



UNIVERSITATEA DIN CRAIOVA
FACULTATEA DE AUTOMATICĂ, CALCULATOARE ȘI ELECTRONICĂ

TEZĂ DE DOCTORAT

MODELAREA DATELOR ÎN BAZE DE DATE MULTIMEDIA

-REZUMAT-

Doctorand
Anca Loredana Ion

Conducător științific
Prof.Dr.Ing. Mircea Petrescu

-2009-

Alegerea temei pentru teza de doctorat a pornit de la limitele stadiului actual al cercetărilor privind modelarea semantică a datelor multimedia. Datorită creșterii exponențiale a volumului de date netextuale, a apărut necesitatea dezvoltării de metode și algoritmi pentru regăsirea și clasificarea semantică automată a datelor multimedia. Rata de creștere a volumului de date vizuale digitale nu are același ritm cu dezvoltarea de tehnologii care să suporte analiza, clasificarea și regăsirea eficientă a datelor multimedia.

Modelarea datelor multimedia continuă să fie una dintre cele mai captivante și dinamice arii de cercetare din domeniul „computer vision”. Dezvoltările recente din tehnologiile hardware și telecomunicațiilor, în asociere cu proliferarea web-ului au sporit crearea și diseminarea la scară largă a conținutului vizual digital.

Teza de doctorat tratează modalități de a reduce decalajul semantic între caracteristicile vizuale de nivel jos extrase automat din conținutul vizual și conceptele semantice de nivel înalt. Studiarea comparativă a unor metode de reprezentare a caracteristicilor vizuale ale imaginilor color reprezintă una din principalele contribuții importante din cadrul tezei. Dezvoltarea unui cadru experimental care permite căutarea vizuală bazată pe conținut la nivel de imagine este una din contribuțiile aplicative ale tezei de doctorat. Concepția și dezvoltarea unor algoritmi noi de adnotare automată bazată pe învățare a imaginilor color reprezintă contribuția majoră a tezei de doctorat. O altă contribuție aplicativă a tezei de doctorat este dezvoltarea unui sistem software prototip pentru clasificarea semantică automată a imaginilor.

Teza de doctorat este structurată pe 5 capitole urmate de bibliografie și anexe.

În **Capitolul 1 „Noțiuni introductive”** se realizează introducerea în problematica temei tratate. Pe parcursul acestui capitol este justificată importanța și mai ales actualitatea acestei teme, privind necesitatea dezvoltării de algoritmi pentru modelarea datelor multimedia, în special adnotarea semantică și regăsirea vizuală a imaginilor. De asemenea, este realizat un studiu privind stadiul actual al modelării datelor multimedia. Totodată sunt stabilite și obiectivele urmărite de autor de-a lungul tezei.

Cea mai mare provocare a secolului XXI sunt aspectele semantice ale informației vizuale, de obicei descrise de atribute textuale sau mapate în scheme de descrieri specializate. Adnotarea manuală este subiectivă, mare consumatoare de timp și conduce la descrieri subiective, incomplete ale imaginilor. Astfel, sunt necesare tehnologii noi pentru reducerea costurilor adnotării manuale a imaginilor.

Datorită mării dificultăți în a recunoaște și clasifica imaginile la nivelul general, metodele de a identifica caracteristicile semantice ale imaginilor pentru navigare și regăsire au înregistrat mare succes.

Astfel, numeroase cercetări au fost făcute pentru a investiga tehnici automate care să genereze descrieri semantice ale conținutului multimedia. Două din direcțiile fundamentale sunt:

- o metodele de învățare a mașinii (*“machine learning”*) bazate pe statistică care adnotează manual seturi de date de test pentru a genera din ele grafuri, modele statistice sau alte tehnici de indexare pentru colecții mari de date.
- o dezvoltarea de ontologii pentru datele multimedia. Aceste metode utilizează legături descrise de ontologie sau tezaur pentru a permite interogări semantice complexe pe colecții de date multimedia adnotate sau pentru a infera informație nouă.

În **Capitolul 2 „Descrierea vizuală a imaginilor”** se studiază, comparativ eficiența și performanța metodelor de reprezentare a caracteristicilor vizuale de nivel jos ale imaginilor. Scopul acestui studiu este determinarea metodelor performante care regăsesc cu acuratețe imaginile color.

Deoarece nu există o descriere perfectă a conținutului vizual al imaginilor, cele mai multe metode încearcă să stabilească un compromis în alegerea diferitelor aspecte ale conținutului imaginilor. Găsirea unui set de descriptori care să descrie conținutul vizual la imaginilor este o precondiție pentru ca regăsirea și adnotarea imaginilor să fie făcută cu acuratețe.

Deși conceptele semantice nu sunt direct legate de caracteristici vizuale (culoare, textură, formă, poziție, dimensiune etc.), aceste atribute capturează informația despre înțelesul semantic al imaginilor.

În acest capitol s-au studiat și experimentat mai multe caracteristici de nivel jos ale imaginilor pentru a stabili corelația cu categoriile semantice. Caracteristicile vizuale de nivel jos considerate sunt: culoare, textură, dimensiune, poziție, coerența spațială, forma regiunilor relevante ale imaginii. Pentru selectarea celui mai bun set de caracteristici vizuale au fost analizate, studiate și comparate următoarele metode:

- o pentru caracteristica *culoare*: histograma color în spațiul color HSV cuantificat la 166 de culori, descriptorul de structură color în spațiul color HMMD, culori dominante în spațiul color CIE-LUV.
- o pentru caracteristica *textură*: matrici de coocurență și filtre Gabor.
- o pentru caracteristica *formă*: metode bazate pe contur și suprafață.

Capitolul se încheie cu un studiu experimental cu scopul de a compara performanța de regăsire a imaginilor color folosind descriptorii vizuali prezentați mai sus.

Pentru *caracteristica culoare*, pe baza experimentelor realizate în acest capitol, performanțele cele mai bune au fost obținute de reprezentarea acesteia în spațiu color HSV cuantificat la 166 de culori.

Pentru *caracteristica textură*, pe baza experimentelor realizate în acest capitol, performanțele cele mai bune au fost obținute de reprezentarea texturii folosind matrici de coocurență.

Pentru *caracteristica formă* s-au selectat numai metode bazate pe suprafață, deoarece cele bazate pe contur au dezavantajul că obiectele din imagini trebuie să aibă conturul închis. Metodele bazate pe contur au dat rezultate foarte slabe pe imagini care nu conțineau obiecte centrale cu conturul închis. Pe baza experimentelor realizate în acest capitol, dintre metodele bazate pe suprafață, performanțele cele mai bune au fost obținute de metoda excentricitate.

În **Capitolul 3 „Extragerea conceptelor semantice din imagini”** se studiază posibilitățile de a descoperi corelații între caracteristicile vizuale primitive, de nivel jos ale unei imagini și conceptele semantice, de nivel înalt dintr-un domeniu folosit de om, ceea ce înseamnă extragerea de concepte semantice bazată pe învățare, dintr-o bază de date cu imagini. Fără o indexare eficientă, nu există regăsire eficientă. Întrebarea principală este cum poate un sistem să extragă, nu numai caracteristicile primitive, vizuale, ci și asociațiile ascunse dintre caracteristici pentru a face căutarea bazată pe conținut mai performantă. Prin studiile realizate în cadrul tezei de doctorat s-au dezvoltat metode care să răspundă la această provocare care a inaugurat o nouă generație a sistemelor de regăsire în care cunoștințele sunt extrase automat.

În acest capitol se abordează problema descoperirii automate de reguli semantice de inferență din imagini. Metodele dezvoltate se bazează pe:

- o segmentarea automată a imaginilor și indexarea regiunilor color obținute.
- o maparea automată a caracteristicilor vizuale ale imaginilor la valorile indicatorilor semantici.
- o definirea unei baze de cunoștințe folosind limbajul declarativ Prolog care facilitează procesul de mapare.
- o descoperirea automată de reguli semantice de inferență pentru recunoașterea conceptelor semantice în imagini.
- o reprezentarea regulilor semantice folosind limbajul declarativ Prolog pentru a putea fi aplicate cu ușurință oricărui domeniu.

Alegerea setului de caracteristici vizuale și a algoritmului de segmentare a imaginilor este etapa definitorie pentru procesul de adnotare semantică a imaginilor. Din experimentele realizate în teza de doctorat, s-a dedus importanța conceptelor semantice pentru stabilirea similitudinii dintre imagini. Deși conceptele semantice nu sunt direct legate de caracteristici vizuale (culoare, textură, formă, poziție, dimensiune, etc.), aceste atribute capturează informația despre înțelesul semantic.

Utilizând rezultatele experimentelor din capitolul II, pentru reprezentarea caracteristicii de culoare vom folosi spațiul color *HSV* cuantificat la 166 de culori. Această metodă de reprezentare a informației de culoare a obținut rezultatele cele mai bune, superclasând metoda de reprezentare a culorii la spațiul color *HMMD* cuantificat la 256 de culori și metoda de culori dominante.

Astfel, înainte de a fi segmentate, imaginile sunt transformate de la spațiul color *RGB* la *HSV* și cuantificate la 166 de culori.

Extragerea regiunilor color și a caracteristicilor lor este realizată cu algoritmul cu proiecție în urmă peste seturi color (color-set back projection). Acest algoritm detectează regiunile de o singură culoare.

Pentru indexarea regiunilor extrase din imagini se folosesc următoarele caracteristici:

- o Caracteristicile de culoare sunt reprezentate în spațiul color *HSV* cuantificat la 166 de culori. O regiune este reprezentată de un index de culoare care reprezintă un număr întreg între 0..165.
- o Coerența spațială este descriptorul care măsoară compactitudinea spațială a pixelilor de aceeași culoare într-o regiune.
- o Caracteristica de textură este reprezentată printr-un vector cu 7 componente: energie, entropie, probabilitatea maximă, contrast, diferența inversă, cluster shade și cluster prominence.
- o Descriptorul de dimensiune al regiunii reprezintă numărul de pixeli din regiune.
- o Informația spațială este reprezentată prin coordonatele centrului de greutate al regiunii și prin dreptunghiul minim care încadrează regiunea.
- o Forma este reprezentată de caracteristica excentricitate.

Vocabularul creat pentru adnotarea imaginilor este bazat pe conceptul indicatorilor semantici (descriptori intermediari semantici), în timp ce sintaxa capturează modelele de bază din percepția umană asupra șabloanelor și categoriilor semantice. Sintaxa este reprezentată de modul în care sunt descrise imaginile. Limbajul de reprezentare propus în acest studiu este simplu din cauza faptului că sintaxa și vocabularul sunt elementare. Din această cauză, cuvintele limbajului sunt limitate la numele

indicatorilor semantici. Fiind elemente vizuale elementare, indicatorii semantici sau descriptorii intermediari sunt, de exemplu, culoarea (culoare – roșu – deschis), coerența spațială (coerența spațială mică, coerența spațială medie, coerența spațială mare), textura (energie mică, energie mare, etc.), dimensiune (dimensiune mică, dimensiune mare, etc.), poziție (vertical sus, orizontal stânga, etc.), forma (excentricitate mică, excentricitate mare, etc.).

După ce imaginile din baza de date pentru învățare sunt reprezentate cu ajutorul indicatorilor semantici, urmează procesul de generare automată a regulilor semantice de inferență

Metoda de adnotare automată a imaginilor propusă în teza de doctorat include:

- o faza de învățare a regulilor semantice de inferență,
- o faza de testare a regulilor semantice de inferență.

1. Faza de învățare: generarea regulilor

O regulă semantică de inferență este de forma:

“descriptori semantici->concepte semantice”

Etapele procesului de învățare sunt:

- o pentru a învăța fiecare concept semantic se folosesc imagini relevante respectivului concept.
- o fiecare imagine este procesată și segmentată automat în regiuni și se calculează caracteristicile primitive vizuale.
- o pentru fiecare imagine se mapează caracteristicile primitive de nivel jos la indicatori semantici.
- o se aplică algoritmi de generare a regulilor semantice de inferență.

2. Faza de testare/recunoaștere a imaginilor: are ca scop adnotarea automată a imaginilor

- o fiecare imagine nouă este procesată și segmentată automat în regiuni și se calculează caracteristicile primitive vizuale.
- o pentru fiecare imagine nouă se mapează caracteristicile primitive de nivel jos la indicatori semantici.
- o se aplică algoritmul de clasificare pentru a identifica categoria/conceptul semantic al imaginii.

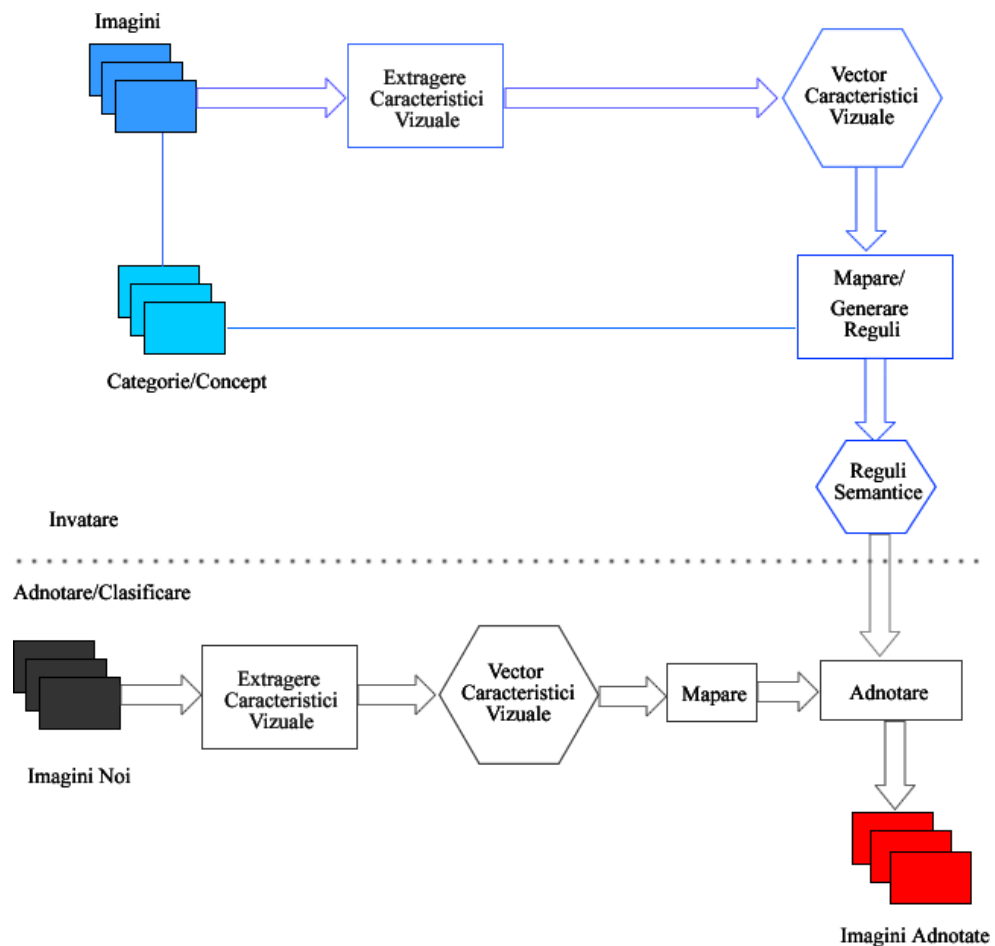


Fig. 1. Descrierea procesului de adnotare/ clasificare a imaginilor

În această lucrare, descoperirea de cunoștințe din imagini este folosită pentru a defini reguli care să convertească caracteristicile primitive de nivel jos ale imaginilor în caracteristici semantice de nivel înalt.

Metodele propuse în teza de doctorat aduc îmbunătățiri în ceea ce privește utilizarea descrierilor detaliate ale imaginilor care sunt necesare pentru definirea legăturilor între:

1. obiecte/regiuni,
2. clase de caracteristici vizuale,
3. obiecte/regiuni și clase de caracteristici vizuale.

În teza de doctorat s-au propus algoritmi pentru generarea automată a regulilor semantice de inferență care se bazează pe algoritmul Apriori pentru găsirea *itemset-urilor* frecvente. În cazul regulilor semantice de inferență pentru imagini, scopul este acela de a găsi asocieri semantice.

Pentru prima variantă (Algoritm 3.2) a algoritmului de generare a regulilor semantice de inferență, modelarea imaginilor în termenii *itemset-urilor* și tranzacțiilor este următoarea:

- tranzacțiile reprezintă mulțimea de imagini.
- mulțimea de *itemset-uri* este formată din culorile (C_k) ale regiunilor imaginilor care reprezintă aceeași categorie.
- mulțimea de *itemset-uri* frecvente: reprezintă *itemset-urile* care au suportul mai mare sau egal cu suportul minim.
- iterativ, se găsesc *itemset-urile* cu cardinalitate între 1 și k (*itemset-uri* de lungime k)

- o *itemset-urile* frecvente se folosesc pentru generarea de reguli. Fiecărei reguli i se asociază:
 - suportul = procentul de tranzacții în care este prezent atât precedentul cât și consecventul regulii
 - confidența = raportul dintre numărul de tranzacții în care apar împreună atât *precedentul* cât și *consecventul* regulii și numărul de tranzacții în care apare numai precedentul.

O regulă semantică de inferență generată cu acest algoritm este de forma:

$(C_1 \{ \text{reuniune indicatori semantici ai regiunilor de culoare } C_1 \text{ din cele 5 imagini} \} \text{ și } \dots$

$\text{și } C_n \{ \text{reuniune indicatori semantici ai regiunilor de culoare } C_n \text{ din cele 5 imagini} \}) \rightarrow \text{categorie}$ În varianta a doua (Algoritm 3.4), algoritmul ia în considerare toate caracteristicile unei regiuni, nu doar caracteristica de culoare. Această variantă se bazează pe „șabloane regiune” și necesită calcule în plus, fiind necesară o fază de preprocesare în care să determinăm similitudinea vizuală între regiunile imaginilor din baza de date.

În faza de preprocesare se determină șabloanele regiune care apar în imagini. Astfel, fiecare regiune Reg_{ij} a imaginii este comparată cu celelalte regiuni ale altor imagini din aceeași categorie. Dacă regiunea Reg_{ij} se potrivește cu altă regiune Reg_{km} având comune caracteristicile de pe pozițiile n_1, n_2, \dots, n_c atunci șablonul regiune generat este $SR_j(-, -, -, n_1, n_2, \dots, n_c, -, -)$, iar caracteristicile care nu sunt comune sunt ignorate. O regulă semantică de inferență generată cu acest algoritm este de forma:

$SR_1(-, -, -, n_1', n_2', \dots, n_c', -, -)$ și...și $SR_n(-, -, -, n_1, n_2, \dots, n_c, -, -) \rightarrow \text{categorie}$

Înainte de a fi clasificată, fiecare imagine este procesată automat:

- o se generează descriptorii matematici și descriptorii intermediari pentru fiecare imagine și se salvează ca o faptă Prolog,
- o se aplică regulile semantice pe setul de fapte deja existent, folosind un motor de inferență Prolog.

Pentru a valida performanța algoritmilor de adnotare semantică a imaginilor color au fost realizate experimente pe diverse colecții de imagini din natură.

Baza de date pentru învățare conține 200 de imagini din natură și este folosită pentru a învăța legăturile (corelațiile) dintre caracteristicile vizuale ale imaginilor și conceptele semantice. Toate imaginile din baza de date sunt în format JPEG, având diverse dimensiuni. Baza de date pentru procesul de învățare este categorizată în 50 de concepte semantice. Fiecare concept/categorie este învățat de sistem în urma analizei a câte 20 de imagini, în medie.

Cum sistemul de adnotare este bazat pe învățare, acesta poate fi folosit pentru imagini din diferite domenii.

Tabelul cu categorii din baza de date folosită pentru învățare și descrierile lor este prezentat:

Tabel 1. Categoriile de imagini din baza de date

ID	Categorie	Descriere categorie
1	Foc	foc, noapte, căldură, lumină
2	Iceberg	iceberg, gheata, peisaj, ocean
3	Copac	copac, copaci, cer, peisaj, natură
4	Apus de soare	apus de soare, natură, peisaj, soare, seara, cer
5	Faleză	faleză, rocă, mare, natură, peisaj, cer
6	Deșert	deșert, arid, căldură, nisip
7	Trandafir roșu	trandafir, floare, dragoste
8	Elefant	elefant, animal, junglă
9	Munte	munte, lac, stâncă, cer, peisaj
10	Mare	mare, cer, apă, faleză, peisaj
11	Flori	trandafiri, margarete, maci

Cuvintele cheie sunt asociate manual pentru a descrie imaginile din baza de date pentru învățare. Descrierile acestor colecții de imagini sunt făcute de la concepte simple "floare, ciuperci", la concepte complexe "munți, faleză, lac". În medie, 3.5 cuvinte cheie sunt folosite pentru a descrie fiecare categorie de imagini. Procesul de adnotare manuală a imaginilor folosite în faza de învățare a sistemului a durat 7 ore. Fiind adnotate manual, s-au făcut eforturi din partea autorului pentru a folosi cuvinte cheie potrivite pentru fiecare imagine.

Pentru fiecare categorie de imagini din baza de date se calculează procentul de imagini clasificate corect, folosind cei doi algoritmi de generare a regulilor și algoritmul de clasificare cu potrivire perfectă.

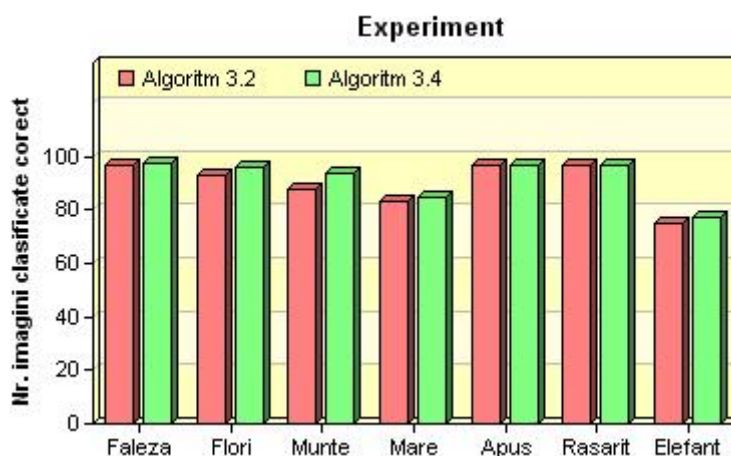


Fig. 2. Graficul categorie vs. procent de imagini clasificate corect de sistem

Din experimentele realizate, *Algoritmul 3.4* înregistrează rezultate cele mai bune, deoarece această se bazează pe șabloane regiune, care selectează caracteristicile cu probabilitatea cea mai mare de apariție și oferă generalitate mai mare.

În **Capitolul 4 „Dezvoltarea unui cadru experimental pentru adnotarea semantică a imaginilor”** se descrie cadrul experimental dezvoltat pentru studierea algoritmilor de extragere a caracteristicilor vizuale, de segmentare și de adnotare semantică a imaginilor.

Sistemul software **SIRS (Semantic Image Retrieval System)** este creat pentru studiul unor metode folosite în căutarea vizuală bazată pe conținut și adnotarea semantică în baze de date cu imagini. Folosind algoritmi descriși în capitolele 2 și 3 s-a implementat un cadru software experimental cu ajutorul căruia sunt studiate următoarele probleme:

- Studierea comparativă a algoritmilor de extragere a caracteristicilor vizuale din imagini în scopul selectării celui mai bun set de metode care să regăsească cu acuratețe imaginile color.
- Maparea caracteristicilor de nivel jos la descriptori intermediari/indicatori semantici.
- Algoritmi pentru generarea automată prin învățare a regulilor semantice de inferență pentru extragerea caracteristicilor de nivel înalt din imagini.
- Clasificarea imaginilor folosind reguli semantice de inferență.
- Căutarea vizuală bazată pe conținut sau după cuvinte cheie.

Prin comparație cu alte sisteme de adnotare semantică a imaginilor, *SIRS* are următoarele avantaje: în primul rând întreg procesul este automat și se pot defini o varietate mare de concepte semantice. În al doilea rând *SIRS* este proiectat pentru imagini din natură, dar poate fi cu ușurință extins oricărui domeniu, deoarece caracteristicile vizuale, indicatorii semantici rămân neschimbați, iar regulile semantice se generează pe baza mulțimii de imagini-exemplu etichetate și folosite pentru învățare. Performanța mulțimii de caracteristici vizuale a fost testată experimental și s-au obținut rezultate foarte bune pe diverse tipuri de imagini color.

Spre deosebire de alte sisteme de adnotare semantică, sistemul *SIRS* consideră informația spațială a regiunilor color detectate din fiecare imagine care furnizează informație semantică bogată (legăturile în care se găsesc o regiune cu alta: la stânga, la dreapta, în centru, sus, jos).

Sistemul software prototip *SIRS* are totuși și câteva limitări, datorate imperfecțiunii algoritmului de segmentare a imaginilor color, incapabil să detecteze obiecte reale complexe. De asemenea, pentru obținerea unor reguli semantice sofisticate, algoritmi de generare a regulilor semantice necesită să fie elaborați mai mult. În studiul viitor vor fi adresate aceste probleme.

În **Capitolul 5 „Concluzii generale. Contribuții originale”** se prezintă principalele contribuții originale ale tezei. Pe parcursul tezei au fost evidențiate și tratate următoarele aspecte cu privire la modelarea datelor în baze de date multimedia:

- Studiul unor metode de modelare a datelor în baze de date multimedia.
- Studiul comparativ al metodelor de reprezentare a caracteristicilor vizuale de nivel jos, culoare, textură și formă, în vederea selectării setului de descriptori cu cea mai bună performanță de regăsire.
- Dezvoltarea unor metode de adnotare semantică automată a imaginilor color.
- Dezvoltarea unui sistem software prototip pentru clasificarea semantică a imaginilor.

Sunt propuse noi abordări pentru problema adnotării semantice a imaginilor, ca de exemplu metodele de generare automată a regulilor de inferență bazate pe învățare. Acest lucru reprezintă o contribuție importantă adusă temei de cercetare.

Contribuțiile privind adnotarea automată a imaginilor se pot rezuma la următoarele:

- S-a determinat setul de metode de reprezentare a imaginilor cu cea mai bună performanță de regăsire (Cap. 2).
- S-a realizat un sistem software experimental implementat în *Java* cu ajutorul căruia s-au studiat comparativ descriptori pentru caracteristici de culoare, textură și formă. Găsirea unui set de descriptori care să descrie conținutul vizual la imaginilor este o condiție pentru ca regăsirea și adnotarea imaginilor să fie făcută cu acuratețe (Cap. 2).
- S-au propus metode și reprezentări noi pentru adnotarea imaginilor pe baza regiunilor de o singură culoare (Cap. 3).

Acestea constau în:

- Segmentarea imaginilor în regiuni după caracteristica culoare.
- Calcularea descriptorilor vizuali de nivel jos selectați în Cap. 2 ca fiind cei mai performanți.
- Maparea descriptorilor vizuali de nivel jos la indicatori semantici și reprezentarea imaginilor în *limbajul declarativ Prolog*, în termenii indicatorilor semantici. Corespondența între valorile matematice și valorile indicatorilor semantici sunt determinate pe baza experimentelor efectuate.
- Crearea unui limbaj de reprezentare care este simplu din cauza faptului că sintaxa și vocabularul sunt elementare.
- Descoperirea de cunoștințe din imagini folosită pentru a defini reguli care să convertească caracteristicile de nivel jos ale imaginilor în caracteristici semantice de nivel înalt.
- Concepția a două metode de generare a regulilor semantice de inferențe bazate pe algoritmul a-priori.
- Dezvoltarea unei metode de clasificare cu potrivire perfectă a imaginilor pe baza regulilor de inferență.
- Dezvoltarea unui cadru experimental pentru studierea comparativă a eficienței metodelor de adnotarea automată a imaginilor color.

Concluzionând, înțelegerea semantică a conținutului vizual este ultima frontieră în domeniul regăsirii imaginilor. Dificultatea provine din decalajul semantic dintre caracteristicile vizuale de nivel jos și reprezentările care pot fi automat calculate din conținutul vizual și conceptele semantice de nivel înalt pe care oamenii le recunosc.

O parte a studiului viitor, cu privire la regăsirea imaginilor, va fi implementarea în acest sistem a feedback-ului de relevanță, care va îmbunătăți în mod cert și vizibil performanța acestuia. Un astfel de sistem poate fi utilizat în diferite domenii: medicină, artă, divertisment, mass media etc. Încurajăm de asemenea efectuarea de studii asupra nevoilor utilizatorilor pentru a obține o înțelegere completă a căilor și dorințelor acestora. O direcție interesantă a evoluției acestui studiu și totodată o mare provocare o constituie furnizarea de noi posibilități pentru detectarea și urmărirea stării emoționale umane.

Cererea pentru o tehnologie demnă de încredere și robustă, de înțelegere a imaginilor continuă. Viitorul acestui domeniu depinde de concentrarea colectivă și progresul general în fiecare aspect al extragerii de imagini.