolarea temperaturilor între punctele fixe $13,81^{\circ}\text{K}$ și $630,74^{\circ}\text{C}$, conform SIPT-68 (Scara Internațională pentru Temperaturi) [Marc77].

- *Avantaje*: precizie foarte bună;
- *Dezavantaje*: sensibilitatea relativ redusă și precizia scad cu creșterea temperaturii, inerție.

- **TC** senzorul de temperatură cu termocuplu (90 Pt – 10 Rh) reprezintă etalonul pentru interpolarea temperaturilor între punctele fixe $630,74^{\circ}\text{C}$ și $1064,43^{\circ}\text{C}$, conform SIPT-68 [Marc77].

- *Avantaje*: stabilitate și reproductibilitate foarte bune, precizie bună;
- *Dezavantaje*: sensibilitate redusă, inerție.

- **TP** senzorul de temperatură cu piometru cu radiație: reprezintă etalonul pentru interpolarea temperaturilor mai mari de $1064,43^{\circ}\text{C}$, conform SIPT-68 [Marc77].

- *Avantaje*: măsurare fără contact, inerție scăzută;
- *Dezavantaje*: precizie scăzută.

După cum se observă, cei trei senzori primari de temperatură au performanțe complementare, gradele lor de încredere fiind maxime pe domenii de temperatură diferite. Inerția senzorilor cu contact TC și TR este cauzată în principal de învelișurile protectoare la care trebuie să se apeleze pentru a evita deteriorarea elementelor active ale senzorilor.

b) **Modelul intern**, determinist și structural, permite simularea comportării termice a cuptorului, asupra căruia factorii de influență cei mai importanți sunt puterea disipată de elementele de încălzire și coeficientul de transmisie a căldurii prin pereți. Principalele fenomene fizice din cuptor sunt modelate prin ecuația diferențială, adaptată după [Băla98a]:

$$[V_m \cdot \rho_m \cdot c_m + (V - V_m) \cdot \rho_a \cdot c_a] \cdot \frac{d\theta_i(t)}{dt} = P(t-\tau) - \alpha \cdot S \cdot [\theta_i(t) - \theta_e(t)] \quad (5.1)$$

unde:

- V este volumul interior al cuptorului [m^3];
- V_m este volumul ocupat de materialul tratat în cuptor [m^3];
- ρ_m densitatea materialului [kg/m^3];
- ρ_a densitatea aerului ($\rho_a = 1,293 kg/m^3$);
- c_m căldura specifică a materialului [$kg \cdot ^\circ K$];
- c_a căldura specifică a aerului ($c_a = 1000 J/kg \cdot ^\circ K$);
- θ_i temperatura interioară [$^\circ C$];
- α coeficientul mediu de transfer termic al pereților cuptorului [$W/m^2 \cdot ^\circ K$];
- S suprafața radiantă a cuptorului [m^2];
- θ_e temperatura exterioară [$^\circ C$];
- P puterea elementului de execuție [W];
- τ timpul mort [s].

Volumul intern al cuptorului este doar parțial ocupat de materialele tratate termic, restul fiind ocupat de aer.

Mărimea de intrare este $P(t)$ iar mărimea de ieșire este $\theta_i(t)$. În cadrul acestei lucrări restul parametrilor constructivi și de material vor fi considerați constanți.

În cazul în care precizia impusă este critică, caracterul determinist al modelului permite și luarea în considerare a unor dependențe neliniare dintre parametri, cum ar fi $\alpha(\theta_i)$, $V_m(\theta_i)$, etc. în măsura în care ei sunt cunoscuți sau pot fi determinați experimental.

c) **Blocul de fuziune fuzzy** are la intrare semnalele furnizate de TR, TC și TP, respectiv θ_{TR} , θ_{TC} și θ_{TP} precum și estimarea calculată de model θ_{MOD} . Prin fuziunea controlată fuzzy se obține estimarea finală a temperaturii din cuptor θ_{EST} . Calculul gradelor de încredere în senzorii primari μ_{TR} , μ_{TC} , μ_{TP} și μ_{MOD} este efectuat prin intermediul unui controler, descris în continuare.

5.1.2. Implementarea în Simulink

Implementarea Simulink a unui SITC este prezentată în cele ce urmează.

Întrucât scopul acestei aplicații se limitează la simularea comportării SITC, modulul *Cuptor*, care are rolul simulării cuptorului real, este cel realizat conform formulei (5.1). S-a ales cazul testării cuptorului gol, cu tot volumul intern ocupat de aer. Timpul mort este de 5s. Modulul corespunzător ecuației (5.1) este reprezentat în fig. 5.2.

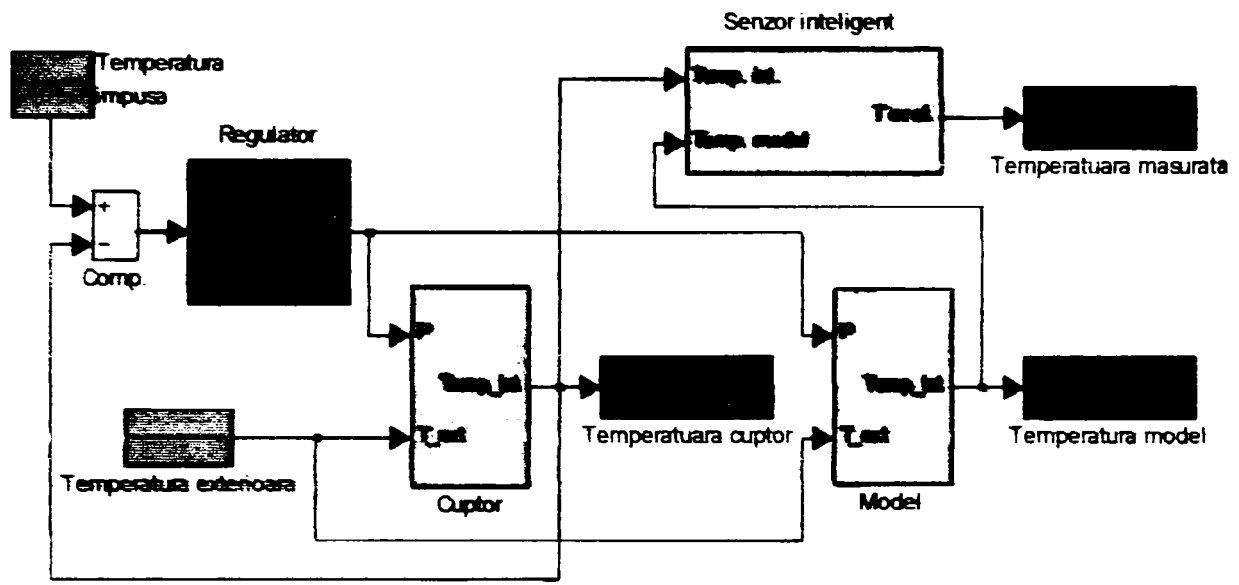


Figura 5.2. Fereastra principală a implementării SITC în Simulink

Pentru modulul *Model* s-a utilizat un sistem de ordin II, cu funcția de transfer

$$H_{II}(s) = \frac{1}{s^2 + 2600 \cdot s + 2.5} \quad (5.2)$$

obținut printr-o identificare utilizând modulul Simulink NCD.

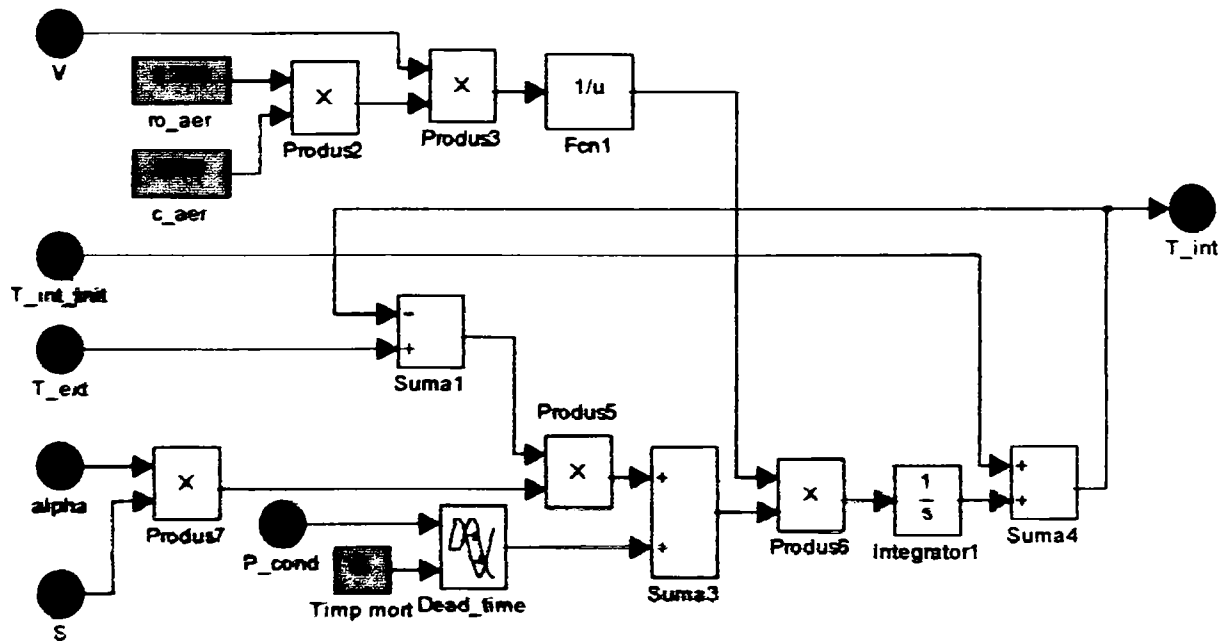


Figura 5.3. Implementarea modelului (5.1)

Pentru ilustrarea evoluției erorii modelului s-a ales un program de încălzire care include trei paliere: 500^oC, 1000^oC și 1500^oC, astfel încât să se poată măsura erorile staționare în puncte în care senzorii primari au pe rând precizia maximă. Variația erorii modelului pe durata unei astfel de program este prezentată în fig. 5.3.




Figura 5.4. Evoluția erorii modelului

Modulul *Senzor inteligent* prezentat în fig. 5.5 conține cei trei senzori primari de temperatură (rezistență R, termocuplu C și pirometru P) și modulul *Fuziune*.

Senzorii de temperatură sunt modelați cu ajutorul a câte unui look-up table care generează eroarea de temperatură în funcție de temperatura cuptorului și a câte unui modul de tip *dead time*, notat *Intarziere*. Erorile lor statice (măsurate în regim staționar, la echilibru termic) apar în fig. 5.6. S-au ales pentru toți senzorii primari erori de același semn pentru că această situație este cea mai defavorabilă din punctul de vedere al fuziunii datelor.

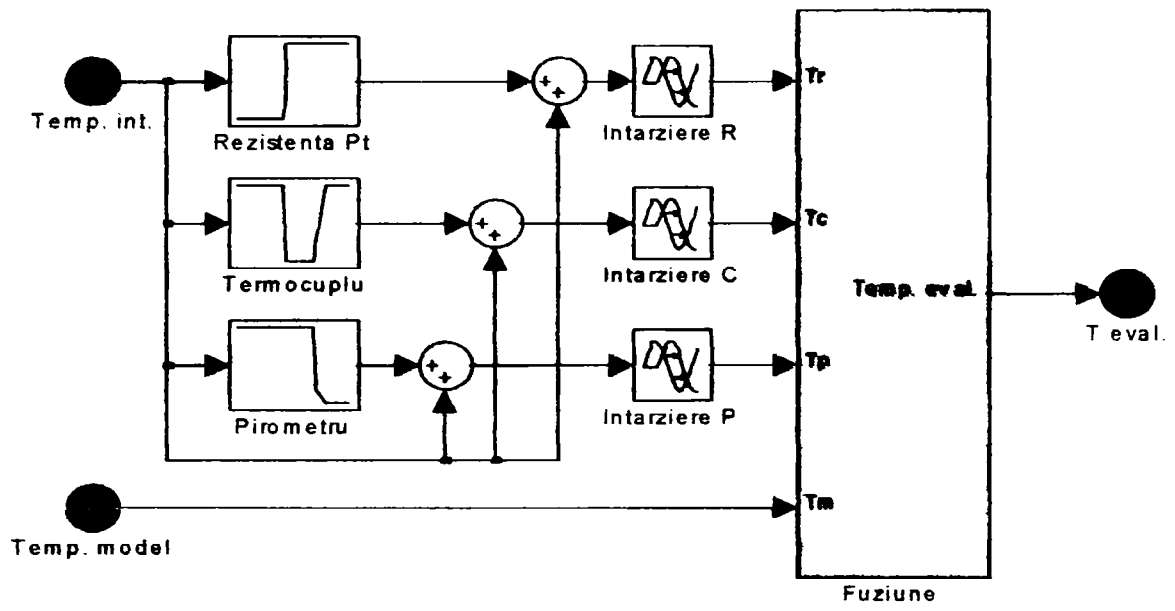


Fig. 5.5. Modulul *Senzor inteligent*




Figura 5.6. **Erorile statice ale senzorilor primari**

5.2. Fuziunea prin mediere ponderată neliniară cu senzorii primari etalonati

O primă variantă de fuzionare, care va fi luată ca termen de referință pentru evaluarea soluțiilor originale, constă din simpla mediere aritmetică (liniară) a indicațiilor senzorilor și a estimării modelului. Această variantă, din punctul de vedere al formulei (3.13) este echivalentă cu cazul:

$$\mu_{TR} = \mu_{TC} = \mu_{TP} = \mu_{MOD} = 0,25 \quad (5.3)$$

Evoluția în timp a erorilor senzorilor primari, a modelului și a rezultatului fuzionării prin mediere este prezentat în fig. 5.7. Diferențele față de erorile statice din fig. 5.6 sunt produse de inertiile termice.

Eroarea maximă în regim staționar este de aproximativ $3,25^{\circ}\text{C}$.




Fig. 5.7. Erorile în cazul fuzionării prin mediere aritmetică

În cazul în care dispunem de informații detaliate despre senzorii primari, gradele lor de încredere pot fi modificate în cursul fuzionării, ca și în relația (3.13). **Legile particulare de modificare a gradelor de încredere se sintetizează pornind de la informațiile disponibile. De exemplu atunci când sunt disponibile diagrame de etalonare ale senzorilor primari, de tipul celor din fig. 3.7, fuziunea**

datelor poate fi realizată astfel încât gradele de încredere în senzorii primari să fie invers proporționale cu eroarea rezultată din diagrame. În acest caz imprecizia din proces este datorată doar impreciziei etalonării.

O variantă originală de aplicare a metodei este prezentată în continuare.

Să considerăm notațiile din capitolul 3. Eroarea sensorului i în funcție de valoarea măsurată y se va nota $e_i(y)$ iar modulul valorii sale maxime $abs(e_{iM})$. În aceste condiții gradul de încredere în sensorul i va fi definit prin

$$\mu_i(y) = \frac{abs(e_{iM}) - abs(e_i(y))}{abs(e_{iM})} \quad (5.4)$$

Pentru reducerea influenței inerției termice a senzorilor primari, pe durata regimurilor tranzitorii gradul de încredere al modelului poate fi crescut.

Rezultatele obținute pentru o simulare efectuată în condițiile din §5.1 sunt prezentate în figura 5.8. Gradul de încredere în model a fost stabilit printr-o funcție de tip releu bipozițional, pragul derivatei temperaturii din cuptor fiind $0.3 \text{ } ^\circ\text{C/s}$:

$$\mu_{MOD} = \begin{cases} 0 & \dot{\theta}_i < 0.3 \text{ } ^\circ\text{C/s} \\ 1 & \dot{\theta}_i \geq 0.3 \text{ } ^\circ\text{C/s} \end{cases} \quad (5.5)$$

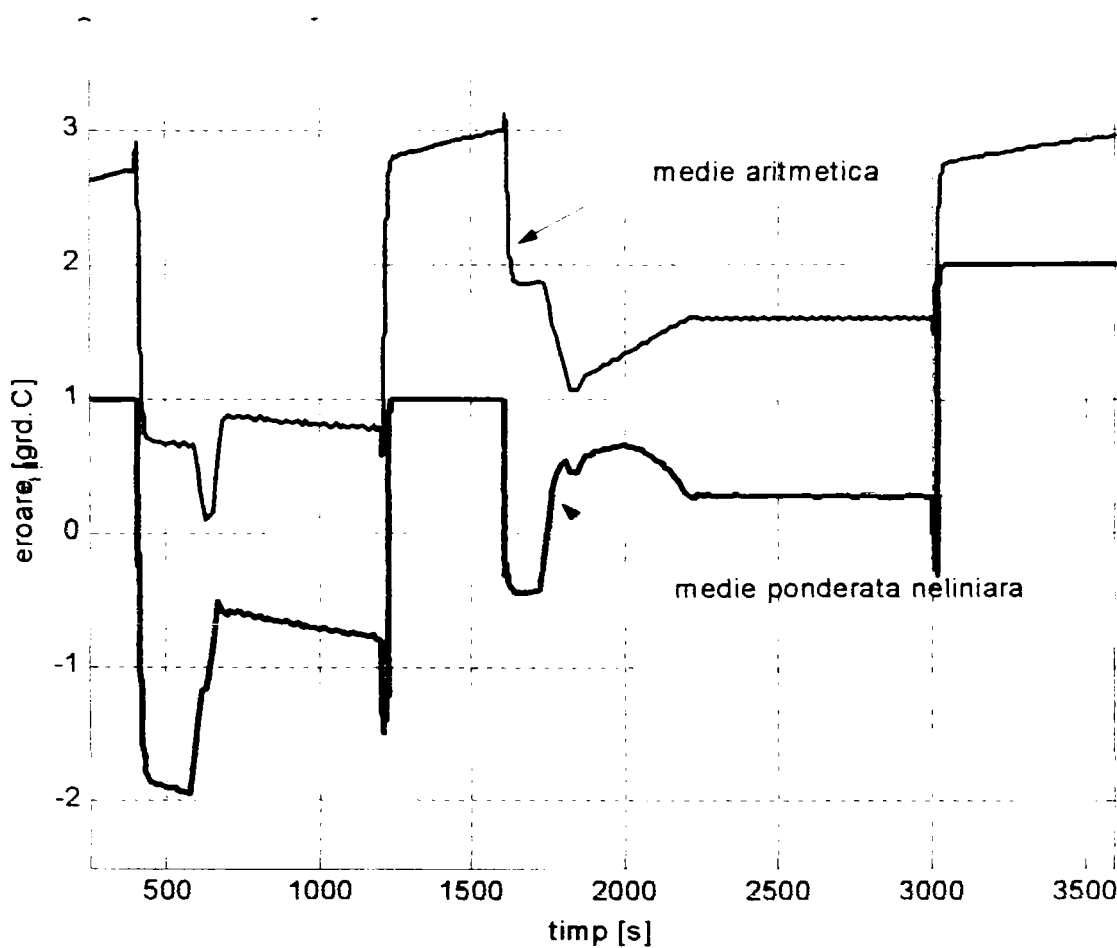



Fig. 5.8. Comparație între erorile obținute aplicând fuziunea prin mediere aritmetică respectiv fuziunea prin mediere ponderată neliniară


5.3. Fuziunea fuzzy

Încrederea în senzorii primari se bazează pe informațiile referitoare la precizia lor. Domeniul de temperaturi este delimitat în trei regiuni prin cele două valori $630,74^{\circ}\text{C}$ și $1064,43^{\circ}\text{C}$ recomandate de SIPT-68. Principala problemă ridicată de această operație constă din determinarea formelor funcțiilor de apartenență corespunzătoare gradelor de încredere.

O primă premisă acceptată în majoritatea aplicațiilor este adoptarea funcțiilor de apartenență triunghiulare sau trapezoidale. **Variantele care delimitează câmpul de opțiuni sunt reprezentate în fig. 5.9a și 5.9b.**



a) Delimitări gradate între gradele de încredere



b) Delimitări bruște între gradele de încredere

Figura 5.9. Forme de apartenență a gradelor de încredere în senzorii primari

Varianta a) elimină discontinuitățile din estimarea temperaturii dar are dezavantajul că produce o alterare gradată a preciziei evaluării, în zonele în care funcțiile de apartenență au valori comparabile. În cazul unor aplicații la care precizia este mai puțin importantă decât dinamica sau fiabilitatea, așa cum a fost cazul în §4.1, această variantă este acceptabilă. În situația acestei aplicații însă, este nerațional să se scadă gradul de încredere al sensorului cu precizia cea mai bună în alte zone decât cele care mărginesc domeniul său de încredere maximă.

Varianta b) se caracterizează prin delimitarea relativ bruscă dintre gradele de încredere ale senzorilor primari. Cazul extrem, cel al unor funcții de apartenență de tip Boole-ean este nerecomandabil din cauza discontinuităților produse la trecerea dintr-o regiune în alta.

Funcția de apartenență Boole-eană (5.5) poate fi înlocuită cu una fuzzy, prezentată în fig. 5.10. Modulul de fuzionare fuzzy va trebui prin urmare să includă două intrări: temperatura θ și derivata ei $\dot{\theta}$.




Figura 5.10. Funcția de apartenență a încrederii în model

Evoluția erorii în cazul fuziunii fuzzy, comparată cu cazurile anterioare este prezentată în fig. 5.11.




Fig. 5.11. Variația cu temperatura a erorilor care caracterizează trei variante de fuzionare a datelor: prin medie aritmetică, medie ponderată neliniară și fuzzy

În cazul aceleiași aplicații, rezultatele obținute prin aplicarea fuziunii fuzzy nu sunt calitativ diferite de cele obținute prin fuziunea prin mediere ponderată neliniară. Față de fuziunea prin mediere aritmetică, ambele metode se comportă mai bine mai ales în regimurile tranzitorii, pe durata cărora ponderea modelului, care nu are inerție, este crescută. Alegerea între cele două metode se face în funcție de incertitudinea măsurătorii: *fuziunea prin mediere ponderată neliniară este recomandabilă atunci când dispunem de informații amănunțite despre*

senzorii primari, iar fuziunea fuzzy atunci când aceste informații nu sunt disponibile, sau nu sunt de încredere.

Modelul Simulink prin care a fost realizată simularea de mai sus este prezentat în fig. 5.12 și 5.13. Din aceste implementări reiese simplitatea tuturor tehnicilor de fuziune, precum și posibilitățile multiple de implementare la care se poate recurge în aplicații.

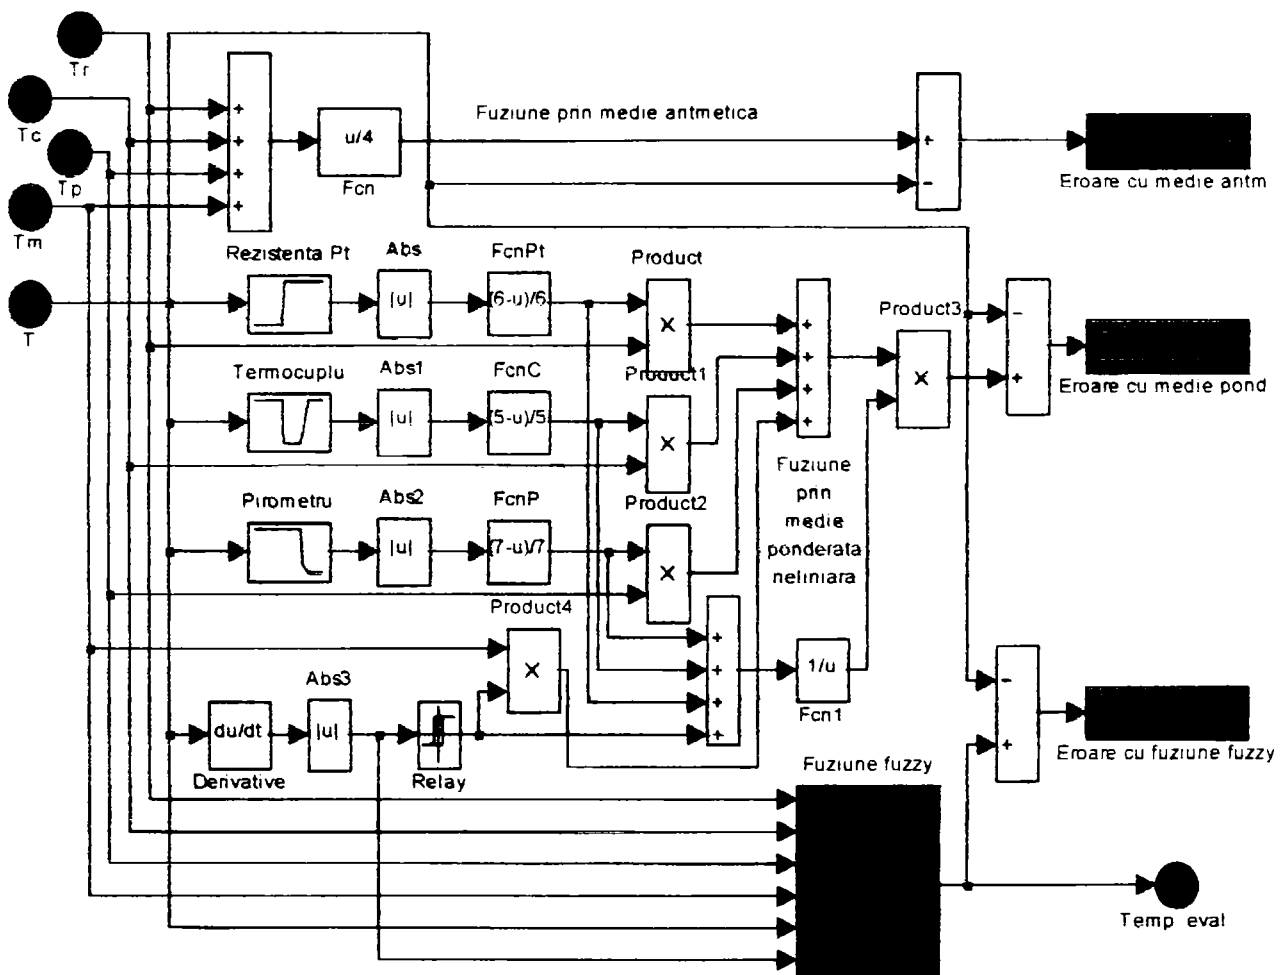


Figura 5.12. Fereastra principală a modelului

În acest model sunt cuprinse cele trei metode de fuziune menționate, aranjate de sus în jos în ordinea: fuziune cu medie aritmetică, fuziune cu medie ponderată neliniară și fuziune fuzzy. Simulările prin cele trei metode decurg în paralel, obținându-se trei seturi de date, așa cum se observă din fig. 5.11. Pentru implementarea dependențelor numerice din fig. 5.6 s-au utilizat tabele de căutare cu interpolare liniară

Fuziunea fuzzy poate fi implementată în mediul Matlab fie prin interfața grafică FIS (*Fuzzy Inference System*) din componența toolkit-ului *Fuzzy Logic*, fie așa ca în fig. 5.13, prin metoda fuzzy-interpolativă [Băla01a], pe bază de tabele de căutare cu interpolare liniară.

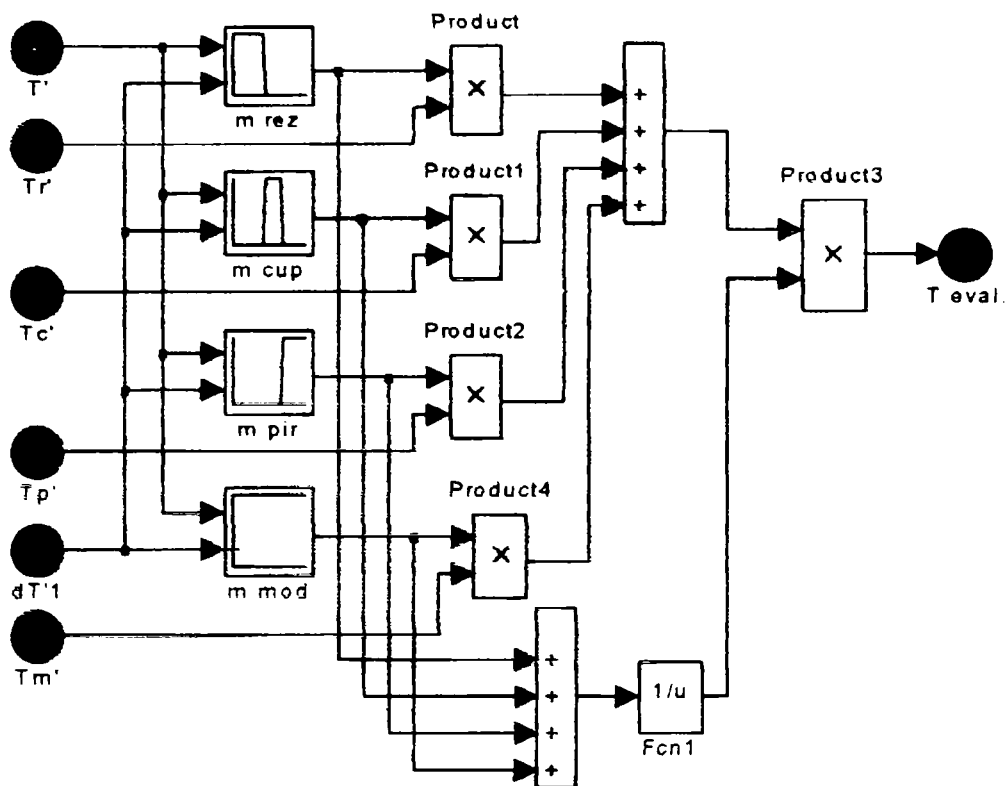


Figura 5.13. Modul de fuzionare fuzzy, în implementare fuzzy-interpolativă

În soluția de fuziune fuzzy din fig. 5.13 cele patru grade de încredere ale celor trei senzori primari și ai modelului sunt calculate cu ajutorul a patru controlere separate: *m rez*, *m cup*, *m pir* și *m mod*. Controlerele au aceleași mărimi de intrare: temperatura din cuptor evaluată de către modelul intern T' și derivata ei dT' .

5.4. Concluziile capitolului 5

În capitolul 5 se propune o a doua aplicație bazată pe fuziunea asistată de model intern: un senzor inteligent de temperatură pentru cuptoare, SITC.

SITC include trei senzori primari de temperatură: un senzor de temperatură cu rezistență de platină, un senzor de temperatură cu termocuplu, un pirometru cu radiație precum și un model funcțional al cuptorului.

Oricare dintre metodele de fuzionare menționate în lucrare poate fi aplicat cu ușurință. S-au exemplificat prin simulare două metode originale: *fuziunea prin medie ponderată neliniară*, recomandabilă când dispunem de informații amănunțite despre senzorii primari și *fuziunea fuzzy* când aceste informații nu sunt disponibile, sau nu sunt de încredere.

Avantajele obținute prin aplicarea SITC sunt:

- optimizarea preciziei pe întregul domeniu de măsură;
- compensarea inerției termice a senzorilor primari;
- creșterea fiabilității.

Concluzii

Lucrarea are ca obiectiv studierea utilității și aplicabilității senzorilor inteligenți și identificarea unor soluții aplicative prin care acestora să li se crească precizia, fiabilitatea și în general gradul de încredere, în condițiile în care măsurătorile sunt afectate de imprecizie și de incertitudine.

Modalitatea principală de atingere a obiectivelor constă din valorificarea superioară a informațiilor care se pot extrage din datele senzorilor primari și a cunoștințelor apriorice de tip expert referitoare la procesul măsurat și la senzor.

Ca principale puncte teoretice de sprijin s-a apelat la:

1. *fuzionarea datelor și informațiilor* sub forma fuziunii fuzzy și a fuziunilor bazate pe medierea ponderată, care aduce următoarele avantaje:

- performanțele metrologice ale senzorului inteligent sunt superioare performanțelor fiecărui senzor primar luat în parte;
- posibilitatea operării cu date imperfecte: imprecise și incerte;
- fiabilitatea senzorului inteligent este crescută, prin creșterea redundanței;
- este posibilă fuziunea unor date și informații de natură diferită: numerică și simbolică (lingvistică);

2. *modelarea prin modele deterministe structurale* cu mai multe scopuri:

- asistarea funcțiilor de validare și diagnosticare automată a senzorilor primari;
- estimarea măsurandului pe durata regimurilor tranzitorii, când senzorii primari introduc erori mari din cauza inerției; astfel se evită riscul instabilizărilor, în cazul utilizării senzorului în bucle de reglare;
- estimarea unor mărimi de influență sau indici de calitate ai procesului care nu sunt măsurabili direct;
- asistarea auto-ajustării și auto-configurării, prin care senzorul inteligent se poate adapta la condițiile de măsurare și la starea sa tehnică.

Ca metodă originală de realizare a scopurilor, în capitolul 3 se propune introducerea în structura senzorilor inteligenți a unui model intern determinist structural al procesului măsurat, al senzorilor primari și al canalului de măsură. Prin utilizarea modelului intern se introduce și o nouă funcțiune „inteligentă”, estimarea, care crește capacitatea de prelucrare a informației la nivelul senzorilor. Estimarea urmează să fie aplicată în cadrul soluțiilor originale propuse în teză.

Soluția teoretică obținută constă dintr-o structură de senzor inteligent adaptiv cu model intern, SIAMI. Pe lângă tehnica modelului intern necesară pentru autoadaptare și autodiagnoză, SIAMI face apel la fuziunea mai multor senzori primari lucrând în redundanță. Modelul intern va acționa asupra rezultatului final al măsurătorii atât prin intermediul propriei sale estimări a mărimii măsurate, cât și prin adaptarea mecanismului de fuzionare la condițiile concrete de măsură. Structura SIAMI este ușor implementabilă atât software cât și hardware.

Aplicațiile posibile sunt extrem de variate, în lucrare fiind tratate doar trei:

- un senzor al vitezei vagonului pe durata frânărilor ABS;
- un estimator on-line al uzurii frânei disc a vagoanelor;
- un senzor al temperaturii din interiorul unui cuptor de tratamente termice;

Prezenta teză pune în evidență actualitatea tehnicilor fuzzy pentru senzorii inteligenți și fuziunea informației imperfecte, deoarece ele permit integrarea într-un formalism unic a informațiilor numerice și a cunoștințelor experților.

Pe baza investigațiilor teoretice și a simulărilor numerice se poate afirma că structura SIAMI permite abordarea unui domeniu extrem de larg de măsurări caracterizate de imprecizie a senzorilor actuali și de diferite forme de incertitudine. *Se justifică continuarea cercetării acestei metode inteligente de măsurare, existând premisele realizării unor aplicații imediate în tehnologie PC sau DSP precum și premisa realizării unui circuit integrat ASIC.*

Contributii personale

a) Contribuții teoretice

- *Metoda fuzionării prin medie ponderată neliniară neortogonală* (§2.2) și (§5.3). Conform acestei metode fuziunea mai multor senzori primari se realizează prin medierea ponderată a măsurilor lor, ponderile fiind identice cu gradele de încredere ale senzorilor respectivi, rezultate din operația de validare. La calculul ponderilor se aplică mai multe metode, în funcție de nivelul de incertitudine din proces și din canalul de măsură. În lucrare s-au exemplificat două:

- o metodă originală prin care ponderea este dependentă de inversul erorii senzorului atunci când se cunoaște fișa sa de etalonare, fiind cu atât mai mare cu cât eroarea este mai mică, conform formulei (5.4) din §5.2;
- calculul prin controlere fuzzy-expert proiectate euristic, atunci când datele metrologice ale senzorilor sunt incerte sau necunoscute (§4.1.3.5 și §5.3);

Originalitatea metodei constă din renunțarea la condiția de ortogonalitate (2.42) astfel încât fuziunea fuzzy-expert euristică să fie posibilă și în validarea pe baza comparației măsurilor senzorilor primari cu estimarea globală a senzorului inteligent, adusă de la ieșirea blocului de fuziune la blocurile de validare prin reacție (fig. 2.1. și fig. 2.9)

Legate de această metodă, sunt originale formulele (2.43) și (2.44).

- *Studiul unor sisteme de reglare adaptivă și identificare cu model intern.* Ecuațiile care modelează comportarea sistemului de reglare adaptivă cu model intern pentru cazul cu timp continuu cu parametri constanți pe subintervale de timp, sunt prezentate în §3.1.1, §3.1.2 și §3.1.3.

Legate de această metodă sunt originale formulele (3.1), (3.5) și (3.11) referitoare la precizarea analitică a rolului corectoarelor adaptive în cadrul sistemelor de reglare și identificare cu model intern cunoscute.

- *Introducerea în structura senzorilor inteligenți a modelelor interne deterministe și structurale*, prin analogie cu metodele de conducere automată cu model intern (fig. 1.5 din §1.4 și fig. 3.6 din §3.2). Modelele interne includ cunoștințele disponibile despre modul de acțiune a diferiților parametri din proces asupra măsurandului și asupra senzorilor primari și canalului de măsură.
- *Elaborarea unei structuri originale de senzor inteligent adaptiv cu model intern și fuziune a datelor*, SIAMI, cu o aplicabilitate largă (§3.2 fig. 3.6).

SIAMI prezintă următoarele elemente de originalitate:

- Estimarea măsurandului realizată de către modelul intern participă la fuziune împreună cu senzorii primari care lucrează în redundanță;
- Fuziunea prin mediere ponderată neliniară este condusă de către un corector care asigură și validarea senzorilor primari și a modelului. Corectorul calculează gradele de încredere în senzorii primari și în modelul intern, și identifică aceste grade de încredere cu ponderile aferente fuziunii.

Legate de SIAMI sunt originale formulele (3.13) – (3.17).

Pe lângă avantajele globale oferite de fuziunea senzorilor, SIAMI oferă următoarele avantaje specifice:

- ◆ *creșterea fiabilității*, prin participarea modelului intern la diagnosticarea și la auto-configurarea senzorului inteligent;
- ◆ *îmbunătățirea performanțelor metrologice statice*, prin adaptarea la condițiile de măsură și corecții bazate pe estimarea on-line, asistată de modelul intern, a unor mărimi de influență sau indici de calitate care nu pot fi măsurati direct;
- ◆ *îmbunătățirea performanțelor metrologice dinamice*, prin estimarea măsurandului de către model pe durata regimurilor tranzitorii, în care senzorii primari oferă măsuri eronate din cauza inerției;
- ◆ *implementare ușoară* în majoritatea tehnologiilor software și hardware.

b) Contribuții aplicative

Contribuțiile aplicative constă din investigarea teoretică și simularea numerică a unor senzori inteligenți de tip SIAMI, care aduc îmbunătățiri fundamentale actualelor soluții prezentate în literatura de specialitate. frânarea ABS și măsurarea temperaturii într-un cuptor de tratamente termice.

Pentru fiecare element teoretic studiat au fost scrise module specifice originale, în limbaj MATLAB–SIMULINK, care reflectă exact conceptul studiat, sub forma prezentată în lucrare.

Cele trei aplicații studiate sunt:

- *Senzorul inteligent al vitezei vagonului SIVV* (§4.1) are rolul de a oferi regulatoarelor frânelor ABS, cu care sunt dotate fiecare dintre osiile unui vagon, o informație cât mai precisă referitoare la viteza momentană a vagonului, chiar și atunci când toate

roțile sunt în regim de alunecare iar senzorii de viteză ai roților nu mai indică viteza vagonului ci viteza momentană a fiecărei roți.

SIVV funcționează prin fuzionarea fuzzy a datelor numerice provenite de la trei surse diferite de informații referitoare la viteza vagonului: senzorii de viteză ai roților agregați prin operatorul *max*, un accelerometru a cărui indicație este integrată și un model funcțional al sistemului de frânare al vagonului.

Pe lângă rolul principal, cel de estimator al vitezei vagonului, SIVV are și rolul de a estima on-line una dintre principalele mărimi de influență, care nu poate fi măsurată direct, în timp real: aderența sistemului roată-șină. Aderența astfel obținută este utilizată la adaptarea estimatei vitezei vagonului și la adaptarea regulatorului frânei ABS.

Legate de SIAMI sunt originale formulele (4.5) - (4.8).

- *Estimatorul on-line al uzurii frânei disc* (§4.2) se obține incluzând în structura SIVV un bloc de estimare on-line a intensității de uzare a frânei disc. Uzura se obține integrând intensitatea de uzare pe durata perioadelor în care vagonul frânează.

Legate de estimarea on-line a uzurii frânei disc sunt originale formulele (4.9), (4.10) și (4.11).

Prin aplicarea acestei metode se ușurează mult activitatea de mentenanță a vagoanelor, controlul dimensional ale discurilor și garniturilor de fricțiune putând fi evitat în mare măsură.

- *Senzorul inteligent de temperatură pentru cuptoare*, SITC (§5.1, §5.2 și §5.3) se obține aplicând structura SIAMI în măsurarea temperaturii în cuptoarele de tratamente termice.

SITC include trei senzori primari de temperatură: un senzor de temperatură cu rezistență de platină, un senzor de temperatură cu termocuplu, un pirometru cu radiație precum și un model funcțional al cuptorului. Domeniile în care precizia acestor senzori primari este maximă sunt diferite, complementare. Fuziunea datelor se poate face prin: fuziune prin medie ponderată neliniară, recomandabilă când se dispune de informații precise despre senzorii primari și prin fuziune fuzzy când aceste informații nu sunt de încredere, sau nu sunt disponibile.

Legate de SITC sunt originale formulele (5.4) și (5.5).

Avantajul specific obținut prin aplicarea SITC este evitarea pierderilor economice mari care se produc atunci când se greșesc tratamentele termice, deoarece SITC beneficiază în mod deosebit de două avantaje ale SIAMI: creșterea fiabilității și a performanțelor metrologice dinamice, care sunt critice deoarece de regulă senzorii de temperatură au inerții termice mari.

Referințe bibliografice

- [Abde90] Mona AbdelRahman, "Fuzzy Sensors for Fuzzy Logic", Control Engineering, pag. 50-51, December, 1990.
- [Abde95] Mona AbdelRahman, "Artificial Intelligence, Fuzzy Logic and Sensor Clusters", Industrial Applications of Fuzzy Logic and Intelligent Systems, Edited by John Yen, Reza Langary, Lotfi Zadeh, IEEE Press, 1995
- [Abde02] Mohamed Abdelrahman, "Integrated Intelligent Industrial Process Sensing and Control Applied to and Demonstrated on Cupola Furnances" S&C FY Annual review Meeting, 2002.
- [Agui92] J. A. Aguilar-Crespo, X. Alaman, "A Fuzzy Logic Approach for Sensor Validation in Real Time Expert Systems", IPMU'92, Advances Methods in Artificial Intelligence, Palma de Mallorca, Spain, 1992.
- [Albu02] C. Albu-Iacob, „Contribuții privind îmbunătățirea constructiv funcțională a instalațiilor de tratamente termice ale aliajelor de cupru”, Teză de doctorat, Universitatea Tehnică „Gheorghe Asachi” Iași, 2002.
- [Alie94] R. Aliev, K. W. Bonfig, F. Aliew, "Messen, Steuern und Regeln mit Fuzzy-Logic", Franzis-Verlag GmbH, Munchen, 1994.
- [Altr96] C. von Altrock, "Fuzzy Logic in Automotive Engineering", Proceedings of the Embedded Systems Conference, Santa Clara, 1996.
- [Asch91] G. Asch, "Les capteurs en instrumentation industrielle", Edition DUNOD, 4eme edition, 1991
- [Auma86] J. Aumaréchal, "Le systeme antienrayeur Faiveley". Revue générale des chemins de fer, pag. 82-86, feb. 1986.
- [Band95] Hans Bandemer, Siegfried Gottwald, "Fuzzy Sets, Fuzzy Logic, Fuzzy Methods with Applications", John Wiley & Sons, 1995..
- [Bara01] A. Bara, "Sisteme fuzzy. Aplicații la conducerea proceselor", Editura U. T. Pres, Cluj-Napoca, 2001.
- [Băla98] M. Bălaș, "Modelling an Air-Conditioning System for the Railway Coaches", Bulletin for Applied & Computer Mathematics, PAMM Centre, Technical University of Budapest, pag. 61-68, July, 1998.
- [Băla00a] M. Bălaș, "Despre unele regimuri de frânare controlată a vagoanelor", Analele Univ. "Aurel Vlaicu" din Arad, seria Electrică, fascicola Electrotehnică, Electronică, Automatizări, pag. 35-44, oct. , 2000.
- [Băla01a] M. Bălaș, "Regulatoare fuzzy interpolative cu aplicații în construcția vagoanelor de călători", Teză de doctorat, Timișoara, Dec., 2001.
- [Băla02a] M. Bălaș, „Regulatoare fuzzy-interpolative”, Editura Politehnica, Timișoara, 2002.
- [Beno91] E. Benoit, L. Foulloy, "Symbolic sensors:one solution to the numerical-symbolic interface", Proceedings of the IMACS DSS & QR workshop, Toulouse, France, March, pp.321-326, 1991.

- [Beno93a] E. Benoit, "*Capteurs symboliques et capteurs flous: un nouveau pas vers l'intelligence*", These de doctorat d'etat, l'Universite Joseph Fourier – Grenoble I, France, 1993.
- [Beno93b] E. Benoit, L. Foulloy, "*Capteurs flous multicomposantes application a la reconnaissance des couleurs*", Journées Nationale sur les Applications des ensembles flous, Nimes, pp.167-175, Nov. 1993.
- [Beno94a] E. Benoit, L. Foulloy, G. Mauris, "*Fuzzy sensor for the perception of colour*", IEEE World Congress on Computational Intelligence, June 26 – July 2, Orlando, USA. pp. 2008-2013, 1994.
- [Beno94b] E. Benoit, G. Mauris, L. Foulloy, "*Fuzzy sensor aggregation: application to comfort measurement*", Cinquieme Conference Internationale IPMU, Paris, 4-8 Juillet, pp.721-726, 1994.
- [Bloc96] I. Bloch, "*Information combination operators for Data Fusion: A comparative review with clasification*", IEEE Trans. Sys. Man Cybern.. vol. SMC-26, pp.52-67, 1996.
- [Bloc98] Isabele Bloch, Henry Maître, "*On some features of fuzzy set theory for date fusion*", IFAC, pag. 91-96, 24-26 June, Nancy –Metz, 1998.
- [Boite86a] M. Boiteux, "*Le probleme de l'adhérence en freinage*". Revue générale des chemins de fer, pag. 50-72, feb. 1986.
- [Boite86b] M. Boiteux, "*Les antirayeurs modernes. Principes constructifs*". Revue générale des chemins de fer, pag. 73-81, feb.1986.
- [Bord96] Diego Bordegari, Daniel J. Chin, Danielle Marini, "*Fuzzy logic based voxel classification and fusion of confocal laser scan volume data*", NATO Grant Nr. 40225518, 1996.
- [Bouc95] Bouchon Meunier B., "*La logique floue et ses applications*", Paris, Addison – Wesley, 1995.
- [Bouc98] B. Bouchon-Meunier, L. Foulloy, M. Ramdany, "*Logique Floue*", Cepadues – Edition, France, 1998.
- [Bouk97] R. Boukezzula, S. Galichet, L. Foulloy, "*Commande a Modele Interne Flou*", Actes des rencontres francophones sur la logique floue et se applications, Lyon, France, pp.11-16, 3-4 Dec. 1997.
- [Bouk01] R. Boukezzoula, S. Galichet, "*La fusion fuzzy*". Conferință susținută de S. Galichet la Univ. "Politehnica" din Timișoara și la Univ. "Aurel Vlaicu" din Arad, iunie, 2001.
- [Bove94] M. S. Boverie "*Application de la commande floue dans les systemes automobiles*", Congres International S.I.A. Systemes automobiles a controle electronique integre, Toulouse 6-8 Avril, 1994.
- [Calu00] Sorin Caluianu – "*Inteligența artificială în instalații. Logica fuzzy și teoria posibilităților*", MATRIX ROM, 2000.
- [Chab94] M. Chabbert, M. Chatenay, "*Diagnostics automobile par estimation. La logique floue pour l'attenuation de transitoires. Application en simulation a la regulation de freinage*", Congres International S.I.A. Systemes automobiles a controle electronique integre, Toulouse 6-8 Avril, 1994.

[Chat99] T. Chateau, C. Debain, F. Collange, L. Trassoudaine, J. Alizon, "Fusion d'attributs: application to an automatic guidance d'engines agricoles", *Rencontres Francophones sur la Logique Floue et ses Applications*, Valenciennes pag. 141-148, 21-22 oct. 1999.

[Cheo00] A.D. Cheok, S. Shiomi. „*Combined Heuristic Knowledge and Limited Measurement Based Fuzzy Logic Antiskid Control for Railway Applications*”, *IEEE Transactions on Systems, Man and Cybernetics, Part C: Applications and Reviews*, vol. 30, no. 4, Nov. 2000, pag. 557-568.

[Dail96] Daniel J. Dailey, Patricia Harn, Po-Jung Lin, "ITS - Data Fusion", Final Research Report, Project T9903, Task 9, University of Washington Seattle, Department of Transportation, April 1996.

[Dasa97] Belur Dasarathy, *Sensor Fusion Potential Exploitation – Inovative Architectures and Illustrative applications*, *Proceedings of the IEEE*, Vol. 85, No 1, pp.24 – 38, January 1997.

[Delg98] M. Delgado, F. Herrera, E. Herrera-Viedma, L. Martinez, "Combining numerical and linguistic information in group decision making", *Journal of Information Sciences*, Vol. 107, pag. 177-194, 1998.

[Dobr95] R. Dobrescu, "Autovehicule inteligente", Editura MATRIX ROM, Buc., 1995.

[Drag01b] T.L. Dragomir, S. Dale, M. Bălaș, „Some aspects regarding Interpolative Control”, *Proceedings of the 13-th International Conference on Control Systems CSCS13*, București, Nov. 2001.

[Dubo80] D. Dubois, H. Prade , "Fuzzy sets and systems: theory and applications", Academic Press, New York, 1980.

[Dubo88] D. Dubois, H. Prade, "Theorie des possibilites. Applications a representation des connaissances en informatique", Masson, Paris , 1988.

[Dubo91] D. Dubois, H. Prade, "Basic Issues on Fuzzy Rules and their Application to Fuzzy Control", *Proceedings of the IJCAI'91, Workshop on Fuzzy Control*, Sydney, 1991.

[Dubo94a] D. Dubois, H. Prade, "Possibility theory and data fusion in poorly informed environment," *Control Engineering Practice*, 2 (5), pag 811 –823, 1994.

[Dubo94b] D. Dubois, H. Prade, "La fusion d'informations imprecises", *Traitement du Signal*, Volume 11 – no. 6, pag. 447-458, 1994.

[Dubo94c] D. Dubois, M. Grabisch, "Agregation multicritere et optimisation", *Logique floue*, Masson, pag. 179-200, 1994.

[Dubo00a] D. Dubois, H. Nguyen, H. Prade, "Possibility Theory, Probability and Fuzzy Sets. *Fundamental of Fuzzy Sets*", Kluwer Academic Publishers, pp. 343-438, 2000.

[Dubo00b] D. Dubois, H. Prade, "Possibility Theory in Information Fusion", *Fusion 2000*, 3rd International Conference on Information Fusion 10-13 July, pp.PS-6-PS-19, Paris, 2000.

[Duje98] C. Dujet. N. Vincent, "Data Fusion Modeling Human Behavior", *International Journal of Intelligent Systems*, Vol. 13, pp. 27-39, 1998.

[Dumi80] I. Dumitrache, "Tehnica reglării automate", Editura Didactică și Pedagogică, București, 1980.

[Dumi93] I. Dumitrache și colectiv, "Automatizări electronice", Editura Didactică și Pedagogică, București, 1993.

[Fodo00] J. Fodor, R. R. Yager, "Fuzzy Set-Theoretic Operators and Quantifiers. *Fundamentals of Fuzzy Sets*", Kluwer Academic Publishers, pp. 125-193, 2000.

[Foul91] L. Foulloy, E. Benoit, G. Mauris, "Les capteurs flous: une nouveauté". Rapport LAMII, Université de Savoie, May 1991.

[Foul93] L. Foulloy, S. Galichet, "Fuzzy Sensors and Controllers" *Proceedings of the 8th Conference on Application of Artificial Intelligence in Engineering*, pp. 7-20. Toulouse, France, July 1993.

[Foul94b] L. Foulloy, S. Galichet, J. F. Josserand, "Fuzzy Components for Fuzzy Control", *Proceedings of the 2nd IFAC Symposium on Intelligent Components and Instruments for Control Applications*, pp. 122-126, June, Budapest, Hungary, 1994.

[Foul94c] L. Foulloy, S. Galichet, E. Benoit, "Fuzzy Control with Fuzzy State Sensors", *Proceedings of the 2nd European Congress on Intelligent Techniques and Soft Computing*, Aachen, Germany, pp. 1156-1160, Sept. 1994.

[Foul95] L. Foulloy, "Fuzzy Sensors and Fuzzy Controllers: an Overview", Internal Report 95-4, January, Université de Savoie, Annecy, LAMII, 1995

[Frio95] L. Friot, "Méthodologie de mise en oeuvre d'une régulation de climatisation par modèle interne appliquée au transport ferroviaire", Thèse présentée à l'Université de Poitiers, soutenue le 17 Novembre 1995, directeur de Thèse J. C. Trigeassou.

[Fuku92] T. Fukuda, K. Shimojima, F. Arai, H. Matura, "Multi-Sensor Integration System based on Fuzzy Inference and Neural Network". *Information and Science*, Vol. 71, No. 1, pp. 27-41, 1992.

[Geor95] V. Georgescu, "Proiectarea sistemelor expert în logică fuzzy și teoria posibilităților", Editura Intarf, Craiova, 1995.

[Goeb96] K. F. Goebel, "Management of Uncertainty in Sensor Validation, Sensor Fusion and Diagnosis of Mechanical Systems Using Soft Computings Techniques", A dissertation for the degree of Doctor of Philosophy, University of California at Berkeley, 1996.

[Gree97] E. Greeneich, "Analog Integrated Circuits", Chapman & Hall, 1997.

[Gruy99] D. Gruyere, "Etude du traitement de donnée imparfaites pour suivi multi-objets: Application aux situations routieres", These de doctorat d'état, l'Université de Technologie de Compiègne, France, 1999.

[Guel94] F. Guelly, "Les composants flous industriels", *Logique floue*, Masson, pag. 233-244, 1994.

[Gupt88] M. M. Gupta, "Cognition, Perception and Uncertainty", *Fuzzy Computing Theory. Hardware and Applications*, Elsevier Science Publishers B.V., Amsterdam, pag. 1-10, 1988.

[Guu02] S. M. Guu, "Fuzzy weighted averages revisited", *Fuzzy Sets and Systems*, Volume 126, Number 3, pp. 411-414, March 16 2002.

[Hami98] B. Hamidin, S. Buyamin, "Investigations of Control Algorithms for Antilock Braking System". University of Toledo, 1998.

- [Hiro91] K. Hirota, W. Pedrycz, M. Yuda – *Fuzzy Set-Based Models of Sensor Fusion*, Fuzzy Engineering toward Human Friendly Systems, IFES, pag. 623-633, 1991.
- [Houz94] S. Houzelle, G. Giraudon, "Contribution to multisensor fusion formalisation", *Robotic and Autonomous Systems*, Elsevier, Vol. 13, pp.69-85, 1994.
- [Isak95] S. Isaka, "Fuzzy Logic Applications at OMRON Corporation", din "Industrial Applications of Fuzzy Logic and Intelligent Systems", editată de J. Yen, R. Langari, L.A. Zadeh, IEEE Press, pag. 55-67, 1995.
- [Jane96] Fabrice Janez, "Fusion de sources d'information définies sur des référentiels non exhaustifs différents", These pour le grade de docteur, Université d'Angers, 1996.
- [Jose95] J.F. Josserand, L. Foulloy, "Reseau de composants flous pour la mesure et la commande intelligentes", Journée SEE "Nouvelles techniques par une instrumentation intelligente" Annecy, pp. IV.3.1-IV.3.10, Oct. 1995.
- [Klei96] R. Klein, A. Daiss, H. Eichfeld, "Antilock-Braking System and Vehicle Speed Estimation using Fuzzy Logic", 1st Embedded Computing Conference, Paris, 1996.
- [Koba99] F. Kobayashi, T. Fukuda, M. Onoda, Y. Hotta, "Sensor Selection Based on Possibility Measure for Grinding System", IEEE International Fuzzy Systems Conference Proceedings, August 22-25, pp. I-492 – I-497, Seoul, Korea, 1999.
- [Lars99] H. Legind Larsen, "Importance weighted OWA aggregation of multicriteria queries". Proceedings of the North American Fuzzy Information Processing Society Conference, New York, 10-12 June, pp.740-744, NAFIPS '99, 1999.
- [Lass99] V. Lasserre, "Modélisation floue des incertitudes de mesures de capteurs", These de doctorat d'état, Université de Savoie, Annecy, France, 1999.
- [Lee02] H. S. Lee, "Optimal consensus of fuzzy opinion under group decision making environment", *Fuzzy Sets and Systems*, Vol 132, Number 3, pp.303-315, December 16 2002,
- [Leon95] N.E. Leonard, W.S. Levine, "Using Matlab to Analyze and Design Control Systems", Editura II, Addison-Wesley Publishing Company, 1995.
- [Loon01] C. G. Looney, "Fuzzy Fusion of Information", Unit 4, March, 2001.
- [Lütt97] D. Luttenbacher, "Modélisation du concept capteur intelligent par une approche orientée objet", These, Université Henry Poincaré, Nancy 1, 1997.
- [Many94] J. Manyiaka, H. Durrant-Whyte, "Data fusion and sensor management: A Decentralized Information – Theoretic Approach, Ellis Horwood Limited, Great Britain, 1994.
- [Marc77] D.I. Marchidan, M. Ciopec, „Temperatura. Scări, metode și mijloace de măsurare”, Editura Științifică și Enciclopedică, București, 1977.
- [Maur92] G. Mauris, "Capteurs ultrasonores "intelligents". Application a la representation symbolique de mesures de distance par codage flou", These de doctorat d'état, Université de Savoie, Annecy, France, 1992.
- [Maur94a] G. Maauris, E. Benoit, L. Foulloy, "Fuzzy symbolic sensors from concept to applications", *Measurement*, ISSN 0263-2241, No. 12, pp. 357-384, 1994.

- [Maur94b] G. Mauris, E. Benoit, L. Foulloy, "The aggregation of information by examples via fuzzy sensors", The 3rd IEEE Conference Fuzzy Logic, Orlando, Florida, pp.1867-1872, 26-29 June, 1994.
- [Maur95] G. Mauris, E. Benoit, L. Foulloy, "Capteurs intelligent ultrasonore pour mesure validee de distance" Journee SEE "Nouvelles techniques pour une instrumentation intelligente", Annecy, pp.1.1-1.1.6, Oct. 1995
- [Maur96a] G. Mauris, E. Benoit, L. Foulloy, *The aggregation of complementary information via fuzzy sensors*, Measurement, Vol 17, No.4, pag 235 -249, 1996.
- [Maur96b] G. Mauris, E. Benoit, L. Foulloy, "Local measurement validation for an intelligent telemeter", IEEE Instrumentation and Measurement Technology Conference, Brussels, Belgium, pp 94-99, 1996.
- [Maur97] G. Mauris, E. Benoit, L. Foulloy, "Fuzzy sensors: An overview", Fuzzy Information Engineering. A Guided Tour of Applications, John Wiley & Sons Inc. pp. 13-30, 1997.
- [Naka95] M. Nakazawa, O. Isobe, S. Takahashi, Y. Watanabe, "Braking Force Distribution Control for Improved Vehicle Dynamics and Brake Performance" Vehicle System Dynamics, nr. 24, pag. 413-426, Swets & Zeitlinger, 1995.
- [Negn02] M. Negnevitsky, "Artificial Intelligence A Guide to Intelligent Systems". Addison-Wesley, 2002.
- [Nguy98] H. T. Nguyen, M. Sugeno, "Fuzzy Sistems. Modeling and Control", Kluwer Academic Publishers, 1998.
- [Nifl98] A. Nifle, "Modelisation comportementale en fusion de donnees. Application a la detection et identification d'objets ou de situations", These de Doctorat, Universite Paris XI, 1998.
- [Odeb93] H. Odeberg, "Distance measures for fuzzy sensor opinions" Measurement Science & Technology, Vol. 4, No. 8, 1993.
- [Odeb94] H. Odeberg, "Fusing sensor in information using fuzzy measures", Robotica, Vol.12, 1994.
- [Pal94] P. Palacharla, P. C. Nelson, V. P. Sisiopiku, "Data Fusion Using Fuzzy-Valued Logic", Proceedings of the intelligent Vehicles '94 Symposium, Paris, France, 1994.
- [Păne00] D.A. Pănescu, "Sisteme bazate pe cunoștințe. Reprezentarea cunoașterii", Editura Matrix Rom, București, 2000.
- [Pedr81] W. Pedrycz, E. Czogala, „On Identification in Fuzzy Systems and its Application in control problems”, Fuzzy Sets and Systems 6, pp 73-83, 1981.
- [Pedr93] W. Pedrycz, "Fuzzy Control and Fuzzy Systems", second extended edition, John Wiley & Sons, 1993.
- [Pedr99] W. Pedrycz, E. Roventa, "From fuzzy information processing to fuzzy communication channels", Kybernetes The International Journal of Systems & Cybernetics, 1999.

- [Perr00] N. Perrot, G. Mauris, G. Trystram, J. Hossenlopp, "Modelisation de la mesure sensorielle operateur par mesure symbolique floue", LFA'2000, Rencontres Francophones sur la Logique Floue et ses Applications, pp. 113-120, La Rochelle, 18-20 Oct. 2000.
- [Peti96] J.F. Petin, B. Iung, E. Neunreuther, "Contribution methodologique a l'Actionnement et la Mesure Intelligents". *RAIRO - APII - JESA* Volume 30, No. 6, pag. 897 - 918, 1996.
- [Petr00] E. M. Petriu, N. D. Georganas, D. C. Petriu, D. Makrakis, V. Z. Groza, "Sensor-Based Information Appliances", *IEEE Instrumentation Measurement Magazine*, Vol. 4 No. 4, December 2000.
- [Piat96] E. Piat, D. Meizel, "Fusion de degres de confiance dans le cadre de la theorie des probabilites. Application a la fusion de donees telemetriques". *Rapport interne*, URA CNRS 817 Heudiasyc, l'Universite de Technologie de Compiègne, 1996.
- [Prec95] R.E. Precup, Șt. Preitl, "Sisteme de reglare avansată", Curs, vol. 1, Univ. "Politehnica" Timișoara, 1995.
- [Prei97] Șt. Preitl, R.E. Precup, "Introducere în conducerea fuzzy a proceselor", Editura Tehnică, București, 1997.
- [Rao99] N. S. V. Rao, "Multisensor fusion under unknown distributions". *Journal of the Franklin Institute*, 336, 2, 1999.
- [Robe93] M. Robert, M. Marchadieux, M. Porte, "Capteur intelligents et methodologie d'evaluation", Hermes, Serie Automatique, Paris, 1993.
- [Robe99] M. Robert, "Capteurs intelligents, etat de l'art et perspectives", *REE*, Nr. 3, Mars, pag. 43-46, 1999.
- [Roth98] A. Rotshtein, A. Kashkanov, "Fuzzy expert system for identification of the car wheels adhesion factor with a road surface", *EUFIT'98*, Aachen, Sept., 1998.
- [Roux96] L. Roux, J. Desachy, "Fusion d'un grand nombre de sources: un apercu general des methodes disponibles en theorie des possibilites", *Journees thematiques en fusion d'informations*, GDR-PRC ISIS, 7-8 Oct. Paris, 1996.
- [Said96] L. Saidi, „Commande a modele interne: inversion et equivalence structurelle”, thèse de doctorat presentée a L'Université de Savoie, 1996.
- [Smet99] P. Smets, "Imperfect information" Université Libre de Bruxelles, UMIS, 1999.
- [Smol02] R. Smolikova, M. P. Wachowiak, "Aggregation operators for selection problems", *Fuzzy Sets and Systems*, Vol. 131, pp.23-34, 2002.
- [Șand82] E. Șandru și colectiv, "Termotehnică și aparate termice", Ed. Didactică și Pedagogică, București, 1982.
- [Taga99] T. Tagarev, P. Ivanova, "Computational Intelligence in multi-source Data and Information Fusion", *Information & Security*, Volume 2, Sofia, 1999.
- [Taka85] T. Takagi, M. Sugeno, "Fuzzy Identification of Systems and Its Applications to Modeling and Control", *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-15, nr. 1, Jan./Feb., pp. 116-130, 1985.
- [Vale00] L. Valet, G. Mauris, Ph. Bolon, "A Statistical Overview of Recent Literature in Information Fusion", "Fusion 2000", Paris, pag. 322 - 329, 2000.

- [Vădă96] M. Vădăsan, "Instalația de frână pentru vagonul de mare viteză tip CORAIL", proiect de diplomă, Universitatea "Politehnica" Timișoara, 1996, coordonator conf. dr. M. Dungan.
- [Voge93] M. Vogel, "Demarche industrielle pour la logique floue en traction ferroviaire", Journée regionale sur la logique floue, Lyon, 1993.
- [Wal00] A. J. Wal, M. Shao, "Sensor fusion: The application of soft computing in monitoring and control for railroad maintenance", International Conference on Intelligent Control and Automation, Heifei, P.R. China, June 2000.
- [Yage88] R. R. Yager, "On ordered weighted averaging aggregation operators in multicriteria decision making", IEEE Transactions On Systems, Man and Cybernetics, Volume 18, pages 183-190, 1988.
- [Yage94] R. R. Yager, D. P. Filev, "Aggregation Operations on Fuzzy Sets". Essential of Fuzzy Modeling and Control, pp.29-78, John Wiley & Sons, Inc. 1994
- [Yage97a] R. R. Yager, "A General Approach to the Fusion of Imprecise Information", International Journal of Approximate Reasoning, Vol.12, pag. 1-29. 1997 .
- [Yage97b] R. R. Yager, "Fuzzy logics and artificial intelligence", Fuzzy Sets and Systems, No. 90, pp.193-198, 1997.
- [Yage98a] R. R. Yager, "New Modes of OWA Information Fusion". International Journal of Approximate Reasoning, Vol 13, pag. 661-681, 1998.
- [Yage98b] R. R. Yager, "Fusion of ordinal information using weighted median aggregation", International Journal of Approximate Reasoning, 18, pag. 35 - 52. 1998.
- [Zade72] L. A. Zadeh, "A rationale for fuzzy control". Jurnal of Dynamical Systems Measurement and Control, Transactions ASME, Ser. G, Vol. 94, No.1, pp. 3-4, 1972.
- [Zade75] L.A. Zadeh, "The Concept of a Linguistic Variable and its Application to Approximate Reasoning", Information Science, Part. I (8) pp 199-249, Part II (8) pp 301-357, Part III (9) pp 43-80, 1975.
- [Zade78] L. A. Zadeh, "Fuzzy Sets as a Basis for a Theory of Possibility", Fuzzy Sets and Systems 1, pag. 3-28, 1978.
- [Zade96] L. A. Zadeh, "Fuzzy logic = Computing with words", IEEE Transactions on Fuzzy Systems, Vol. 4, No. 2, pp. 103-111, 1996.
- [Zade 01] L. A. Zadeh, Interview, Erschienen: KI 3/-1, Kunstlike Intelligenz, 24.09.2001.
- [Băla94] M. Bălaș, V. Bălaș, C. Nicolescu, "Traductoare pentru măsurarea vitezei vagoanelor realizate în Arad", Sesiunea a II-a de Comunicări Științifice a Universității "Aurel Vlaicu" Arad, pag. 65-69, mai, 1994.
- [Băla97] M. Bălaș, V. Bălaș, "Metode ale inteligenței artificiale aplicate în construcția vehiculelor moderne de cale ferată", Sesiunea a IV-a de Comunicări Științifice ale Univ. "Aurel Vlaicu" Arad, Vol. VIII - Electrotehnică, Electronică și Automatizări, pag. 379-386, octombrie 1997.
- [Băla98a] V. Bălaș, "Traductoare inteligente și aplicațiile lor". Referat I pentru doctorat, Universitatea „Politehnica” Timișoara, 1998.

[Băla 99a] V. Bălaș, "The Computer Model of an Intelligent Speed Sensor for Railway Coaches". Proceedings of the 5th International Conference on Engineering of Modern Electric Systems, University of Oradea, Romania, May, 1999.

[Băla99b] V. Bălaș, "Posibilitatea aplicării sistemelor fuzzy în tractoare inteligente". Referat II pentru doctorat, Universitatea „Politehnica” Timișoara, 1999.

[Băla00b] V. Bălaș, "Rolul de interfață simbolică a senzorilor fuzzy ", Analele Universității „Aurel Vlaicu”, seria Electrică, fascicula Electrotehnică, Electronică și Automatizări, Arad, oct., 2000, pag. 55-62.

[Băla01b] M. Bălaș, V. Bălaș, L. Foully, S. Galichet, "A model of the sliding wheel during braking", 5th International Conference on Railway Bogies and Running Gears, Budapest, BOGIE'01, 2001.

[Băla 02b] V. Bălaș, "A fuzzy fusion sensor of the speed of a railway car during the sliding of the wheels including a model of the ABS braking equipment". 9-th International Conference on Information Processing and Management of Uncertainty in Knowledge based systems, IPMU'02, Annecy, France, July 1-5, 2002, pag. 1979-1986.

[Băla02c] V. Bălaș, M. Bălaș, "The real-time evaluation of the adherence by internal model", Proceedings of the International Mini-Conference on Vehicle Dynamics, Budapest University of Technology and Economics, Department of Railway Vehicles, Budapest, Hungary, Nov., 2002.

[Băla02d] M. Bălaș, V. Bălaș, L.S. Bocii, I. Radu, I. Koles, "The real-time evaluation of the weariness of the disk brake ", Proceedings of the International Mini-Conference on Vehicle Dynamics, Budapest University of Technology and Economics, Department of Railway Vehicles, Budapest, Hungary, Nov., 2002.

[Băla02e] V. Bălaș, M. Bălaș, "Senzor inteligent al aderenței roată-șină pentru vagoanele de călători", Analele Universității „Aurel Vlaicu”, seria Electrică, fascicula Electrotehnică, Electronică și Automatizări, Arad, noiembrie, 2002, pag. 27-34.

[Băla02f] M. Bălaș, V. Bălaș, "Utilitatea modelelor interne pentru vagoanele de călători ", Analele Universității „Aurel Vlaicu”, seria Electrică, fascicula Electrotehnică, Electronică și Automatizări, Arad, noiembrie, 2002, pag. 19-26.

[AFNO88] AFNOR, "Maintenance industrielle", Recueil de norms, francaises, Edition AFNOR, 3eme edition, Paris, 1988.

[CIAM87] Livre Blanc "Les capteurs intelligents - Reflections des utilisateur", CIAME AFCET, 1987,

[Diet90] *** - "Schema de principiu 2613.80.001", De Dietrich et C^{ie} (schema instalației electrice a vagonului CORAIL).

[GUI93] *** - Guide for the expression of uncertainty in measurement, ISO, 1993.

[ICPV] *** - Documentații referitoare la frâne - I.C.P. Vagoane Arad.

[Knor90] *** - Frâna KE P-R-MG 8X10'', Knorr Bremse.

[Knor94] *** - "Specifications techniques. Manuel d'entretien des antirayeurs pour bogie Y 32 Roumanie", De Dietrich & Cie, 1994.

[UIC] *** - Fișele UIC.

Măsurători și traductoare

A1.1. Măsurători

Știința și tehnica interferează puternic constituind împreună *tehnologia*. Știința enunță legi bazate pe diferite mărimi pentru alcătuirea unui ansamblu coerent de cunoștințe. Operațiunile de *măsurare* permit trecerea de la aprecierile calitative (descrierea percepției) la cele cantitative (transformarea acestei percepții în cantitate).

Prin *măsurand* înțelegem orice mărime fizică sau variabilă de stare care face obiectul unei măsurători. Măsurătoarea reprezintă acțiunea de cuantificare a valorii unui măsurand. Rezultatul unei măsurători poate fi denumit *măsură*.

La început omul, nomad fiind, s-a luat pe el ca referință, utilizând diferite părți ale corpului său ca unități de măsură - unități aproximative, dar în același timp universale și întotdeauna disponibile. De exemplu un picior este echivalent cu 33cm.

Măsurătorile au devenit una dintre sursele principale de cunoștințe științifice: “Doar despre ceea ce măsurați puteți vorbi” - observa lordul Kelvin - și “doar comparând prin numere veți ști ceva despre subiectul vostru, dar dacă nu știți măsura, cunoștințele vor fi slabe și puțin satisfăcătoare”. Într-adevăr științele experimentale nu se pot dezvolta decât cu prețul evaluărilor cantitative din ce în ce mai precise.

Omul are întotdeauna tendința de a atribui o valoare mărimilor care-l înconjoară, fie pentru schimburi comerciale, fie pentru a compara, fie pentru a îmbunătăți condițiile de viață sau cunoștințele sale.

Măsurarea presupune construirea unei corespondențe între valoarea măsurandului și o scală numerică absolută sau relativă. Este necesar ca această corespondență să fie ușor reproductibilă și transmisibilă. De asemenea măsurării trebuie să-i poată fi asociat un grad de încredere, care să reflecte măsura în care rezultatul obținut este cert sau mai puțin cert.

Pentru ca unui dispozitiv de măsurare să-i poată fi certificat un anumit grad de încredere, el trebuie comparat cu alte dispozitive de măsurare, având un grad foarte mare de încredere, numite *etalioane*. Etaloanele sunt dispozitive fizice sau materiale a căror valoare este cunoscută și permite verificarea cu exactitate a rezultatelor oferite de alte dispozitive de măsurare. Influența pe care alte mărimi, diferite de măsurand, o exercită asupra măsurătorilor, este nedorită dar de cele mai multe ori nu poate fi evitată. Este de dorit ca mărimile de influență să fie determinate cât mai precis, pentru ca influența lor asupra măsurătorii să fie minimizată.

Măsurarea este *directă* atunci când nu necesită *intermedieri*. Atunci când măsurarea directă nu este posibilă, se pot aplica metode de *estimare*, prin care valoare măsurandului se obține combinând date și informații indirecte.

Fără îndoială progresul metrologiei, disciplina științifică dedicată măsurării, urmează progresului celorlalte științe, dar adesea îl și precedă și îl provoacă. Tehnologiile apărute în ultimele decenii au permis dezvoltarea unor noi concepte și produse în domeniul măsurătorilor. Astăzi dispozitivele de măsură nu se mai mulțumesc să transforme pur și simplu mărimile de intrare în date, ci devin “inteligente”.

A1.2. Senzori și traductoare

A1.2.1. Definiții și caracteristici generale

După norma AFNOR (NF X 07-001) [AFNO88], un senzor este elementul sensibil al unui aparat de măsură sau al unui canal de măsură, pe care este aplicată direct măsurandul. O altă definiție posibilă este următoarea: dispozitiv care permite conversia unui fenomen fizic sub forma unui semnal, definit pe un domeniu pe care consumatorul poate să îl manipuleze, în vederea reprezentării. De regulă semnalele de la ieșirea senzorilor moderni sunt de natură electrică.

În funcție de proveniența energiei necesară măsurării se disting:

- *senzorii activi*, care funcționează pe baza energiei furnizate chiar de către măsurand; Un exemplu de senzor activ este termocuplul, care furnizează o tensiune dependentă de temperatură;
- *senzorii pasivi*, care trebuie să fie excitați printr-o energie suplimentară (de obicei electrică). Un astfel de senzor este rezistența unui fir de platină, care variază cu temperatura, dar nu poate fi măsurată fără aplicarea unui curent cunoscut.

Senzorii pot fi utilizați în două categorii de aplicații:

- în aparatura de măsură;
- în componența sistemelor de conducere automată, în bucle de reglare automată;

În continuare senzorii incluși în sistemele de conducere automată vor fi denumiți *traductoare*.




Figura A1.1. Structura unui traductor

Traductorul permite obținerea unei reprezentări a stării procesului (vezi fig. A1.2). Această reprezentare trebuie să fie cât mai “adevărată” posibil. Credibilitatea măsurii definește aptitudinea dispozitivului de măsură de a furniza informații de măsură cu un grad de încredere impus.

Pentru condiționarea și transmiterea semnalelor produse de senzori, aceștia trebuie incluși în *canale de măsurare*, constituite din ansamblul dispozitivelor care concurează la realizarea măsurătorilor și la transmiterea rezultatelor înspre utilizator. Fără canalul de măsurare senzorii sunt inutilizabili [Băla94].

Într-un sistem automatizat de producție, canalul de măsură permite achiziția de informații despre starea proceselor, având ca destinație sistemul informatic care elaborează semnalele de comandă și sintetizează informațiile destinate operatorilor.

La traductoarele analogice, semnalul electric rezultat din senzor este purtător de informație utilă legată de fenomenele fizice dar este în general de nivel scăzut și depinde atât de măsurand cât și de alte mărimi de influență care “bruiază” semnalul. Semnalul purtător de informație suferă o serie de transformări efectuate printr-un circuit de condiționare a semnalelor. Aceste condiționări pot consta din amplificări, filtrări, compensări analogice ale mărimilor de influență, etc. Semnalul este apoi transmis utilizatorului după anumite standarde cu ajutorul transmițătorului.

Ansamblul prezentat în fig. A1.2, formează traductorul analogic clasic sub forma sa cea mai simplă.

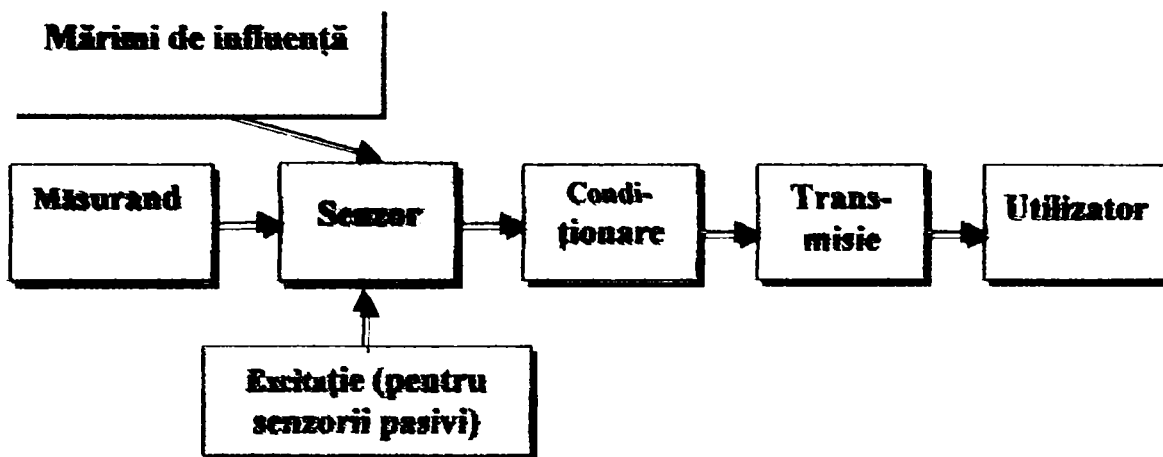


Fig. A1.2. Traductor analogic tradițional

A1.2.2. Principalele caracteristici metrologice

a) Sensibilitatea și rezoluția

Sensibilitatea unui senzor S_i , definită în jurul unui punct de funcționare m_i (o valoare constantă a măsurandului), este definită ca raportul dintre creșterea mărimii de ieșire Δs și creșterea corespunzătoare a măsurandului Δm , în jurul valorii m_i .

$$S_i = \left[\frac{\Delta s}{\Delta m} \right]_{m=m_i} \quad (\text{A1.1})$$

Sensibilitatea este constantă într-un sistem linear și depinde de valoarea măsurandului m_i ; într-un sistem neliniar.

Sensibilitatea este în general dată pentru condiții de folosire specifice.

Rezoluția definește creșterea minimă a măsurandului care provoacă o modificare decelabilă a mărimii de ieșire.

b) Decalajul de zero

Noțiunea de *decalaj de zero* se aplică senzorilor al căror semnal de ieșire este teoretic nul pentru o valoare a măsurandului egală cu zero. Decalajul de zero (offset zero) este valoarea măsurandului pentru care ieșirea este efectiv nulă.

c) Eroarea de măsură

Valoarea adevărată a măsurandului este cea care determină excitația senzorului. O măsură este atinsă de eroare când ea se îndepărtează de adevărata valoare a măsurandului, acest ecart numindu-se *eroare de măsură*. Singurii măsuranzi a căror valoare de măsură este cunoscută perfect sunt mărimile etalon, deoarece ele sunt fixate prin convenție. Este de remarcă de la început că valoarea adevărată rămâne din principiu inaccesibilă măsurătorilor, deoarece și etaloanele prezintă și ele erori de măsură, care însă se caută să fie minimizezate, atât de către producători (prin măsuri constructive) cât și de către utilizatori (prin metodele de exploatare și mentinere).

Valoarea măsurată, la care are acces utilizatorul, depinde de răspunsul global al canalului de măsură. Eroarea de măsură care nu poate fi cunoscută cu exactitate, dar poate fi estimată, este produsă de imperfecțiunile senzorului și canalului de măsură, care degradează informația în cursul tratării semnalului. Se disting:

- **erorile sistematice**, caracterizate de un ecart constant între valoarea adevărată și cea măsurată. Ele sunt puse în evidență statistic, printr-un ecart dintre valorile cele mai probabile a două serii de măsurători făcute pe același măsurand și efectuate prin metode și senzori diferiți. Cauzele erorilor sistematice sunt de obicei: decalajul de zero al unui aparat de măsură, deriva tensiunii de alimentare, îmbătrânirea senzorului, perturbațiile, etc.
- **erorile accidentale**, caracterizate de o apariție, amplitudine și semn aleatorii. Atunci când anumite cauze legate de apariția acestor erori pot fi determinate, ecarturile care le antrenează asupra valorii măsurandului rămân necunoscute. Erorile accidentale care rezultă sunt: erori de parallaxă, fluctuații ale tensiunii de alimentare (modificând performanțele aparatelor), influența unui parametru necorectat, perturbațiile electromagnetice, etc.

d) Precizia, justețea și fidelitatea

Precizia (exactitatea) unui senzor este aptitudinea sa de a da date apropiate de valoarea adevărată a măsurandului. Precizia depinde de *fidelitate* și de *justețe*.

Fidelitatea (repetabilitatea) permite evaluarea erorilor accidentale: cu cât gruparea rezultatelor este mai bună, erorile accidentale sunt mai reduse.

Justețea permite evaluarea erorilor sistematice: cu cât valoarea medie a rezultatelor este mai apropiată de valoarea măsurandului, justețea este mai bună.

Legendă: m = măsurand

$p(m)$ = densitatea de probabilitate

\bar{m} = valoare medie




Fig. A1.3. Componentele preciziei senzorului

e) Etalonarea și calibrarea

Etalonarea senzorului cuprinde un ansamblu de operații, efectuate în condiții specifice, care permit să se definească (sub formă grafică sau analitică) relația dintre valorile unui etalon al măsurandului și cele ale mărimii de ieșire din senzor, care este afectat de mărimile de influență. Cel mai adesea etalonarea se face într-un mod indirect, prin comparare cu un captor de referință. Etalonarea se finalizează prin *fișa de etalonare*, în care sunt detaliate erorile dispozitivului de măsurare etalonat.

Calibrarea corespunde poziționării materiale a reperelor unui aparat de măsură în funcție de valorile corespunzătoare ale mărimii măsurate. În cea mai mare parte, aceste reperi corespund zeroului aparatului și întinderii scalei.

Pentru ca un captor să dea rezultate de măsură precise după etalonare trebuie ca *repetabilitatea* măsurilor să fie garantată. Repetabilitatea exprimă capacitatea senzorului de a da valori de ieșire identice în limitele specificate, de fiecare dată când el este utilizat în condiții identice (aceeași măsură și aceeași parametri adiționali).

Pentru preîntâmpinarea uzurilor și a erorilor produse de îmbătrânire, etalonările trebuie repetate periodic.

f) Limitele de utilizare ale senzorului

Constrângerile mecanice, termice sau electrice la care este supus un senzor cauzează modificarea caracteristicilor sale. Domeniul de utilizare în care senzorul își păstrează caracteristicile nominale este delimitat de valori precise, care pot fi cunoscute prin etalonarea prealabilă a senzorului sau din specificațiile producătorului. Este indispensabil ca utilizatorul să fie avertizat asupra diverselor limite de utilizare ale senzorilor și asupra riscurilor la care se expune la depășirea lor.

Domeniul nominal de utilizare: corespunde condițiilor nominale de utilizare a senzorului; limitele sale sunt valorile extreme pe care le pot atinge în mod permanent măsurandul, mărimile fizice care îi sunt asociate sau mărimile de influență, fără ca să fie modificate diversele specificații care caracterizează funcționarea senzorului.

Domeniul de nedeteriorare: atunci când valorile măsurandului, mărimile fizice asociate sau mărimile de influență depășesc limitele domeniului nominal de folosire dar rămân în interiorul domeniului de nedeteriorare, caracteristicile metrologice ale captorului riscă să fie modificate; această alterare este totuși reversibilă: când condițiile de funcționare redevin cele nominale, senzorul își regăsește parametrii specificați.

Domeniul de nedistrugere: atunci când valorile măsurandului, mărimile fizice asociate sau mărimile de influență depășesc limitele domeniului de nedeteriorare, rămânând totuși în limitele domeniului de nedistrugere, caracteristicile senzorului sunt modificate în mod ireversibil; reutilizarea senzorului în domeniul său nominal de utilizare va necesita deci o nouă reetalonare [Asch91].

Imperfecțiunea informației: imprecizie și incertitudine

A2.1. Caracterizarea datelor și informațiilor

Toate sistemele de conducere sau de asistare a deciziilor, indiferent de complexitatea lor, au nevoie de mijloace de măsurare (percepție) care le permit să cunoască mediul înconjurător și să apoi să poată funcționa în deplină securitate. Cu ajutorul funcțiilor de măsurare se obțin datele, pe baza cărora se extrag informațiile care vor ajuta la luarea deciziilor sau la acționarea eficace asupra mediului fizic. Prin *date* se înțeleg valori numerice, în timp ce *informațiile* se referă la combinații de date, simboluri, liste, tabele, ecuații, inegalități, propoziții [Loon 01].

În general funcția de măsurare este realizată de către un senzor sau un ansamblu de senzori omogeni sau eterogeni. O altă sursă de informații o constituie cunoștințele de tip expert. Din păcate informațiile indiferent că provin de la senzori sau de la estimările experților nu sunt niciodată precise 100%. Așa cum s-a văzut și din Anexa 1, degradarea informației provine atât de la sursa de informație cât și de la influențele exterioare. Imaginea mediului fizic astfel obținută nu poate să fie perfectă deoarece este construită din date provenind de la *surse de informație imprecise și incerte*. În aplicațiile practice imprecizia trebuie întotdeauna luată în considerare, lucrând cu valori posibile [Nguy98].

Cauzele imperfecțiunii informațiilor sunt în principal două [Gupt88]:

- 1) Imprecizia senzorilor – numită și imprecizie de ordin I.
- 2) Insuficienta cunoaștere a sistemului aflat în discuție, a metodelor de măsurare și chiar a problemelor pe care le avem de rezolvat – imprecizie de ordin II.

Imprecizia poate fi atacată prin creșterea preciziei dispozitivelor de măsurare. Îmbunătățirea cunoștințelor despre sistem este mai greu de realizat, deoarece adesea fenomenele implicate sunt extrem de complexe, sau chiar aleatorii. Discriminarea tranșantă dintre imprecizie și incertitudine este totuși greu de atins [Geor95].

Cu toate dificultățile, un expert poate să depășească această situație, și să *emită* raționamente și decizii corecte în condiții de imprecizie și incertitudine. Prin urmare și sistemele expert se pot bucura de aceeași abilități [Negn02].

Principalul mijloc de limitare a inconvenientelor ridicate de imperfecțiune este apelarea la toate cunoștințele disponibile despre proces, măsuranți și senzori, care vor fi modelate și înglobate în structura senzorilor.

Pentru materializarea ideilor de mai sus, o problemă centrală o reprezintă modalitățile de reprezentare a cunoștințelor. Ce modele matematice ar trebui să alegem pentru a gestiona aceste cunoștințe imperfecte? Care este cea mai bună reprezentare a cunoștințelor pentru o problemă dată? Răspunsurile la astfel de întrebări nu sunt evidente și în continuare se vor prezenta doar câteva posibilități de reprezentare a cunoștințelor imperfecte.

Imperfecțiunea, fie ea *imprecizie* sau *incertitudine* trebuie să fie încorporată în cunoștințele unui sistem care încearcă să realizeze un model complet și precis al unor aplicații reale. Acest lucru este greu de obținut datorită dificultății de a înțelege

diferitele aspecte ale impreciziei și incertitudinii. Până recent, aproape toate aspectele imperfecțiunilor datelor au fost modelate cu ajutorul *teoriei probabilităților*, dar în ultimii 20 de ani, au fost dezvoltate modele noi pentru reprezentarea imperfecțiunii.

În continuare se vor prezenta câteva aspecte ale imperfecțiunii. Un inventar complet nu este practic posibil, dar o clasificare poate cuprinde *imprecizia, inconsistența și incertitudinea*.

A2.2. Varietăți de imperfecțiune

Informația este perfectă când este precisă și sigură. Imperfecțiunea datelor și informațiilor poate fi datorată *impreciziei, inconsistenței și incertitudinii* [Smet99]. Incertitudinea rezultă din lipsa de informație pentru a putea decide dacă starea este adevărată sau falsă. Imprecizia și inconsistența sunt proprietăți esențiale ale informației în timp ce incertitudinea este o proprietate a relației dintre informație și cunoștințele noastre despre lume.

Imprecizia este legată direct de măsurări sau de starea de funcționare a unei surse de informații și *reprezintă eroarea asociată acesteia*. *Incetitudinea* asupra unei ipoteze reprezintă *îndoiala* care se pune asupra existenței sale reale sau asupra validității sale. Imprecizia nu repune în cauză, în nici un caz, percepția pe care o avem asupra unui sistem. Ea modelează o parte a imperfecțiunii mijlocului de percepție.

Putem vedea imprecizia ca o evaluare a aspectului cantitativ a imperfecțiunii și incertitudinea ca o reprezentare a aspectului calitativ. În ciuda faptului că vom trata aceste două noțiuni independent una față de cealaltă este evident că ele sunt strâns legate. Cităm exemplul lui A. Nifle [Nifl98] care prezintă foarte bine această dependență: „Jules are în jur de 18 ani” este o afirmație imprecisă și în același timp conduce la incertitudinea asupra faptului că Jules este major.

Oricare ar fi datele pe care le vom trata, precizia și încrederea lor vor fi întotdeauna limitate de caracteristicile senzorilor care le furnizează. În ciuda acestei lipse de exactitate a măsurătorii, deciziile trebuie luate. Pentru ca aceste decizii să fie raționale și coerente trebuie să se ia în considerare imprecizia și incertitudinea prin folosirea unor instrumente care permit să se măsoare aceste noțiuni, să se modeleze și să se trateze aceste date.

Pentru a ilustra diferența dintre imprecizie și incertitudine, se pot considera următoarele situații:

1. Viteza este cel puțin 100 km/h și sunt sigur de aceasta.
2. Viteza este de 100 km/h, dar nu sunt sigur de aceasta.

În primul caz viteza este imprecisă dar sigură. În cazul al doilea viteza este precisă dar incertă. Ambele situații coexistă dar sunt distincte. De multe ori cu cât o informație este mai imprecisă cu atât este mai sigură și cu cât este mai precisă ea este mai puțin sigură. Pare să existe un fel de *Principiu al Maximalității Informației* care face ca “produsul” dintre precizie și certitudine să nu poată depăși un nivel critic. Orice creștere a unei părți este echilibrată de o descreștere a celeilalte părți.

A2.2.1. Imprecizia

Imprecizia poate fi caracterizată de prezența sau absența unei erori. Ea poate avea două forme principale care pot fi puse în evidență prin valori aproximative sau prin descrieri vagi folosind termeni din limbajul natural.

a) Imprecizia fără eroare

Informația “mâncarea este fierbinte” este *ambiguă* deoarece mâncarea poate să fie picantă sau caldă.

Informația “viteza este în jur de 60 km/h” este *aproximativă* dacă viteza este de 67 km/h. “Viteza este aproape 60 km/h” este o informație vagă (fuzzy). În primul caz este întotdeauna posibil să se determine dacă informația este corectă sau nu. În cazul informației fuzzy determinabilitatea este pierdută. Informația următoare: “Viteza este în jur de 60 km/h” este mai mult sau mai puțin corectă pentru două viteze diferite, dar este mai corectă pentru 58 de km/h decât pentru de 66 km/h. Corectitudinea admite grade odată ce conceptele implicate sunt vagi. Datele pot să *lipsească* sau pot fi *incomplete*. În funcție de context, datele incomplete pot fi asociate cu *deficiența*.

b) Imprecizia combinată cu eroare

Până acum informația nu a fost eronată. Valoarea de adevăr este compatibilă cu informația disponibilă. Se pot descrie multe aspecte ale impreciziei când sunt prezente erorile. Datele vor fi *eronate* sau *incorecte* când se greșește ca în cazul afirmației “viteza este 40 km/h” când de fapt ea este 25 km/h. Datele *imprecise* sunt într-un fel greșite dar eroarea este mică, de exemplu afirmația “viteza este 37 km/h” când viteza este 36 km/h, este desigur eronată, dar nu așa de mult, astfel că poate să fie calificată drept imprecisă.

Datele *nevalabile* sunt nu numai date eronate ci și date care pot fi potențial legate de concluzii neacceptabile.

Distorsiunea datelor este analoagă cu imprecizia combinată cu nevaliditatea. Datele sunt *afectate* dacă au fost subiectul unei erori sistematice. Datele *absurde* sau *lipsite de sens* sunt aspectele extreme ale datelor eronate. Astfel utilizatorul poate descoperi prin evidență că “viteza este de 500 km/h”, sau “starea civilă = măr” sunt informații eronate.

A2.2.2. Inconsistența

Când sunt combinate mai multe formulări pot apărea noi aspecte ale imperfecțiunii, caz în care sunt implicate întotdeauna anumite feluri de erori. O informație poate să fie *conflictuală*: “numele soției = Alexandru”. Conflictul cuprins în date poate conduce la o *incoerență* în concluzii.

Inconsistența: este mai bine folosită în contextul în care apare timpul: “la ora 3 p.m. ouăle au fost fierte și la 3.15 p.m. aceleași ouă erau proaspete”.

Logicienii au folosit inconsistența pentru a defini incoerența care rezultă dintr-o informație conflictuală.

Problema inconsistenței este actuală mai ales în contextul generării automate a regulilor de conducere și a deciziilor, deoarece „bunul simț” al omului, prin care el poate ușor filtra inconsistența informațiilor trebuie modelat și algoritmitizat.

A2.2.3. Incertitudinea

Al treilea aspect al imperfecțiunii informației, incertitudinea, privește starea de cunoștințe a unui agent (de exemplu un observator sau un calculator) despre relația dintre lume și starea despre lume. Starea este fie adevărată, fie falsă, dar cunoștințele despre lume nu permit să se decidă dacă starea este adevărată sau falsă. Certitu-

dinea reprezintă totalitatea cunoștințelor despre valoarea adevărată a datelor. Incertitudinea reprezintă cunoașterea parțială a valorii de adevărat sau fals a datelor. În general nu suntem siguri dacă o stare este adevărată sau falsă din cauza:

- Comportării aleatorii a fenomenelor, ca de exemplu factori legați de o *incertitudine probabilistică*.
- Încrederii unui observator în fenomenele care exprimă o stare, sau în datele unui senzor folosit pentru măsurători. Atunci vorbim despre o *incertitudine non probabilistică*.

Incertitudinile pot fi reprezentate fie numeric, ca în cazul probabilității sau gradelor de încredere exprimate numeric, fie lingvistic, prin grade de încredere exprimate lingvistic, indicând măsura în care suntem siguri de validitatea unei stări.

Incertitudinea poate duce la *ignoranță*. Este important, să se introducă o proprietate epistemică printr-o lipsă a informației. O cauză majoră a incertitudinii este imprecizia datelor. Dacă incertitudinea este o proprietate subiectivă sau obiectivă este încă o chestiune de dezbatere filozofică.

a) Incertitudine obiectivă

Unii specialiști [Smet99] au demonstrat că incertitudinea legată de *întâmplare* este o proprietate obiectivă și termenul *probabil* califică un eveniment care probabil se va întâmpla. Ei apără faptul că “un eveniment este probabil” este independent de opinia unui observator în legătură cu întâmplarea evenimentului și că probabilitatea (ca și întâmplarea) este o proprietate obiectivă a datelor experimentale care generează evenimentul.

Înainte de a discuta *înclinația* unui eveniment, trebuie considerată *dispoziționalitatea*. Numai evenimentele posibile pot să fie probabile. *Posibilitatea* privește capacitatea unui eveniment de a se produce, a “capacității de întâmplare”, în timp ce probabilitatea privește tendința sa de a se întâmpla. În mod identic, ea privește capacitatea propoziției de a fi adevărată.

Necesitatea este duala posibilității și anume necesitatea este imposibilitatea contrariului.

b) Incertitudinea subiectivă

Proprietatea de obiectivitate a incertitudinii este legată de mediu și de informație. Proprietatea de subiectivitate a incertitudinii este legată de opinia unui observator despre valoarea datelor așa cum rezultă din datele disponibile.

Datele sunt *credibile* sau *probabile* dacă sunt acceptate, chiar temporar. Datele sunt *discutabile* dacă nu sunt credibile sau mai rău, dacă ar fi acceptate, dar cu o puternică împotrivire.

Relația dintre *probabilitate* (egalată cu încrederea în contextul subiectiv) și *posibilitate* așa cum s-a întâlnit la incertitudinea obiectivă poate fi de asemenea descrisă în context subiectiv. *Posibilitatea* și *necesitatea* sunt proprietăți epistemice care reflectă opinia unui observator despre starea de adevăr. Numai stările posibile pot fi crezute.

Neîncrederea reflectă opinia observatorului despre sursa datelor, opinie care este transferată în al doilea rând datelor.

Irelevanța caracterizează opinia observatorului despre date iar *hotărârea*, capacitatea observatorului de a decide dacă informația este adevărată sau falsă.

Sursa principală a incertitudinii este imprecizia. De obicei incertitudinea admite un fel de ordonare și reprezintă domeniul privilegiat al aplicațiilor pentru modelare calitativă. Imprecizia induce incertitudine, dar natura acestei incertitudini și cuantificarea sa va depinde de tipul impreciziei.

A2.3. Modelarea

Modelele pentru datele imperfecte pot fi separate în două categorii: modelele *simbolic-calitative* și *numeric-cantitative*. Cele mai multe modele cantitative sunt afectate de incertitudine. Un caz special îl reprezintă teoria mulțimilor fuzzy care este principial fezabilă atât în tratarea impreciziei cât și a incertitudinii.

A2.3.1. Cuantificarea impreciziei: mulțimile fuzzy

Imprecizia este reprezentată de o informație disjunctivă care caracterizează o mulțime de valori posibile la care se știe că aparține valoarea actuală. Recent conceptul clasic de mulțime a fost extins la mulțimi fuzzy care au fost folosite pentru a caracteriza informația disjunctivă “ordonată”. În mod clasic, mulțimile sunt ferme, în sensul că un element fie aparține unei mulțimi, fie este exclus din ea. În 1965 Zadeh a introdus ideea de mulțimi ne-ferme, numite mulțimi fuzzy. Fuzzycitatea este o proprietate legată de folosirea unor predicate vagi ca: „Ion este înalt”. Predicatul de mai sus este fuzzy, deoarece cuvântul folosit la definirea sa este slab definit.

Idea este că apartenența la o mulțime admite un grad de apartenență care nu este necesar să fie exact 0 sau 1 cum ca și în cazul teoriei clasice a mulțimilor. Pentru unele elemente ale universului de discurs nu se poate spune cu certitudine dacă ele aparțin sau nu unei mulțimi. La cele mai multe se pot evalua unele grade de apartenență $\mu_A(x)$ ale elementului x la mulțimea A . Această funcție generalizează indicatorul clasic de funcție $I_A(x)$ al mulțimii:

$$\begin{cases} I_A(x) = 1 \text{ dacă } x \in A \\ I_A(x) = 0 \text{ dacă } x \notin A \end{cases}$$

Lotfi Zadeh înlocuiește domeniul $\{0, 1\}$ cu intervalul $[0,1]$.

Pornind de la această idee pot fi formalizate concepte noi ca: numere fuzzy, probabilitate fuzzy, predicate fuzzy (înalt), cuantificatori fuzzy (mulți, puțini), precum și modificatori lingvistici (foarte) [Dubo80]. Au fost generalizați operatorii clasici ai mulțimilor ca: reuniune, intersecție și negare. Majoritatea soluțiilor fuzzy se bazează pe operatorii min-max:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x)$$

$$\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x))$$

$$\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x))$$

Au mai fost propuși și alți operatori care aparțin familiei de norme și conorme triunghiulare [Dubo88].

Legea terțului exclus nu se aplică în cazul mulțimilor fuzzy. Într-adevăr:

$$\mu_{A \cap \bar{A}}(x) = \min(\mu_A(x), \mu_{\bar{A}}(x))$$

poate fi mai mare decât 0. Acest lucru poate să pară ciudat la prima vedere, dar nu spune altceva decât faptul că se poate să fii simultan într-un fel înalt și nu, o proprietate perfect validă.

Matematic, teoria mulțimilor fuzzy generalizează conceptul de mulțime. Domeniul de aplicație cel mai simplu este modelarea impreciziei și a vagului. Teoria fuzzy creează o ordine printre valorile posibile la care aparține valoarea actuală.

Unii autori au încercat să ignore teoria mulțimilor fuzzy (MF) prin declararea că aceasta este subsumată măsurii de probabilitate.

Teoria MF privește apartenența individuală bine definită la o mulțime slab definită în timp ce probabilitatea privește apartenența individuală nedefinită încă la o mulțime bine definită. Introducerea mulțimilor aleatoare nu schimbă conceptual cadrul. Desigur există relații matematice între cele două teorii dar problema nu este legată de compararea lor matematică ci de compararea problemelor pe care încearcă să le modeleze. Teoria fuzzy tratează imprecizia, iar probabilitatea incertitudinea. Bineînțeles că orice MF are asociată o anumită doză de incertitudine.

A2.3.2. Cuantificarea incertitudinii: măsura fuzzy Sugeno

Michio Sugeno a dezvoltat conceptul de măsură fuzzy. El a studiat funcțiile care exprimă incertitudinea asociate cu afirmația “x aparține lui S” unde S este o mulțime fermă (și generalizarea la mulțimi fuzzy S este posibilă) și x este un element particular arbitrar al lui X, care nu este localizat *a priori* în oricare din submulțimile lui X. Măsura fuzzy Sugeno g satisface următoarele proprietăți:

$$G_1: g(\emptyset) = 0; g(X) = 1$$

$$G_2: \text{pentru toți } A, B \subseteq X, \text{ dacă } A \subseteq B, \text{ atunci } g(A) \leq g(B)$$

$$G_3: \text{pentru toți } A_i \subseteq X, i \in \mathbb{N}, \text{ dacă } A_1 \subseteq A_2 \subseteq \dots \text{ sau } A_1 \supseteq A_2 \supseteq \dots \\ \text{atunci } \lim_{i \rightarrow \infty} g(A_i) = g(\lim_{i \rightarrow \infty} A_i)$$

Pentru X finit, măsura Sugeno este o măsură normalizată, monotonă pentru incluziune. Ea se potrivește cu măsura de probabilitate, măsura de posibilitate, măsura de necesitate, funcțiile de încredere. A fost numită măsură “fuzzy”, dar ar trebui să nu fie confundată cu mulțimile fuzzy.

A2.3.3. Măsurile de posibilitate și necesitate

a) Măsura de posibilitate

O informație incompletă ca de exemplu “înălțimea lui Ion este peste 170cm” implică faptul că înălțimea h este peste 170cm, este posibilă și orice înălțime egală sau sub 170cm este imposibilă. Aceasta poate fi reprezentată printr-o măsură de posibilitate definită pe domeniul a cărui valoare este 0 dacă $h < 170\text{cm}$ și 1 dacă $h \geq 170\text{cm}$ (cu 0 = imposibil și 1 = posibil).

Când predicatul este vag ca de exemplu în “Ion este înalt”, posibilitatea poate admite grade, cel mai mare grad reprezentând cea mai mare posibilitate. Cu toate că posibilitatea este adesea asociată cu fuzzy și evenimentele non fuzzy (ferme) pot admite diferite grade de posibilitate.

Exemplu: Presupunem că într-o mașină încearcă să se urce oameni. Se poate spune: „este posibil să urce 5 oameni, imposibil să urce 10, aproape posibil să urce 6

oameni, dar nu este așa de posibil să urce 7.” Aceste grade de posibilitate sunt grade de realizabilitate și total fără legătură față de orice probabilitate de bază a procesului aleatoriu.

Fie $\Pi: 2^\Omega \rightarrow [0,1]$ *măsura de posibilitate*, definită pe spațiul Ω cu $\Pi(A)$ pentru $A \subseteq \Omega$, fiind gradul de posibilitate a lui A (este adevărat, se întâmplă).

Axioma fundamentală este aceea că posibilitatea $\Pi(A \vee B)$ a două propoziții disjuncte A și B este maximul posibilității propozițiilor individuale $\Pi(A)$ și $\Pi(B)$ [Zade78].

$$\Pi(A \vee B) = \max(\Pi(A), \Pi(B)) \quad (\text{A2.1})$$

De obicei se cere de asemenea ca $\Pi(\Omega) = 1$

Ca și în logica modală, unde *necesitatea* unei propoziții este negarea posibilității negației sale se definește măsura de necesitate $N(A)$ dată unei propoziții A , prin relația:

$$N(A) = 1 - \Pi(\neg A)$$

În acest caz avem următoarele relații:

$$N(A \wedge B) = \min(N(A), N(B))$$

În schimb vom avea:

$$\Pi(A \wedge B) \leq \min(\Pi(A), \Pi(B))$$

$$N(A \vee B) \geq \max(N(A), N(B))$$

Măsura de necesitate a fost introdusă ulterior celei de posibilitate de către Didier Dubois [Dubo88].

Fie Ω universul de discurs pe care este definită măsura de posibilitate. Legat de măsura de posibilitate $\Pi: 2^\Omega \rightarrow [0,1]$ se poate defini *distribuția de posibilitate*:

$$\pi(x) = \Pi(\{x\}), \text{ pentru toți } x \in \Omega.$$

Mulțumită lui (A2.1), avem:

$$\Pi(A) = \max_{x \in A} \pi(x) \text{ pentru toți } A \in \Omega.$$

Un lucru esențial în teoria posibilității (și în teoria MF) când sunt folosiți numai operatorii \max și \min este faptul că valorile date măsurii de posibilitate sau gradului de apartenență nu sunt intrinsec esențiale. *Singurul element important al măsurii este ordinea pe care o creează printre elementele domeniului.* Într-adevăr ordinea este invariantă sub orice transformare strict monotonă. De aceea o schimbare a scalei nu va afecta concluziile. Această proprietate explică de ce se insistă pe faptul că *teoria posibilității este esențial o teorie ordinală* și nu se aplică acolo unde s-au introdus adunarea și multiplicarea, ca în cazul funcțiilor de încredere și de probabilitate.

Exemplu: În exemplul clasic al folosirii măsurii de posibilitate în comparație cu măsura de probabilitate, se consideră numărul de ouă X pe care Hans (Zimmerman) le poate comanda dimineața [Zade78].

Fie $\pi(u)$ gradul de ușurință cu care Hans poate mânca u ouă. Fie $p(u)$ probabilitatea ca Hans să mănânce u ouă la micul dejun mâine. Presupunerile despre valorile lui $\pi(u)$ și $p(u)$ sunt date în tabelul 4.

Tabelul 1: Distribuțiile de posibilitate și de probabilitate asociate lui X.

u	1	2	3	4	5	6	7	8
$\pi(u)$	1	1	1	1	0.8	0.6	0.4	0.2
$p(u)$	0.1	0.8	0.1	0	0	0	0	0

Observăm că, în timp ce posibilitatea ca Hans să mănânce 3 ouă la micul dejun este 1, probabilitatea că el ar fi putut să facă lucrul acesta este foarte mică, adică 0,1. Astfel un grad înalt al posibilității nu implică un grad înalt al probabilității, și nici un grad scăzut al probabilității nu implică un grad scăzut al posibilității. Totuși dacă un eveniment este imposibil, el este limitat să fie improbabil. Această conexiune euristică între posibilitate și probabilitate poate să fie exprimată sub forma a ceea ce se poate numi *principiul consistenței posibilitate probabilitate* [Zade78].

A2.3.4. Posibilitate fizică și epistemică

Au fost descriși doi termeni ai posibilității: *fizic* și *epistemic*. Aceste două forme de posibilitate pot fi recunoscute prin folosirea lor lingvistică diferită: este *posibil ca* și este *posibil pentru*.

Prima formă “e posibil ca” este legată de starea noastră de cunoștințe și se numește *posibilitate epistemică*. A doua formă “e posibil pentru”, are de-a face cu abilitățile actuale independent de cunoștințele noastre despre ele și se numește *posibilitate fizică*. Aceste forme de posibilitate sunt evident concepte neindependente, dar structura exactă a interrelațiilor lor nu este încă clar stabilită.

A2.3.5. Relația dintre fuzzycitate și posibilitate

Zadeh a introdus ambele concepte: cel de mulțime fuzzy în 1965 și cel de măsură de posibilitate în 1978. Primul permite să se descrie gradul de apartenență al unei caracteristici bine cunoscute la o mulțime slab definită. Al doilea permite să se descrie care sunt caracteristicile care satisfac anumite constrângeri slab definite sau care aparțin anumitor mulțimi slab definite.

De exemplu $\mu_{\text{inalt}}(h)$ cuantifică gradul de apartenență a unei persoane cu înălțimea h la mulțimea de oameni *înalti* și $\pi_{\text{inalt}}(h)$ cuantifică posibilitatea ca înălțimea h dată a unei persoane să aparțină mulțimii de oameni *înalti*. *Principiul posibilistic al lui Zadeh* postulează următoarea egalitate:

$$\pi_{\text{inalt}}(h) = \mu_{\text{inalt}}(h) \text{ pentru toți } h \in H$$

unde H este mulțimea de înălțime = $[0, \infty)$

Scrierea este adeseori confuză și ar trebui scrisă ca:

$$\pi(h|\text{inalt}) = \mu_{h|\text{inalt}} \text{ pentru toți } h \in H$$

sau chiar mai bine:

$$\text{Dacă } \mu(h|\text{inalt}) = x \text{ atunci } \pi_{h|\text{inalt}} = x \text{ pentru toți } h \in H$$

Ultima expresie evită confuzia dintre cele două concepte. Ea arată că ele împart aceeași scală fără să determine faptul că posibilitatea este o funcție de apartenență și viceversa. Expresia anterioară indică clar domeniul de măsură (mulțimi pentru gradul de apartenență μ și înălțime pentru distribuția de posibilitate π) și cunoștințele de bază (înălțime pentru μ și mulțime pentru π). Diferența este analoagă cu

diferența dintre distribuția de probabilitate $p(x|\theta)$ (probabilitatea observației x având dată ipoteza θ) și o funcție de probabilitate $l(\theta|x)$ (probabilitatea ipotezei θ având dată observația x) caz în care principiul posibilistic al lui Zadeh devine principiul probabilității:

$$l(\theta|x) = p(x|\theta)$$

Probabilitatea unei ipoteze θ având dată o observație x este egală cu probabilitatea observației x având dată ipoteza θ .

Scrierea inițială a principiului posibilistic al lui Zadeh, este cazul cel mai uzual întâlnit, dar înțelesul său ar trebui să fie interpretat cu grijă. El stabilește că posibilitatea ca un om să aibă înălțimea h este numeric egală cu gradul de apartenență la mulțimea de oameni înalți a unui om cu înălțimea h .

Măsura de posibilitate este legată de distribuția de posibilitate π prin:

$$\Pi_A(X) = \max_{x \in X} \pi_A(x),$$

unde X este o mulțime fermă. Aceasta se generalizează prin:

$$\Pi_A(X) = \max_{x \in \Omega} \min(\pi_A(x), \mu_X(x)),$$

unde Ω este domeniul lui x și X este o submulțime fuzzy a Ω . Se poate astfel exprima posibilitatea ca înălțimea unei persoane să fie aproape 180cm spunând că persoana este înaltă.

În general, avem relațiile:

$$\Pi_A(X \cup Y) = \max(\Pi_A(X), \Pi_A(Y))$$

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

Nu avem relații similare în cazul operatorilor de intersecție. Este adevărat că:

$$\mu_{A \cap B}(X) = \min(\mu_A(X), \mu_B(X))$$

dar nu ar trebui să deducem că:

$$\Pi_{A \cap B}(X) = \min(\Pi_A(X), \Pi_B(X)),$$

asa cum în mod eronat se presupune de către unii autori neglijenți.

Dar nu avem nici:

$$\Pi_A(X \cap Y) = \min(\Pi_A(X), \Pi_A(Y))$$

Prin dualitate avem de asemenea următoarele relații:

$$N_A(X \cap Y) = \min(N_A(X), N_A(Y))$$

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

Nu există relații similare pentru operatorii de reuniune.

Legătura dintre mulțimile fuzzy și măsura de posibilitate este stabilită prin principiul posibilistic al lui Zadeh. Un principiu identic poate fi folosit de asemenea pentru a lega atât mulțimile fuzzy cât și măsura de posibilitate cu adevăruri parțiale. Să presupunem că:

$$v(\text{John este înalt} | \text{înălțime (Ion) = } h) = \mu_{\text{înalt}}(h) = \pi_{\text{înalt}}(h)$$

Astfel gradul de adevăr al propoziției “Ion este înalt”, dacă acest lucru există, cunoscând că “înălțimea lui Ion este h ” este numeric egal cu gradul de apartenență al persoanei cu înălțimea h la mulțimea oamenilor înalți și apoi cu posibilitatea ca înălțimea unei persoane înalte este h .

Fuziunea datelor și informațiilor

A3.1. Introducere în fuziunea senzorilor

Idea fuziunii senzorilor a apărut la începutul anilor 60 în aplicații militare și civile de urmărire multi-radar a traficului aerian. Cu ajutorul *fuziunii multisenzor a datelor* se încearcă să se combine informația generată de senzori multipli pentru a obține o nouă informație care ar fi foarte greu sau imposibil de obținut cu un singur senzor.

La începutul anilor '80 cercetătorii din domeniul militar au fost primii care au folosit în aplicațiile lor ceea ce astăzi este cunoscut sub denumirea de *fuziunea informației*. De atunci acest concept a cunoscut o largă dezvoltare variate domenii.

Mai ales în ultimii ani, datorită dezvoltării puternice a tehnologiei informației s-au publicat foarte multe lucrări despre fuziunea informației. Bibliografia parcursă în această anexă [Vale00], [Wal00], [Dasa97] are scopul să ajute la:

- alegerea unor date relevante și necesare pentru intrările sistemului de fuziune și alegerea senzorilor folosiți pentru achiziționarea acestora.
- alegerea reprezentării matematice a datelor considerate și alegerea mecanismului pentru a le combina în mod adecvat.
- alegerea formatului informației de ieșire pentru a obține o interpretare ușoară a rezultatelor date de către sistemele de fuziune în vederea unor prelucrări viitoare.

Fuziunea senzorilor, studiul conceptelor și tehnicile dezvoltate pentru prelucrarea informației în mediul cu senzori multi-distribuiți mergând spre integrarea inteligentă a datelor multisenzor a câștigat o popularitate deosebită în ultimul deceniu [Dasa97].

A3.2. Definiții

La definirea precisă a fuziunii datelor s-au ridicat o serie de discuții. De aceea s-a propus de către *Joint Directors of Laboratories Data Fusion Working Group*, grup creat în 1986, un *Lexicon* al fuziunii datelor, prin care s-a impus o terminologie specifică. Modelul propus a fost dedicat în principal aplicațiilor militare. În [Bloc98] se prezintă un alt punct de vedere care este adaptat problemelor de fuziune din mai multe domenii. În loc să se focalizeze pe sistem, se definește fuziunea datelor ca un proces care combină informațiile obținute de la mai multe surse pentru luarea unei decizii. Acest proces urmărește îmbunătățirea deciziei care poate fi luată din informația parțială prin adunarea mai multor surse, părți de date sau cunoștințe, obținând o mai bună înțelegere a fenomenelor observate. Această definiție se concentrează mai mult pe combinare și decizie decât pe arhitectura sistemului și pe proiectare.

Definițiile propuse au fost adaptate unor activități specifice sau unei aplicații date. O propunere recentă cu caracter mai general apare în [Vale00]:

“ Fuziunea datelor reprezintă un cadru formal în care sunt cuprinse mijloace și instrumente care reunes date provenite de la diferite surse. Fuziunea încearcă să obțină informație de o calitate mai bună; definiția exactă a termenului “calitate mai bună” va depinde de aplicație”.

Prima parte a definiției scoate în evidență prin “mijloace și instrumente pentru unificarea datelor” importanța arhitecturii și a instrumentelor matematice în sistemele de fuziune. A doua parte a definiției “informație de o calitate mai bună” scoate în evidență scopul și performanțele fuziunii.

În context pot fi incluși termeni ca: fuziunea datelor, fuziunea imaginilor, fuziunea senzorilor, precum și tipuri variate de informații care pot merge de la măsurători până la rapoarte verbale. De exemplu, prin *sursă de informație* se înțelege orice sistem care observă o situație reală, mergând de la un captor fizic până la operatorul uman, sau indicând care sunt a priori situațiile reale posibile [Nif98].

Definiția de bază a fuzionării informației este combinarea sau contopirea datelor de la diferiți senzori pentru a obține (furniza) o informație de o calitate mai bună decât a oricăreia dintre sursele implicate [Rao99],[Loon01].

Fuziunea cuprinde contopirea datelor și/sau a informației, putând fuziona date-date, date-informații sau informații-informații. Prin *date* se înțeleg valori numerice, în timp ce *informațiile* se referă la combinații ale datelor, simboluri, liste, fișiere, ecuații, inegalități, propoziții, etc. Datele se referă la măsurători sau la informația obținută de senzori iar fuziunea este procesul de combinare a acestor date astfel încât rezultatul obținut să furnizeze mai multă informație în comparație cu datele individuale.

Fuziunea poate avea ca efect *agregarea* informației, prin care se pot utiliza fragmente de informație furnizate de diferite surse pentru a ajunge la o concluzie sau la o decizie. Problema este semnificativă pentru înmagazinarea informației numerice în calculatoare.

Fig. A3.1 prezintă fuziunea datelor în cazul a N măsurători multiple și incerte z_i , obținute prin N senzori, pentru a realiza o singură stare estimată a caracteristicii.

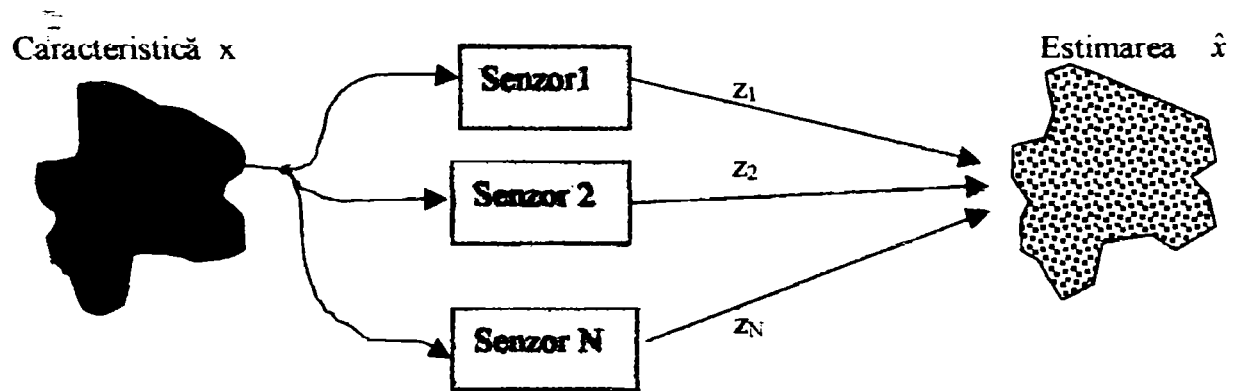


Fig. A3.1. Fuziunea datelor senzorilor

Definirea fuziunii datelor senzorilor poate să varieze în funcție de scop, după cum se poate constata din următoarele definiții reprezentative [Many94]:

„ *Fuziunea datelor este procesul prin care datele de la o multitudine de senzori sunt folosite pentru a produce o estimare optimală a vectorului de stare al sistemului*”.

„ *Problema fuziunii senzorilor este aceea a combinării măsurătoarelor multiple de la senzori, într-o singură măsurătoare a parametrului detectat*”.

„ *Fuziunea datelor lucrează cu combinarea sinergistică a informației disponibile de la variate surse de cunoștințe ca de exemplu senzori, pentru a furniza o mai bună înțelegere a procesului dat*”.

După Richard R. Brooks (Universitatea Monterey Bay-California) și Sitharamar Iyengar (Universitatea Louisiana), „*Integrarea senzorilor se ocupă cu utilizarea sinergistică a surselor multiple de informație*”. Ei spun că fuziunea senzorilor este o componentă majoră a integrării senzorilor, a fuzionării intrărilor multiple într-o reprezentare comună. Ei clasifică senzorii, în funcție de rolul lor în fuziune, în trei categorii: senzori complementari, senzori competitivi și senzori cooperativi.

- *Senzorii complementari* nu depind unii de alții direct, dar pot fi fuzionați pentru a forma o imagine mai completă despre mediu. Fuziunea complementară este ușor de implementat deoarece nu este prezentă nici o informație conflictuală.
- *Senzorii competitivi* furnizează fiecare o informație echivalentă despre mediu. O configurație tipică de senzori competitivi determină o formă de redundanță.
- *Senzorii cooperativi* lucrează împreună pentru a obține informația pe care nici unul dintre senzori singur, nu ar putea să o furnizeze.

Un singur senzor are capacități limitate de a rezolva ambiguitățile și de a furniza descrieri consistente ale mediului supus măsurărilor. În ciuda progreselor făcute în domeniul tehnologiei senzorilor, a metodelor de calcul și algoritmilor, nici un senzor singur, nu este capabil să obțină o *informație sigură*, în orice moment, în împrejurări diferite și uneori dinamice. Luând ca model organismele biologice, care sunt în esență sisteme de percepție multisenzoriale, multe sisteme inteligente fac uz de o multitudine de senzori pentru a extrage cât mai multă informație din mediul înconjurător.

— Sistemele multisenzor utilizează [Many94]:

- *Redundanța*, adică folosirea a doi sau mai mulți senzori pentru a măsura același măsurand. Este binecunoscut faptul că redundanța reduce incertitudinea. Astfel poate fi apreciat faptul că pentru doi senzori semnalul asociat cantității măsurate este corelat, în timp ce incertitudinea asociată cu fiecare senzor tinde să fie necorelată. De asemenea, este de dorit ca redundanța să contribuie la diagnosticarea senzorului.
- *Diversitatea și complementaritatea*. *Diversitatea fizică* a senzorilor este bazată pe folosirea de tehnologii diferite. *Diversitatea spațială* plasează senzorii în diferite locații. Aceste tipuri de diversități sunt utile în idea de a reduce incertitudinea și a rezolva ambiguitățile. *Complementaritatea* senzorilor constă în observarea de către fiecare senzor a unei submulțimi a stării spațiului înconjurător, astfel că reuniunea acestor submulțimi realizează întreg spațiul stărilor mediului de interes perceptual.

Într-un interviu luat profesorului Lotfi A. Zadeh în Germania, acesta a fost întrebat care pare cel mai promițător domeniu de aplicație al logicii fuzzy. Zadeh a răspuns că: “cel mai important lucru care se petrece astăzi este acela că avem la dispoziție foarte multe tipuri de senzori pe care nu i-am avut înainte. Cu acești senzori putem să măsurăm anumite lucruri, putem să conducem procese. Pentru că, calculul a devenit ieftin, putem folosi *soft computing*-ul și putem veni cu diagnosticări, analize, etc. Astăzi senzorii sunt foarte ieftini așa ca se pot folosi peste tot. Senzorii colectează o mulțime de date care pot fi transmise unui sistem central ce poate avea o putere de calcul foarte mare și care poate să dea informații multiple pentru mai multe sisteme. Dacă ar fi existat asemenea sisteme s-ar fi evitat multe catastrofe aviatice. Sunt sigur că în viitor fiecare aplicație, din casă de exemplu, va fi conectată la un calculator central, care îți va spune: mașina ta de spălat nu funcționează corect, sau aparatul TV nu lucrează bine. Acesta va fi un domeniu de aplicații extraordinar. *Analiza deciziei* este un domeniu mai extraordinar decât detecția. Astfel de aplicații vor cere inteligență. *Senzorii bazați pe inteligență artificială unde avem multă informație care trebuie agregată, lucru care cere luarea deciziei, analiza deciziilor, reprezintă domeniul viitorului*” [Zade01].

Așa cum s-a menționat în [Dasa97], în cadrul comunității fuziunii *senzorilor datelor informațiilor* există două curente de opinie, cea ce produce anumite conflicte în utilizarea terminologiei. Un exemplu este folosirea expresiei „*fuziunea datelor*”. Această expresie este așa numita platforma-senzor și are un înțeles specific în sensul referirii la informația de cel mai de jos nivel, adică datele brute, care au fost supuse numai câtorva prelucrări preliminare, ca de exemplu filtrarea. Pe de altă parte în cazul altor aplicații esențiale fuziunea datelor se vede într-un sens mai generic: *informațiile* cuprind date neprelucrate precum și date prelucrate care sunt intrări pentru decizii de nivel mai înalt.

Creierul uman reprezintă poate cea mai bună paradigmă pentru a ilustra conceptele despre fuziune, gândite pentru prelucrarea informației într-un mediu multisenzor. În mod obișnuit, omul fuzionează cinci tipuri diferite de semnale (vedere, auz, gust, miros și pipăit) recepționate de la cinci senzori umani de bază (ochi, urechi, limbă, nas și piele) și apoi ajunge la ceea ce numim *decizie optimă în timp real*. Această fuziune se petrece la diferite nivele, pentru funcții diferite, în combinații diferite și astfel creierul reprezintă un sistem cu o arhitectură de fuziune foarte flexibilă. Emularea paradigmatelor naturii a fost întotdeauna scopul cercetătorilor din diferite domenii – în acest caz sistemul de fuziune multisenzor [Duje98].

Procesul de fuziune poate fi văzut în diferite moduri. Se poate vedea sinergia dintre senzori ca o problemă de planificare: cum să se planifice resursele disponibile (o mulțime de senzori) în așa fel ca observarea procesului să fie optimă [Houz94], [Jane96] și [Lee02]. Un cuvânt cheie în fuziunea senzorilor îl reprezintă *optimizarea neliniară*. Abordarea generală a acesteia o reprezintă *metodele euristice* [Wal00].

În sistemele ingineresti fuziunea furnizează posibilități superioare față de sistemele cu un singur senzor.

Problemele de fuziune a senzorilor reprezintă provocări tehnice deosebite. Primele metode de fuziune a informației au cerut fie independența erorilor senzorilor, fie expresii analitice apropiate de distribuția senzorilor. În primul caz este suficientă o regulă generală, în timp ce în al doilea trebuie să se poată calcula o regulă de fuziune folosind metodele Bayesiene. Acestea nu sunt în mod deosebit favorabile atât din cauza

informațiilor cât și din perspectiva costului. Pe de altă parte distribuțiile senzorilor nu sunt la îndemâna utilizatorului și pot să fie destul de complicate în sistemele ingineresti complexe. Ca rezultat problema obținerii distribuțiilor senzorilor care necesită metode Bayesiene este mai dificilă în sensul informației teoretice decât problema fuziunii însăși. În plus obținerea formei expresiilor apropiate de distribuțiile senzorilor este o sarcină dificilă și scumpă în aceste sisteme deoarece ea necesită cunoștințe din diverse domenii ca dispozitive fizice, inginerie electrică și modelare statistică [Păne00].

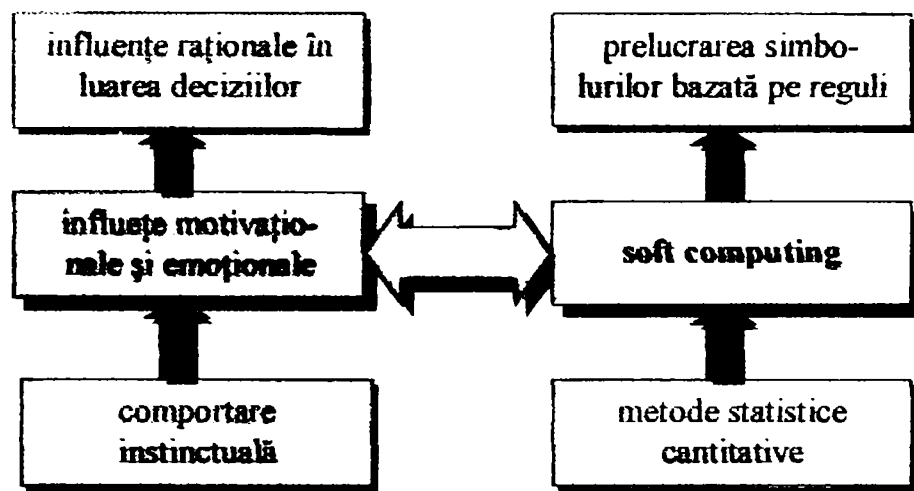
Fuziunea datelor poate implica atât disciplinele tradiționale cât și domenii noi ca sistemele expert, teoria comunicării și a deciziei, epistemologia, teoria estimării, DSP, logica fuzzy, rețelele neuronale, etc. Dezvoltarea explozivă a tehnologiei informației a creat posibilități pentru înmagazinarea datelor calitative, creșterea puterii de prelucrare și prezentare. Pe această bază procesele de fuzionare include colectarea datelor de la senzori multipli, asocierea, agregarea și fuzionarea datelor pentru a crește înțelegerea situațiilor trecute și prezente și pentru a furniza noi oportunități. În cele din urmă, ieșirea dintr-un sistem de fuziune a datelor deservește un sistem de decizie.

În procesul luării deciziei, multe persoane nu pot prelucra în mod rațional cantități mari de date rapid și precis. Dar, ca regulă, oamenii pot lucra bine cu situații caracterizate de informații incomplete, imprecise și incerte. Apoi avem nevoie de "tehnologii" care cu toate că au de prelucrat un număr mare de date, exploatează toleranța umană pentru imprecizie, incertitudine și adevăr parțial. O astfel de tehnologie este *inteligenta computațională*.

Waltz și Buede împart partea de "informație" a modelului în două subsisteme distincte: fuziunea datelor și suportul deciziei. *Fuziunea datelor* colectează date de la diferiți senzori sau surse pentru a dezvolta cea mai bună percepție a situației. Funcția de *suport a deciziei* creează și evaluează alternative estimate din situația reală și dă răspunsuri pentru conducere [Taga99].

De asemenea se folosește termenul de *decizii soft a datelor*, ca reprezentare a incertitudinii folosind probabilitățile, posibilitățile sau reguli fuzzy, în opoziție deciziilor hard. Acestea sunt raportate ca declarații (afirmații) singulare și deciziile soft sunt furnizate ca ipoteze multiple fiecare cu propria reprezentare a incertitudinii asociată cu ipotezele. Când se folosesc regulile fuzzy, incertitudinea este reflectată atât prin caracterul regulilor *dacă – atunci* cât și prin reprezentarea fuzzy a informațiilor de intrare prin funcțiile de apartenență. La nivelul următor al sistemului de fuziune - *nivelul de decizie al fuziunii* se folosește inferența clasică, inferența Bayesiană, metoda Dempster-Shafer, teoria evidenței, rețelele neuronale.

Recent termenul *inteligentă computațională* IC a câștigat o influență în analiza, modelarea și comanda proceselor complexe. Acesta descrie conceptul de implementare sinergistică a metodelor de prelucrare a informației în paralel cu nivelele umane de prelucrare a informației. Fig. A3.2 prezintă acest paralelism. În stânga sunt procesele "biologice" corespunzând ideii de "creier triunic". Acesta cuprinde un cortex organizat în trei straturi responsabile respectiv pentru comportarea instinctuală, a influențelor motivaționale și emoționale și a influențelor raționale în luarea deciziilor. În paralel este prezentată IC. Cele trei straturi cuprind implementări prin metode statistice cantitative, și prin soft computing (reguli și prelucrări simbolice).



Prelucrarea umană a informației

Inteligență computațională

Fig. A3.2. Paralelă între inteligența umană și cea computațională

Principiul implementării *soft computing* SC îl reprezintă exploatarea toleranței pentru imprecizie și incertitudine în ideea de a obține maleabilitate, robustețe și costuri scăzute. În 1994 profesorul Lotfi A. Zadeh a considerat ca principale componente soft computing logica fuzzy, rețelele neuronale, raționarea probabilistă, cea posibilistă, calculul evoluționist, teoria învățării, rețelele de încredere și teoria haosului. Dintre acestea, prima componenta este interesată de imprecizia datelor și informațiilor, a doua cu învățarea iar a treia și a patra de incertitudine. În multe aplicații este avantajos să se exploateze sinergismul acestor metode prin combinarea lor, în locul folosirii uneia singură. SC nu este o singură metodologie ci mai degrabă un consorțiu de metodologii. SC se regăsește astăzi în foarte multe domenii ale fuziunii informației: apărare, mediul industriei, biologie, psihologie, etc.

La Universitatea Berkeley California ființează grupul BISC (Berkeley Initiative in Soft Computing) condus de L.A. Zadeh a cărui scop este dezvoltarea tehnicilor pentru combinarea implementării metodelor fuzzy, neuro, genetice, probabiliste și posibiliste în proiectarea *sistemelor autonome*.

Studiile în domeniul fuziunii senzorilor pot fi grupate pe mai multe direcții: după nivelul la care are loc fuziunea în cursul prelucrării informației, după obiectivul sau scopul procesului de fuziune, după tipul senzorilor, etc. Aceste puncte de vedere diferite sunt prezentate pe scurt, pentru a explora complet potențialului fuziunii senzorilor.

A3.3. Fuziunea ca proces de fisiune inversă

În general senzorii pot fi priviți ca niște ferestre înspre lumea mediului înconjurător. Aceste ferestre sunt constrânse să sesizeze numai ce pot percepe sau măsura. Corespunzător, informația generată poate fi gândită ca o descompunere în componentele sale de către senzori, concept denumit *fisiunea senzorilor* [Dasa97]. Pe această linie, fuziunea senzorilor poate fi utilizată pentru contracararea fisiunii.

A3.4. Instrumente matematice

Sistemele de fuziune a informațiilor cuprind următoarele etape: *modelarea*, *combinarea* (fuziunea propriu zisă) și *decizia*. Trecerea de la cunoașterea unei informații la o reprezentare matematică constituie etapa de modelare a informației, independentă de etapa de decizie. De aceea este necesar ca modelarea să fie adaptată informației disponibile. *Fidelitatea* modelării conduce la probleme de *heterogenitate* sau *hibriditate*.

Metodele cele mai răspândite de gestiune a incertitudinii se înscriu în cadrul teoriei probabilității. Există două direcții de dezvoltare ale acestei teorii: abordarea tradițională *probabilistică* și abordarea *subiectivă*, în care se consideră că o probabilitate reflectă o stare de cunoștințe a cărei legătură cu frecvența reală de apariție nu există decât în anumite cazuri. Abordarea subiectivă căuta o modelare cât mai fidelă semantic vis-à-vis de informația disponibilă [Nif198]. Datele de intrare sunt modelate într-un spațiu comun al probabilităților incertitudinii măsurătorii, cunoscute "a priori". Fuziunea probabilităților se poate obține prin formula lui Bayes rezultând probabilitatea fiecărei ipoteze de ieșire. În literatură se întâlnește de asemenea și filtrarea Kalman. Principalul neajuns al metodei Bayesiene pare a fi identificarea distribuțiilor de probabilitate în special pentru senzorii de măsurare slabi. În plus pentru a simplifica calculele, sursele sunt considerate ca independente.

În paralel cu abordarea probabilistă se întâlnesc teoriile mai recente ale incertitudinii ca *teoria posibilității*, dezvoltată original în cadrul teoriei logicii fuzzy de către L. A. Zadeh [Zade78] și *teoria evidenței* propusă de Shafer în 1976.

Teoria mulțimilor fuzzy este bazată pe apartenența parțială la o clasă. Funcțiile de apartenență pot de asemenea să reprezinte înțelesuri ale cuvintelor, permițând astfel o interfață convenabilă între reprezentarea numerică și cea simbolică. Acest lucru este interesant în fuziune pentru a avea modelarea cunoștințelor expertului modelată în general prin reguli legate de trăsături. În plus o mulțime de operatori sunt capabili să modeleze comportarea datelor numerice. Un alt aspect al teoriei fuzzy este reprezentarea incertitudinii, adică teoria posibilității. Aceasta din urmă permite să se lucreze cu stări neprecise și de asemenea să se combine informație într-un mod adaptiv.

Teoria evidenței este o generalizare a teoriei probabilităților. Fiecare măsură atașează o probabilitate la fiecare element al mulțimii putere. Această teorie modelează atât imprecizia cât și incertitudinea. Regula Dempster-Shafer este folosită pentru a agrega aceste funcții de masă de intrare.

Mai recent au fost folosite pentru agregarea informației și rețelele neuronale. Ele constau din elemente de prelucrare în straturi, sau noduri, care pot fi interconectate în multe feluri. Rețelele neuronale realizează o transformare neliniară a vectorului de intrare. Această teorie este folosită când relația dintre datele de ieșire și cele de intrare este necunoscută. Legătura dintre intrări și ieșiri este învățată de către rețeaua neuronală. Algoritmii dezvoltați permit să se considere o cantitate mare de date. De menționat că tehnicile neuronale sunt uneori folosite în combinație cu celelalte teorii prezentate pentru construirea distribuțiilor de probabilitate, posibilitate sau evidență.

Fig. A3.3 arată că teoria fuzzy, teoria probabilităților și teoria evidenței sunt cel mai mult folosite pentru agregarea informației.




Fig. A3.3. Distribuția lucrărilor publicate în funcție de instrumentele matematice folosite

A3.5. Niveluri de fuziune

În practica fuziunii se pot distinge trei niveluri ierarhice: *fuziunea datelor*, *fuziunea caracteristicilor* și *fuziunea deciziilor*. Ele au fost larg acceptate ca terminologie deși într-o anumită măsură rămân încă opționale, având o natură subiectivă [Dasa97]. Fig. A3.4 prezintă distribuția lucrărilor publicate în literatură după cele trei nivele [Vale00].




Fig. A3.4. Distribuția lucrărilor publicate după nivelul fuziunii

Configurațiile de fuziune au fost dezvoltate fie din considerente teoretice fie din constrângeri aplicative. Configurațiile cele mai obișnuite sunt cele în serie, paralel sau în tandem. Configurația paralel este cea mai studiată literatură și reprezintă scenariul în care observațiile senzorialor sunt obținute concurrent. Configurațiile seriale sau în tandem apar când observațiile diferiților senzori sunt separate temporal.

O dimensiune în plus, mai puțin recunoscută în cadrul procesului de fuziune, este *fuziunea temporală*, adică fuziunea datelor sau informației achiziționate pe o perioadă de timp. Aceasta poate să se petreacă pe oricare din cele trei niveluri prezentate mai sus. Au mai fost folosiți ocazional și alți termeni ca fuziune spațială sau spectrală, pentru a caracteriza anumite facilități specifice fuziunii. Paradigma creierului uman este în mod sigur aplicabilă la toate cele trei niveluri ca și în sensul de fuziune temporală. *Triumful omului asupra mașinii este în principal datorat nivelului de fuziune al deciziei, din cauza abilității umane înnăscute de a putea lua o perspectivă globală, în timp ce mașina este mai eficientă la nivelul datelor, datorită abilității de a prelucra cantități mari de date brute într-o perioadă scurtă de timp.* Prelucrarea informației la fiecare dintre aceste niveluri de fuziune are avantaje ca și dezavantaje. De asemenea intrarea și ieșirea procesului de fuziune nu e nevoie să fie la același nivel.

Extinderea celor trei niveluri de ierarhizare a fuziunii (date-caracteristici-decizii) în cele cinci modalități de fuziune intrare-ieșire care acoperă toate situațiile posibile este prezentată în fig. A3.5 [Dasa97].

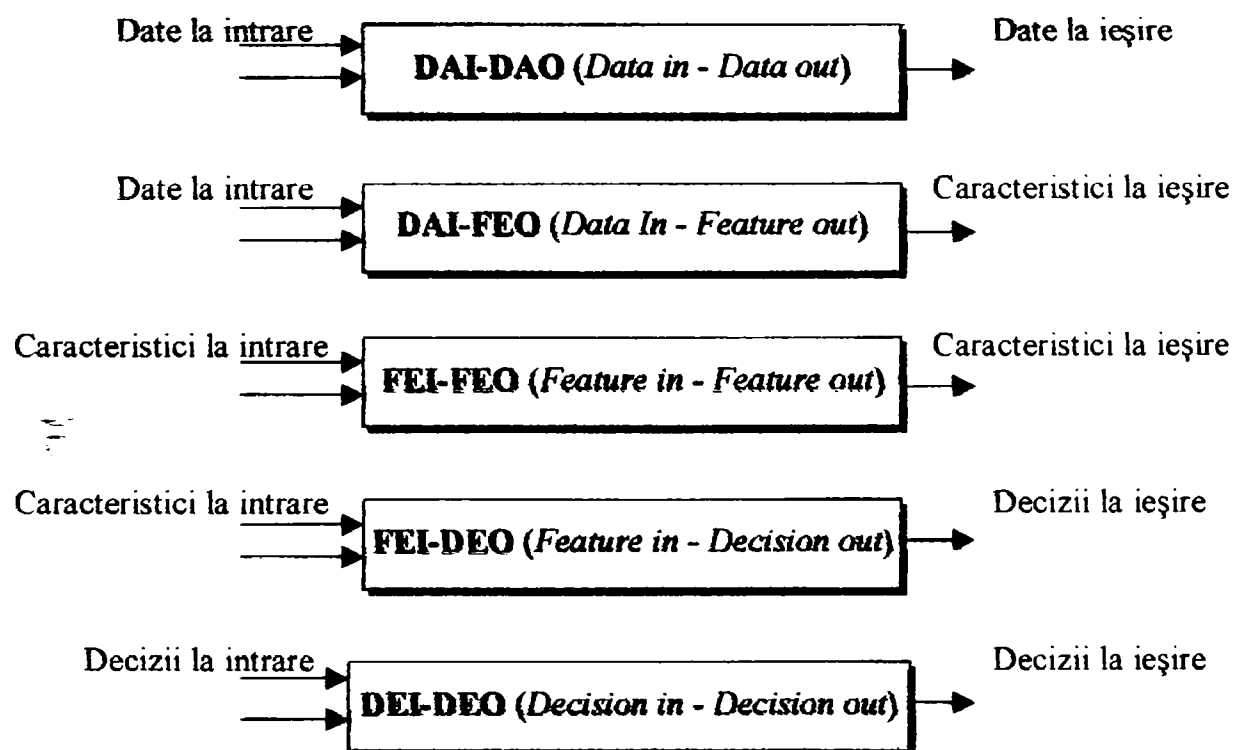


Fig. A3.5. Tipuri de fuziune intrare-ieșire

A3.6. Fuziune cu autoîmbunătățire

Multe dintre arhitecturile sistemelor de fuziune discutate în literatură sunt construite ca un flux cu direcție unică de la subsistemul de senzori spre procesorul central de fuziune. În [Dasa97] s-a introdus conceptul procesorului de fuziune de tip *profesor cu feedback în luarea deciziilor* așa cum se prezintă în fig. A3.6, pentru a îmbunătăți performanțele în timp. Comportarea subsistemului sensor este îmbunătățită prin folosirea reacției negative în acordarea fină a suprafețele de decizie. Acest ciclu de acordare *fuziune-reacție negativă-decizie locală* reprezintă un nou concept semnificativ în proiectarea arhitecturilor sistemelor de fuziune.

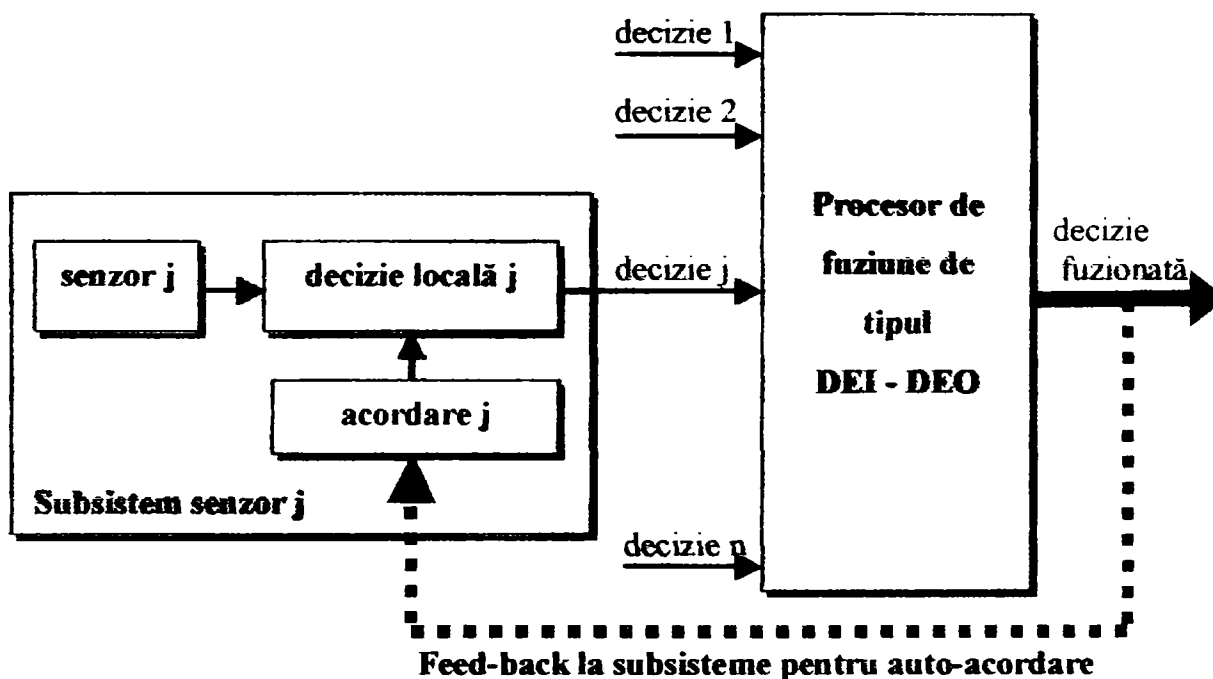


Fig. A3.6. Sistem de fuziune cu arhitectură multisenzor cu auto-acordare

Acest sprijin mutual, poate fi realizat cu ajutorul procesorului de fuziune privit ca un *profesor nefamiliarizat*, adică un profesor a cărui încredere sau nivel al imperfecțiunii este necunoscut inițial. Tehnicile “cu profesor nefamiliarizat” care implementează conceptul de “învățare cu ajutorul profesorului despre profesor” au fost extinse recent la învățarea în împrejurări incerte și imprecise.

A3.7. Distribuția aplicațiilor fuziunii informației

Cele mai multe aplicații ale fuziunii întâlnite în literatură sunt în: apărare, robotică, industrie, medicină și tehnologiile spațiale. În fig. A3.7 se prezintă distribuția lucrărilor publicate după tipul de aplicație [Vale00], [Dail96], [Abde02]. Cele mai multe aplicații sunt în domeniul apărării pentru că acest domeniu a fost primul în care s-a folosit fuziunea informației. Partea denumită “concepte generale” însumează documente despre fuziunea informației fără aplicații specifice și care tratează teoria fuziunii informației (arhitecturi de fuziune, instrumente matematice, etc.).




Fig. A3.7. Distribuția lucrărilor publicate după domeniul de aplicație

A3.8. Concluzii referitoare la fuziunea datelor și informațiilor

Fuziunea datelor și informațiilor poate să aducă un număr însemnat de beneficii:

1. *Creșterea acoperirii spațiale și a cardinalității*, deoarece domeniul de funcționare rezultat prin fuziune este reuniunea domeniilor senzorialor componente;
2. *Acoperire temporală extinsă*, din același motiv;
3. *Comportare robustă*, atât datorită creșterii redundanței prin mărirea numărului de senzori cât și datorită robusteții fuziunii în sine;
4. *Îmbunătățirea diagnosticării*, prin comparațiile posibile între senzori concurenți;
5. *Creșterea preciziei*, rezultă atât prin creșterea rezoluției datorată (1) cât și prin posibilitățile de selectare a celor mai preciși senzori într-o anumită situație;
6. *Creșterea încrederii* este o consecință globală a beneficiilor anterioare și a reducerii ambiguității;
7. *Scăderea posibilă a costurilor*, prin înlocuirea unor senzori foarte scumpi cu mai mulți senzori ieftini și prin facilitarea operațiilor de întreținere indusă de (4);

Global putem distinge trei tipuri de beneficii:

- Extinderea acoperirii spectrale (beneficiile 1 și 2);
- Creșterea încrederii (beneficiile 3, 4, 5 și 6) și posibilitatea cuantificării ei;
- Comportare robustă, sigură și economică (beneficiile 3, 4, 5, 6 și 7).

Teoria posibilităților Fuzionare posibilistică

4.1 Introducere

Teoria posibilităților introdusă în 1978 de către L. A. Zadeh [Zade78] și dezvoltată ulterior de către D. Dubois și H. Prade [Dubo88], constituie un cadru care permite tratarea conceptelor de incertitudine de natură non-probabilistică.

Teoria mulțimilor fuzzy (MF) prezintă avantajul modelării cunoștințelor *imprecise* (de exemplu aproximarea unei valori numerice ca temperatura, viteza, etc.) sau *vagi*. De asemenea este singura metodă care tratează în același cadru, cunoștințe numerice furnizate de către instrumente de măsură (captoare) cu cele exprimate simbolic (lingvistic/semantic) de către un observator uman. Cu toate acestea **teoria MF nu permite manipularea cu același formalism a cunoștințelor *imprecise* și *incerte***. Ori aceste două tipuri de imperfecțiuni sunt legate intim între ele.

Pomind de la noțiunea de MF, teoria posibilităților constituie un cadru perfect pentru exploatarea în cadrul aceluiași formalism a impreciziilor și incertitudinilor. [Calu00].

“Teoria posibilităților oferă un cadru formal natural pentru reprezentarea datelor imprecise, ale informațiilor sărace” [Dubo88].

Teoria posibilităților alături de teoria probabilităților și teoria evidenței permite luarea în considerare și modelarea diferitelor tipuri de informații.

4.2 Prezentare sintetică a modelării

4.2.1 Submulțimi fuzzy

Teoria mulțimilor fuzzy a fost introdusă de Lotfi A. Zadeh în 1965 și se bazează pe ideea apartenenței parțiale a unui individ la o clasă, pe continuitatea în trecerea de la o situație la alta.

O mulțime fuzzy este reprezentată printr-o funcție de apartenență (pe care o vom nota cu μ în cele ce urmează) care permite luarea în considerare a categoriilor cu limite slab definite. De exemplu, reprezentarea mulțimii de oameni “tineri” pare dificil de reprezentat în teoria clasică a mulțimilor. Funcția de apartenență traduce imprecizia unui predicat.

Exemplu: Ion măsoară în jur de 1,80 m” poate să fie modelată prin funcția următoare (fig. 4.1):




fig. 4.1 Funcția de apartenență

Un om de talie 1,73m aparține cu un grad de apartenență $\mu_{\text{in jur de } 1,80 \text{ m}}(1,73)$ la o mulțime fuzzy de oameni de talie “în jur de 1,80”. O funcție de apartenență permite să se ajungă la un consens asupra definiției unui vocabular (“tânăr”, “mare”) care prin natură este imprecis.

Operațiile fundamentale definite pe mulțimile fuzzy sunt: incluziune, egalitate, inter- secție, reuniune și complementaritate.

Egalitate – incluziune:

Fie două submulțimi fuzzy A și B definite pe aceeași mulțime de referință Ω prin μ_A și μ_B :

$$A = B \text{ dacă } \forall x \in \Omega, \mu_A(x) = \mu_B(x)$$

$$A \subset B \text{ dacă } \forall x \in \Omega, \mu_A(x) \leq \mu_B(x)$$

Reuniune și intersecție

$$\forall x \in \Omega, \mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x))$$

$$\forall x \in \Omega, \mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x))$$

Complementaritate

$$\forall x \in \Omega, \mu_{\bar{A}}(x) = 1 - \mu_A(x)$$

Domeniul de definiție sau mulțimea de referință poate să fie produsul cartezian al unor mulțimi de referință: *Exemplu:* {persoane} = {talie} x {greutate}.

O submulțime fuzzy poate să fie definită pe această mulțime de referință. Astfel de exemplu {persoane zvelte} = {persoane înalte} x {persoane vioaie} și

$$\mu_{\text{zvelte}}(t,g) = \min(\mu_{\text{inalt}}(t), \mu_{\text{vioi}}(g)), t \text{ fiind talia, iar } g \text{ fiind greutatea.}$$

Această nouă submulțime definește o relație fuzzy R între talie și greutate .

4.2.2 Introducere în teoria posibilităților

Teoria posibilităților (TP) [Zade78], [Dubo88] permite modelarea și manipularea incertitudinilor într-un mod diferit față de teoria probabilităților. TP este preferabilă teoriei probabilității în situațiile în care putem spune că un eveniment este posibil fără să fim capabili să-i asociem o probabilitate.

4.2.2.1 Modelarea incertitudinii

Incetitudinea unui eveniment A se modelează prin două grade, care corespund unui nivel de încredere slab și unui nivel de încredere puternic:

Gradul de necesitate (N) reprezintă gradul de certitudine asociat unui eveniment.

$$(N(A) = 1) \Leftrightarrow A \text{ este sigur.}$$

Gradul de posibilitate (Π) reprezintă o încredere optimistă asupra unui eveniment.

$$(\Pi(A) = 0) \Leftrightarrow A \text{ este imposibil.}$$

Aceste două grade sunt cazuri limită ale unei măsuri de încredere G care satisface următoarele trei condiții:

- Dacă A este sigur, $G(A) = 1$,
- Dacă A este imposibil, $G(A) = 0$ ($G(A) = 1$ nu implică obligatoriu că A este sigur și $G(A) = 0$ nu implică nici că A este imposibil).
- $(A \subset B) \Rightarrow (G(A) \leq G(B))$

Se deduce

$$G(A \cup B) \geq \max(G(A), G(B)) \text{ și}$$

$$G(A \cap B) \leq \min(G(A), G(B))$$

Gradul de posibilitate corespunde cazului limită în care:

$$\Pi(A) = 0 \Rightarrow A \text{ este imposibil.}$$

$$\Pi(A) = 1 \Rightarrow A \text{ este posibil dar nu sigur}$$

$$\Pi(A \cup B) = \max(\Pi(A), \Pi(B))$$

și gradul de necesitate corespunde unui caz limită unde:

$$N(A) = 0 \Rightarrow A \text{ nu este sigur de loc dar posibil}$$

$$N(A) = 1 \Rightarrow A \text{ este sigur}$$

$$N(A \cap B) = \min(N(A), N(B))$$

4.2.2.2 Distribuția de posibilitate

O distribuție de posibilitate definită pe o mulțime de referință este o distribuție de incertitudine care permite să se traducă imprecizia unei surse de informație, într-un mod coerent cu definiția mulțimilor fuzzy. Incertitudinea poate să nască o imprecizie. Astfel că, dacă o sursă de informație declară că un parametru aparține unei mulțimi fuzzy definită prin funcția sa de apartenență μ_A , atunci receptorul de informație va avea o incertitudine cu privire la acest parametru, modelată prin repartiția de posibilități π astfel că:

$$\forall x \in \Omega, \pi(x) = \mu_A(x) \quad [\text{Zade78}].$$

Exemplu: “Marian revine în jurul orei 15” este imprecis și implică faptul că este posibil și incert ca Marian să revină la ora 14,57 (presupunând aici o discretizare a mulțimii de referință cu un pas de un minut de exemplu). Incertitudinea $\pi(14h57)$ acestui eveniment poate să fie definită indirect prin intermediul funcției de apartenență $\mu_{=15h}(t)$:

$$\forall t \in \Omega, \pi(t) = \mu_{=15h}(t).$$

Una dintre criticile formulate teoriei probabilităților era aceea că, independent de interpretare (subiectivă sau frecventistă), atunci când nu se cunosc decât limitele de variație ale unei variabile, modelarea sub forma distribuției de probabilitate uniformă între cele două limite corespunde de fapt unei introduceri de informație în realitate nedisponibilă. O distribuție de posibilitate reprezintă un mijloc de a modela fidel această informație pe care o considerăm sau nu fuzzy pe gamițele sale. O interpretare propusă în [Dubo88] și [Dubo93] constă în considerarea tuturor distribuțiilor de probabilitate coerente cu distribuția de posibilitate după cum urmează:

Fie p o distribuție de probabilitate definită pe o mulțime de referință continuă $\Omega = \mathfrak{R}$. Constrângerea de coerență se exprimă prin:

$$\forall A \subset \Omega, N(A) \leq P(A) = \int_{x \in A} p(x) dx \leq \Pi(A)$$

Coeficienții de posibilitate și de necesitate pe submulțimile lui Ω pot să fie deduși dintr-o distribuție de posibilitate. Să presupunem o mulțime de referință Ω pe care este definită o repartiție de posibilitate π . Fie $A \subset \Omega$, atunci *măsura de posibilitate* asociată lui A este:

$$\Pi(A) = \sup_{x \in A} (\pi(x))$$

De aici rezultă că este posibil să se definească gradul de necesitate al unui eveniment, exprimând imposibilitatea unui eveniment contrar: $N(A) = 1 - \Pi(\bar{A})$.

Se regăsește:

$$N(A \cap B) = 1 - \Pi(\bar{A} \cap \bar{B}) = 1 - \max(\Pi(\bar{A}), \Pi(\bar{B})) = 1 - \max(1 - N(A), 1 - N(B)) = \min(N(A), N(B))$$

Încrederea într-un eveniment A este modelată fie prin cuplul (necesitate, posibilitate) cu $N(A) = 1 - \Pi(\bar{A})$, fie printr-o distribuție de posibilitate care permite accesarea la acest cuplu.

4.2.2.3 Interpretare și comentarii

Un grad de necesitate egal cu 1 sau o posibilitate nulă sunt informații forte, în timp ce un grad de necesitate nul sau o posibilitate egală cu 1 sunt informații slabe.

În conformitate cu intuiția, un eveniment este posibil înainte de a fi necesar și dacă un eveniment A este cât de puțin necesar ($N(A) > 0$), atunci el este în întregime posibil ($\Pi(A) = 1$). Contrar, dacă un eveniment nu este complet posibil ($\Pi(A) < 1$), atunci nu este de loc necesar ($N(A) = 0$).

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

și

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

Spre deosebire de coeficienții de probabilitate care sunt aditivi, (adică $P(A) + P(\bar{A}) = 1$), gradele de încredere definite în cadrul teoriei posibilităților respectă constrângerile mai puțin puternice

$$N(A) + \Pi(\bar{A}) = 1,$$

$$N(A) + N(\bar{A}) \leq 0$$

și

$$\Pi(A) + \Pi(\bar{A}) \geq 1$$

Întradevăr două evenimente contrare pot să fie în întregime posibile și dacă: $N(A) > 0$, atunci $\Pi(A) = 1$ de unde $N(\bar{A}) = 0$

Gradul de necesitate exprimă indicii în favoarea unui eveniment. Este necesar tot ceea ce poate fi dedus dintr-un corp de cunoștințe.

Gradul de posibilitate exprimă indicii împotriva acestui eveniment. Este posibil tot ceea ce nu contrazice corpul de cunoștințe.

Aceste grade pot să fie reprezentate pe segmentul $[0, 1]$ ca în fig. 4.2:




fig. 4.2 Necesitate și posibilitate

Invers unui grad de probabilitate, un grad de posibilitate are un sens mult mai slab și mai ales relativ. Într-adevăr, cu excepția interpretării unui grad de posibilitate ca o limită maximă a unei probabilități imprecise în cele mai multe dintre cazuri $\Pi(A) = 0,1$ nu se interpretează în termeni de frecvență. În schimb, aceasta semnifică faptul că acest eveniment A este mai puțin posibil decât un eveniment B astfel că $\Pi(B) = 0,2$. Numai aspectul ordinal este important.

Gradul de posibilitate poate să reprezinte un grad de fezabilitate [Smet98] (de exemplu al unei acțiuni). În acest sens, el nu modelează o incertitudine și se apropie mai repede de un grad de apartenență la o mulțime de acțiuni fezabile.

4.3 Fuziunea clasică

Se consideră doi senzori C_1 și C_2 (sau două surse de informație oarecare) capabili să furnizeze fiecare o repartiție de posibilități pe un domeniu de definiție discret sau continuu Ω . Se presupune că în primul moment acești senzori sunt absolut fiabili și că măsurile lor se raportează la același obiect. Necunoașterea sistemului este redusă la imprecizia senzorilor și cele două informații vor trebui să fie fuzionate conjunctiv.

Vom considera numai operatorii *min* și *max* pentru conjuncția și disjuncția informației. Familii de astfel de operatori au fost introduse la început în domeniul spațiilor probabiliste. Aceștia pot fi definiți după cum urmează:

Se numește **normă triunghiulară** (sau T-normă) o funcție

$T: [0,1] \times [0,1] \rightarrow [0,1]$ astfel că:

$\forall x, y, z \in [0,1]$,

1. $T(x,y) = T(y,x)$ (comutativitatea)
2. $T(x,T(y,z)) = T(T(x,y),z)$ (asociativitatea)
3. $T(x,y) \leq T(z,t)$ dacă $x \leq z$ și $y \leq t$ (monotonie)
4. $T(x,1) = x$ (element neutru 1)

Toate normele T sunt operatori de intersecție. Operatorul *min* verifică bine condițiile 1 la 4.

Se numește **conormă triunghiulară** (sau conormă T) o funcție

$\perp : [0, 1] \times [0, 1] \rightarrow [0, 1]$ astfel că:

$\forall x, y, z \in [0, 1]$,

1. $\perp(x, y) = \perp(y, x)$ (comutativitatea)
2. $\perp(x, \perp(y, z)) = \perp(\perp(x, y), z)$ (asociativitatea)
3. $\perp(x, y) \leq \perp(x, t)$ dacă $x \leq z$ și $y \leq t$ (monotonie)
4. $\perp(x, 0) = x$ (elementul neutru)

Se verifică faptul că operatorul *max* satisface aceste patru condiții. Toate conormele T sunt operatori de reuniune.

Dacă senzorii introduși mai sus furnizează măsurile ale căror valori și imprecizii asociate sunt modelate prin repartițiile de posibilitate π_1 și π_2 (vezi fig.4.3) atunci se definește fuziunea conjunctivă a două informații după cum urmează:

$$\pi(x) = \min(\pi_1(x), \pi_2(x))$$

Această fuziune ne permite să ne desăvârșim cunoștințele despre x.




fig. 4.3 Combinarea conjunctivă

Alegerea acestui operator corespunde ideii următoare: pentru oricare x al domeniului de definiție, fiecare sursă de informație furnizează un interval de încredere $[N_1, \pi_1]$ și $[N_2, \pi_2]$. Fuziunea corespunde intersecției a acestor intervale pe mulțimea de definiție:

$$N(x) = \max(N_1(x), N_2(x))$$

și

$$\pi(x) = \min(\pi_1(x), \pi_2(x))$$

Cantitatea de informație despre sistem nu poate să crească. Astfel, necesitatea (informația forte) nu poate decât să crească și posibilitatea (informația slabă) nu poate decât să se diminueze.

Această formă de fuziune permite luarea în considerare a informațiilor comune, care vor furniza la rândul lor o informație.

Astfel dacă:

$\Pi_1 = \Pi_2$, $\Pi = \min(\Pi_1, \Pi_2) = \Pi_1 = \Pi_2$, informația despre sistem nu crește. Dependența celor două surse de informații este considerată subiectiv.

4.4 Fuziunea adaptivă

Se presupune cazul în care senzorii nu sunt în totalitate fiabili sau/și că asocierea datelor poate să pună probleme. Necunoașterea presupune aici imprecizie și incertitudine. Sunt posibile multe combinații [Kelm95]. Se prezintă în continuare o abordare propusă de Dubois și Prade [Dubo94].

4.4.1 Cazul a două surse

Dacă informațiile furnizate de către cei doi senzori sunt conflictuale, se presupune că unul din cei doi captori nu este fiabil sau că cele două măsuri nu sunt asociabile, atunci distribuțiile de posibilitate se combină disjunctiv (SAU logic):

Astfel: $\pi(x) = \max(\pi_1(x), \pi_2(x))$ (vezi fig. 4.4)




fig. 4.4 Combinarea disjunctivă

În cazul contrar, distribuțiile de posibilitate se combină conjunctiv (vezi fig. 4.3).

În realitate trebuie luate în considerare toate cazurile intermediare în care informațiile sunt mai mult sau mai puțin conflictuale.

Se introduce *gradul de conflict* $c \in [0, 1]$ definit după cum urmează [Dubo94]:

$$c = 1 - h(\pi_1, \pi_2)$$

cu

$$h(\pi_1, \pi_2) = \sup_x (\min(\pi_1(x), \pi_2(x)))$$

Înălțimea h se traduce prin *gradul de compatibilitate*, de consens dintre cele două surse (vezi fig.4.5).




fig. 4.5 Înălțime și compatibilitate

Dubois și Prade [Dubo94] au definit regula de combinare adaptivă următoare:

$$\pi_{ad} = \max\left(\frac{\pi_1 \wedge \pi_2}{h(\pi_1, \pi_2)}, \min(1 - h(\pi_1, \pi_2), \pi_1 \vee \pi_2)\right) \quad \text{dacă } h(\pi_1, \pi_2) > 0,$$

și $\pi_{ad} = \pi_1 \vee \pi_2$ altfel

Proprietăți:

- Dacă $c = 0$ ($h = 1$) atunci $\pi_{ad} = \min(\pi_1, \pi_2)$ și fuziunea este în întregime conjunctivă.
- Dacă $c = 1$ ($h = 0$) atunci $\pi_{ad} = \max(\pi_1, \pi_2)$ prin definiție și fuziunea este în întregime disjunctivă.
- Dacă nu, comportamentul este intermediar: cu cât este mai mare conflictul cu atât mai mult combinarea este disjunctivă și cu cât conflictul este mai mic combinarea este conjunctivă (vezi fig. 4.6)




fig. 4.6 Combinarea adaptivă a două surse

Comportamentul acestei fuziuni este puternic dependent de zonele fuzzy asociate fiecărei surse. Dacă pantele sunt foarte abrupte, se va trece foarte rapid de la o conjuncție pură la o disjuncție.

Această combinație nu este aplicabilă la mai mult de două surse pentru că nu este asociativă. Rezultatul depinde de ordinea în care sunt fuzionate informațiile.

4.4.2 Cazul a k surse

Fie K o mulțime de surse π_j și J o submulțime a lui K . Se notează:

$$h(J) = \sup_x (\bigwedge_{S_j \in J} (\pi_j(x))) \text{ , gradul lor de consens.}$$

Se pune

$$m = \sup_{J: h(J)=1} (\text{card}(J))$$

și

$$n = \sup_{J: h(J)=0} (\text{card}(J))$$

m este numărul maxim de surse compatibile în întregime și n este numărul maxim de surse puțin compatibile. Se presupune că există un grup de m surse fiabile și că în nici un caz nu sunt mai multe decât n . Dubois și Prade au propus combinația adaptivă următoare:

$$\pi_{ad} = \max\left(\frac{\pi_{(n)}(x)}{h(n)}, \min(1 - h(n), \pi_{(m)}(x))\right)$$

cu $\pi_{(n)}(x) = \max_{J: \text{card}(J)=n} (\pi_j(x))$ și $\pi_j(x) = \bigwedge_{j \in J} \pi_j(x)$

și $h(n) = \max_{J: \text{card}(J)=n} (h(J))$

$h(n)$ reprezintă consensul maxim a n surse.

Toate sursele trebuie să fie considerate simultan. Chestiunea ordinii în care sosesc informațiile nu se pune.

Exemplu: Se consideră trei surse reprezentative. Se observă ușor că $m = 2$ și $n = 3$.




fig. 4.7 Combinația adaptivă a trei surse

Repartiția rezultantă (vezi fig.4.7) nu este simplă, dar ea ține cont de valorile cele mai plauzibile ale parametrului descris de cele trei surse. S-ar putea considera de asemenea cazul surselor de fiabilitate diferită.

4.5 Concluzii

Teoria mulțimilor fuzzy și a posibilităților oferă un cadru puțin constrictiv permițând combinarea informațiilor. Posibilitatea de a alege un mecanism de modelare și de combinare este relativ largă și există posibilitatea alegerii unui bun combinator.

Capacitatea de a reprezenta fidel informațiile slabe face din teoria posibilității un cadru adaptat situațiilor în care se cunosc slab sursele de informație (fuziunea expert, utilizarea bazelor de date simbolice). Formulele de combinare trebuie și pot să fie adaptate problemei. Se poate alege o formulă de funcționare a comportamentului pe care îl dorim.

Decizia de a alege cadrul teoriei posibilităților în competiție cu cel al probabilităților trebuie să se bazeze pe o judecare aprofundată a naturii datelor disponibile.

Teoria mulțimilor fuzzy și a posibilităților permit să se diferențieze precis conceptele de imprecizie și incertitudine. Pot fi definiți diferiți operatori pentru reprezentarea impreciziei (lucrul pe submulțimile fuzzy, relațiile fuzzy, logica fuzzy) sau pentru reprezentarea planul incertitudinii (lucrul cu necesitatea și posibilitatea), cu relațiile clare între aceste două planuri. Această dualitate imprecizie/incertitudine este văzută de asemenea ca o dualitate între distribuția de posibilitate provenită dintr-o sursă de informație imprecisă și o distribuție de posibilitate discretă.

Teoria posibilității alături de alte teorii ale incertitudinii oferă un cadru foarte deschis în comparație cu teoria probabilității, pentru modelarea și tratarea diferite tipuri de informații. Cadrul probabilist este mult prea constrictiv.

Alegerea plasării într-un anumit cadru trebuie să se bazeze pe o gândire aprofundată asupra naturii informațiilor disponibile. Din punct de vedere industrial, de la achiziția acestor informații va exista tentația ca mai întâi să se obțină reprezentări probabiliste pentru că ele permit o gestiune mai precisă. Dacă informațiile probabiliste nu sunt accesibile este necesar să se propună un cadru mai adaptat pentru a reprezenta informațiile (slabe) de care se dispune. Aceste informații slabe sunt în general mai puțin scumpe dar dacă se pune accentul pe cercetarea tuturor informațiilor disponibile, este posibil ca în final să se obțină performanțe bune.

Una dintre criticile formulate adesea teoriilor incertitudinii, altele decât teoria probabilităților, este multiplicarea parametrilor (costuri, subiectivitate, alegerea tipurilor de decizie...). Ori sistemele de informație trebuie să lase liberă mâna operatorilor în ceea ce privește informațiile de nivel înalt. Teoria posibilităților oferă un cadru care permite să se dea un sens precis fiecărui parametru, relativ la un concept precis, ușor comprehensibil prin operator.

Sistemele de informație luate în considerare trebuie să fie în măsură să țină cont de informații de natură diferită: de la informații de nivel scăzut (numerice) până la informații de nivel înalt (simbolice). Astfel apar în mod natural probleme de hibriditate, când informațiile sunt eterogene.