



Rezumatul tezei de doctorat

Ing. Bența Kuderna-Iulian

SISTEME SENZITIVE LA CONTEXT PERSONALIZATE AFECTIV

PREȘEDINTE: - Prof.dr.ing. **Marina ȚOPA** - decan, Facultatea de Electronică, Telecomunicații și Tehnologia Informației,
Universitatea Tehnică din Cluj-Napoca;

MEMBRII: - Prof.dr.ing. **Costin MIRON** - conducător științific, Universitatea Tehnică din Cluj-Napoca;
- Prof.dr. **Dan DUMITRESCU** - referent, Universitatea „Babeș-Bolyai” din Cluj-Napoca;
- Prof.dr. **Nicolae Adrian OPRE**- referent, Universitatea „Babeș-Bolyai” din Cluj-Napoca;
- Prof.dr.ing. **Mircea-Florin VAIDA** - referent, Universitatea Tehnică din Cluj-Napoca.

2010

Cuprins

1	Introducere	1
1.1	Domeniul și obiectivul cercetării.....	1
1.2	Întrebările de cercetare.....	1
1.3	Abordarea cercetării	2
1.4	Principalele contribuții ale tezei	2
2	Stadiul actual al cunoașterii.....	3
2.1	Definirea noțiunilor importante din domeniile sistemelor senzitive la context și a calculului afectiv	3
2.2	Soluțiile actuale pentru modelarea contextului	3
2.3	Soluțiile actuale pentru modelarea stărilor afective.....	5
2.4	Metode actuale pentru determinarea stărilor afective.....	6
2.5	Mecanisme actuale de adaptare la context	8
2.6	Sinteza limitărilor soluțiilor existente și concluzii	9
3	Modelarea stărilor afective	10
3.1	Modelul afectiv FLAVI (Fuzzy Logic Activation Valence Intensity).....	10
3.2	Extinderea modelului ontologic de context cu modelului afectiv FLAVI.....	12
3.3	Concluzii	14
4	Contribuții la detecția stărilor afective	15
4.1	Detecția din context a stărilor afective	15
4.2	Determinarea valenței	17
4.3	Concluzii	21
5	Adaptarea la contextul afectiv	22
5.1	Formularea problemei	22
5.2	Soluția propusă	22
5.3	Implementarea soluției pentru cazul unei case inteligente	23
5.4	Testarea soluției propuse.....	25
5.5	Evaluarea ACBAM	25
5.6	Direcții deschise	26
5.7	Concluzii	26
6	Concluzii și perspective	27
6.1	Principalele contribuții din teză.....	27
6.2	Dezvoltări ulterioare	28
	Bibliografie.....	29

Introducere

Se prezintă domeniul și obiectivul cercetării, terminologia, motivația pentru explorarea acestuia, întrebările pentru cercetare și abordarea temei. În finalul capitolului se prezintă principalele contribuții și organizarea tezei pe capitole.

Odată cu răspândirea în masă a dispozitivelor mobile și a creșterii puterii lor de procesare a apărut necesitatea ca sistemele de calcul să se adapteze la contextul în care sunt utilizate (temperatură, luminozitate, bandă, profil utilizator etc.). Scopul adaptării este eliberarea atenției utilizatorului de la introducerea manuală a datelor de context și asigurarea unei funcționări optime a aplicației în raport cu resursele disponibile. Adaptarea la context, numită aici *senzitivitate la context*, presupune un anumit grad de inteligență a sistemului.

În abordarea din această teză, în fiecare componentă importantă a arhitecturii unui sistem senzitiv la context se introduc elemente afective. La preluarea datelor de context se adaugă detectoare ale stării afective a utilizatorului. Modelul de context este extins cu informații afective. Adaptarea la context se optimizează prin interpretarea răspunsului afectiv al utilizatorului la deciziile sistemului. Toate acestea sunt detaliate în continuare.

1.1 Domeniul și obiectivul cercetării

Domeniul de cercetare al acestei teze este legat de zona de intersecție dintre domeniile senzitivitate la context și calculul afectiv, denumită aici *senzitivitate la context personalizată afectiv* (Figura 1.1):




Figura 1.1 Definierea domeniului de cercetare în raport cu domeniile proximale

Obiectivul tezei este crearea unui cadru (modele, metode, algoritmi) care să permită determinarea și modelarea stărilor afective ale utilizatorului și utilizarea lor pentru adaptarea aplicațiilor sensibile la context. Toate acestea cu scopul de a facilita utilizatorului un comportament al aplicației adecvat necesităților sale.

În secțiunea următoare se explică termenii importanți care apar în această lucrare.

1.2 Întrebările de cercetare

Întrebările de cercetare, la care s-a urmărit să se răspundă în această lucrare, sunt descrise în cele ce urmează:

1. Cum se poate extinde modelul dimensional activare-valență pentru a include următoarele caracteristici (pe care modelele actuale nu le includ în totalitate):
 - să permită corespondența cu modelele discrete,
 - să modeleze relația dintre stările secundare și cele de bază,
 - să permită personalizarea modelului,
 - să exprime explicit dimensiunea intensitate a stării afective?
2. Cum se poate extinde modelul ontologic de context SOCAM pentru a include următoarele caracteristici:
 - reprezentarea elementelor modelului afectiv activare-valență-intensitate,
 - relația dintre stările afective și elementele de context?
3. Cum și cu ce precizie se pot determina stările afective secundare pe baza analizei parametrilor contextului?
4. Care să fie metoda de evaluare a preciziei cu care detectoarele de stări afective (care funcționează în timp real și sunt ne-invasive prin faptul că pornesc de la trăsături faciale, determină stările afective și, în particular, valența stării curente?)
5. Cum se poate calcula valența stării afective curente, în funcție de valorile instantanee ale stărilor afective de bază, furnizate în timp real, obținute folosind un detector de tipul celui de la întrebarea 4?

6. Cum se poate îmbunătăți precizia de măsurare a valenței, cu 3 sau 9 niveluri, pentru detectoarele de tipul celui de la întrebarea 4?
7. Care să fie mecanismul prin care o aplicație senzitivă la context își poate adapta, în mod transparent, prin comenzi implicite (reacții afective), comportamentul la nevoile utilizatorului?

1.3 Abordarea cercetării

Căutând răspuns la aceste întrebări, s-a constatat că este binevenit un cadru de lucru care să furnizeze dezvoltatorilor de aplicații senzitive la context un set de unelte cu diferite niveluri de abstractizare, de la modele până la exemple de implementări software. Astfel s-a născut tema de cercetare a acestei teze de doctorat. Pentru o privire de ansamblu, sintetică, în Figura 1.2 se prezintă părțile unui sistem senzitiv la context (modelare, achiziție, adaptare) la care s-au făcut inovările necesare integrării elementelor de calcul afectiv în sistemele senzitive la context:




Figura 1.2 Elementele de calcul afectiv inserate în părțile unui sistem senzitiv la context

1.4 Principalele contribuții ale tezei

Principalele contribuții originale prezentate în teză sunt:

1. Un model unificator al stărilor afective, care permite cuantizarea spațiului activare-evaluare și personalizarea lui folosind logica nuanțată.

Cuantizarea se bazează pe definirea statistică a câte două mulțimi nuanțate (fuzzy) triunghiulare pentru reprezentarea gradului de apartenență a stării secundare la fiecare dintre stările de bază pe axele activare și valență. S-a propus o metodologie de construire a modelului. În urma testării ipotezei relației de proporționalitate între distanța de la originea planului activare-valență și intensitatea stărilor emoționale (3 niveluri), s-a dovedit necesitatea dimensiunii distincte intensitate care să fie adăugată perpendicular planului activare-valență.

2. Un model ontologic de context extins. Modelul este bazat pe ontologia de context SOCAM, dar este extins cu modelul stărilor afective FLAVI ce cuprinde elemente afective detaliate, față de ontologia existentă pentru descrierea utilizatorilor GUMO, și cuprinde, de asemenea, reprezentarea ontologică a relațiilor dintre stările: curentă, secundare și de bază pe de o parte și a relației dintre stările afective și context, pe de o alta.

3. Metoda de detecție a stărilor afective secundare din context folosind metoda profilelor utilizator și îmbunătățirea acestei metode folosind o rețea neuronală care personalizează detecția prin feedback de la utilizator.

4. Metoda de calcul a valenței cu trei niveluri, pe baza analizei în timp a eșantioanelor corespunzătoare stărilor de bază detectate de o unealtă soft (FaceReader) pentru starea curentă, pe baza unor valori de prag determinate empiric.

5. Metoda de evaluare a preciziei pentru detectoare ale stărilor afective ce funcționează în timp real, pentru stări afective spontane.

S-a aplicat metoda pentru unealta soft FaceReader pentru determinarea valenței cu 3 și 9 niveluri din trăsături faciale. S-a considerat cazul utilizării de trăsături faciale induse în mod spontan prin prezentare de imagini subiectului, comparativ cu valențele etichetate IAPS și prin comparație cu trei experți umani.

6. Metoda de creștere a procentului de detecții corecte ale valenței, cu 3 și 9 niveluri, a FaceReader-ului, în timp real, din trăsături faciale.

S-a considerat cazul utilizării de trăsături faciale ce corespund unor trăiri spontane induse prin prezentare de imagini subiectului, folosind pentru personalizare învățarea supervizată.

7. Un mecanism de reglare a comportamentului unei case inteligente pe baza reacției afective a utilizatorului la deciziile sistemului care permite descoperirea, memorarea și folosirea preferințelor pentru a răspunde nevoilor utilizatorului, care sunt mereu în schimbare.

S-a proiectat și implementat platforma de agenți JADEx folosind TAOM4E, s-a creat ontologia casei inteligente, s-au integrat senzorii și actuatorul Phidgets. Reprezentarea preferințelor comportamentului unui sistem senzitiv la context s-a făcut prin ponderi salvate în fișier, în timp ce contextul și actuatorii au fost reprezentați în ontologie.

Stadiul actual al cunoașterii

Se trec în revistă, din perspectiva autorului, câteva dintre definițiile din literatura de specialitate pentru domeniile senzitivității la context și a calculului afectiv. Se prezintă stadiul actual al cercetării în cele două domenii analizându-se comparativ soluțiile existente pentru modelarea, reprezentarea, determinarea și adaptarea la stările afective în sisteme senzitive la context. În finalul capitoului se arată limitările soluțiilor existente și se justifică alegerile pentru anumite soluții existente, selectate pentru a fi bază de pornire pentru propunerile din această lucrare.

2.1 Definirea noțiunilor importante din domeniile sistemelor senzitive la context și a calculului afectiv

Domaniul senzitivității afective se află la intersecția senzitivității la context și a calculului afectiv. Ca urmare este potrivit să începem descrierea stadiului actual al cunoașterii cu definirea noțiunilor importante ale acestor două domenii.

Definirea noțiunilor din domeniul senzitivității la context.

Definirea contextului. Există mai multe definiții ale contextului în literatura de specialitate. Sintetizând definițiile existente, se urmărește în continuare răspunsul la următoarele întrebări care să lămurească această noțiune:

1. *Cine* (constituie contextul)? Utilizatorul, mediul și sistemul de calcul, fiecare dintre acestea având o ierarhie de proprietăți și de entități care le constituie.
2. *Ce* (fac aceste entități)? Interacționează.
3. *Cum* (interacționează)? Într-un mod relevant, care contează, cu un sens. În mod causal (acțiunea fiind urmată de o reacțiune).
4. *De ce* (în ce scop)? Pentru a realiza sau împlini un anumit comportament dorit sau așteptat de utilizator (în funcție de credințele, dorințele și intențiile sale).
5. Când? Mereu. Stările sistemului, utilizatorului și mediului se modifică tot timpul.

Definirea noțiunilor din domeniul calculului afectiv

Definirea stării afective și a emoțiilor. În cercetarea de față s-a considerat starea afectivă ca o trăire umană interioară cauzată de un factor exterior (perceperea unui obiect, a unei ființe sau declanșarea unui eveniment) sau unul interior (evocarea unui obiect, a unei ființe sau unui eveniment).

Comunitatea științifică încă nu s-a pus de acord în ceea ce privește definirea stărilor afective [Pic97]. Stările afective sunt împărțite, conform [Roe04], după următoarele clase: emoții, dispoziții, atitudini interpersonale, preferințe/atitudini, dispoziții afective. Dintre acestea, în prezenta teză, atenția este orientată asupra emoțiilor deoarece sunt de durată scurtă sau medie, ceea ce corespunde duratei de interacțiune directă cu aplicațiile care rulează pe dispozitivele mobile.

Emoțiile sunt definite ca „episoade de sincronizare masivă a resurselor somatice și mentale care permit adaptarea la, sau rezolvarea unui eveniment-stimul subiectiv evaluat ca fiind foarte pertinent pentru nevoile, scopurile și valorile indivizilor” [Roe04]. Din perspectiva psihologiei cognitive, emoția este o reacție (comportamentală și/fiziologică) la o anumită situație, determinată de un proces cognitiv de evaluare (appraisal) și urmată de un proces de adaptare (coping). Noțiunea de stare afectivă cuprinde atât ideea de emoție, cât și pe cea de dispoziție. În contextul tezei se consideră doar emoțiile, deci când nu se explicitează altfel, starea afectivă se referă la o emoție.

Definirea stărilor afective primare și secundare. În psihologie se face distincție între stările afective (emoțiile) primare (sau de bază) și derivatele acestora, numite secundare.

Ființele umane au dezvoltat pentru a putea supraviețui opt stări afective primare (de bază): bucurie, anticipare, mânie, dezgust, tristețe, surpriză, frică, încredere [Plu80]. Prin combinarea acestor stări primare rezultă 28 de stări secundare, de ex. optimismul = anticipare + bucurie.

2.2 Soluțiile actuale pentru modelarea contextului

Modelarea contextului presupune un proces de abstractizare prin care elementele din realitate, din mediul înconjurător (elemente de context, valorile posibile ale acestora), sunt conceptualizate pentru a putea fi apoi reprezentate în sistemele de calcul. Acest proces este asimilabil cu cel al modelării realității în cazul concepției de programe pentru calculator, cu diferența că, datorită complexității și dinamicii lui, necesită metode specifice.

Reprezentarea contextului într-un sistem de calcul este aproape imediat realizabilă după modelare, în cele mai multe din cazuri cele două noțiuni sunt considerate ca desemnând același lucru. Reprezentarea fiind partea „vizibilă”, implementată a modelului abstract. Păstrând referința la conceperea programelor, modelarea folosind clase și obiecte are ca o consecință reprezentarea în calculator a claselor și a instanțelor lor care sunt obiectele concrete.

Caracteristici ale modelelor de context. În continuare se face o comparație a modelelor de context din perspectiva următoarelor caracteristici, având ca punct de pornire lucrarea de referință [Tho04]: compoziția distribuită, validarea, cantitatea și calitatea informației, completitudinea și suportul pentru raționare.

Principalele clase de modele de context. Se analizează clasele de modele prezentate în [Tho04], la care se adăugă clasa de modele bazate pe tehnologie web [Bil93]. Se face analiza într-o ordine care merge de la simplu la complex, urmărind cum au fost abordate caracteristicilor enunțate mai sus. În urma analizării caracteristicilor, se observă ca unele sunt satisfăcute, iar altele nu. Următoarele modele sunt detaliate și exemplificate pe situații concrete în teză: modele bazate pe perechi atribut-valoare, modele bazate pe tehnologie web, modele ce folosesc scheme de marcare, modele grafice, modele bazate pe logică, modele orientate obiect și modelele bazate pe ontologii.

Modele bazate pe ontologii. Ontologiile sunt folosite în sistemele de calcul pentru a reprezenta realitatea nu doar ca un set de concepte distincte, ci ca un ansamblu de concepte între care există relații diverse (nu doar ierarhice și de apartenență). În modelarea contextului, ontologiile facilitează o reprezentare precisă a elementelor de context, a parametrilor acestora și a legăturilor dintre ele și permit raționarea asupra conceptelor existente și a relațiilor dintre ele pentru a deduce noi valori ale elementelor de context și pentru verificarea consistenței modelului. Ontologiile folosesc clase pentru a reprezenta concepte și oferă suport pentru raționare (ca cele bazate pe logică). De aceea moștenesc caracteristicile acestor două tipuri de modele, dovedind în privința validării calitățile modelelor bazate pe scheme de marcare. Ca urmare, compoziția distribuită, validarea, cantitatea și calitatea informației, completitudinea, suportul pentru raționare sunt cel mai bine rezolvate de această clasă. Prețul de plătit pentru aceste performanțe este însă, în acest caz, creșterea complexității.

Ex. SOCAM (Service Oriented Context Aware Middleware) [Gu05]. Această reprezentare rezolvă următoarele:

- reduce complexitatea reprezentării contextului prin separarea ontologiei în generală și specifică aplicației;
- permite deducerea valorilor contextului superior prin inferență asupra valorilor contextului inferior;
- permite rezolvarea conflictelor dintre diferitele surse de context;
- facilitează menținerea consistenței bazei de cunoștințe;
- detectează și corectează inconsistențele informației de context pe baza mecanismului de inferență;
- permite reprezentarea claselor de surse de informații de context.

Comparație între clasele de modele de context. În tabelul de mai jos sintetizăm modul în care clasele de modele de context răspund la caracteristicile enunțate în secțiunea 1.2.3:

Clasă de model de context	Compoziția distribuită	Validarea	Cantitatea și calitatea	Completitudinea	Suportul pt. raționare
Perechi atribut-valoare	-	-	-	-	-
Web	-	+	-	-	-
Scheme de marcare	+	++	+	-	-
Grafice	-	-	+	-	-
Logice	++	-	-	-	++
Orientate obiect	++	+	+	+	+
Ontologice	++	++	+	+	++

Tabelul 2.1 Comparație între modele de context după criteriile 1-5 enunțate în secțiunea 2.2.1

Analizând acest tabel se pot formula întrebările: când este recomandat să folosim un model dintr-o anumită clasă și când dintr-o alta și de ce? Răspundem la aceste întrebări în continuare.

Aplicațiile simple cu un număr redus de elemente de context (unu, două), între care nu se pot stabili ușor relații, pot beneficia de simplitatea claselor de modele atribut-valoare și bazate pe web. Acestea din urmă vin cu un mic avantaj, acela de a permite, într-o mică măsură, validarea conținutului paginii web în care sunt prezente atributele modelului.

Lipsa suportului pentru raționare nu este aici critic, deoarece avem un număr redus de elemente de context care sunt independente.

Modelele bazate pe scheme de marcare sunt potrivite aplicațiilor în care elementele de context sunt puternic ramificate, cu majoritatea relațiilor între ele de tip ierarhic, dar care se bazează pe surse de informații de încredere și care sunt relativ puțin distribuite în rețea. Situațiile simple de context nu cer acestei clase de modele de context suport pentru raționare.

Modelele bazate pe grafică își găsesc utilitatea ca bază de proiectare a aplicațiilor mai complexe. Tot ca o unealtă poate fi considerată clasa de modele bazate pe logică, deoarece ele permit o testare în avans a regulilor ce descriu comportamentul aplicației senzitive la context folosind limbaje dedicate.

Modelele orientate obiect sunt o soluție bună când numărul elementelor de context este mediu sau mare cu reguli de comportament relativ puține și simple, structura modelului de context fiind ușor de gestionat de către proiectant.

Aplicațiile cu multe elemente de context care au relații complexe între ele, care provin din surse diferite ca debit și calitate, susceptibile de a fi incomplete și ca urmare cu reguli ce au mulți parametri, găsesc o fundație solidă în modelele de context ontologice.

O abordare hibridă care consideră toate aceste modele este prezentată în [Bet09]. Autorii propun 3 niveluri distincte peste nivelul de senzori, care au roluri după cum urmează: primul nivel este cel de fuziune a datelor de la senzori, la al doilea nivel se reprezintă datele de context superficiale, se integrează sursele externe de date de context și se face o raționare eficientă asupra contextului, iar la al treilea nivel are loc reprezentarea și raționarea la nivel abstract. Ca urmare modelele ontologice vor ocupa nivelul al treilea pentru verificarea consistenței, specificarea semnificativității contextului și abstractizarea lui. La nivelul 2 se recomandă folosirea modelelor de marcare, RDF, de tip CC/PP sau logice. Pentru primul nivel nu se indică un anumit model. Deși promițător, modelul hibrid astfel propus, este un model de context încă în lucru.

De ce sunt potrivite ontologiile în modelarea contextului? Ontologiile sunt independente față de limbajele de programare, permit analiza formală a domeniului cunoașterii [Gu05], au putere de expresie (OWL suportă restricții de cardinalitate) și oferă suport pentru raționare eficientă, abstractizarea programării și interoperabilitate [Eji07].

În cazul modelării contextului ontologiile permit reprezentarea formală a contextului [Wan04], distribuirea cunoașterii și reutilizarea ei [Yau06], raționarea logică asupra contextului (verificarea consistenței, subsumarea, raționarea pentru cunoaștere implicită) [Yau06], organizarea ierarhică a informației, descrierea formală (fiind standardizate) [Eji07]. În [Luc06] se spune că folosind mecanismele de raționare (inferența intra-context (ex. definirea contextului de ordin superior), raționarea asupra contextului pentru rezolvarea informației imprecise sau parțiale), contextul poate fi mărit, îmbogățit, sintetizat, distribuit.

Ontologiile de context rezolvă problema heterogenității datelor, ambiguității, calității și validității datelor de context [Kru07].

Model pentru contextul utilizatorului. Explorând domeniul senzitivității la context s-a constatat că sunt foarte puține modele de context care să includă detalierea datelor utilizatorului. Modelul GUMO (General User Model and Context Ontology) este dedicat, așa cum îi spune numele, descrierii utilizatorului în cazul aplicațiilor senzitive la context, beneficiind de avantajele specifice unei reprezentări ontologice.

Stilul GUMO [Hec05] de a descrie stările afective are atributele: etichetă, identificator, data expirării, intimitate, imagine, adresă internet.

Remarcăm că în acest mod de a descrie stările afective lipsesc parametrii importanți ai stărilor afective: valența și activarea și nu se stabilește nici o relație nici între stările de bază și celelalte, nici între stări și celelalte elemente de context.

2.3 Soluțiile actuale pentru modelarea stărilor afective

Charles Darwin, în cartea sa „The Expression of Emotion in Man and Animal” [Dar72], a pornit studiul modelelor emoțiilor umane. De atunci au fost dezvoltate un număr mare de modele ale emoțiilor care au fost dezvoltate din perspective aparținând unor domenii diverse ale științei: medicină, fiziologie, psihologie [Roe04][Mar10]. În funcție de domeniul pentru care au fost create, aceste modele evidențiază un anumit aspect al emoțiilor cu predominanță. Astfel există modele ale emoțiilor care descriu nivelul fizic-fiziologic (modele de reacție periferică, de circuite neuronale), modele emoționale determinate de interacțiunile sociale, modele motivaționale ale emoțiilor, modele de adaptare, modele lexicale (rezultate din analiza structurii implicațiilor semantice ale cuvintelor emoționale). Mai aproape de obiectivul tezei (modelarea și determinarea emoțiilor utilizatorului într-un context care se modifică dinamic) sunt: modele discrete, modele dimensionale și modele evaluative (appraisal). Clasele de modele dimensionale și discrete sunt generale și provin

din teoria evoluționistă cu o puternică tendință spre observarea fenomenului emoțional din exterior (de obicei prin trăsături faciale). Modelele cognitive ale emoțiilor studiază emoțiile din perspectiva relației lor cauzale cu procesele cognitive.

Totuși aceste modele nu se exclud mutual, emoțiile fiind un domeniu în care cercetarea continuă. Un exemplu este că există lucrări actuale [Moo07][Pes08] care arată că emoțiile și cogniția sunt forțat separate și că este posibil ca unele procese emoționale (de exemplu calculul valenței) să preceadă cogniția și ca urmare să nu fie o cauză a acestora.

Modelele computaționale ale emoțiilor sunt necesare pentru a permite sistemelor de calcul să modeleze (reprezinte) în limbaj de programare și să proceseze apoi informațiile preluate de la senzori în scopul determinării sau simulării emoțiilor. Comparativ cu modelele discrete și dimensionale, modelele cognitive ale emoțiilor prezintă următoarele două avantaje: i. oferă cadrul teoretic în care se evidențiază relația dintre emoțiile utilizatorului și mediu (context) prin intermediul componentei relației persoană-mediu și ii. teoria evaluării (appraisal) explică de ce subiecții răspund emoțional diferit la un același stimul.

În cadrul sistemelor computaționale, modelele cognitive ale emoțiilor au fost implementate cu scopul de a le folosi în principal pentru studiul fenomenelor psihice, utile, în sisteme computaționale, mai ales agenților software care simulează trăiri afective (agenți conversaționali) (de ex. FLAME[EI00]).

Două dezavantaje ale modelele computaționale cognitive care cuprind și emoții (de exemplu CogAff, Minsky EM, EMA [Lee08][Mar09]) sunt că:

1. sunt generice, descriu generic procesele la nivel de arhitectură [Gra09], sunt insuficient evaluate [Gra09] și, în final, folosesc ele însele modele discrete sau dimensionale când descriu emoțiile și
2. implică o modelare mai detaliată a utilizatorului pentru a putea extrage variabilele de apreciere din care să se poată deriva o predicție a viitoarei stări emoționale a utilizatorului, ceea ce crește complexitatea și este mai intruziv.

Sinteza modelelor afective pentru integrarea în sisteme sensitive la context. Pentru a putea integra stările afective în sisteme sensitive la context, modelele afective trebuie să aibă două caracteristici: posibilitatea personalizării modelului afectiv în funcție de specificul utilizatorului și o modalitate de măsurare și codare a stărilor astfel încât ele să fie ușor de transmis (comunicat) la distanță.

Modelele care folosesc logica nuanțată [EI98][Yan95][Mob03][Ger99], datorită flexibilității pe care o oferă, sunt candidați pentru personalizare deși nu o vizează în mod explicit. Cu excepția modelului propus de Roddy Cowie și colectiv [Cow00a][Cow99][Cow00b] care are potențial posibilitatea personalizării, celelalte modele sunt lipsite de această caracteristică.

Măsurarea (cuantificarea) și codarea stării afective lipsește din propunerea lui Robert Plutchik care doar precizează că ar fi patru axe ale afectului [Plu80]. Modelul OCC (Ortony-Clore-Collins) [Ort88] arată că ar exista 22 de stări, cu o anumită valență, accentul fiind pus pe cauzele stărilor și nu pe utilizarea lor. Cele mai importante modele sunt aici cele propuse de J.A. Russell (modelul circumplex al afectului) [Rus80] și Roddy Cowie și colectiv în [Cow00a][Cow99][Cow00b]. J.A.Russell arată că stările sunt reprezentabile prin unghiul pe care îl fac cu abscisa, deci un număr teoretic infinit de stări cuprinse între 0° și 360° ar putea fi definite unic de valoarea acestui unghi. Roddy Cowie și colectiv preia ideea și o dezvoltă arătând că se poate calcula și o valoare a tăriei stării în funcție de distanța pe care o are starea față de originea sistemului de coordonate. Tot aceștia arată [Cow00b] că putem măsura o stare destul de precis, 20 de stări distincte, ca o pereche de coordonate (x, y).

Deoarece tehnologiile de ultimă oră care permit detectarea stărilor afective sunt actualmente doar la nivelul la care clasifică între un set mic de stări, soluțiile pentru modelarea stărilor afective, au fost simple. În cele mai multe cazuri această reprezentare fiind ca perechi atribut-valoare. Odată cu dezvoltarea personajelor grafice animate care imită oamenii, s-a simțit nevoia unei reprezentări mai detaliate a acestor stări. VHML-EML (Virtual Human Markup Language-Emotion Markup Language) [Mar10], APMML (Affective Presentation Markup Language) [Car02], and MPML2.0.e (Multimodal Presentation Markup Language) [Ish06] sunt exemple de limbaje de reprezentare dedicate sau care includ reprezentări afective. Acestea pot fi încadrate în clasa modelelor de reprezentare bazate pe XML.

2.4 Metode actuale pentru determinarea stărilor afective

Detectia stărilor afective presupune în primul rând luarea în considerare a canalelor de comunicare interumană prin care sunt transmise în mod curent trăirile emoționale (stările afective) și găsirea de metode tehnice adecvate pentru preluarea, prelucrarea și interpretarea stărilor. În continuare sunt prezentate pe rând aceste metode tehnice pentru canalele de comunicare vizual, auditiv, fiziologic. Deoarece omul interpretează sintetic starea afectivă, cercetarea în domeniul detecției stărilor afective s-a orientat spre metode de fuziune a rezultatelor detecțiilor pe diferite canale pentru a crește precizia detecției. Pe acestea din urmă le prezentăm în finalul acestei secțiuni 2.4.

Metode de detecție a stărilor afective pornind de la trăsăturile faciale. Un criteriu important pentru compararea soluțiilor de detecție a stărilor afective pentru situații reale este dacă stările evaluate erau spontane sau dramatizate. Un exemplu de evaluare cu stări spontane este [Seb04]; însă se tratează doar patru stări și fără a prevalida setul de inductori pentru a cunoaște efectul lor asupra subiecților. Dintre aceste soluții de detecție, cea descrisă în [Kui05] este singura la care s-a putut avea acces pentru a o testa ca produs comercial [FR09] mai întâi în anul 2008.

Deși progresele cercetării în acest domeniu continuă, se pot observa trei tendințe:

1. Sistemele existente care revendicau rezultate bune ca procente de detecție sunt revăzute sau îmbunătățite pentru că, fie erau testate inițial pe un număr mic de persoane, fie se testa pe același set care era și de antrenare, fie foloseau emoții dramatizate etc.,
2. Orientarea spre determinarea de stări secundare și mai general a unităților de acțiune (AU-Action Unit).
3. Combinarea canalului video cu gesturi pe de o parte și cu voce sau alte canale pe de o alta.

Metode de detecție a stărilor afective din voce. La stadiul actual al cunoașterii din domeniul detecției stărilor afective din voce, putem afirma că vocea poate fi folosită doar ca și complement la alte metode de detecție, cum ar fi cele după trăsăturile faciale, cu mari rezerve în privința situațiilor reale, caz în care utilizatorul se află în mobilitate într-un mediu cu un important zgomot ce însoțește vocea umană. Deși în soluțiile actuale [Zen09] se tinde să se cuprindă și conținutul lexical pentru a deduce starea utilizatorului. Totuși rezultatele de până acum sunt reduse la utilizarea izolată a canalului audio pentru detecția stărilor afective.

Metode de detecție a stărilor afective din stările fiziologice. Datorită instabilității pe care o prezintă în timp, a particularităților pentru fiecare individ la detecție, a complexității, numărului mare de senzori necesari și mai ales a încălcării intimității pe care le prezintă soluțiile de detecție actuale, se consideră neoportună utilizarea acestora, sau cel puțin nu doar a acestora, pentru detecția stărilor afective.

Alte metode de detecție a stărilor afective. Deși problema detecției stării afective din gesturi pare a fi rezolvată pentru sistemele mobile (vezi exemplele eMoto, Siemens CX70 Emoty), totuși ele nu vorbesc de măsura în care detecția a fost corect realizată. Detecția posturii corporale în mediul mobil pare a fi, pentru moment, destul de dificilă în lipsa unor senzori adecvați și care să nu deranjeze și să nu încălce intimitatea: senzori de presiune pe talpa încălțăminte, senzori de poziție pe punctele importante de pe corp (trunchi, membre, cap).

Metode de detecție a stărilor afective multimodale. Deși apare ca o soluție firească pentru detecția mai precisă a stărilor afective, metoda multimodală nu are încă maturitatea necesară pentru a fi folosită ca atare. Totuși în dezvoltarea aplicațiilor reale care țin seama de starea afectivă este de așteptat o fuziune a senzorilor fiziologici, de gestică, presiune, cei vocali și video.

Discuție asupra metodelor de detecție a stărilor afective. Din studiul metodelor tehnice de detecție a stărilor afective rezultă că deși este un domeniu de care se preocupa un număr relativ mare de cercetători și de o perioadă destul de mare de timp (două decenii), totuși metodele prezentate nu îndeplinesc decât parțial condițiile impuse pentru utilizarea lor în situații reale, în contextul mobilității utilizatorului. Ca soluție se propune adoptarea modalității optime pentru un singur canal, cel vizual, ca soluție de bază și se păstrează deschiderea la modalitățile de detecție complementare (voce, gestică, presiune) cu includerea contextului (etapa de desfășurare a sarcinii, durata, locația, contextul social) și a profilului utilizatorului (vârstă, sex, proveniență culturală, model afectiv personalizat).

Un alt aspect important este problema intimității informațiilor utilizatorului. Drept pentru care se urmărește adoptarea unei modalități ne-intrusive. Metodele fiziologice sunt nerecomandate, cele vizuale și audio sunt cele mai adecvate. Totuși cele audio sunt mai expuse la zgomotul din mediul ambiental.

În concluzie, se alege o metodă de detecție vizuală. Anume, cea care s-a dovedit a fi optimă și disponibilă pentru testare în condițiile cele mai apropiate de cele reale, pe care o prezentăm în continuare.

Detectorul de stări afective din trasături faciale FaceReader™. FaceReader™ [FR09] este un sistem automat de analiză a expresiilor faciale în timp real dezvoltat de firma VicarVision și care este disponibil comercial din 2007. Acest produs soft prelucrează imagini statice, video (înregistrate și în timp real) cu o rată de 15 analize pe secundă. El permite clasificări în timp real a expresiilor faciale ce corespund celor șase stări de bază definite de Ekman în 1970 [Ekm70], la care se adaugă starea neutră.

Pentru a realiza aceasta programul funcționează în trei etape [Kui05]: găsirea imaginii faciale, potrivirea măștii și clasificarea. Modulele prezentate în [Kui05] rezolvă problema analizei feței ce constă în diminuarea efectelor a trei surse de variații în imaginile faciale: poziția/orientarea, expresia și lumina.

Deși are unele limitări în privința anumitor parametri, cum ar fi etnicitatea și vârsta utilizatorului și condiții de mediu ca lumina și orientarea feței față de cameră, este singurul program care a fost testat temeinic în condiții de variație a parametrilor de intrare (utilizator și mediu). Mai mult el include mai multe modele selectabile de către utilizator, proiectate pentru a rezolva, chiar și dacă în parte, aceste probleme.

La analiza în timp real, FaceReader™ scrie un fișier de tip jurnal în care înregistrarea stării afective curente se face odată la 200 ms, în condiții de luminozitate egală pe fața citită, a unei rotiri a capului de cel mult 30° și a limitării mișcărilor bruște ale capului (aproape-departe, stânga-dreapta, sus-jos).

Pentru a justifica alegerea pentru FaceReader™ s-au analizat mai multe publicații recente [Seb04, Bai08, Yea06] care afirmă că au obținut rezultate remarcabile în detecția stărilor de bază în timp real din emoții spontane. Alte publicații, fie nu spun în ce condiții s-au obținut rezultatele lor și pe câți indivizi [Bar04, Lit04, Bar03], fie nu este clar dacă metoda prezentată este sau nu utilizabilă în timp real [Lia05]. În [Seb04] fișierele video au fost urmărite de 28 de subiecți, iar camera ascunsă a clasificat în timp real în patru stări (neutru, bucurie, surpriză și dezgust). Un număr de 41 participanți au urmărit filme scurte care le-au provocat emoții spontane, metoda de evaluarea a stării curente fiind din trăsături faciale și din măsurarea unor parametri fiziologici (parțial invaziv) [Bai08]. Au fost considerate doar amuzamentul și tristețea, ca stări opuse. O abordare similară [Yea06] folosește filme încărcate emoțional pentru 21 de subiecți a căror stare curentă o clasifică în șase stări de bază după trăsăturile faciale. Pe lângă neajunsurile precizate la fiecare soluție, ceea ce nu este clar în aceste abordări este măsura în care stimulii inductori ai emoțiilor sunt adecvați pentru a induce stările spontane vizate.

2.5 Mecanisme actuale de adaptare la context

Modelarea preferințelor utilizatorului de comportament al aplicației

În momentul actual în literatura de specialitate există mai multe articole care tratează modelarea preferințelor. Focalizarea este aici asupra reprezentării acestor preferințe în corespondență cu contextul, în scopul adaptării comportamentului.

În tabelul 2.7 se face o comparație sintetică a diferitelor soluții de reprezentare a preferințelor:

Soluție	Context.ontologic	Relația context-serviciu	Actualizare la rulare
CtxPrefScor'06 [Hen06]	-	scor	-
OWLPref'05 [Kim05]	+	relație ontologică	-
Bayes Meta-Net'06 [Has06]	-	probabilistică	++
NNAssoc'05 [Fla05]	-	ponderi rețele asociat.	-
UPM'05 [You05]	-	ponderi neuroni	+
ProbSchemes'07 [Dar07]	-	Bayes și HMM	?

Tabelul 2.2 Comparație a diferitelor soluții de reprezentare a preferințelor

Se remarcă utilizarea modelării ontologice a contextului doar într-un singur caz [Kim05], dar la care lipsește posibilitatea modificării dinamice a preferințelor la rulare. Pentru exprimarea preferințelor unui serviciu, dat fiind contextul, există mai multe soluții. Ultima coloană a tabelului permite evaluarea soluției din perspectiva obiectivului de a oferi posibilitatea personalizării, a modificării preferințelor în funcție de nevoile utilizatorului. Astfel că soluția cu perceptronul multistrat [Youn05] este superioară celei în care se folosesc doar ponderi ce indică asocieri între context și servicii [Flan05] deoarece permite modificarea ponderilor printr-un mecanism de propagare inversă a erorilor (back propagation); dar are dezavantajul că nu face aceasta la rulare în funcție de reacția utilizatorului. Modelele Markov ascunse HMM sunt considerate a fi potrivite, dacă pentru definirea unui context de nivel înalt din mai multe elemente de context de nivel jos [Dar07]. Acestea vor permite calculul valorilor parametrilor mai multor elemente de context de nivel înalt dacă între acestea și altele există o corelație temporală.

Soluția cu meta-rețele Bayes este cea mai apropiată de obiectivul precizat mai sus. Dezavantajul ce apare la nivelul reprezentării la această soluție este că aici modelul contextului nu este ontologic.

Concluzia studiului este că modelarea ontologică a contextului este bine să fie combinată cu o soluție pentru reprezentarea ontologică a relației context-serviciu care să permită modificarea valorilor și înainte (antrenare), dar mai ales la rulare.

Mecanisme de descoperire a preferințelor. În urma studiului prezentat mai sus s-a constatat că sunt puține soluții care iau în calcul reprezentarea și apoi modificarea valorilor relației context-serviciu senzitiv la context.

Folosirea datelor istorice înregistrate ca perechi context (vectori de elemente de context) – servicii [Fla05][You05]. Mecanismul fiind bazat pe rețele neuronale care sunt astfel antrenate să răspundă cu un anumit serviciu la un context dat.

Un element unic al soluției [Has06] este considerarea unei bucle de reacție de la utilizator prin care valorile relației context-serviciu sunt modificate la rulare. Astfel că sistemul va descoperii preferința utilizatorului.

În privința utilizării răspunsului emoțional pentru învățarea comportamentului dorit, articolul [Bro07] prezintă un mecanism de învățare prin întărire în cazul unui robot social care învață prin pedeapsă sau răsplată exprimată de emoții: negativă (frică), respectiv pozitivă (fericire). Mecanismul de învățare implică reacții de acest tip pentru un set de sarcini, dar obiectivul propus este o buclă mai simplă în care răspunsul utilizatorului este imediat și asociat unei singure acțiuni (decizii de comportament a sistemului).

În concluzie, pentru soluția cu meta-rețele Bayes, observăm următoarele două avantaje: i. preferințele fiecărui utilizator sunt separate și reutilizabile și ii. se pot stabili priorități între utilizatori. Ca dezavantaj: probabilitățile condiționate inițiale trebuie completate (calculate de proiectant și editate manual sau utilizând expresii, sau obținute cumva (nu se știe încă în ce fel) din istoric) nefiind dată încă o soluție de inițializare automată a lor.

2.6 Sinteza limitărilor soluțiilor existente și concluzii

Pentru modelarea și reprezentarea contextului complex care să cuprindă și stări afective se alege reprezentarea ontologică. Cu argumentele că: permite distribuirea cunoașterii și reutilizarea ei folosind un format standard (OWL), este independentă de limbajele de programare, permite raționarea logică asupra contextului (verificarea consistenței, subsumarea, raționarea pentru cunoaștere implicită) și definirea relațiilor dintre diferitele elemente de context și între acestea și stările afective ale utilizatorului.

Dintre ontologiile de context se alege ca punct de plecare ontologia SOCAM [Gu04] căreia îi lipsește descrierea detaliată a caracteristicilor utilizatorului. Din studiul reprezentărilor datelor utilizatorului s-a ales ca fiind cea mai expresivă ontologia GUMO [Hec05] însă din care lipsesc parametrii importanți ai stărilor afective: valența și activarea și nu se stabilește nici o relație nici între stările de bază și celelalte, nici între stări și celelalte elemente de context.

Analiza modelelor stărilor afective după criteriile personalizare și cuantificare a dus la concluzia că modelul circumplex al afectului [Rus80] și dezvoltat ulterior [Cow00a][Cow99][Cow00b] ca spațiu activare-valență poate fi folosit ca model de bază dar cu rezolvarea următoarelor limitări: lămurirea ipotezei care afirmă că relația între intensitățile stărilor afective este una de directă proporționalitate cu distanța până la centrul cercului ce definește planul activare-evaluare, stabilirea unei relații între stările secundare și cele de bază și personalizarea modelului.

Metodele de detecție a stărilor afective care să poată fi folosite în sistemele senzitive la context trebuie să fie adecvate mediului mobil al utilizatorului, să fie cât mai puțin invazive și să fie cât mai bine adaptate la condiții variabile de mediu. La stadiul actual al dezvoltării metodelor de detecție, canalul de comunicare emoțională cel mai potrivit este cel facial. Pentru aceasta s-a ales programul FaceReader™ [FR09] deoarece acesta este capabil să facă analiza în timp real a stării afective de bază curente, în condiții de luminozitate egală pe fața citită, a unei rotiri a capului de cel mult 30° și a limitării mișcărilor bruște ale capului (aproape-departe, stânga-dreapta, sus-jos). Un neajuns important constă în faptul că acest program nu consideră trăsăturile faciale specifice fiecărui individ și nici modul distinct în care individul trăiește stările afective atât în evaluarea stărilor afective de bază cât și în evaluarea valenței.

Pentru a face adaptarea sistemului senzitiv la context la contextul curent, în condiții optime pentru utilizator, este nevoie de reprezentarea preferințelor. Dintre soluțiile existente remarcăm utilizarea modelării ontologice a contextului doar într-un singur caz [Kim05], dar la care lipsește posibilitatea modificării dinamice a preferințelor la rulare. Pentru exprimarea formală a preferințelor unui serviciu, dat fiind contextul, există mai multe soluții. Soluția cu perceptronul multistrat [Youn05] este superioară celei în care se folosesc doar ponderi ce indică asocieri între context și servicii [Flan05] deoarece permite modificarea ponderilor printr-un mecanism de propagare inversă a erorilor (back propagation); dar are dezavantajul că nu face aceasta la rulare în funcție de reacția utilizatorului. Soluția cu meta-rețele Bayes este cea mai apropiată de obiectivul optimizării adaptării. Dezavantajul ce apare la nivelul reprezentării la această soluție este că aici modelul contextului nu este ontologic.

Concluzia studiului este că modelarea ontologică a contextului este bine să fie combinată cu o soluție pentru reprezentarea ontologică a relației context-serviciu care să permită modificarea valorilor și înainte (antrenare), dar mai ales la rulare.

Pentru mecanismul de adaptare propriu-zis sunt puține soluții. S-a prezentat soluția cu meta-rețele Bayes, la care se observă dezavantajul că probabilitățile condiționate inițiale trebuie calculate și editate manual, nefiind dată încă o soluție de inițializare automată a lor.

Modelarea stărilor afective

Se prezintă modelul afectiv unificator bazat pe logică nuanțată FLAVI (Fuzzy Logic Activation Valence Intensity) propus în [Ben05][Ben07b]. Se descrie algoritmul de construire a modelului afectiv personal PersFLAVI. Apoi se detaliază algoritmul de construire a modelului generalizat GenFLAVI folosind două metode de calcul diferite (P-probabilistic și CI-cu intervale de încredere). În final se descrie extinderea modelului ontologic de context SOCAM cu model afectiv FLAVI [Ben07a].

3.1 Modelul afectiv FLAVI (Fuzzy Logic Activation Valence Intensity)

Formularea problemei. Modelul afectiv FLAVI, de la Fuzzy Logic Activation Valence Intensity (model afectiv activare valență intensitate bazat pe logică nuanțată/fuzzy), extinde modelul activare-valență [Cow00b] pentru a răspunde problemelor P1-P4, prezentate în continuare:

P1. Modelele afective actuale reprezintă stările sunt fie discret (o instanță dintr-o listă de stări), fie puncte într-un spațiu de stări (de exemplu, activare-valență), fără a defini o relație matematică, numerică între punctul ce reprezintă starea și axele de coordonate ale spațiului stărilor.

P2. Modelele afective actuale ce reprezintă stările într-un spațiu continuu de stări posibile, nu prezintă o modalitate de definire a relației dintre stările secundare și stările de bază.

P3. Modelele stărilor afective actuale sunt generale și ca urmare nu reflectă individualitățile utilizatorului.

P4. În modelele stărilor afective existente în general se ignoră parametrul intensitate, doar în cazul modelului activare-valență se face ipoteza că intensitatea este un parametru implicit prezent, având valoarea definită de distanța dintre punctul din plan ce definește acea stare și origine, fără o demonstrație a acestei afirmații.

Propunerea modelului afectiv FLAVI. Pornind de la studiul soluțiilor existente, se reutilizează fie unele modele ca bază de pornire, fie se preiau caracteristici ale lor pentru a rezolva problemele enunțate în secțiunea anterioară. Se denumește acest nou model afectiv FLAVI, de la Fuzzy Logic Activation Valence Intensity (model afectiv Activare-Valență-Intensitate bazat pe logică nuanțată/fuzzy). Descrierea formală a modelului este dată în continuare punctual, soluțiile corespunzând, unu la unu, problemelor formulate:

S1. Se alege ca bază modelul de reprezentare bidimensională xOy a stărilor în spațiul activare-valență în care se poziționează atât stările secundare și cele de bază.

S2. Fiecare stare secundară (derivată a stărilor de bază) va fi definită o mulțime nuanțată pentru fiecare stare din setul de stări definite în spațiul activare-valență pentru acea aplicație, atât pe axa Ox cât și pe Oy , care va fi același și la emisie și la recepție.

S3. Se definesc setul stărilor secundare care vor fi folosite în acea aplicație și mulțimile nuanțate corespunzătoare domeniului acoperit de fiecare dintre ele pe fiecare axă. Se stabilesc un model general și unul particular în care parametrii mulțimilor nuanțate sunt definiți pe baze statistice.

S4. Se adaugă axa intensitate Oz , perpendiculară pe planul activare-valență, pe care se definesc trei mulțimi nuanțate triunghiulare ce corespund intensității mici, medii și mari.

Concret, propunerea de model al stărilor afective, care permite cuantizarea spațiului activare-valență și personalizarea folosind logica nuanțată, constă în:

Modelul personalizat. Definim pe baze statistice pentru persoana i ($i=1, \dots, N$) două mulțimi nuanțate triunghiulare μ pe axa Ox și ν pe axa Oy pentru fiecare dintre stările de bază. Fie Ψ_j setul stărilor de bază, $j=1, \dots, n$, unde n este numărul stărilor de bază (de obicei $6+1$). Fie: a_{ij} minimul valorilor determinate pe axa Ox corespunzătoare persoanei i și stării Ψ_j , b_{ij} media valorilor determinate pe axa Ox corespunzătoare persoanei i și stării Ψ_j , c_{ij} maximul valorilor determinate pe axa Ox corespunzătoare persoanei i și stării Ψ_j . Pentru fiecare Ψ_j , pe axa Ox , a valenței, se definește $\mu_{i,j}$ ca în relația 3.1.

Fie: d_{ij} minimul valorilor determinate pe axa Oy corespunzătoare stării Ψ_j , e_{ij} media valorilor determinate pe axa Oy corespunzătoare stării Ψ_j , f_{ij} maximul valorilor determinate pe axa Oy corespunzătoare stării Ψ_j . Similar, pentru fiecare Ψ_j , pe axa Oy , se definește $\nu_{i,j}$.

$$\mu_{i,j}(x) = \begin{cases} 0, & x \leq a_{ij} \\ \frac{(x - a_{ij})}{(b_{ij} - a_{ij})}, & x \in (a_{ij}, b_{ij}] \\ \frac{(c_{ij} - x)}{(c_{ij} - b_{ij})}, & x \in (b_{ij}, c_{ij}) \\ 0, & x \geq c_{ij} \end{cases} \quad (3.1)$$

Modelul general. Similar cu modelul personalizat, se definesc, pe baze statistice, două mulțimi nuanțate triunghiulare μ pe axa Ox și ν pe axa Oy pentru fiecare dintre stările de bază. Fie Ψ_{ij} setul stărilor de bază, $j=1, \dots, n$, n -numărul stărilor de bază (de obicei 6+1) care corespund utilizatorului i . Fie $A_j = \min\{a_{ij}: i=1, \dots, N\}$, $B_j = (b_{1j} + b_{Nj})/N$, $C_j = \max\{c_{ij}: i=1, \dots, N\}$. Pentru fiecare utilizator i și stare Ψ_j , avem pe axa Ox, a valenței mulțimea nuanțată μ . Fie $D_j = \min\{d_{ij}: i=1, \dots, N\}$, $E_j = (e_{1j} + \dots + e_{Nj})/N$, $F_j = \max\{f_{ij}: i=1, \dots, N\}$. Similar, pentru fiecare utilizator i și stare Ψ_j , avem pe axa Oy, a activării ν_j .

Construirea modelului afectiv. Fie mulțimea stărilor de bază $\{\Psi_j: j=1, \dots, n\}$, unde n este numărul de stări de bază considerate în model (furie (mânie), dezgust, frică, fericire, tristețe, surpriză și starea neutră). Fie N numărul total de persoane implicate în experiment.

Pentru fiecare persoană se determină un model personalizat al stărilor afective. Algoritmul corespunzător, numit PersFLAVI (**Personalized FLAVI** – FLAVI personalizat), parcurge, după autentificarea utilizatorului, în mod aleator, setul de 217 imagini în care sunt fotografiate persoane diferite. Acestea manifestă pe rând toate cele 7 stări de bază într-un număr de 31 de imagini pentru fiecare stare. Se cere utilizatorului să evalueze starea pe care crede el că o simte acea persoană în termeni de perechi (x, y) în spațiul activare-evaluare și ca intensitate (z) . Fiecare imagine are o etichetă, stabilită dinainte și salvată în baza de date, cu una din cele 7 stări de bază. Apoi, pe baze statistice, plecând de la etichete, se calculează parametri mulțimilor nuanțate la stările de bază, pe cele două axe: activare și valență.

Pornind de la modelele individuale, se aplică algoritmul denumit **GenFLAVI** (**Generalized FLAVI** – modelare afectivă nuanțată generalizată) pentru realizarea unui model general corespunzător unui grup de persoane. Calculul parametrilor modelului se poate face pe baza a două metode diferite, prezentate în secțiunile următoare. Indiferent de metodă, se iau pe rând cele $m=7$ stări de bază. Pentru fiecare dintre ele, se consideră modelele individuale pentru minim $n=31$ de subiecți. se calculează valorile parametrilor A, B, C, D, E și F după formule specifice metodei statistice abordate în care se parcurg cele p imagini cu eticheta stării de bază curente. În final rezultă modelul general pentru acel grup de m subiecți. Varianta prezentată este a calculului cu întrevale de încredere (GenFLAVI-CI).

Metoda probabilistică. Folosind înregistrările determinate experimental s-a calculat, pentru fiecare din cele 6+1 stări de bază, punctul ce îi corespunde în planul activare-valență prin media aritmetică a punctelor ce corespundeau imaginilor etichetate inițial cu o anumită stare de bază. A rezultat astfel un modelul afectiv individual, personalizat PersFLAVI-P (P de la probabilistic). Fiecare suprafață colorată este mulțimea nuanțată a stării de bază, centrul fiind dat de media statistică a evaluării eșantioanelor din acea stare și începutul și finalul pantei (aici fiind în plan se vede doar valoarea de pornire și de oprire pe fiecare axă) fiind minimele și maximele rezultate din evaluarea eșantioanelor etichetate inițial cu starea precizată. S-a păstrat aici ideea de elipse pentru fiecare stare de bază, deși, așa cum se arată în secțiunea 3.1.5, suprafețele ar trebui să fie dreptunghiulare.

Metoda bazată pe intervale de încredere. Pentru a crește precizia medierii se folosește metoda intervalelor de încredere pentru media teoretică (notată M_j) pentru calculul valorilor A_j și C_j , pentru un eșantion aleator care urmează o distribuție necunoscută, dar pentru care avem suficient de multe observații (mai multe de 30) (vezi [Fah01], p. 381).

Aplicația de modelare a stărilor afective „FuzzyAffectiveModeller”. Comparând cele două metode de definire a parametrilor mulțimilor nuanțate (fuzzy) se observă că:

- metoda GenFLAVI-P care face doar medierea simplă a valorilor coordonatelor pe fiecare axă determină suprafețe de definire pentru stările de bază prea mari și deci nespecifice
- metoda GenFLAVI-CI, care folosește intervale de încredere este mai flexibilă, permițând controlul procentelor de acoperire pentru suprafețele ocupate de o anumită stare de bază în planul activare-valență (de exemplu, 70% din punctele care corespund stării „fericit” sunt prezente în suprafața definită pentru acea stare dacă nivelul de semnificație este $\alpha=0.001$).

Axa intensității. R. Plutchik reia, sub o altă formă [Plu80], ideea postulatului 10 în cartea sa despre emoții [Plu94] spunând că „fiecare emoție poate exista în diferite grade de intensitate”. O persoană poate avea

simultan mai multe stări afective dar generate de factori diferiți, selectarea stării dominante făcându-se după intensitatea acelor stări [Slo99].

Intensitatea stării afective este proporțională cu distanța de la origine la cele două axe [Plu94]. Pentru a testa această ipoteză, s-a procedat în felul următor:

Subiecților din experimentul anterior li s-a prezentat în mod aleator un set de 90 de tablouri selectate din autori diferiți, cu o distribuție proporțională între intensități mici, medii și mari; pentru fiecare din acestea declarând o stare afectivă în planul activare-valență și o intensitate a stării predominante trăite la vederea tabloului.

Datele indică o distribuție simetrică, aleatoare a punctelor pe discul stărilor declarate ca având intensitate mică, respectiv a suprafețelor corespunzătoare stărilor afective declarate a fi de intensitate medie și mare. De asemenea putem observa că cercul care delimitează discul stărilor în planul activare-valență este depășit într-un număr mic, dar semnificativ de situații, ceea ce arată că mai degrabă acest plan este unul care cuprinde și stări care se află dincolo de acest cerc. Acesta arată că în cazul modelului activare-valență cercul nu este o graniță a stărilor posibile. În urma acestei constatări s-a decis ca în modelul FLAVI suprafețele care definesc stările de bază să fie de formă dreptunghiulară, ceea ce a făcut ca, în corelație cu funcțiile triunghiulare ale funcțiilor de apartenență, reprezentarea stărilor de bază să fie una piramidală, așa cum este ilustrat în Figura 3.1.

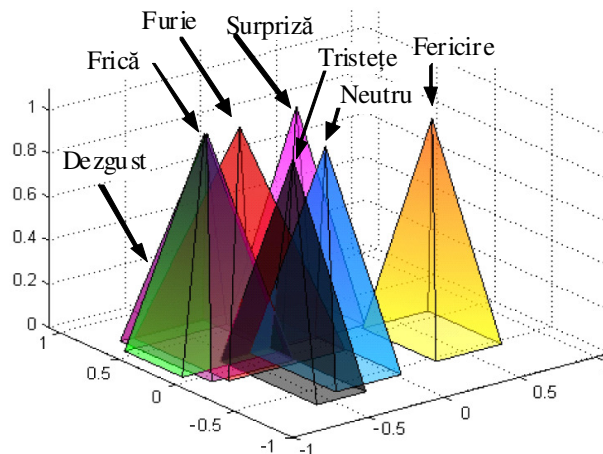


Figura 3.1 Un exemplu de model afectiv personalizat.

Evaluarea modelului FLAVI. Modelul FLAVI extinde modelul activare-valență [Cow00b] prin adăugarea dimensiunii intensitate justificată experimental și oferă o metodologie de construire a suprafețelor de definiție a stărilor de bază. FLAVI rezolvă problema numărului limitat de stări distincte (20 după [Cow00b]), suprapunerea stărilor de bază reprezentate rigide în spațiul activare-valență în [Cow00b]).

În sinteză menționăm următoarele **avantaje** ale modelului FLAVI precum și ale metodelor de construire a lui, GenFLAVI-P și GenFLAVI-CI:

1. permite definirea suprafețelor celor șapte stări de bază și a relației matematice între orice stare secundară și fiecare din stările de bază prin grade de apartenență exprimate pe fiecare dintre axele activare și valență;
2. definirea relației dintre stările secundare și cele de bază se face folosind o interfață grafică cea ce facilitează utilizatorului introducerea datelor;
3. suprafețele stărilor de bază sunt definite și ele folosind logica nuanțată (fuzzy) în planul activare-valență ceea ce permite o nuanțare a definirii fiecărei stări de bază în parte;
4. permite reglarea parametrului α , cu ajutorul căruia putem redefini cu ușurință, în același timp, toate definițiile mulțimilor de apartenență ale stărilor, ceea ce este util în personalizarea modelului FLAVI și adaptarea lui la diferite aplicații.

Direcții deschise de modelul FLAVI. Într-o manieră similară celei prezentate, se pot defini arii pentru clase de valență sau clase de activare. Folosirea de mulțimi nuanțate (fuzzy) permite personalizarea definițiilor și pentru aceste clase.

Este posibilă explorarea avantajului definirii nuanțate a stărilor pentru menținerea actuală a modelului în timp. Se poate propune un mecanism de optimizare și evoluție a modelului prin implicarea utilizatorului în bucla de reglare. O idee ar fi ca utilizatorul să regleze parametrii mulțimilor de apartenență. Aceasta se poate face etichetând cu nume de stări imaginile etalon care îi sunt expuse utilizatorului periodic, într-o ordine aleatoare.

3.2 Extinderea modelului ontologic de context cu modelului afectiv FLAVI

În această secțiune se arată modul în care s-a extins modelul ontologic SOCAM cu elemente afective pe baza ontologiei utilizatorului GUMO și a modelului afectiv propus FLAVI[Ben07a].

Formularea problemei. P1. Reprezentarea ar trebui să fie cât mai generală și flexibilă cu putință pentru a permite diferitelor modele existente să fie mapate pe ea, dar totuși să creeze cadrul descrierii efective a modelului teoretic în detaliu.

P2. Cum ar trebui exprimată legătura dintre stările de bază și cele secundare astfel încât stările secundare să se poată deduce din cele de bază.

P3. Cum să se exprime relația dintre stări potențiale și stările curente (dominante).

P4. Cum putem exprima relații ca: i. a cui este sau cine trăiește o anumită stare afectivă, ii. care este relația cauzală: stare afectivă – obiect, iii. care este legătura dintre starea afectivă și timp?

Reprezentarea ontologică a modelului afectiv FLAVI. Există o distanță conceptuală între cele două modele afective principale (vector și spațiu de stări afective) deoarece nu există niciun mecanism pentru a cuantifica spațiul afectiv continuu într-un set discret de stări afective și vice-versa. Prin reprezentarea modelului afectiv unificat FLAVI, se facilitează și reprezentarea celorlalte modele fie discrete, fie continue.

Se definește o clasă *State* în ontologia de context SOCAM [Wan04] cu trei subclase: *Affective*, *Mental* și *Physiological*. Clasa *Affective* are trei subclase: *Basic*, *Secondary* și *Current*. *Affective* are atribute care definesc regiunea ocupată de fiecare stare pe fiecare din cele trei axe: \minValence , $\maxValence \in [-1,1]$; \minActivation , $\maxActivation \in [-1,1]$; $intensity \in [0,1]$. Clasa *Basic* are subclase în funcție de modelul afectiv folosit. Se propune folosirea celui cu șapte stări: furios, neutru, fericit, supărat, surprins, dezgustat și înfricoșat. Clasa *Secondary* are ca subclase, un număr de elemente care sunt specifice aplicației. În scenariul prezentat se definesc doar curioz și stresat (reprezentate de o formă de inimă desenată cu linie punctată în Figura 3.12). Clasa *Current* va fi descrisă în secțiunea următoare.

Reprezentarea stării afective curente. Starea curentă $\Psi_{curenta}$ ar trebui să fie cea stare care este cea mai puternică pentru utilizator dintre stările pe care el le trăiește la acel moment dat. Starea curentă va fi dată de indicele ce corespunde valorii maxime dintre produsul dintre intensitatea de stare Ψ_i și senzitivitatea stării ϕ_i pentru fiecare dintre stările 'i' considerate.

Stările afective în relație cu alte elemente de context. Se propune ca reprezentarea relației dintre stările afective și alte elemente de context ca proprietăți ale claselor stărilor afective: *owl:ObjectProperty* pentru a-l desemna pe cel sau cea care trăiește acea stare și pentru relațiile cauzale obiect inductor al acelei stări-stare. Pentru exprimarea atributelor temporale ale stării afective s-a decis să se folosească *owl:datatypeProperty*.

Reprezentarea relației Person este într-o stare afectivă. Așa cum a fost descris în scenariu, Victor trecea de la plictiseală la entuziasm. Fiecare din aceste stări secundare pot fi induse de către alte elemente de context. În acest caz doar plictiseala este ilustrată. Pentru fiecare individ al clasei *Person* va fi realizată o relație specifică *isInTheState* *owl:ObjectProperty* cu indivizii din *Current*.

Reprezentarea relația cauzale între starea afectivă și ceea ce a determinat-o. Victor se află în Camera1 când devine plictisit, așa că obiectul plictiselii lui poate fi considerat a fi Camera1. Pentru fiecare stare afectivă curentă *Current* propunem o proprietate *owl:ObjectProperty* numită *isInducedBy* care indică obiectul acelei stări în acel moment specific, adică ceea ce a determinat acea stare.

Reprezentarea temporală a stării afective. Stările afective pe care le trăiește o anumită persoană sunt într-o continuă schimbare. Se propune adăugarea informației legată de timp stărilor. Eticheta de timp va permite sistemului automat să înțeleagă aceste succesiuni în timp ale stărilor afective ale utilizatorului. Ca o consecință clasa părinte *Affective* va avea următoarele instanțe *owl:datatypeProperty* : *start*, *stop*, *duration* (durată). Semnificația primelor două (*start* și *stop*) este evidentă. *Duration* (durata) este valoarea temporală estimată inițial de către senzorul care a indicat timpul de viață a stării afective respective. Este deci o durată estimată, spre deosebire de durata obiectivă care poate fi calculată prin diferența între valorile parametrilor *stop* și *start*.

Extinderea SOCAM pentru a include informații afective. În capitolul 2 s-a arătat de ce sunt preferate ontologiile pentru reprezentarea contextului. Dintre ontologiile de context existente s-a ales extinderea ontologiei SOCAM detaliind descrierea stărilor utilizatorului într-un mod similar cu elementul de context locație și activitate, genrealizând apoi starea (mentală, afectivă, fiziologică) de la utilizatorii umani la entități computaționale.

Cum se reprezintă mulțimile nuanțate în OWL? S-a propus ca, în cadrul modelului FLAVI, să se exprime relația dintre stările secundare și cele de bază ca mulțimi nuanțate. SOCAM nu oferă suport explicit pentru această reprezentare. Folosirea logicii nuanțate mai este menționată [Ran04] însă acolo formalizarea este bazată pe logica predicatelor. Abordarea din această teză o urmează pe cea prezentată în [Wan04]. Este bazată pe OWL, deoarece OWL a devenit standard al Web Semantic W3C [McG04]. Se propunem ca *AffectiveMembershipDegree* să aibă două *owl:DatatypeProperty*: *valenceDegree* și *activationDegree*. Relația dintre stările *Secondary* și *Basic*, să fie reprezentată

prin owl:ObjectProperty *hasAffectiveMembershipDegree* și *isAFuzzyMemberOf*, respectiv. Valorile sunt pentru *activationDegree* și *valenceDegree* și pot fi determinate experimental.

Exprimarea relației dintre diferitele stări și starea predominantă în OWL. OWL nu permite unui ObjectProperty să aibă atribute. Se folosește clasa *Sensitivity* pentru a stoca valoarea ϕ (*senzitivitate*) pentru fiecare dintre stările potențiale curente. Similar clasei *AffectiveMembershipDegree* relația dintre *Current* și *Basic* și *Secondary* este un owl:ObjectProperty. Mai mult decât atât fiecare dintre instanțele *Sensitivity* sunt specifice pentru o anumite persoană (ex. un coleric este predispus la furie, $\phi_{Furie}=0.9$) iar *isOwnedBy* reprezintă această relație. Valorile pentru senzitivitate sunt obținute prin experimente. Pentru a determina starea curentă dominantă a utilizatorului trebuie scrisă o regulă pentru motorul de raționament.

Evaluarea modelului SOCAM-FLAVI. Sintetizăm evaluarea modelului de reprezentare SOCAM-FLAVI în tabelul 1:

Trăsături caracteristice	[W3C08]	[Gar06]	[Fra07]	[Cea07]	[Lop08]	[Ben07]
Generalitatea utilizării oricărei teorii a emoțiilor	x	-	-	x	x	unificat
Reprezentare ontologică	-	x	x	x	x	x
Relația stări secundare-stări de bază	-	-	intervale	-	-	logică nuanțată
Relația context-emoții	-	-	-	x	x	x
Relația emoții-canal de exprimare	-	-	-	x	x	-
Relația stări curente-stare predominantă	-	-	-	-	-	x
Personalizarea modelului	-	-	-	-	-	x

Tabelul 3-1 Comparație între modelele de reprezentare existente pentru stările afective (emoții)

Avantajul net pe îl are modelul SOCAM-FLAVI este că permite personalizarea reprezentării relațiilor dintre stările de bază și secundare pe baza definirii unor mulțimi nuanțate pe axele activare și valență și a relațiilor dintre stările curente și a stării predominante. De remarcat că este că articolul care prezintă propunerea SOCAM-FLAVI [Ben07a] este citat în [Lop08] unde se spune „Pe de altă parte, focalizându-se pe context [Ben07a] prezintă o reprezentare bazată pe ontologiei a stărilor afective pentru aplicații senzitive la stările afective care permit exprimarea relațiilor complexe care există între stările afective și între acestea și alte elemente de context”.

Direcții deschise. Modelul extins SOCAM-FLAVI crează cadrul pentru extinderea SOCAM cu date utilizator ce descriu stările mentale și fiziologice și relația lor cu contextul. Descrierea semantică a acestor stări poate aduce avantaje la nivelul personalizării aplicației.

O altă direcție interesantă ar fi cuprinderea în modelul SOCAM-FLAVI a variabilelor de evaluare (appraisal variables) care determină, conform psihologiei cognitive, reacțiile emoționale diferite pentru fiecare individ. Aceste variabile sunt în legătură cu elementele de context, dar la un nivel înalt de abstractizare. Ca urmare, determinarea lor din context reprezintă o provocare. Beneficiile previzibile ale acestei direcții rezultă din modelarea mai precisă a utilizatorului din perspectiva științelor cognitive (psihologie, inteligență artificială, lingvistică, filozofie, științe neuronale educație și antropologie). Aceasta poate determina un comportament mai prietenos cu utilizatorul al acelei aplicații.

3.3 Concluzii

S-au propus două modele: un model afectiv FLAVI și un model de context, care integrează acest modelul afectiv, numit SOCAM-FLAVI, ambele obținute prin extensia unor modele existente.

Modelul afectiv FLAVI extinde modelul activare-valență și permite cuantizarea spațiului activare-evaluare și personalizarea lui folosind logica nuanțată. Acesta constă în definirea pe baze statistice a două mulțimi nuanțate triunghiulare μ_x (pe axa valență) și μ_y (pe axa activare) pentru reprezentarea gradului de apartenență a stării secundare la fiecare dintre stările de bază. Pentru aceasta s-a propus o metodologie de construire a modelului cu doi algoritmi PersFLAVI și GenFLAVI. În urma testării ipotezei relației de proporționalitate între distanța de la originea planului activare-valență și intensitatea stărilor emoționale (3 niveluri), s-a dovedit necesitatea dimensiunii distincte intensitate, care să fie adăugată perpendicular planului activare-valență.

Modelul ontologic de context extins, bazat pe ontologia de context SOCAM, cuprinde și modelul stărilor afective FLAVI, conținând elemente afective detaliate, față de ontologia existentă pentru descrierea utilizatorilor GUMO. De asemenea, SOCAM-FLAVI cuprinde reprezentarea ontologică a relațiilor dintre stările: curentă, secundare și de bază pe de o parte și a relației dintre stările afective și context, pe de o alta.

Contribuții la detecția stărilor afective

Se propun contribuții originale pentru determinarea stărilor afective, combinând informațiile de context și profilul utilizatorului, pe de o parte [Ben08] și metode de detecție adecvate mediului mobil, în situații cât mai apropiate de viața reală [Ben09c], pe de altă parte. Prin aceasta se înțelege determinare în timp real, a stărilor afective spontane, nuanțate (nu doar un set mic de stări de bază care să aproximeze doar starea utilizatorului), în condițiile prezenței factorilor perturbatori și a mișcării utilizatorului.

4.1 Detecția din context a stărilor afective

Aplicațiile mobile ce se dezvoltă actualmente solicită din ce în ce mai mult o paradigmă în care utilizatorul este figura centrală (user-centred). Cu toate acestea, există un număr mic de servicii care să țină seama și de starea utilizatorului (mentală, afectivă, fiziologică). S-a ales să se aprofundeze modalitățile tehnice de determinare a stărilor afective, care sunt instrumente importante de comunicare socială. Este o chestiune cunoscută din viața de zi cu zi (din păcate foarte puține studii au fost întreprinse în acest sens) că oamenii folosesc informația contextuală pentru a realiza care este starea afectivă a altei persoane. Există articole din domeniul psihologiei care arată corelații între factori de mediu (context) și emoții [Plu94]. Însă nimeni, din câte se cunoaște, nu a încercat să deducă stările afective actuale ale utilizatorului din context folosind sisteme de calcul. În continuare se prezintă rezultatele acestui demers, publicat în [Ben08].

Formularea problemei

În psihologie există o distincție importantă, cu o largă acceptare, între stările afective de bază și cele secundare. Plutchik vorbește în [Plu80] despre cele de bază ca fiind dezvoltate în decursul evoluției noastre ca specie. În domeniul calculului afectiv au fost propuse, cu preponderență, soluții pentru determinarea acestor stări de bază. Au existat totuși preocupări și pentru stările secundare (amuzament [Bai08], iubire [Nez08], vinovăție [Ton07]), care sunt totuși prezente și importante în viața cotidiană. Mai mult, există cercetători care insistă că stările secundare sunt exclusiv umane [Dem04] și dependente cultural [Har89].

Pentru a ilustra utilitatea stărilor afective secundare, menționăm ca domeniu de aplicabilitate a lor procesul de învățare. Este cunoscut faptul că tehnologiile care prezintă inteligență socială sunt eficiente ca suport pentru învățare [Wan08] iar studii teoretice au arătat corelații între stările afective și rezultatul procesului de învățare [Kor01]. Un tutore senzitiv la stările afective, care sunt de cele mai multe ori secundare, poate mai apoi să le folosească [Kap01] pentru creșterea eficienței învățării. În articolul [Kor01] au fost enunțate un număr mare de emoții dispuse pe 5 axe (câte 6 stări pe fiecare axă), cu ar fi anxietate-încredere, frustrare-euforie. Un studiu mai recent al aceluiași grup de lucru de la MIT se focalizează pe un set mai precis de stări, toate secundare relevante pentru învățare: frustrare, confuzie și plictiseală [Bur06a].

În timp ce abordarea lor este să determine aceste stări secundare din combinarea de detectoare fiziologice, de presiune și vizuale, aici se urmărește să se verifice în ce măsură se pot extrage aceste informații de stare din context și pe baza profilului utilizatorului.

Varianta determinării stărilor secundare din valorile pe care detectoarele de stări de bază ni le furnizează și pe baza unui profil individual a fost prezentată în capitolul 4, în acest capitol perspectiva este asupra obținerii acestor informații din context.

O posibilă întrebare este de ce să nu se combine diversele metode existente de detectare a stărilor secundare pentru a avea cât mai multe dintre ele disponibile? Răspunsul este că metodele de detecție a stărilor secundare sunt realizate pentru medii în care există o mică variabilitate a factorilor de mediu. Astfel, în [Mot03] autorii propun utilizarea unui scaun dotat cu senzori de presiune în încercarea de a determina nivelul de implicare al subiectului (interes ridicat, scăzut și dorința de a lua o pauză). Din studiul lor rezultă că există 9 posturi relevante pentru detecția implicării și au folosit HMM pentru a antrena un sistem pentru a asocia posturilor un anumit grad de interes. Rezultatele raportate de ei au fost de 87.6% clasificări corecte din date de test distincte de cele de antrenare. Un alt articol [Kap01] propune folosirea unei combinații a mai multor medii (facial, postural și din activitatea curentă (joc)) pentru determinarea

interesului (interes puternic, slab, plictiseală, revigorare, neutru sau altele. Rezultatele au arătat 67.8% precizie folosind HMM pentru antrenare cu valori ce proveneau de la diferitele medii.

Soluția propusă pentru deducerea de stări afective secundare

S-au propus două metode de deducere a stării afective actuale: prima se bazează pe profilul utilizatorului, extras din chestionar (cel pe care utilizatorul a trebuit să-l completeze înainte de a folosi acest ghid). Cea de-a doua metodă constă în îmbunătățirea primei metode cu un sistem expert. El învață să prevadă starea afectivă, luând în considerare valorile factorilor de context actuali și preferințele utilizatorilor existente în profil.

Metoda de deducție bazată pe profil ConAff2-UP. Pentru a anticipa starea afectivă curentă, s-au extras factorii contextuali curenți ca un vector F cu 18 valori binare (de exemplu, având în vedere că numărul de persoane este de 3, atunci valoarea pentru cel de-al 10-lea factor este 1, iar pentru cel de-al 11-lea și al 12-lea este 0). Profilul utilizatorului extras din chestionar este o matrice tridimensională (factor, stare afectivă, intensitatea stării afective) numită P . Înmulțind matricea F și P se obține o matrice bidimensională (stări și intensitate afectivă). Starea prezisă ar fi cea care este cea mai intensă (prin adăugarea tuturor valorilor de intensitate pentru o stare afectivă).

Deducția bazată pe rețele neuronale ConAff2-NN. S-a propus folosirea unui sistem expert pentru creșterea ratei de predicție pentru starea afectivă curentă. În urma unei analize comparative (Figura 4.3) s-a decis utilizarea unei rețele neuronale perceptron multistrat cu algoritmul propagării inverse (back propagation). Mai întâi s-a folosit un perceptron simplu cu 18 factori * 30 valori extrase din profilul utilizatorului, adică 540 de valori, ca intrări și cele șase stări afective ca ieșiri. S-a testat configurația în Matlab. Rezultatele nu au fost satisfăcătoare datorită numărului mare de intrări. Ca urmare s-a ajuns la o anumită configurație. Numărul de intrări a fost de $18+30 = 48$, numărul de niveluri ascunse a fost 8 (Nhid) și s-a folosit funcția *newff* pentru perceptronul multistrat pentru calculul valorilor de ieșire (feed forward) cu funcții sigmoid și pas liniar. Numărul optim de epoci a fost de 150.

S-a antrenat rețeaua cu un set de 200 de înregistrări obținute de la 8 utilizatori. Fiecare înregistrare a fost o pereche de valori (intrare, ieșire dorite). Ca intrări s-a folosit un vector cu exact acele valori pentru cei 18 factori binari și un set de 30 de valori obținute din produsul dintre matricile F și P . Ieșirea dorită a fost starea declarată (una din șase).

Platforma de testare a ghidului muzeal. Lucrarea este bazată pe cercetări anterioare asupra ghidurilor pentru muzee senzitive la context [Lon05][Sto07]. Aplicația, descrisă în detaliu în teză, are două părți: una este aplicația web pentru realizarea profilului utilizatorului, iar cealaltă este ghidul mobil senzitiv la context.

Rezultatele metodelor de deducție a stărilor secundare din context ConAff2-UP și ConAff2-NN

Rezultate pentru metoda de deducție bazată pe profilul utilizatorului ConAff2-UP. S-au înregistrat 231 de evenimente (factori curenți contextuali și stările declarate cu intensitatea corespunzătoare) pentru 8 persoane în diferite scenarii de test: experiență singulară, grupuri mici (2-5 persoane), grup mare. În unele cazuri s-a simulat presiunea de timp (prin reducerea timpului rămas pentru vizită). Vremea a fost diferită în zilele în care s-au făcut testele, chiar dacă nu au fost acoperit toate situațiile posibile. Tablourile expuse în sală au fost și ele diverse: unele dintre ele erau renumite datorită conținutului (de exemplu, "Nașterea lui Venus") sau datorită autorului (de exemplu, Paul Cézanne), dar de obicei, ambele (de exemplu, Leonardo da Vinci, "Mona Lisa"). Variații au fost și din punct de vedere al conținutului (peisaje, oameni) sau culori (calde și reci).

Folosind profilul extras din chestionar s-au obținut 40 predicții corecte din 231 de evenimente, adică un procent de 17.316%. Pentru a avea o referință cu care să putem compara acest rezultat, s-a calculat probabilitatea de a nimeri starea afectivă curentă: dat fiind faptul că utilizatorul este într-o stare (să spunem „Fericit”), probabilitatea de a nimeri corect este de $1/6$, adică 16,17%. Comparând procentul de predicție corectă, pe bază de profil de utilizator (17.316%), cu probabilitatea de a nimeri corect (16,17%), putem spune că este aproape nesemnificativă și deci nesatisfăcătoare.

Rezultatele metodei bazate pe rețele neuronale ConAff2-NN. S-a antrenat rețeaua neuronală concepută, descrisă mai sus, cu 200 din cele 231 de înregistrări și testat cu cele 31 de valori rămase pentru a afla procentajul de predicții corecte.

Rezultatele indică 11 predicții corecte din 31, adică 35.484%. Chiar dacă acest rezultat nu e atât de bun ca și cel așteptat, este o îmbunătățire comparativ cu cel obținut cu soluția bazată pe profil. Pentru antrenare au fost considerate 200 de înregistrări, 48 de valori de intrare și 6 clase de ieșire. Clasificatorul *Naïve Based Classifier* a avut 0.730288 rata de clasificare, clasificatorul *Gaussian Classifier* a avut 0.730288 și pentru *t-dist* au fost trei situații: a) *full* rata eroare = 0.730288; b) *semi-naïv* rata eroare = 0.835835 ; c) *naïv* rata eroare = 0.835835

Valoarea optimă a fost obținută de către clasificatorul *Neural Network Classifier*, cu 8 neuroni în stratul ascuns. Valoarea obținută este chiar mai bună decât cea găsită anterior, adică o rată a erorii de 0.68253. S-a făcut, de asemenea, și un test pentru metoda SVM [asi09] pe datele prezentate. Rezultatele indică o clasificare corectă de 15.50%. Acest rezultat este explicabil datorită numărului mare de intrări (48).

Evaluarea metodelor de deducție a stărilor secundare din context ConAff2-UP și ConAff2-NN.

Rezultatele numerice prezentate indică valori reduse, chiar slabe dacă este să comparăm cu valorile detectoarelor de stări secundare menționate în secțiunea 4.1.1. Comparativ cu valoarea obținută dacă s-ar selecta starea afectivă secundară în mod aleator 16,17%, metoda ConAff2-NN clasifică în mod corect în 35.484% din cazuri. Aceasta indică un număr dublu de cazuri, dar totuși de 3 ori mai mic decât 100%. Merită menționat că aceste valori au fost obținute în timp real și în mod neintruziv. Ca urmare, este dificilă o comparație strict numerică deoarece celelalte metode fie nu funcționează în timp real, fie sunt intruzive (folosesc senzori care se atașează pe diverse părți ale corpului subiectului).

În concluzie, se constată că metodele bazate pe deducție din context a stărilor afective sunt recomandate ca sursă complementară celorlalte metode existente pentru determinarea stărilor afective secundare.

Direcții deschise. O ipoteză de luat în calcul este creșterea preciziei determinării stărilor afective dacă se extinde profilul utilizatorului cu noi parametri cum ar fi: tipul de personalitate al utilizatorilor, starea afectivă de bază curentă și folosirea lor ca intrare pentru rețeaua neuronală.

O altă ipoteză este creșterea preciziei determinării stărilor afective dacă se folosește reacția (feedback-ul) utilizatorului în legătură cu corectitudinea predicțiilor sistemului în deducerea stării afective. Pentru aceasta, se poate dezvolta aplicația astfel încât să permită folosirea GARIC [Ber92], care este un sistemul de învățare prin întărire neuro-fuzzy.

Precizia detecției poate crește prin folosirea unui model computațional cognitiv (evaluativ, appraisal) al emoțiilor, de exemplu EMA, pentru determinarea prin deducere/derivare a stărilor afective folosind variabile de apreciere (relevanță, perspective, dezirabilitate, probabilitate, expectanță, atribuire cauzală, controlabilitate, capacitate de schimbare). Valorile variabilelor de apreciere vor trebui să fie extrase folosind informații provenite din context prin senzori sau prin raționare. De exemplu, relevanța unei acțiuni se poate obține pe baza calculului utilității acelei acțiuni în trecut. Pentru acesta este, desigur, necesar un algoritm de calcul a utilității acelei acțiuni pentru utilizator.

4.2 Determinarea valenței

Valența (valence, în limba engleză), uneori numită și măsura plăcerii pe care o provoacă o anumită trăire (pleasure, în limba engleză) este o proprietate a oricărei stări afective. Valența stării curente a utilizatorului este un factor important în interacțiunea om-mașină [Col05] deoarece caracterizează la modul general răspunsul emoțional în termeni de acceptare (+), respingere (-) sau neutru (0). Cu toate acestea este arareori adresată în evaluarea non-invazivă a stărilor afective cum sunt cele bazate pe interpretarea trăsăturilor faciale. În continuare se propune o metodologie de evaluare a preciziei de măsurare a valenței în situații reale și două metode de determinare a valenței, una empirică și cealaltă prin personalizare.

Formularea problemei. Interesul pentru determinarea emoțiilor ce sunt manifestate spontan este foarte important pentru aplicații om-calculator în timp real [Seb04]. Numărul de unelte soft să determine stările afective în timp real prin modalități ne-invazive este redus și este deficitar în privința evaluării performanțelor în cazul stărilor ce apar în mod spontan. FaceReader este unul dintre puținele sisteme de recunoaștere automată a trăsăturilor faciale, disponibile public, ce permite analize avansate și funcții de raportare [FR09]. Deși FaceReader s-a dovedit a fi destul de precis în cazul unor expresii faciale "pozate" (ne-spontane) [Kui05], nu există nici un studiu comparativ și cantitativ care să indice capabilitățile sale în privința detectării emoțiilor spontane.

Publicații recente [Seb04, Yea06, Bai08] revendică rezultate remarcabile în privința determinării în timp real a stărilor afective spontane. În privința cadrului de testare există mai multe abordări. În [Seb04] se folosesc filme scurte de prezentare care au fost urmărite de 28 de subiecți și a căror trăsături faciale au fost capturate și analizate de o cameră ascunsă iar apoi clasificate în timp real în 4 stări afective (neutru, bucurie, surpriză și dezgust). În articolul [Bai08] emoțiile sunt provocate cu ajutorul unor filme scurte. Apoi li se preiau participanților, în număr de 41, datele parametrilor faciali și fiziologici (soluție parțial invazivă), dar, în final, se clasifică doar în amuzament și tristețe ca stări afective complementare. O abordare similară găsim în [Yea06] unde se spune că, pe baza trăsăturilor faciale determinate în cei 21 de subiecți de filme încărcate emoțional se face o clasificare în cele 6 stări de bază.

Observăm că în cazurile expuse stimulii inductori ai stărilor afective nu sunt evaluați înainte pentru a certifica cu precizie efectul pe care îl are asupra subiecților țintă. Ca urmare este dificil de spus ceva despre performanțele prezentate în condițiile acestei neclarități metodologice.

Ca urmare există două probleme importante ce prezintă o numită dependență:

1. Care este cadrul metodologic în care uneltele soft ce determină stări afective (sau parametric caracteristici ale lor cum ar fi valența), în cazul stărilor ce sunt spontane, în timp real și prin metode ne-invazive (în particular din trăsături faciale) sunt evaluate (testate) pentru a se măsura acuratețea cu care ele fac determinările?

2. a) Care este precizia cu care pot uneltele soft de determinare a stărilor afective să măsoare valența stării curente pe care o are utilizatorul?

b) Cum se poate măări acuratețea cu care se face citirea valenței?

Dependența menționată se referă la faptul că, dacă nu se cunoaște un cadru metodologic corect, chiar dacă se revendică procente impresionante de clasificări de exemplu 93%, dar nu se spune clar pe câte persoane s-a făcut evaluarea, care erau caracteristicile grupului țintă, în ce condiții a decurs experimentul, cu ce s-a făcut inducerea stării și dacă inductorii stărilor au fost prevalidați, nu sunt extrapolabile și deci nu se poate răspunde la a doua întrebare (2.a). A treia întrebare 2.b, se poate formula doar după ce avem un răspuns clar la a doua și care să arate că precizia determinării valenței este nesatisfăcătoare.

Abordarea a fost ca mai întâi, în colaborare cu psihologii să se propună un cadru metodologic de evaluare și apoi să se aplice această metodologie la cel puțin o unealtă de determinare a stărilor afective. Iar apoi să se găsească metode de ameliorare a preciziei determinării valenței.

Soluția propusă: metodologia de evaluare a preciziei de măsurare a valenței în situații reale din trăsături faciale FANAR-EM

În urma constatării că în domeniul calculului afectiv, soluțiile de determinare a stărilor afective nu au o metodologie de evaluare care să precizeze clar, riguros care sunt pașii și care sunt condițiile în care se face evaluarea, propusă în [Ben09c] o astfel de metodologie care este detaliată în secțiunea următoare, după care este aplicată pentru detectorul FaceReader.

Pașii metodologiei de evaluare a valenței în situații reale. Algoritmul FANAR-EM este aplicat pentru fiecare subiect uman, considerat în continuare ca utilizator al sistemului. Evaluarea valenței se face pentru mai mulți utilizatori pentru a avea diversitate atât a caracteristicilor faciale cât și a caracteristicilor subiective de percepere a stărilor afective.

După autentificarea utilizatorului se inițializează un contor în care se memorează în câte cazuri valoarea valenței detectate cu programul de evaluat coincid cu valoarea declarată de utilizator pentru valență. Se prezintă apoi un set de n imagini, special pregătite, inductoare de diferite stări afective cu valențe egal distribuite între tipurile de valențe pozitive, neutre și negative. Prezentarea fiecărei imagini se face pentru un timp dat. Se recomandă o durată de minim 4.5 de secunde, valoare pentru care s-a constatat [Ben09c] că apare un maxim al reacției utilizatorului. Pe parcursul prezentării imaginii sistemul preia imaginea facială a utilizatorului și îi evaluează valența pe baza valorii stărilor de bază sau cu un alt algoritm specific acelei aplicații de evaluat. Se solicită apoi utilizatorului să-și declare valența folosind o modalitate consacrată; se recomandă folosirea SAM (Self-Assessment Manikin) [Lan80]. Incrementează contorul *corect* dacă valoarea declarată a valenței și cea determinată de programul care estimează valența, pe care noi îl evaluăm. În final se afișează sau se returnează valoarea contorului *corect*.

Evaluarea metodologiei FANAR-EM. Stabilirea acestei metodologii a apărut ca urmare a lipsei unei metodologii riguroase pentru evaluarea stărilor afective, în timp real, din trăsături faciale. Comparativ cu metodologiile de testare existente, vezi secțiunea 4.2.1, FANAR-EM prezintă un salt calitativ evidențiat prin următoarele avantaje:

1. fixează ferm că testarea se face în timp real, ceea ce presupune existența subiectului uman cărui i se preiau imagini faciale cu o cameră video

2. factorii inductori ai stărilor afective aparțin unui set de imagini care sunt prevalidate experimental de psihologi, ele fiind astfel etalonate (IAPS)

3. folosește un număr de imagini diferite, cât mai bine distribuite în spațiul stărilor de bază pentru a parcurge întreaga mulțime de stări posibile

4. fixează ferm numărul de clase ale stărilor de bază la 6+1 (furie, dezgust, frică, fericire, tristețe, surpriză și starea neutră) iar la evaluarea valenței folosește SAM (Self-Assessment Manikin) pentru a evalua precizia valenței cu 9 niveluri.

Direcții deschise. Există două tipuri de direcții de cercetare deschise: unul psihologic și unul tehnic. Psihologic, există o provocare pentru inducerea, folosind imagini sau alte modalități, a stărilor de surpriză, furie și frică. Aceasta deoarece acestea au fost mai dificil de selectat din mulțimea de imagini IAPS.

Etalonarea unei mulțimi de imagini inductoare de stări secundare ar fi de asemenea o provocare atât datorită numărului mare de stări secundare, cât și a diferențelor culturale care există între diferitele ființe umane. Tehnic, testarea mai multor aplicații de determinare a stărilor afective din trăsături faciale ar fi oportună pentru o mai bună validare a metodologiei propuse. FANAR-EM ar putea fi extrapolat pentru alte canale de comunicare (vocal, fizilogic, kinestezic și chiar multimodal) a stărilor afective.

Metodă de calcul a valenței pe baza unor praguri determinate empiric (AVED – Affective Valence Empirical Determination)

În literatura de specialitate nu s-a găsit o formulă de calcul a valenței în funcție de stările de bază ale utilizatorului. Softul FaceReader este singurul care oferă o soluție de calcul a valenței. Formula, verificabilă practic în fișierele de log, este: $Valence = Happy - \text{Max}(\text{Sad}, \text{Angry}, \text{Fear}, \text{Disgusted})$, unde fiecare din stările de bază au valori reale normalizate în intervalul [0,1].

Formularea problemei. Datorită folosirii acestei formule simple, valența este mult mai sensibilă la stări negative și are variații importante în zona din jurul valorii zero, zona de valență neutră. Deoarece, așa cum s-a mai arătat, în literatura de specialitate se consideră niveluri discrete de valență (3 sau 9), era necesară o prelucrare a valorilor stărilor de bază așa încât să se facă o clasificare în trei sau nouă categorii și care să reducă imprecizia soluției cu funcția bazată pe valoarea maxim instantanee a unui subset al stărilor de bază.

Soluția propusă. Metoda de calcul a valenței propusă constă din următoarele: i. stabilirea valorii pragurilor determinate empiric pe baza declarației clasei de valență pentru o anumită persoană, ii. urmărirea valorilor medii ale eșantioanelor corespunzătoare celor cinci stări de bază polare (fericire, tristețe, supărare (mânie), frică și dezgust, care) în timp și clasificare pe baza valorilor de prag medii, stabilite empiric. Se urmărește atât valoarea instantanee, cât și valoarea în timp (medie), iar clasificarea se face pe baza unor valori de prag determinate empiric, ca în exemplul dat, pentru starea „Fericire”, din Figura 4.2. În cazul ariei notate cu valoarea 1 încercuită, valorile instantanee sunt mai mari decât valoarea de prag 0.4, dar media eșantioanelor nu depășește pragul valorilor medii de 0.47. În al doilea caz, aria cu valoarea doi încercuită, și valoarea medie depășește pragul. Ca urmare valoarea valenței este clasificată ca pozitivă.

Experimente numerice. Aplicând practic această metodă pentru o persoană, s-a constatat că anumite stări negative nu ajung să mai influențeze deloc, cum a fost cazul stărilor de tristețe și de frică, pentru persoana considerată, datorită unor particularități fizionomice ale acelei persoane. În Figura 4.13 s-a reprezentat evoluția eșantioanelor pentru starea pozitivă (fericire) și pentru stările negative (furie și dezgust) pe parcursul unui minut. Ca urmare, experimental s-au stabilit următoarele praguri: fericire: prag valoare instantanee 0.4, prag valoare medie 0.47; supărare: prag valoare instantanee 0.78, prag valoare medie 0.68; dezgust: prag valoare instantanee 0.82, prag valoare medie 0.72. Pragul de timp a fost ales în acest caz de o secundă, ceea ce corespunde la 5 eșantioane, fiecare eșantion fiind, în cazul general, 5 dimensional, în acest caz particular, prin simplificare, 3 dimensional.




Figura 4.1 Modul de calcul al valenței

Evaluarea metodei AVED. Comparând metoda inițială (cu funcție) și cea propusă, se observă două elemente ce fac diferența calitativă între ele (avantaje): 1. analiza și în timp a eșantioanelor pentru o anumită fereastră de timp, 2. existența pragurilor de clasificare determinate pentru acel utilizator.

Metodă de creștere a preciziei determinării valenței din trăsături faciale prin personalizare (PAVD)

Formularea problemei. Ca urmare a situației prezentate în finalul secțiunilor 4.2.2 și 4.2.3, formulăm următoarea problemă. Factorii individuali, subiectivi ai modului în care utilizatorul se exprimă facial, atunci când trăiește o anumită stare, nu sunt luați în calculul valenței de către unelte de detecție a trăsăturilor faciale, în particular FaceReader. Astfel,

utilizatorul nu poate interveni în nici un fel în a indica în ce măsură valoarea determinată de acea unealtă (FaceReader) pentru valența stării sale curente este cea trăită de el în realitate.

Soluția de principiu. În Figura 4.3 se arată componentele de adăugat unei unelte de detecție a stărilor afective din trăsături faciale (de exemplu FaceReader) pentru personalizare. Astfel s-a adăugat o aplicație web care prezintă aleator pentru utilizatorul pe care îl modelează, într-o interfață web, subsetul de 175 de imagini evaluat în prealabil. Această interfață declară valența după formatul specific SAM cu 9 niveluri și ale stării de bază predominante din cele 7 stări de bază posibile.

Personalizarea. Descriem acum partea care face personalizarea. Modulul de selecție eșantioane și sincronizare extrage eșantioanele semnificative din setul continuu de eșantioane generate în timp real de FaceReader și memorate într-un fișier de log, fiecare înregistrare fiind formată din vectorul stărilor de bază Ψ_j . Tot în acest modul se sincronizează eșantioanele preluate cu valorile auto-evaluării stării și valenței. Astfel se pregătesc pe rând perechile de vectori stări de bază-valență (Ψ_{ij}, v_i^9). Sistemul expert va fi antrenat cu acest set de perechi de valori pentru personalizare. Baza de date va stoca parametrii rezultanți în urma antrenării.

Algoritmul de personalizare PersFR. Se propune un algoritm pentru personalizare, numit PersFR. Acesta are două etape: I. Antrenarea sistemului

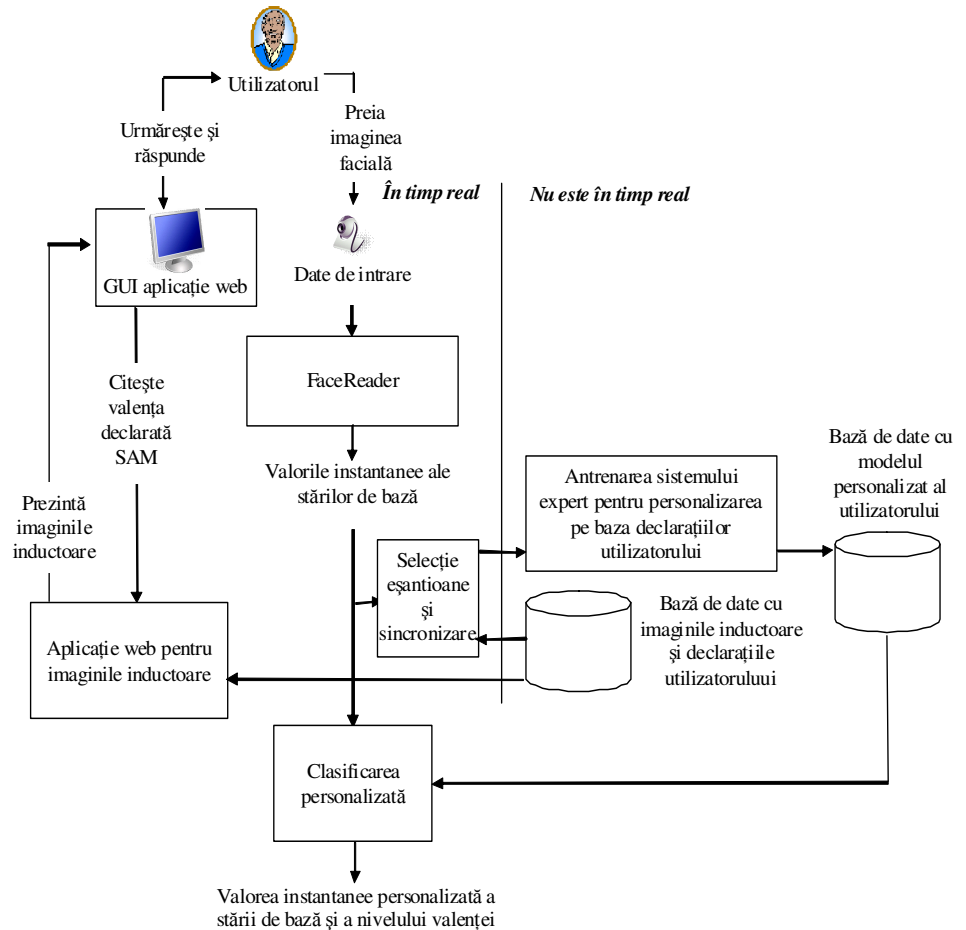


Figura 4.2 Noua arhitectură pentru personalizarea detecției valenței

expert pentru memorarea caracteristicilor individuale, subiective ale trăirii specifice a stărilor afective, și II. Funcționarea personalizată de după antrenare.

Algoritmul de antrenare constă în prezentarea într-o interfață grafică pe rând, în mod aleator a celor 175 de imagini etalon validate în experimentele anterioare. Imaginile faciale ale utilizatorului ce corespund perioadei în care acesta vizionează fiecare imagine și imediat următoare (în perioada de pauză dintre imaginile inductoare ale stărilor afective) sunt prelucrate de FaceReader care generează un set de 5 eșantioane pe secundă ce constă din vectorul celor 7 stări de bază Ψ_j , unde $j=1, \dots, 7$. Eșantionul optim din perioada corespunzătoare prezentării unei anumite imagini inductoare este considerat, împreună cu indicele nivelului de valență declarat ca pereche intrare-ieșire din sistemul expert care învață răspunsul personalizat pe care îl dorește utilizatorul. După un număr de repetări se ajunge la o eroare de predicție convenabilă și sistemul se consideră antrenat pentru acea pereche și se continuă până ce toate cele 175 de perechi au fost folosite pentru antrenare.

În etapa a doua, fiecare imagine facială a utilizatorului este prelucrată de FaceReader pentru a obține valorile instantanee ale vectorului stărilor de bază Ψ_j , $j=1, \dots, 7$. Acestea sunt apoi aduse ca intrări ale sistemului expert și se calculează indicele nivelului de valență în funcție de parametri personalizați memorați de către sistemul expert.

Proiectarea modului de personalizare. Modulul de personalizare constă într-un sistem expert cu următoarele caracteristici:

- Intrări – se aduc la intrare cele 7 ieșiri produse de FaceReader corespunzătoare stărilor de bază, adică Ψ_j , unde $j=1,7$ și $\Psi_j=[0,1]$.
- Ieșirea – este valența, considerată conform modelului SAM (Self Assessment Manikin) cu nouă niveluri posibile $\{0, \dots, 8\}$, v^9 .

Pentru alegerea sistemului expert care să permită aproximarea acelei funcții care mapează vectorul stărilor de bază pe nivelurile de valență declarate de utilizator s-au studiat mai multe variante de învățare mașină.

S-a folosit Weka 3.7. cu 175 vectori dintre care 144 de antrenare și 31 de vectori de testare pentru a menține semnificația statistică. Deoarece era un volum foarte mare de date complexe, s-a ales să se exploreze subiecții pentru care s-au obținut valori extreme de precizie pentru situația în care se considerau 9 niveluri de valență, respectiv un subiect ale cărui valori de precizie a valenței sunt ușor superioare mediei: u13 cu 14.85714%, u11 cu 21.71429% și u3 cu 25.5814%.

Metoda de învățare mașină	u13	u11	u3
NaiveBayesMultinomial	25.8065	25.8065	29.0323
LibSVM	25.8065	25.8065	25.8065
RBFNetwork	16.129	25.8065	22.5806
MultilayerPerceptron	29.0323	32.2581	35.4839

Tabelul 4-1 Comparatie între diferite soluții de învățare mașină pentru personalizarea valenței

Cele mai bune rezultate se obțin folosind rețelele neuronale de tip perceptron multistrat. Rețeaua optimă pentru subiectul u3 are configurația: niveluri ascunse 1, cu 6 neuroni în stratul ascuns, rata de învățare 0.4, momentul 0.2, număr de epoci optim 500, pentru care se ajunge la eroarea minimă de 0.0764. Cu această configurație se ajunge de la 54,65117% acuratețe la măsurarea valenței cu 3 niveluri cu FaceReader la 93,5484 % cu FaceReader personalizat cu perceptronul multistrat prezentat.

Evaluarea metodei PAVD. S-a aplicat PAVD pentru aplicația FaceReader. În acest caz PAVD crește acuratețea măsurării valenței cu 3 niveluri de la 54,6% la 93,5 %. Această îmbunătățire este importantă în raport cu valoarea probabilistică de 33,3% și acuratețea determinărilor făcute de observatorii umani 44,8%. Din perspectiva psihologiei cognitive există o anumită limitare. Anume, în experimentele făcute cu subiecții umani, se ignoră procesele de reevaluare (re-appraisal) a stării afective (emoțiilor) și controlul cognitiv asupra emoțiilor pe baza criteriului de timp. Astfel că se consideră că în medie, în timpul celor 4.5 secunde de vizionare, subiectul reacționează afectiv cu o stare asimilabilă uneia din cele 6 stări de bază + starea neutră.

Direcții deschise. Detecția stărilor afective de bază ar putea beneficia și ele de algoritmul PAVD, principiul rămânând același, doar că la ieșirea rețelei neuronale se vor afla 7 clase corespunzătoare claselor de bază. Similar se poate aplica și pentru stările secundare. Acuratețea clasificărilor ar putea crește dăugând un mecanism de reglare în care utilizatorul să poată corecta clasificările făcute de rețeaua neuronală. Ar fi interesant de cercetat cum se modifică acuratețea determinării valenței dacă s-ar defini funcții de apartenență pentru nivelurile de valență.

4.3 Concluzii

S-au propus metode pentru determinarea stărilor afective, fie folosind contextul, fie personalizarea.

S-a propus metoda ConAff-UP de detecție a stărilor afective secundare din context, folosind metoda profilelor utilizator și îmbunătățirea acestei metode folosind o rețea neuronală care personalizează detecția prin feedback de la utilizator.

Pentru generalitate, s-a propus metoda ConAff-NN de evaluare pentru detectoare ale stărilor afective ce funcționează în timp real, pentru stări afective spontane și aplicarea ei pentru unealta soft FaceReader pentru determinarea valenței cu 3 și 9 niveluri din trăsături faciale în cazul utilizării de trăsături faciale induse în mod spontan prin prezentare de imagini subiectului, comparativ cu valențele etichetate IAPS și prin comparație cu trei experți umani.

S-a descris metoda AVED de calcul a valenței cu trei niveluri, pe baza analizei în timp a eșantioanelor corespunzătoare stărilor de bază detectate de o unealtă soft (FaceReader) pentru starea curentă, pe baza unor valori de prag determinate empiric.

S-a propus metoda de creștere a procentului de detecții corecte ale valenței PAVD, cu 3 și 9 niveluri, a unui detector al stărilor afective. Acesta era bazat pe analiza trăsăturilor faciale (FaceReader), în timp real. Aceste trăiri corespund unor trăiri spontane induse prin prezentare de imagini subiectului, folosind pentru personalizare învățarea supervizată.

Adaptarea la contextul afectiv

Se prezintă un mecanism de reglare a comportamentului unui sistem senzitiv la context, pe baza reacției afective a utilizatorului la deciziile sale. Mecanismul propus permite descoperirea, memorarea și folosirea preferințelor de comportament pentru a răspunde nevoilor utilizatorului, care sunt mereu în schimbare. Se exemplifică acest mecanism pe cazul concret al unei case senzitive la context (SmartHouse) [Ben09a] [Ben09b] [Ben09c].

5.1 Formularea problemei

Sistemele senzitive la context, casele inteligente în particular, nu își adaptează comportamentul în funcție de dorințele sau nevoile utilizatorilor, care au apărut ulterior momentului în care specialistul a scris regulile de comportament, ele fiind dificil de cunoscut în mod anticipat în detaliu, dinainte.

Subprobleme. 1. Cum să se facă reprezentarea cunoașterii sistemului senzitiv la context cu comportament adaptabil în funcție de dorințele sau nevoile utilizatorilor? Cum să se reprezinte contextul (inclusiv datele despre utilizator)? Cum să se reprezinte preferințele utilizatorului privind comportamentul sistemului ?

2. Cum să se facă descoperirea preferințelor utilizatorului pentru ca sistemul să se comporte astfel încât să răspundă dorințelor sau nevoilor lui? Cum să se definească reacția utilizatorului? Cum să se interpreteze această reacție? În ce constă mecanismul prin care sistemul învață noul comportament?

5.2 Soluția propusă

Pentru reprezentarea cunoștințelor din casa senzitivă la context, s-au luat următoarele decizii:

1. Utilizarea ontologiilor pentru reprezentarea serviciilor și a contextului
2. Reprezentarea relației context-serviciu, reprezentarea preferințelor comportamentale ca ponderi, stocate în ontologie
3. Actualizarea preferințelor se va realiza în conformitate cu reacția afectivă a utilizatorului (emoții) la deciziile sistemului .

În principiu, s-a considerat contextul C ca fiind compus din elemente de context relaționate între ele, un vector de servicii S și un vector de ponderi W . În ponderi se înregistrează comportamentul preferat, și anume serviciul care trebuie ales atunci când contextul C este prezent, utilizatorul U având starea afectivă Ψ .

Reprezentarea preferințelor. Se argumentează că stocarea preferințelor într-o rețea neuronală sub formă de ponderi este o abordare mai bună decât utilizarea Meta-Rețelelor Bayes RN (Bayes RN Meta-networks) așa cum este realizată în [Has06] prin următoarele aserțiuni:

1. Rețeaua neuronală permite antrenarea inițială printr-un set de exemple de antrenare, ceea ce simplifică mult munca în această etapă, în comparație cu necesitatea calculării unor probabilități prealabile.
2. Spre deosebire de abordarea bazată pe reguli sau rețele Bayes care necesită o descriere exhaustivă a comportamentului (toate combinațiile de valori de context și comportamentul dorit pentru fiecare dintre aceste cazuri), o rețea neuronală poate rula și cu câteva exemple (dacă și acelea există), datorită capacității de generalizare și de adaptare online.
3. Rețelele neuronale au capacitatea de a generaliza pornind de la un set de exemple dat
Reprezentarea preferințelor în ontologie este justificată deoarece:
 1. Ontologia asigură distribuția și reutilizarea preferințelor învățate în alte aplicații care utilizează aceleași elemente de context sau similare (creșterea sau scăderea numărului de elemente de context sau servicii).
 2. Rețeaua neuronală poate fi reconfigurată în mod dinamic (parametrii rețelei se pot modifica la runtime: număr de niveluri ascunse, număr de neuroni pe fiecare nivel, tipul funcției de activare, rata de învățare pentru neuronii de pe fiecare nivel)

Pentru moment, parametrii rețelei neuronale sunt salvați într-un fișier.

Principiul mecanismului buclei de control afectiv (ACBAM). Se propune înlocuirea mecanismului decizional bazat pe reguli cu o rețea neuronală care învață care este noul comportament preferat de utilizator din răspunsul afectiv al acestuia. Scopul învățării fiind de a răspunde adecvat la noile necesități ale utilizatorului. Se denumește această soluție ACBAM – Affective Controlled Behaviour Adaptation Mechanism, adică mecanism de adaptarea a comportamentului prin control afectiv.




Figura 5.1 Principiul actualizării preferințelor bazat pe răspunsul afectiv al utilizatorului

Pentru a putea estima starea afectivă curentă ar trebui să se utilizeze o unealtă software capabilă să estimeze emoția curentă predominantă a unei persoane din trăsăturile ei faciale (Figura 5.1).

Mecanismul este explicat în cele ce urmează:

1. La momentul t_0 sistemul va alege un serviciu pentru contextul prezent în funcție de valorile actuale ale ponderilor rețelei neuronale antrenată în mod aleatoriu sau în prealabil (cu valori din istoricul de comportament al utilizatorului sau în condiții similare) (feedforward).
2. Decizia pentru alegerea unui serviciu la t_0 va determina o reacție a utilizatorului în următorul interval t_1 . Din această reacție este de interes doar valența emoției: pozitivă (însemnând acceptarea) sau negativă (respingere).
3. Acceptarea sau respingerea va determina modificarea adecvată a ponderii w . Ciclul se reia de la pasul 1. În acest fel sistemul se adaptează în etape succesive.

5.3 Implementarea soluției pentru cazul unei case inteligente

Implementarea soluției propuse are trei părți: 1. platforma care asigură suportul implementată cu agenți JADE, 2. descrierea ontologică a preferințelor și 3. implementarea mecanismul ACBA. Prezentăm în continuare aceste părți.

Platforma JADE. JADE este o platformă foarte populară, în deplină concordanță cu standardele FIPA, cu foarte bune facilități de securitate, având integrate cu mai multe protocoale de comunicare, precum și un suport pentru mobilitatea agenților, îmbunătățită permanent nu doar de către programatorii de la Tilab, dar și de către membrii comunității JADE. Platforma Jade a fost aleasă în implementarea sistemului multi-agent pentru sistemul Smart House.

Reprezentarea cunoștințelor. Utilizarea ontologiilor în modelarea contextului este importantă deoarece este independentă de orice limbaj de programare și asigură reprezentarea formală a contextului. Ontologia permite diseminarea și reutilizarea informației, raționarea bazată pe contextul logic (verificarea consistenței, raționarea bazată pe subsumare, inferențe implicite) [Yau06], având putere expresivă (e.g. OWL integrează constrângeri de cardinalitate), organizare ierarhică, utilizând standarde pentru eficientizarea raționării, programare abstractă și interoperabilitate. Prin utilizarea mecanismelor de raționare, contextul poate fi augmentat, îmbogățit și sintetizat [Bur06b]. De asemenea, rezolvă aspectele legate de heterogenitate, ambiguitate, calitate și validitate a datelor de context.

Pentru proiectarea ontologiei de context s-a utilizat ca punct de pornire ontologia SOCAM [Wan04][Gu05], care s-a extins astfel:

- s-a înlocuit clasa Utilizator („User”) cu clasa Actor și subclasele Grup („Group”), Individ, Om („Human”) și Entitate non-umană („NonHuman”)
- s-a adăugat clasa Stare („State”), cu subclasele: Mental, Fiziologic („Physiological”) și Afectiv („Affective”)
- s-a adăugat clasa RețeaNeuronală („NeuralNetwork”) (pentru utilizare ulterioară) și Sensibilitate („Sensitivity”) [Buc05]

S-a realizat împărțirea ontologiei pe două niveluri principale:

- nivelul superior – concepte generale pentru aplicații sensitive la context, și
- nivelul inferior –specific aplicației „Smart House”.

Pentru moment, Jadex suportă doar comunicarea prin mesaje ontologice, RDF. Comparat cu OWL, RDF este mai puțin expresiv (indică doar relații între subiecte-predicat-obiect, neavând integrate restricții (universale, cardinale, etc.) sau caracteristici ale proprietăților. În aplicația noastră, ontologia de comunicare inter-agenți este prezentată în Figura 5.5. Conține în plus clasele necesare pentru comunicarea între agenți.

S-a utilizat limbajul de conținut Nuggets XML Content Language pentru realizarea comunicării inter-agenți bazate pe ontologie. Acesta este un pachet specific platformei Jadex. Ontologia de comunicare permite accesul la un model structurat al domeniului de cunoștințe și facilitează crearea obiectelor Java-Bean [Bea09]. Pentru a exporta obiectele într-un format compatibil cu Nuggets XML, s-a utilizat un plug-in Protégé, numit Beanyizer.

Sistemul expert de reguli și de comportament (Rule and Behavior Expert System). Pentru a susține mecanismele de raționare și de decizie a agentului Raționator (Brain Agent), localizat la nivelul de raționare și decizie, s-au integrat în sistemul „Smart House” două subsisteme:

- un sistem care stochează regulile și istoricul informațiilor de context în mod persistent
- un sistem expert

Motorul de reguli este bazat pe subsistemul de inferențe Jena2 [Jen09], care integrează mai multe motoare de inferență sau raționatoare (Raționator tranzitiv, RDFS- raționator bazat pe reguli, OWL, OWL Mini, micro raționatorul OWL, micro raționatorul DAML, raționator de reguli generice). Motorul de reguli rulează regulile stocate în modulul Reguli BD (DB Rules Repository) și monitorizează modificările la nivelul valorilor datelor de context ontologice. Motorul de reguli susține inferența pe obiectele de context iar apoi actualizează modelul ontologic cu contextul dedus în urma inferenței.

Modulul de Reguli BD stochează regulile pentru domeniu într-un format specific (cerut de Jena) și include parametri care urmează a fi modificați de către sistemul expert (valorile ponderilor din matrice).

Ontologia stochează conceptele, reprezentate ca și clase precum și relațiile dintre ele. Pe măsură ce modelul ontologic este actualizat cu noi valori pentru elementele de context (obținute de la senzori, aparate sau alte surse ce oferă informații de context), valorile vechi sunt înregistrate în baza de date persistentă a ontologiei în asociere cu marcajul de timp.

Sistemul Expert învață în conformitate cu reacția utilizatorului, care ar fi răspunsul cel mai bun așteptat de utilizator din parte sistemului. Rețeaua neuronală este antrenată prin utilizarea unui set general de exemple pre-definite. După aceasta sistemul rulează și se adaptează online în funcție de reacția utilizatorului (e.g. nivelul de satisfacție măsurat sin reacțiile afective la comportamentul sistemului).

Editorul ontologic citește caracteristicile rețelei neuronale (e.g. matricea ponderilor, numărul nivelurilor ascunse, tipul funcției de prag) și le stochează în ontologie pe măsură ce valorile se modifică în timp.

Proiectarea interfeței utilizator. Sistemul „Smart House” include mai multe interfețe utilizator menite să ofere suport pentru reprezentarea vizuală a informației de context furnizată de către senzori, aparate și obiecte și de asemenea pentru interacțiunea vizuală cu sistemul ca întreg (prin comandarea unor noi planuri și misiuni sau prin emiterea unor comenzi specifice către obiectele din interior).

S-a dezvoltat un sistem de agenți mobili bazat pe Jade-Leap (Lightweight) pentru monitorizarea și controlul senzorilor și dispozitivelor din casa inteligentă. S-a implementat agentul de autentificare care rulează pe container-ul FrontEnd și care comunică cu agentul responsabil cu efectuarea autentificării, localizat în Back-end. Agentul de monitorizare mobil solicită informația de context de la agentul ontologic (care rulează pe container-ul Back-End) și o prezintă într-o formă grafică pe ecranul dispozitivului mobil.

Implementarea stratului fizic. La acest nivel s-a folosit o rețea fără fir compusă dintr-o stație master și mai multe stații slave. O altă parte a fost implementată folosind două platforme Phidgets [Phi09], una pentru senzori și alta pentru actuatori.

Reprezentarea cunoștințelor afective. S-a adăugat în ontologie conceptul „Stare” („State”) ca și în [Ben07a], însă, deoarece interesul era pentru reprezentarea valenței pentru starea curentă, s-a definit subclasa „StareCurentă” (CurrentState) cu proprietatea „valență” având trei valori posibile (pozitivă, negativă și neutră) așa cum este descrisă în Figura 5.2:

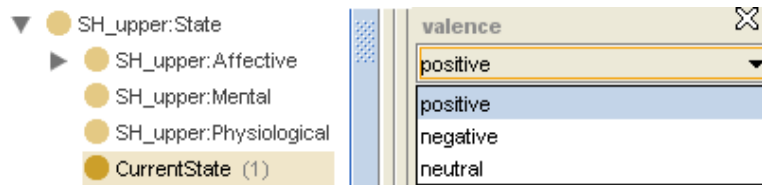


Figura 5.2 Fragment din ontologia SH_lower ilustrând o instanță a conceptului „CurrentState” (stânga) și proprietatea asociată, „valence”, cu cele trei valori posibile (dreapta).

Modelarea preferințelor într-o rețea neuronală MLP. În această fază s-a implementat perceptronul multi-nivel (MultiLayer Perceptron) (MLP) utilizând un API pentru rețele neuronale, implementat în Java [FNN09], care salvează parametrii rețelei într-un fișier.

Rețeaua MLP are două intrări, valoarea luminozității din cameră (LightSensor1) și luminozitatea din exterior (LightSensor0), cu trei valori posibile (joasă, medie și ridicată), fiind actualizată în ontologie de către agentul senzor:

```
light_indoor=sensorMap.getSensorById("LightSensor1").getSensorValue();
```

Există singură ieșire a rețelei neuronale, poziția jaluzelelor (deschis/închis) care trebuie actualizată la luarea deciziei: `deviceMap.setDeviceStatus("Blind_2","ON");`

5.4 Testarea soluției propuse

S-au utilizat senzorii Phidgets [Phi09] pentru a măsura luminozitatea din interiorul și din exteriorul camerei, un cititor RFID pentru autentificarea utilizatorului și un motor pentru închiderea/deschiderea jaluzelelor. S-a rulat mai aplicația SmartHouse cu reguli pentru a-i verifica funcționalitatea. În pasul următor s-a pus problema reglării parametrilor rețelei neuronale care înlocuiește regulile.

Calculul parametrilor rețelei neuronale. Setul inițial de antrenare al rețelei este generat prin utilizarea unei reguli predefinite, doar pentru faza de testare: atunci când luminozitatea din exterior este mai mare decât în interior, jaluzelele se vor deschide, altfel vor fi închise; un total de 9 combinații de intrări, cu normalizarea valorilor de la intrare și ieșire (-0.5 pentru luminozitate scăzută, 0.0 pentru luminozitate medie, 0.5 pentru luminozitate ridicată). În condiții reale, datele istorice pot fi utilizate (intrări, combinațiile de ieșiri dorite) pentru această antrenare. După repetarea mai multor simulări, configurația optimă a parametrilor MLP obținută a fost cea cu 6 neuroni pe nivelul ascuns și 50000 de epoci, sau o rată echivalentă a erorii de antrenare de 0.05.

Rezultate. S-au realizat 100 de simulări pentru două intrări (luminozitate din exterior, luminozitate în cameră) cu trei niveluri (scăzut, mediu, ridicat) și o ieșire (deschis/închis) și s-a variat numărul neuronilor în stratul ascuns (1-10) și numărul exemplilor de antrenare (1-9) pentru a determina care este minimul de exemple necesare pentru a învăța noile preferințe, după antrenarea inițială. Cea mai bună configurație a fost cea cu 6 neuroni în nivelul ascuns, fiind necesare minimum 3 exemple din 9 posibilități pentru a estima 80% din comportamentul corect la apariția unui nou comportament, procent care crește la 90% pentru 6 exemple. Durata reantrenării este de 780 milisecunde, mai puțin decât 1 secundă, timpul considerat pentru ca o persoană să exprime o emoție.

S-a realizat experimente pilot, în condiții reale în laboratorul nostru de cercetare (platforma de senzori, motor care acționează jaluzelele, camera web pentru captarea feței utilizatorului pentru ca FaceReader-ul să poată evalua emoțiile) pentru o singură persoană, în care rețeaua neuronală pre-antrenată a înlocuit setul de 9 reguli de comportament. În majoritatea cazurilor de test regulile de antrenare au fost substituite cu succes. S-a reușit să obținem o reantrenare cu succes cu un nou comportament preferat cu doar 3 exemple, dar sunt necesare câteva modificări pentru ca sistemul să ruleze la parametrii optimi: creșterea numărului de exemple de antrenare aleatorii la 6, reducerea ferestrei de timp pentru exprimarea emoțiilor și creșterea acurateții valenței.

5.5 Evaluarea ACBAM

Putem compara rezultatele obținute cu soluția utilizării rețelelor echivalente Bayes (Bayes RN Meta-networks)[Has06], unde avem o creștere importantă a probabilităților inițiale o dată cu creșterea numărului de intrări. În scenariul prezentat era avea nevoie să se completeze $3^2 \cdot 2^1 = 18$ combinații, iar prin adăugarea unei singure intrări binare (utilizator autorizat/neautorizat) numărul de probabilități estimate anterior s-ar dubla: 36. Deci, o creștere exponențială.

În plus, prezența a două cereri ale utilizatorilor pentru încă un nivel, rezultă că pentru 2 utilizatori sunt necesare $n+1$ niveluri Bayes. Prin urmare $3*36=108$ valori care trebuie calculate.

Complexitatea meta-rețelelor Bayes (Bayes RN Meta-networks) este:

$$O(N*p*q^\alpha + q^{\alpha*N*p}) \quad (5.1)$$

Unde N este numărul utilizatorilor, p este probabilitatea ca utilizatorului să aibă o anumită locație, q este numărul valorilor serviciilor sau numărul acțiunilor posibile, α este o valoare proporțională cu numărul de elemente de context multiplicat cu numărul valorilor posibile pentru acel element. Pentru exemplul dat, complexitatea ar fi $O(1*1*2^6 + 2^{6*1*1}) = O(128)$.

În cazul rețelelor neuronale putem reduce complexitatea la:

$$O(e*q). \quad (5.2)$$

Unde e este numărul elementelor de context, q este numărul valorilor serviciilor sau acțiunilor posibile, deci avem $O(2*2) = O(4)$. Aceasta reduce complexitatea de 32 de ori.

5.6 Direcții deschise

Rămâne să se cerceteze următoarea chestiune: cum evoluează numărul de exemple de antrenare date de utilizator pentru învățarea preferințelor pe măsură ce incrementăm numărul elementelor de context.

Metoda PAVD de estimare a valenței cu nouă niveluri ar permite varierea ratei de învățare a rețelei neuronale în acord cu nivelul de acceptare sau refuz al utilizatorului la decizia casei.

Diferența ce apare între curba de învățare și cea de re-învățare (descoperire a preferințelor) poate să indice fie o inerție în învățare, fie o „uitare” de către sistem a ceea ce învățase înainte. În oricare dintre aceste cazuri, este de dorit să se exploreze și alte variante de soluții de învățare mașină.

Stocarea parametrilor de comportament pentru personalizare în reprezentarea ontologică ar permite reutilizarea preferințelor de comportament ale aceluși utilizator într-un context similar.

Adaptarea unui sistem senzitiv la context poate fi îmbunătățită prin folosirea unui model evaluativ (appraisal) al emoțiilor de către un agent conversațional emoțional care oferă o interfață cu facilități emoționale utilizatorului.

5.7 Concluzii

S-a propus și testat un nou mecanism de control comportamental pentru sisteme senzitive la context, bazat pe reacțiile afective ale utilizatorului la deciziile sistemului. Acesta permite descoperirea, stocarea, utilizarea preferințelor pentru a răspunde la nevoile în continuă schimbare ale utilizatorului.

Pentru a determina reacția afectivă s-a utilizat varianta personalizată a soft-ului FaceReader cu algoritmul AVED, care estimează valența stării curente cu trei niveluri (pozitiv, negativ și neutru).

S-a implementat o ontologie centrală pentru reprezentarea contextului, a actuatorilor și pentru a oferi suport pentru modificările comportamentale conform reacției afective a utilizatorului. Reprezentarea preferințelor de comportament ale sistemului senzitiv la context s-a făcut prin ponderi salvate în fișier. Pentru a personaliza și optimiza comportamentul casei inteligente, s-au implementat regulile sub forma unei rețele neuronale a cărei ieșiri se activează la schimbarea contextului. Aceasta reprezintă o abordare mai flexibilă decât soluția cu reguli *if-then* pentru situația în care se dorește includerea de noi elemente de context în sistem.

La nivel de platformă suport, s-a proiectat și implementat platforma de agenți JADEx folosind TAOM4E, s-a creat ontologia de agenți a casei inteligente, au fost integrați senzorii și actuatorul Phidgets.

Aplicația a fost testată pentru funcționalitate atât cu reguli cât și cu mecanismul ACBA (Affective Controlled Behaviour Adaptation Mechanism). În urma testării pentru două intrări ternare și o ieșire binară, ACBA reînvață noua preferință a utilizatorului în procent de 80%, după 3 exemple din 9 posibile. Rămâne de testat cum variază numărul minim de exemple pe care trebuie să le dea utilizatorul odată cu creșterea numărului de elemente de context și ce consecințe decurg de aici.

Concluzii și perspective

Obiectivul tezei a fost crearea unui cadru de lucru destinat dezvoltatorilor de aplicații senzitive la context. Cadrul propus constă în modele, metode, algoritmi. El permite modelarea, reprezentarea, achiziția, interpretarea stărilor afective ale utilizatorului și adaptarea comportamentului aplicațiilor senzitive la context. Adaptarea se face în funcție de răspunsurile afective ale utilizatorului, pentru a fi adecvat necesităților și preferințelor sale, care se modifică în timp.

Din studiul literaturii de specialitate s-au constatat următoarele probleme grupate în funcție de locul unde apar ele în arhitectura unei aplicații senzitive la context (modelarea și reprezentarea, preluarea valorilor instantanee corespunzătoare elementelor de context și adaptarea la context). Astfel, în cazul comportamentului preferat al aplicațiilor, soluțiile existente se bazează pe reguli care erau dificil de editat sau pe soluții cu complexitate ridicată (rețele Meta-Bayes). Acestea ridicau probleme la creșterea numărului de elemente de context. De asemenea, reprezentarea acestor preferințe se făcea fără a permite actualizarea valorilor acestor preferințe la rulare și fără memorarea în ontologia de context a acestora.

Pentru descoperirea preferințelor s-a adoptat varianta utilizării reacțiilor afective, operaționalizabile prin parametrul valență, care să indice gradul subiectiv de satisfacție al utilizatorului. S-a constatat lipsa, din literatura de specialitate, a unei metode riguroase de evaluare a detectoarelor stărilor afective, și implicit și a valenței lor, pentru trăiri spontane și detecție ne-intruzivă (din trăsături faciale). Ca urmare, nu se cunoștea nici precizia cu care se poate măsura valența.

Determinarea stărilor afective, mai ales cele secundare, se făcea cu dificultate și nu lua în calcul informațiile provenite de la valorile curente ale elementelor de context care acționau ca factori inductori sau favorizanți pentru starea curentă.

În privința reprezentării stărilor afective, în sistemele senzitive la context, se ignorau, la momentul propunerii soluției din teză, parametrii caracteristici stărilor afective (valență, activare, intensitate) și relațiile atât între diferitele tipuri de stări (curentă, de bază și secundare) cât și între stările afective și alte elemente de context. De asemenea, modelarea stărilor afective suferea de lipsa dimensiunii distincte a intensității, care se considera, fără o demonstrație, a fi implicit prezentă și proporțională cu distanța stării de la centrul planului activare-valență. La fel, lipsea nuanțarea relației dintre stările secundare și cele de bază.

În teză se propun soluții pentru problemele formulate mai sus, sintetizate în secțiunea următoare.

Înainte de a prezenta contribuțiile, menționăm că acestea prezintă, din perspectiva psihologiei cognitive, două limitări. Prima este că în cazul contribuțiilor propuse se urmăresc aspectele de la nivelul reprezentational-algoritmice al sistemului cognitiv din care decupează emoțiile, neglijând relația lor cu cogniția. Și a doua este că în experimente se ignoră procesele de re-apreciere a stării afective (emoțiilor) și controlul cognitiv asupra emoțiilor pe baza criteriului de timp. Mai precis, în experimentele de evaluare a capacității unei soft care determină stările afective din trăsături faciale (FaceReader), se consideră că, în medie, în timpul celor 4.5 secunde de vizionare, subiectul reacționează afectiv cu o stare asimilabilă uneia din cele 6 stări de bază + starea neutră.

6.1 Principalele contribuții din teză

Principalele contribuții pentru crearea cadrului de lucru pentru sisteme senzitive la context personalizate afectiv sunt:

1. Un model unificator al stărilor afective, numit FLAVI (Fuzzy Logic Activation Valence Intensity), care permite cuantizarea spațiului activare-evaluare și personalizarea lui folosind logica nuanțată. Cuantizarea se bazează pe definirea statistică a două mulțimi nuanțate (fuzzy) triunghiulare pentru reprezentarea gradului de apartenență a stării secundare la fiecare dintre stările de bază pe fiecare dintre axele activare și evaluare. În urma testării ipotezei relației de proporționalitate între distanța de la originea planului activare-valență și intensitatea stărilor emoționale (3 niveluri), s-a dovedit necesitatea dimensiunii distincte intensitate care să fie adăugată perpendicular planului activare-valență. S-a propus o metodologie de construire a modelului constând în doi algoritmi, unul pentru modelul personalizat PersFLAVI și celălalt pentru modelul general GenFLAVI-P/CI [Ben05][Ben07b] (cap.3).

2. Modelul ontologic de context SOCAM extins cu modelul stărilor afective FLAVI pentru a cuprinde elemente afective detaliate, față de ontologia existentă pentru descrierea utilizatorilor GUMO. Noul model, SOCAM-FLAVI,

permite în plus reprezentarea ontologică a relațiilor dintre stările curentă, secundare și de bază, pe de o parte și a relației dintre stările afective și context, pe de o altă [Ben07a] (cap3).

3. Metoda ConAff2-UP (Context Affective Secondary(2) - User Profile) de detecție a stărilor afective secundare din context folosind metoda profilului utilizator. Varianta îmbunătățită a acestei metode, numită ConAff2-NN (Context Affective Secondary(2) Neural Network) folosește o rețea neuronală care personalizează detecția prin feedback de la utilizator [Ben08] (cap.4).

4. Metoda de calcul AVED (Affective Valence Empirical Determination) a valenței cu trei niveluri, pe baza analizei în timp a eșantioanelor corespunzătoare stărilor de bază detectate de o unealtă soft (FaceReader) pentru starea curentă pe baza unor valori de prag determinate empiric [Ben09c] (cap.4).

5. Metoda FANAR-EM (Facial Assessment for Natural occurring Affective states in Real-time - Evaluation Method) de evaluare a preciziei pentru detectoare ale stărilor afective ce funcționează în timp real, pentru stări afective spontane, naturale. S-a aplicat metoda pentru unealta soft FaceReader pentru determinarea valenței cu 3 și 9 niveluri din trăsături faciale. S-a considerat cazul utilizării de trăsături faciale induse în mod spontan prin prezentare de imagini subiectului, comparativ cu valențele etichetate IAPS și prin comparație cu trei experți umani [Ben09c] (cap.4).

6. S-a propus metoda PAVD (Personalized Affective Valence Determination) de creștere a procentului de detecții corecte ale valenței, cu 3 și 9 niveluri, în timp real, din trăsături faciale. S-a considerat cazul utilizării de trăsături faciale ce corespund unor trăiri spontane induse prin prezentare de imagini subiectului, folosind pentru personalizare învățarea supervizată. S-a aplicat metoda pentru unealta soft FaceReader [Ben09c] (cap.4).

7. S-a propus mecanismul ACBAM (Affective Controlled Behaviour Adaptation Mechanism) de reglare a comportamentului unei case inteligente pe baza reacției afective la deciziile sale, care permite descoperirea, memorarea și folosirea preferințelor pentru a răspunde nevoilor utilizatorului, care sunt mereu în schimbare. S-a proiectat și implementat platforma de agenți JADEx folosind TAOM4E, s-a creat ontologia casei inteligente, s-au integrat senzorii și actuatorul Phidgets. Reprezentarea preferințelor comportamentului unui sistem senzitiv la context s-a făcut prin ponderi salvate în fișier, în timp ce contextul și actuatorii au fost reprezentați în ontologie [Ben09a][Ben09b] (cap.5).

6.2 Dezvoltări ulterioare

Cercetările din teză au generat câteva probleme deschise și direcții de continuare a cercetării. Principalele direcții de continuare sunt:

Modelarea stărilor afective în sisteme senzitive la context:

- optimizarea în timp a modelului FLAVI prin implicarea utilizatorului în bucla de reglare,
- folosirea unui model computațional cognitiv al emoțiilor pentru determinarea prin deducere/derivare a stărilor afective folosind variabile de apreciere (relevanță, dezirabilitate, expectanță etc.).

Detecția stărilor afective:

- crearea de modele temporale pentru facilitarea detecției stărilor secundare din trăsături faciale (folosind, de exemplu, unealta soft FaceReader),
- creșterea procentului de clasificări corecte a stărilor afective (de bază și secundare) prin personalizare, urmând metoda aplicată pentru valență (PAVD),
- explorarea detecției multimodale a stărilor afective în context mobil.

Adaptarea aplicațiilor senzitive la context cu un comportament personalizat afectiv:

- adaptarea unui sistem senzitiv la context poate fi îmbunătățită prin folosirea unui model evaluativ al emoțiilor de către un agent conversațional emoțional care oferă o interfață cu facilități emoționale utilizatorului,
- stocarea parametrilor de comportament pentru personalizare în reprezentarea ontologică ar permite reutilizarea preferințelor de comportament ale aceluși utilizator într-un context similar,
- studiul comparativ de soluții de învățare rapidă și persistentă a comportamentului pentru sisteme senzitive la context pe baza reacției (feedback-ului) de la utilizator.

Bibliografie

- [Bai08] Bailenson, J.N., Pontikakis, E.D., Mauss, I.B., Gross, J.J., Jabon, M.E., Hutcherson, C.A.C., Nass, C., John, O., „Real-time classification of evoked emotions using facial feature tracking and physiological responses”, *Int. J. Human-Computer Studies*, vol. 66, pag. 303-317, 2008.
- [Bar04] Bartlett, M., Littlewort, G. Lainscsek, C., Fasel, I. și Movellan, J., „Machine learning methods for fully automatic recognition of facial expressions and facial actions In IEEE International Conference on Systems”, *Man & Cybernetics*, Olanda, pag. 592-597, octombrie 2004.
- [Ben05] **Kuderna-Iulian Beța**, „Affective Aware Museum Guide”, IEEE WMTE 2005, Japonia, pag. 53-55, noiembrie 2005.
- [Ben07a] **Kuderna-Iulian Beța**, Anca Rarau, Marcel Cremene, „Ontology Based Affective Context Representation”, *Euro American Association on Telematics and Information Systems 2007*, Portugalia, mai 2007.
- [Ben07b] **Kuderna-Iulian Beța**, Hannelore-Inge Lisei, „Towards a Unified 3D Affective Model”, Marcel Cremene, *Doctoral Consortium Proceedings of International Conference on Affective Computing and Intelligent Interaction (ACII2007)*, pag 75-85, Portugalia, septembrie 2007.
- [Ben08] **Kuderna-Iulian Beța**, Marcel Cremene, Nicoleta Ramona Gibă, Ulises Xolocotzin Eligio, Anca Rarău, „Secondary Emotions Deduction from Context”, *CISSE 08*, Ed. Springer, decembrie 2008.
- [Ben09a] **Kuderna-Iulian Beța**, Amalia Hoszu, Lucia Văcariu, Octavian Creț, „Agent based smart house platform with affective control”, *EATIS*, Republica Cehă, iunie 2009.
- [Ben09b] **Kuderna-Iulian Beța**, Marcel Cremene, Valeriu Todica, *Towards an Affective Aware Home*, *International Conference On Smart homes and health Telematics*, Springer LNCS, vol. 5597, pag. 74-81, Franța, iulie 2009.
- [Ben09c] **Kuderna-Iulian Beța**, Hans van Kuilenburg, Ulises Xolocotzin Eligio, Marten den Uyl, Marcel Cremene, Amalia Hoszu și Octavian Creț, „Evaluation of a System for RealTime Valence Assessment of Spontaneous Facial Expressions”, *Distributed Environments Adaptability, Semantics and Security Issues International Romanian - French Workshop*, Romania, septembrie 2009.
- [Ber92] H.R. Berenji, P. Khedkar, „Learning and tuning fuzzy logic controllers through reinforcements”, *IEEE Transactions on Neural Networks*, vol.3, nr.5, pag.724-740, septembrie 1992.
- [Bet09] Claudio Bettini, Oliver Brdiczka, Karen Henriksen, Jadwiga Indulska, Daniela Nicklas, Anand Ranganathan, and Daniele Riboni, „A survey of context modelling and reasoning techniques”, *Pervasive and Mobile Computing*, iunie 2009.
- [Bi193] Bill, N. S., Marvin, M., Theimer și Brent, B. W., „Customizing Mobile Application”, în volumul „USENIX Symposium on Mobile and Location-independent Computing”, Cambridge, MA, august 1993.
- [Buc05] Oana, B., Philippe, B., Olivier, B., „Representing Context in an Agent Architecture for Context-Based Decision Making”, în volumul *CRR'05 Workshop on Context Representation and Reasoning*, Franța, iulie 2005.
- [Bur06a] Burleson, W., „Affective Learning Companions: Strategies for Empathetic Agents with Real-Time Multimodal Affective Sensing to Foster Meta-Cognitive and Meta-Affective Approaches to Learning, Motivation, and Perseverance”, teză de doctorat la MIT, septembrie 2006.
- [Bur06b] Buriano, L. Marchetti, M. Carmagnola, F., Cena, F., Gena, C., Torre, I., „The Role of Ontologies in Context-Aware Recommender Systems”, în: *IEEE International Conference on Mobile Data Management*, pag. 80, 2006.
- [Car02] B. De Carolis, V. Carofiglio, M. Bilvi, C. Pelachaud, „APML, a Mark-up Language for Believable Behavior Generation”, “Embodied conversational agents - let's specify and evaluate them!” în conjuncție cu “The First International Joint Conference on Autonomous Agents & Multi-Agent Systems”, Italia, iulie 2002.
- [Cea07] Cearreta I., López J. M., Garay N., „Modelling multimodal context-aware affective interaction”, In: *Proceedings of the Doctoral Consortium of the Second international conference on Affective Computing and Intelligent Interaction (ACII 2007)*, pag. 57-64, Portugalia, 2007.
- [Col05] Colombetti, G., „Appraising valence”, *J. Consciousness Studies*, nr. 8/10, pag. 103-126, 2005
- [Cow99] Cowie, R., Douglas-Cowie, E., Appolloni, B., Taylor, J., Romano, A., și Fellenz, W., „What a neural net needs to know about emotion words”, în editura N. Mastorakis, *Computational Intelligence and Applications*, pag. 109-114, World Scientific & Engineering Society Press, 1999.
- [Cow00a] Roddy Cowie, „Describing the Emotional States Expressed in Speech”, în *dezbaterile ISCA ITRW on Speech and Emotion*, Textflow, Belfast, septembrie 2000.
- [Cow00b] Roddy Cowie, Ellen Douglas-Cowie, Susie Savvidou, Edelle McMahon, Martin Sawey, Marc Schröder, “Feeltrace”: An Instrument for Recording Perceived Emotion in Real Time”, *ISCA Workshop on Speech and Emotion: A Conceptual Framework for Research*, UK, 2000.
- [Dar72] Charles Darwin, „The Expression of Emotion in Man and Animal”, 1872.
- [Dar07] Walteneus Dargie, „The Role of Probabilistic Schemes in Multisensor Context-Awareness”, în *Proceedings of the Fifth IEEE international Conference on Pervasive Computing and Communications Workshops, PERCOMW*, IEEE Computer Society, Washington, DC, pag. 27-32, martie 2007.
- [Dem04] S. Demoulin, J.-P. Leyens, M.-P. Paladino, R. Rodriguez-Torres, R.-P. Armando și J.F. Dovidio, „Dimensions of "uniquely" and "non-uniquely" human emotions”, *Cognition and Emotion*, 18(1) , pag. 71-96, 2004.
- [Eji07] Ejigu, D., Scuturici, M., Brunie, L., „An Ontology-Based Approach to Context Modeling and Reasoning in Pervasive Computing”, în volumul „Fifth IEEE international Conference on Pervasive Computing and Communications Workshops, PERCOMW”, IEEE Computer Society, Washington, DC, pag 14-19, martie 2007.
- [Ekm70] Ekman, P., „Universal facial expressions of emotion”, *California Mental Health Research Digest*, 8, pag. 151-158, 1970.
- [Ekm92] Paul Ekman, „An argument for basic emotions”, *Cognition and Emotion*, 6, pag. 169-200, 1992.
- [EI98] Magy Seif El-Nasr, „Modeling Emotion Dynamics in Intelligent Agents”, Master's thesis, Department of Computer Science, Texas A&M University, College Station, TX, 1998.
- [EI00] Magy Seif El-Nasr, John Yen și Thomas Joerger, „FLAME - A Fuzzy Logic Adaptive Model of Emotions”, *Autonomous Agents and Multi-agent Systems*, 3, pag. 219-257, 2000.
- [Fah01] Fahrmeir, L., Künstler, R., Pigeot I., Tutz G., „Statistik – Der Weg zur Datenanalyse”, Springer Verlag, Berlin, 2001.
- [Fla05] John Flanagan, „Context awareness in a mobile device: Ontologies versus unsupervised/supervised learning”, în Timo Honkela, Ville Kõnönen, Matti Pöllä, and Olli Simula, editori, în vol. *AKRR'05, International and Interdisciplinary Conference on Adaptive Knowledge Representation and Reasoning*, pag. 167-170, Finland, iunie 2005.
- [Fra07] V. Francisco, P. Gervás, and F. Peinado, „Ontological Reasoning to Configure Emotional Voice Synthesis”, în volumul *First International Conference on Web Reasoning and Rule Systems (RR2007)*, LNCS vol. 4524, pag. 88-102, Austria, 2007.
- [Gar06] A. Garcia-Rojas, F. Vexo, D. Thalmann, A. Raouzaoui, K.Karpouzis, S. Kollias, „Emotional Body Expression Parameters In Virtual Human Ontology”, In *Proceedings of 1st Int. Workshop on Shapes and Semantics*, pag. 63-70, Japonia, iunie 2006.
- [Ger99] Carlos Gershenson, „Modelling Emotions with Multidimensional Logic”. In *Proceedings 18th International Conference of the North American Fuzzy Information Processing Society (NAFIPS'99)*, pag. 42-46, USA, 1999.
- [Gra09] Jonathan Gratch, Stacy Marsella, Ning Wang, Brooke Stankovic, „Assessing the validity of appraisal-based models of emotion”, *International Conference on Affective Computing and Intelligent Interaction*. Amsterdam, IEEE, 2009.
- [Gu04] Tao Gu, Xiao Hang Wang, Hung Keng Pung, Da Qing Zhang, „An Ontology-based Context Model in Intelligent Environments”, în volumul conferinței *Communication Networks and Distributed Systems Modeling and Simulation Conference*, San Diego, California, USA, ianuarie 2004.
- [Gu05] Tao Gu, Hung Keng Pung, Da Qing Zhang, “A service-oriented middleware for building context-aware services”, *Journal of Network and Computer Applications*, vol. 28, nr. 1, pag. 1-18, Londra, 2005.
- [Har89] R. Harré, „An Outline of the Social Constructionist Viewpoint”, Harre, R. (ed.), *The Social Construction of Emotions*, Blackwell Publishing, Oxford and New York, pag. 2-13, 1989.
- [Has06] Hasan, Md. K., Anh, K., Mehedy, L., Lee, Y.K., Lee, S. „Conflict Resolution and Preference Learning in Ubiquitous Environment”, în conferința internațională *Intelligent Computing, LNAI*, vol. 4114 0355, Kunming Yunnan Province, 2006.
- [Hen06] Henriksen, K., Indulska, J., Rakotonirainy, A., “Using context and preferences to implement self-adapting pervasive computing applications”, *Software-practice & Experience*, vol. 36, issue 11-12, pag. 1307-1330, Ed. John Wiley & Sons Ltd, 2006.
- [Hol02] Hartwing Holzappel, Christian Fuegen, Matthias Denecke, Alex Waibel, „Integrating Emotional Cues into a Framework for Dialog Management”, în vlumul conferinței *Fourth IEEE International Conference on Multimodal Interfaces (ICMI'02)*, Pittsburgh, Pennsylvania, octombrie 2002.
- [Ish06] M. Ishizuka, H. Prendinger, “Describing and Generating Multimodal Contents Featuring Affective Lifelike Agents with MPML “ (articol invitat), *New Generation Computing*, Vol.24, Nr.2, pag.97-128, februarie 2006.
- [Kap05] Ashish Kapoor, Hyungil Ahn, Rosalind W. Picard, „Mixture of Gaussian Processes for Combining Multiple Modalities”, *Multiple Classifier Systems*, pag. 86-96, 2005.

- [Kim05] Kim Anh Pham Ngoc, Young-Koo Lee, Sungyoung Lee, "OWL-Based User Preference and Behavior Routine Ontology for Ubiquitous System", pag. 1615-1622, Springer, Lecture Notes in Computer Science, vol.3761, 2005.
- [Kor01] B. Kort, R. Reilly and R. Picard, „An Affective Model of Interplay between Emotions and Learning: Reengineering Educational Pedagogy-Building a Learning Companion”, Proc. Second IEEE International Conference on Advanced Learning Technologies (ICALT'01), 2001.
- [Kru07] Reto Kruppenacher, Thomas Strang, „Ontology-Based Context Modeling”, 3rd Workshop on Context Awareness for Proactive Systems, iunie 2007.
- [Kui05] van Kuilenburg, H., Wiering, M., den Uyl, M. „A model-based method for automatic facial expression recognition”, Springer LNAI, Vol. 3720, pag. 194-205, 2005.
- [Lan80] Lang, P. J. „Behavioral treatment and bio-behavioral assessment: Computer applications”, în J. B. Sidowski, J. H. Johnson, & T. A. Williams (Eds.), Technology in mental health care delivery systems, pag. 119-137, Norwood, NJ: Ablex, 1980.
- [Lee08] Christopher Peter Lee-Johnson, „Emotion-based Parameter Modulation for a Mobile Robot Planning and Control System”, teză de doctorat, 2008.
- [Lia05] Wei-Kai Liao, Isaac Cohen, „Classifying Facial Gestures in Presence of Head Motion”, IEEE Workshop on Vision for Human-Computer Interaction (V4HCI), în conjuncție cu IEEE CVPR 2005, iunie 2005.
- [Lit04] Littlewort, G., Bartlett, M., Fasel, I., Susskind, J., and Movellan, J., „Dynamics of facial expression extracted automatically from video”, în IEEE Conference on Computer Vision and Pattern Recognition, Workshop on Face Processing in Video, 2004.
- [Lon05] P. Lonsdale, R. Beale și W. Byrne, „Using context awareness to enhance visitor engagement in a gallery space”, McEwan, T., Gulliksen, J. și Benyon, D. (ed.), Proc. People and computers xix - the bigger picture, vol. HCI 2005, pag. 101-112, Springer, Londra, 2005.
- [Lop08] López, J. M., Gil, R., García, R., Cearreta, I., and Garay, N. 2008. Towards an Ontology for Describing Emotions”, în vol. „1st World Summit on the Knowledge Society: Emerging Technologies and Information Systems For the Knowledge Society”, M. D. Lytras, J. M. Carroll, E. Damiani, and R. D. Tennyson, Eds. Lecture Notes in Artificial Intelligence, vol. 5288. Springer-Verlag, Berlin, Heidelberg, pag. 96-104, Grecia, septembrie 2008.
- [Luc06] Luca Buriano, Marco Marchetti, Francesca Carnagnola, Federica Cena, Cristina Gena, Ilaria Torre, „The Role of Ontologies in Context-Aware Recommender Systems”, Mobile Data Management, IEEE International Conference on, pag. 80, 7th International Conference on Mobile Data Management (MDM'06), 2006.
- [Mar09] Stacy Marsella și Jonathan Gratch, „EMA: A Model of Emotional Dynamics”, Journal of Cognitive Systems Research, vol. 10(1), pag 70-90, 2009.
- [Mar10] Stacy Marsella, Jonathan Gratch și Paolo Petta, „Computational Models of Emotion”, în K. R. Scherer; T. Baenziger; E. Roesch, „A blueprint for an affectively competent agent: Cross-fertilization between emotion psychology, affective neuroscience, and affective computing” în curs de apariție, Oxford, England: Oxford University Press.
- [Mic94] Mircea Miclea, „Psihologie cognitivă”, Casa de editură Gloria, Cluj-Napoca, 1994.
- [Mob03] Mobahi, H., Ansari S., „Fuzzy Perception, Emotion and Expression for Interactive Robots”, Proceedings of IEEE International Conference on Systems, Man and Cybernetic (SMCC04), volumul 4, pag. 3918-3923, USA, octombrie 2003.
- [Moo07] Moors, A., „Can cognitive methods be used to study the unique aspect of emotion: An appraisal theorist's answer”, Cognition and Emotion, vol. 21, pag.1238-1269, 2007.
- [Mot03] S. A. Mota Toledo și R. W. Picard, „Automated Posture Analysis for Detecting Learner's Interest Level”, Workshop on Computer Vision and Pattern Recognition for Human-Computer Interaction, CVPR HCI, iunie 2003.
- [Nez08] J.B. Nezelek, K. Vansteelandt, I. Van Mechelen, P. and Kupens, „Appraisal-Emotion relationships in daily life”, Emotion, 8(1), pag. 145-150, 2008.
- [Ort88] Ortony, A., Clore, G. L. and Collins, A., „The Cognitive Structure of Emotions”, Cambridge University Press, Cambridge, UK, 1988.
- [Pes08] Luiz Pessoa, „On the relationship between emotion and cognition”, Nat Rev Neurosci, vol. 9, nr. 2, pag. 148-158, 2008.
- [Pic97] R. Picard, „Affective Computing”, MIT Press, 1997.
- [Plu80] Robert Plutchik, „A general psychoevolutionary theory of emotion” în R. Plutchik & H. Kellerman (Eds.), „Emotion: Theory, research, and experience: Vol. 1. Theories of emotion”, pag. 3-33, 1980.
- [Plu94] Plutchik, R.: The Psychology and Biology of Emotion, Harper Collins Ed., New York (1994)
- [Ran03] Pramila Rani, Nilanjan Sarkar, Craig A. Smith, Julie A. Adams, „Affective Communication for Implicit Human-Machine Interaction”, IEEE Transactions on Systems, Man, and Cybernetics, 2003.
- [Roe04] Roesch, E. B., Banziger, T., Scherer, K. R., „D3c – Preliminary plans for exemplars: Theory and Models”, Technical report of HUMAINE, Human-Machine Interaction Network on Emotions, IST-FP6 Contract No 507422, mai 2004.
- [Rus80] J.A. Russell, „A Circumplex Model of Affect”, Journal of Personality and Social Psychology 39, pag.1161–1178, 1980.
- [Seb04] N. Sebe, M.S. Lew, I. Cohen, Y. Sun, T. Gevers, T.S. Huang, „Authentic Facial Expression Analysis”, International Conference on Automatic Face and Gesture Recognition (FG'04), pag. 517-522, Coreea, mai 2004.
- [Slo99] Sloman A., „Review of Affective Computing”, AI Magazine, vol. 20, nr. 1, pag. 127-133, 1999.
- [Sto07] O. Stock, M. Zancanaro, P. Busetta, C. Callaway, A. Krüger, M. Kruppa, T. Kuflik, E. Not și C. Rocchi, „Adaptive, intelligent presentation of information for the museum visitor in PEACH”, User Modeling and User-Adapted Interaction vol. 17(3), 2007.
- [Tho04] Thomas, S., Claudia, L. P., „A Context Modeling Survey”, Workshop on Advanced Context Modelling, Reasoning and Management, England, septembrie 2004.
- [Ton07] E.M.W. Tong, G.D. Bishop, H.C. Enkelmann, P.Y. Why și M.S. Diong, „Emotion and appraisal: A study using ecological momentary assessment”, Cognition and Emotion, pag. 1361-1381, vol. 21, nr. 7, 2007.
- [Wan04] Xiao Hang Wang, Tao Gu, Da Qing Zhang, Hung Keng Pung, „Ontology-Based Context Modeling and Reasoning using OWL”, Context Modeling and Reasoning Workshop în cadrul conferinței PerCom 2004, 2004.
- [Wan08] N. Wang, L. Johnson, R. Mayer, P. Rizzon, E. Shaw and H. Collins, „The politeness effect: Pedagogical agents and learning outcomes”, International Journal of Human-Computer Studies, pp.98-112, vol. 66, nr. 2, 2008.
- [Yan95] Tarao Yanaru, „An emotion processing system based on fuzzy inference and subjective observations”, pag.15-21, 2nd New Zealand Two-Stream International Conference on Artificial Neural Networks and Expert Systems (ANNES '95), Noua Zeelandă, noiembrie 1995.
- [Yau06] Yau, S. S., Liu, J., „A Hierarchical Situation Modeling and Reasoning for Pervasive Computing”, Proceedings of the the Fourth IEEE Workshop on Software Technologies For Future Embedded and Ubiquitous Systems, and the Second international Workshop on Collaborative Computing, integration, and Assurance (Seus-Wccia'06), SEUS-WCCIA, IEEE Computer Society, pag. 5-10, aprilie 2006.
- [Yea06] Yeasin, M., Bullot, B., Sharma, R.: Recognition of Facial Expressions and Measurement of Levels of Interest From Video, IEEE Transactions On Multimedia, vol. 8, nr. 3, 2006.
- [You05] Youngjung Suh, Dongoh Kang, Woontack Woo, „Context-based User Profile Management for Personalized Services”, ubiComp, workshop ubiPCMM, 2005.
- [Zen09] Zeng, Z., Pantic, M., Roisman, G. I., and Huang, T. S., „A Survey of Affect Recognition Methods: Audio, Visual, and Spontaneous Expressions”, IEEE Transaction on Pattern Analysis and Machine Intelligence, pag. 39-58, vol. 31, nr. 1, ianuarie 2009.

Resurse disponibile pe internet

- [asi09] <http://asi.insa-rouen.fr/enseignants/~arakotom/toolbox/index.html>, accesată la 25.09.2009
- [Bea09] Beanyziner, <http://jadex.informatik.uni-hamburg.de/docs/jadex-0.94x/toolguide/tools.beanyziner.html>, accesată la 28.09.2009.
- [FNN09] Feed Forward Neural Networks v2.0, <http://ncorpus.com/neural/>, accesată la 28.09.2009.
- [FR09] Produsul FaceReader, versiunea 2.0 dezvoltat de firma VicarVision <http://www.vicarvision.nl/FaceReader.html> și comercializat de firma Noldus <http://www.noldus.com/human-behavior-research/products/facereader>.
- [Jen09] Jena, <http://jena.sourceforge.net/downloads.html>, accesată la 28.09.2009.
- [Mar01] A. Marriott, S. Beard, J. Stallo, Q. Huynh, „VHML-Working Draft”, <http://www.vhml.org/>, martie 2001.
- [McG04] D.L. McGuinness, F.v. Harmelen, „OWL Web Ontology Language Overview”, <http://www.w3.org/TR/owl-features>, W3C Recommendation, februarie 2004.
- [Phi09] Phidgets - USB sensing and control, <http://www.phidgets.com/>, accesată la 28.09.2009
- [W3C08] <http://www.w3.org/2005/incubator/emotion/XGR-emotionml-20081120/>, noiembrie 2008.