

UNIVERSITATEA TEHNICĂ A MOLDOVEI

Cu titlu de manuscris

C. Z. U: 004.93

RUSU MARIANA

**ANALIZĂ ȘI RECUNOAȘTERE DE FORME
PENTRU APLICAȚII CU IMAGINI DIGITALE**

**122.03 – MODELARE, METODE
MATEMATICE, PRODUSE PROGRAM**

Autoreferatul tezei de doctor în informatică

CHIȘINĂU, 2019

Teza de doctor a fost elaborată în cotutelă în cadrul catedrei *Informatică Aplicată* a Universității Tehnice a Moldovei (UTM) și în cadrul *Centrului de cercetare în sisteme inteligente și electronică aplicată* a Universității Tehnice „Gh. Asachi”, Iași, România.

Conducători științifici:

UTM - conf.univ., dr. Vasile MORARU

UT “Gh.Asachi” – acad., prof.univ., dr. Horia-Nicolai TEODORESCU (Exclusiv pe durata a două stagii de pregătire)

Referenți oficiali:

GORAȘ Liviu, prof. univ., dr. Academia de Științe Tehnice,
Universitatea Tehnică “Gheorghe Asachi” Iași;

COJOCARU Victor, conf. cercetător, dr., Institutul de
Inginerie Electronică și Nanotehnologii "D. Ghițu" al AȘM.

Componența consiliului științific specializat:

GAINDRIC Constantin președinte, prof.univ., dr. hab., m.cor. AȘM
Institutul de Matematică și Informatică "VI. Andrunachievici";

ZAPOROJAN Sergiu secretar științific, conf. univ., dr.,
Universitatea Tehnică a Moldovei;

GUȚULEAC Emilian, prof. univ., dr. hab., Universitatea Tehnică a
Moldovei;

BOLUN Ion, prof. univ., dr. hab., Universitatea Tehnică a Moldovei;

CĂPĂȚĂNĂ Gheorghe, prof. univ., dr., Universitatea de Stat a
Moldovei;

ZBANCIOC Marius-Dan, conf. univ., dr., Universitatea Tehnică
“Gh.Asachi” Iași.

Susținerea va avea loc la 15 mai 2019 la ora 15:00 în ședința Consiliului științific specializat D122.03-34 din cadrul Universității Tehnice a Moldovei, str. Studenților 9/7, aud.3-208, , or. Chișinău, MD-2045

Teza de doctor și autoreferatul pot fi consultate la biblioteca Universității Tehnice a Moldovei.

Autoreferatul a fost expediat la 10 aprilie 2019

Secretar științific al Consiliului științific specializat,

dr., conf.

ZAPOROJAN Sergiu

Conducători științifici,

dr., conf.univ.

dr., acad., prof.univ.

Vasile MORARU

Horia-Nicolai TEODORESCU

Autor

Mariana RUSU

(© Mariana RUSU, 2019)

REPERELE CONCEPTUALE ALE CERCETĂRII

Actualitatea temei este confirmată de numărul crescător de lucrări, proiecte, aplicații în domeniul procesării de imagini cu scopul interpretării automate a acestora: asistarea unui diagnostic medical; recunoașterea amprentelor, vocii, retinei și a persoanelor (pentru securitate); dirijări și evitări de rachete, submarine, roboți etc. în servicii militare; observarea și preîntâmpinarea cataclismelor naturale bazate pe imaginile captate de sateliți; recunoașterea scrisului de mână la serviciile poștale pentru gruparea scrisorilor etc.

Pentru aplicarea în practică a algoritmilor de recunoaștere s-a ales domeniul trierii deșeurilor. Nu este aplicată până în prezent sortarea prin recunoașterea obiectelor, dar sunt deșeuri care nu sunt colectate corect și ar trebui eliminate de pe banda de sortare: containerele care au conținut pesticide; containerele de uleiuri și vopsele, solvenți; containerele de ulei de motor, baterii, containere ce conțin uleiuri alimentare arse sau vechi etc. Aceste deșeuri sunt toxice pentru mediu și sănătate, deci trebuiesc stocate separat. Ar fi bine să poată fi eliminate din grămada de deșeuri pentru reciclare specială.

Scopul lucrării constă în elaborarea unor metode, algoritmi ce ar permite recunoașterea formelor/obiectelor din imagine și clasificarea lor automată, scop atins prin următoarele **obiective**:

- analiza etapelor de procesare a imaginilor în vederea extragerii informației, recunoașterii și clasificării obiectelor din imagini;
- elaborarea unui algoritm de segmentare bazat pe G-U-MM;
- analiza principalelor metode de recunoaștere a formelor din scene mono-obiect;
- analiza metodelor fundamentale de clasificare automată;

- elaborarea unei metode de separare liniară a două mulțimi de date;
- elaborarea unui sistem de recunoaștere și clasificare automată a formelor bazat pe logica fuzzy.
- compararea rezultatelor obținute la fiecare etapă a procesării imaginilor cu metodele de referință respective (segmentare, recunoaștere și clasificare a formelor); concluzionarea eficacității metodelor elaborate.

Noutatea științifică: Au fost identificate și argumentate: o metodă nouă de segmentare bazată pe modele uniforme și gaussiene; un model matematic de separare liniară a două mulțimi de date; o metodă hibridă de recunoaștere (CNN+GA) și clasificare a formelor (logica fuzzy, identificarea semnăturii).

Problema științifică soluționată constă în: elaborarea unei metode de segmentare bazată pe histogramă ce nu necesită indicarea numărului de praguri; propunerea unei metode de separare liniară a două mulțimi de date (descrierea modelului matematic); elaborarea unui sistem de clasificare automată elaborat ce unește diverși algoritmi din inteligența artificială (algoritm genetic, sistem fuzzy) și definește combinația particulară care poate oferi o mai bună soluție pentru clasificarea automată a formelor/obiectelor.

Semnificația teoretică. Lucrarea dată conține o analiză comparativă a metodelor fundamentale de clasificare automată și de recunoaștere a formelor bazate pe descriptorii locali; o descriere detaliată a algoritmului elaborat bazat pe G-U-MM, o evaluare obiectivă nesupervizată pe bază de metrici a rezultatelor obținute la segmentare; o descriere a sistemului hibrid de recunoaștere și o evaluare a rezultatelor obținute la recunoașterea imaginilor.

Valoarea aplicativă a lucrării. La etapa de extragere a informației s-a propus un algoritm de segmentare bazat pe distribuții Gaussiene. Acest algoritm poate fi aplicat ca

extragere de informație: perimetru, suprafață, valoare medie a pixelilor etc. pentru alți algoritmi de recunoaștere bazați pe caracteristicile date de exemplu un sistem fuzzy de decizie. De asemenea, algoritmul este util la separarea obiectului de fundal.

Pentru clasificarea a două mulțimi de date s-a propus un algoritm de separare liniară. S-a prezentat o procedură efectivă de reducere a problemei considerate la rezolvarea unui sistem de ecuații prin reformularea condițiilor de optimalitate Karush-Kuhn-Tucker și utilizând metoda Newton.

Pentru recunoașterea formelor s-a elaborat un sistem bazat pe logica fuzzy cu un pas preliminar de recunoaștere a simbolului de pericol prin algoritm hibrid ce combină coeficientul de corelație cu algoritmul genetic și un pas de verificare a corectitudinii clasificării prin identificarea semnăturii obiectului. Coeficientul de corelație determină potrivirea sau nu a două imagini, iar algoritmul genetic generează noi dimensiuni și unghiuri de rotire ale imaginii căutate. Este un algoritm rapid și poate fi aplicat și pentru alte tipuri de imagine, având un randament de recunoaștere înalt. Identificarea semnăturii obiectului e bazată pe funcția diferență. Sistemul de decizie fuzzy e bazat pe 3 atribute: formă, mărime și simetrie. Sistemul fuzzy poate fi adaptat pentru clasificarea automată și a altor obiecte.

Implementarea rezultatelor științifice. Algoritmul de segmentare elaborat este utilizat la separarea obiectelor de fundal, ca o etapă preliminară pentru recunoașterea de forme într-un sistem de decizie bazat pe caracteristici.

Algoritmul hibrid bazat pe combinarea CCN și GA a fost implementat la trierea deșeurilor, dar poate fi utilizat și la alte tipuri de obiecte pentru recunoaștere, de ex. la găsirea logourilor de pe documente.

Metoda matematică de separare liniară propusă poate fi utilizată la clasificarea automată a obiectelor în două grupuri.

În dependență de obiectele ce necesită sortate, se pot schimba atributele ce sunt semnificative la clasificare și

sistemul propus bazat pe logica fuzzy se adaptează ușor la noi cerințe.

Rezultatele științifice înaintate spre susținere:

- Algoritmul de segmentare bazat pe G-U-MM.
- Metoda matematică de separare liniară a două mulțimi de date.
- Metoda hibridă bazată pe coeficientul de corelație normalizat și algoritm genetic.
- Sistemul automat de clasificare bazat pe logica fuzzy.

Aprobarea rezultatelor cercetărilor. Analiza metodelor implementate, descrierea algoritmului elaborat și unele rezultate prezentate în teză au fost publicate în reviste internaționale și naționale:

- Computer Science Journal of Moldova, Vol.20, Nr.2(59), 2012, Vol.25, Nr.1(73), 2017;
- Proceedings of the Romanian Academy, Series A, Vol.14, No.1, 2013;
- Meridian Ingineresc (2 lucrări), No.2, 2013;
- Romanian Journal of Information Science and Technology, Vol.16, No.1, 2013.

De asemenea, rezultatele obținute pe parcursul anilor de cercetare au fost prezentate la Conferințe Internaționale și publicate în volumele Conferințelor (două dintre care în BDI – IEEE):

- 4th International Conference Telecommunications, Electronics and Informatics, UTM, 2012.
- 2nd International Conference on Nanotechnologies and Biomedical Engineering, Chisinau, Republic of Moldova, 2013.
- 7th International Conference Electronics, Computers and Artificial Intelligence, IEEE Conference Publications, Bucharest – Romania, Vol.7, No.2, 2015.

- International Conference on E-Health and Bioengineering, IEEE Conference Publications, 2015.

Rezultatele finale au fost prezentate la simpozionul IIVA 2016 (Information in Image and Video Analysis Theory and Applications), Academia Română, Iasi – Romania și publicate în revista:

- Computer Science Journal of Moldova, Vol.25, Nr.1(73), 2017.

Publicații la tema tezei. La tema tezei sunt publicate 10 lucrări științifice care sunt parafrazate în conținutul tezei, observându-se astfel importanța teoretică și valoarea aplicativă a lucrării.

Structura și volumul lucrării. Teza de doctor este structurată pe 3 capitole, urmate de bibliografie din 188 titluri și 3 anexe. Lucrarea conține 60 figuri, 25 tabele, text de bază – 116 pagini. Numărul de lucrări publicate la tema tezei este 10, la două dintre care sunt singur autor.

Cuvinte cheie: procesare imagini, segmentare imagini, GMM, G-U-MM, recunoaștere forme, keypoints matching, template matching, clasificare automată, sistem fuzzy, identificare semnătură.

Domeniul de cercetare este procesarea imaginilor în scopul recunoașterii și clasificării formelor/obiectelor din imagine.

CONȚINUTUL TEZEI

În **Introducere** este argumentată actualitatea temei și importanța problemei abordate. Sunt formulate scopul și obiectivele cercetării, sunt prezentate domeniul de cercetare, noutatea științifică a rezultatelor obținute și problema științifică soluționată. Sunt redate semnificația teoretică, valoarea aplicativă a lucrării și posibilități de implementare a rezultatelor științifice.

În **Capitolul 1 „Analiza situației în domeniul procesării imaginilor digitale cu scopul recunoașterii și**

clasificării automate” este prezentată o privire de ansamblu asupra domeniului de recunoaștere de forme și clasificare automată a etapelor de analiză și procesare a imaginilor în vederea clasificării automate: preprocesarea imaginilor, extragerea atributelor/descriptorilor de imagine, analiza și interpretarea rezultatelor. Din metodele de clasificare automată a imaginilor s-au abordat: clusterizarea automată a datelor, clasificatorul Bayes, SVM și rețelele neuronale artificiale. S-a prezentat importanța indicilor de performanță în aprecierea metodelor de clasificare.

Capitolul 2 „**Segmentarea imaginilor folosind modele de mixturi gaussiene și modele de mixturi uniforme-gaussiene**” conține o descriere generală a metodelor uzuale de segmentare a imaginilor și o descriere detaliată și argumentată a produsului program dezvoltat în limbajul C pentru segmentarea imaginilor bazată pe modele de mixturi uniforme și Gaussiene. Compararea cantitativă a rezultatelor obținute aplicând algoritmul GUMM cu rezultatele altor metode e bazată pe implementarea a cinci metode de evaluare a segmentării.

Descrierea algoritmului euristic de segmentare G-U-MM propus [1-3]: Ideea principală a algoritmului este de a obține o aproximare rezonabilă care ajută separarea regiunilor imaginii în funcție de statistica specifică în speranța că distribuția de probabilitate este legată, în mecanismul uman de vedere, de segmentare. De aceea, vom permite aproximări slabe, atunci când acestea păstrează numărul de segmente mic și nu afectează semnificativ regiunile atribuite segmentelor, în imagini. Unele dintre etapele algoritmului prezentate ulterior sunt bazate pe Fig. 1.

Primul pas al metodei îl constituie calcularea distribuirii nivelelor de gri în imagine – histograma, apoi nivelarea histogramei. Pentru a obține o histogramă nivelată se aplică filtrul de mediere de două ori și cel median o singură dată, utilizând o fereastră de 11 elemente și respectiv 5.

Intervalele constante se determină cu o fereastră glisantă de 24 elemente luând în calcul următoarele :

Dacă $\frac{V_{\max} - V_{\min}}{N_w} < p$ atunci intervalul este considerat

constant, unde V_{\max} și V_{\min} sunt valorile maxim și minim ale ferestrei și N_w este numărul de elemente din fereastră, iar p este indicele de comparare care e direct proporțional cu rezoluția imaginii (pentru imagini cu rezoluții mai mari se alege un indice de comparare mai mare). Pentru imaginile test de o rezoluție 170x170, $p=1.5$. Dacă două ferestre consecutive au această proprietate atunci se definește intervalul fiind egal cu lungimea a două ferestre. Altfel intervalul nu este considerat constant.

1. Se presupune intervalul $[x_1, x_2]$ fi clasificat ca "de tip nedeterminat". Se determină nivelul de gri în centrul intervalului: $h(x_1 + x_2) / 2$, în cazul în care h este funcția histogramă.

IF $h(x_1 + x_2) / 2 > h(x_1)$ AND $h(x_1 + x_2) / 2 > h(x_2)$
 THEN mergem la pasul 2, ELSE trecem la pasul 9.




Fig. 1 Fragment al histogramei

2. Găsim $x_3 = \arg \max(h(x)), x \in [x_1, x_2]$.
3. Se presupune că x_3 este vârf de Gaussiană, atunci aproximarea locală (notată cu h , ca histograma)
 $h(x) = A \cdot \exp(-(x - x_3)^2 / b)$. Prin urmare, $A = h(x_3)$.

Comentariu. Presupunerile făcute în pașii 1-3 conduc la o identificare rigidă a vârfului funcției Gauss, și, astfel, o aproximare rigidă. Este posibil ca condiția dublă (conectat cu AND) la pasul 1 să fie falsă, și intervalul corespunde unui vârf Gauss. Pasul 9 are menirea de a corecta aceste situații.

4. Se determină b_1 optimal pentru partea stângă a intervalului:

for $b = 3$ to 7200 ,

se determină eroarea aproximării pentru distribuția Gaussiană:

$$\varepsilon_{(b)}^2 = \sum_{x_i}^{x_3} (h(x) - Ae^{-(x_i - x_3)^2 / b}) .$$

Se găsește b optimal corespunzător $\arg \min \varepsilon_{(b)}^2$.

Comentarii: creșterea în buclă este 1; dispersia trebuie să nu fie un număr întreg; valorile 3 și 7200 s-au constatat empiric convenabil pentru imaginile prelucrate, dar alte limite pot fi necesare pentru alte imagini. Deoarece suma este de la x_1 la x_3 , valoarea optimă a lui b este astfel determinată, de fapt, optimizată pentru partea stângă, care reprezintă b_1 optimal.

5. Se determină eroarea și b_2 optimal pentru partea dreaptă.
6. Se determină b optimal ca media $b = (b_1 + b_2) / 2$ și eroarea totală a intervalului ca $error = error_1 + error_2$,

unde $error_1$ și $error_2$ sunt determinate la pașii 4 și 5.

Comentarii: O altă metodă de găsim a valorii optime a lui b este următoarea:

Utilizând iar $g(x) = A \cdot \exp(-(x - (x_1 + x_2) / 2)^2 / b)$, unde x_1 și x_2 sunt limitele intervalului "de tip nedeterminat", se găsește pentru partea stângă a funcției de aproximare $g(x_1) = A \cdot \exp(-(x_1 - center)^2 / b_1) = h[x_1]$, unde $center$

este x_3 . Atunci $-(x_1 - center)^2 / b_1 = \log(h[x_1] / A)$ sau
 $b_1 = -(x_1 - center)^2 / \log(h[x_1] / A)$ unde b_1 este determinat
 pentru $x = x_1$.

Similar b_2 este determinat pentru $x = x_2$:

$$-(x_2 - center)^2 / b_2 = \log(h[x_2] / A) \text{ sau}$$

$$b_2 = -(x_2 - center)^2 / \log(h[x_2] / A).$$

În final, se consideră $b = (b_1 + b_2) / 2$.

7. Se calculează eroarea

$$\varepsilon_{(b)}^2 = \sum_{x_i}^{x_3} (h(x) - Ae^{-(x_i - center)^2 / b}) \quad i = 1, 2, \text{ similar}$$

pașilor anteriori 4-6.

8. Se compară b optim determinat la pasul 6 de prima metodă cu cel stabilit pe baza erorii calculate de a doua metodă la pasul 7. Se alege b care corespunde erorii mai mici (pentru fiecare b optim se calculează erorile la etapele 6 și 7).

Comentariu. Pașii de mai sus determină și aproximează numai partea de sus (vârfurile) a Gaussienelor, porțiuni de Gaussiene care sunt detectate eronat ca „intervale uniforme”. Pentru segmentele ascendente și, respectiv descrescătoare a Gaussienelor care sunt lăsate ca „nedeterminate” la detectarea intervalelor cu DU, sunt utilizate următoarele etape.

9. Pentru intervalele declarate uniforme în prima etapă a algoritmului, atunci când acestea nu satisfac condiția de la pasul 2, se procedează după cum urmează. Folosind o fereastră cu suprapunere a câte 24 nivele de gri pe histogramă, IF media a 6 nivele de gri de la centru este mai mare decât media a 6 nivele de gri de pe stânga AND media a 6 nivele de gri de la centru este mai mare decât media a 6 nivele de gri din dreapta, THEN intervalul este Gaussian, ELSE, intervalul este considerat constant (DU). Pentru intervale noi Gaussiane, se trece la pasul 4, se

determină b optim și se calculează eroarea în funcție de pașii 4-6.

Comentariu. Următorul pas în algoritm decide dacă pixelii de la limitele intervalelor Gaussiene, aparțin intervalelor cu DU, dacă ar trebui sau nu ar trebui să fie unite la intervale G. Decizia se face pe baza erorii minime de aproximare.

10. Se incrementează cu 1 intervalul Gaussian la stânga; se calculează eroarea pentru Gaussiană și distribuție uniformă. Dacă eroarea de Gaussiană este mai mică, atunci se atașează valoarea nivelului de gri pentru intervalul Gaussian, dacă nu, rămâne în intervalul cu DU și nu se mai încearcă extinderea intervalului la stânga. Apoi, se verifică în același mod la dreapta intervalului. În cazul în care unitatea de extindere a intervalului a fost acceptată la stânga sau la dreapta, atunci se obțin și se păstrează noile Gaussiene și intervale cu DU, care sunt determinate de noile praguri de segmentare.

Mixturile hibride pot fi exprimate ca amestecuri de distribuții pe intervale disjuncte care formează o partajare a intervalului de nivele de gri [0-255]. Alternativ, ele pot fi mixturi aditive, cu distribuții suprapuse pe anumite intervale. Modelele de Mixturi Gaussiene presupun amestecuri aditive cu distribuții suprapuse pe întregul [0, 255] interval. Evident, presupunând o suprapunere totală se simplifică abordarea matematică la aproximări, dar produce convoluția funcțiilor de distribuție de probabilitate.

Pentru evaluarea rezultatelor [4] s-au folosit indicii prezentați mai jos:

- F, propusă de Liu și Yang;
- F' și Q, indici propuși de Borsotti, Campadelli și Schettini ca o îmbunătățire a funcției F;
- Criteriul de uniformitate elaborat de Levine și Nazif;

- E – indice bazat pe analiză empirică, propus de Zhang et al.




Fig. 2. Reprezentarea rezultatelor utilizând metoda de evaluare bazată pe entropie

Capitolul 3 „Algoritmi de recunoaștere și de clasificare automată a formelor/obiectelor în aplicații cu imagini digitale” conține descrierea unor metode de recunoaștere a formelor și rezultatele implementării lor.

Metoda de **separare liniară a două mulțimi de date** este descrisă în [5]. Problema separării liniare a mulțimilor este un concept important în analiza datelor. Fiind date două mulțimi de obiecte (atribute) $A = \{a^1, a^2, \dots, a^m\}$, $B = \{b^1, b^2, \dots, b^k\}$, a^i , și $b^j \in R^n$, $\forall i, j$, $A \cap B = \emptyset$, separarea (clasificarea) lor este formulată ca o problemă de programare pătratică $\left\{ \min \frac{1}{2} \gamma^T Q \gamma : B \gamma = e, \gamma \geq 0 \right\}$ cu o alegere judicioasă a matricei pozitiv semidefinite $Q \in R^{(m+k) \times (m+k)}$ și a vectorului $e(1, 1, \dots, 1)^T \in R^{m+k}$. S-a propus reformularea condițiilor de optimalitate Karush-Kuhn-Tucker pentru problema de programare pătratică într-un sistem echivalent de ecuații neliniare (cubice) netede, utilizând funcțiile de tipul $p(x) = x^2 \max(0, x)$ și $q(x) = -x^2 \min(0, x)$. Sistemul de ecuații astfel obținut poate fi rezolvat numeric eficient cu ajutorul metodei Newton.

Metoda de clasificare automată propusă în lucrarea [6] include patru pași de bază. La primul pas se identifică, dacă există, simbolul de pericol pe etichetă cu ajutorul *Coeficientului de Corelație Normalizat* (CCN) și a unui *Algorithm Genetic* (AG). Dacă eticheta conține unul din simbolurile de pericol ambalajul este considerat periculos și este scos de pe banda ambalajelor pentru reciclare. Pasul 2 constă în extragerea caracteristicilor ambalajelor și include un algoritm de urmărire a conturului și un algoritm de extragere a semnăturii (distanța dintre centroid și contur). La această etapă se aplică operatorii morfologici: dilatarea și erodarea pentru a obține o formă completă (fără găuri) și se calculează perimetrul și aria formei. Un alt parametru al sistemului fuzzy: simetria formei este determinată pe baza semnăturii. Pasul 3 include un sistem de decizie cu logica fuzzy, care pe baza variabilelor de intrare fuzzy: formă, dimensiune, simetrie grupează ambalajele în trei clase: reciclabil, periculos și nedeterminat. La pasul 4 pe baza funcției diferență a semnăturilor se confirmă sau se infirmă decizia luată la pasul anterior.

Metoda hibridă (CCN și AG) permite depistarea simbolurilor de pericol de pe etichetă cu o rată foarte mare de reușită [7-8]. Prima etapă a metodei constă în aplicarea coeficientului de corelație, a doua – implementarea algoritmului genetic pentru generarea de noi valori pentru rotire și scalare. Reluarea etapelor are loc până se găsește soluția optimă sau numărul de încercări a fost depășit. AG reduce pașii de calcul ajungând la un rezultat optim într-un interval de timp rezonabil.

Informația pe care o conține fiecare individ din populație se referă la scalarea și rotația aplicată șablonului. Se consideră că scalarea șablonului are limitele impuse între $[1/3, 3]$ ceea ce implică faptul că în procesul de potrivire șablonul poate fi deformat micșorând respectiv măbind dimensiunea lui inițială de 3 ori. Gradul de rotație este în intervalul $[0, 359]$.

Algoritmul genetic pentru identificarea automată a șabloanelor are următorul pseudo-cod:

Pasul 1: Inițializarea populației;

Pasul 2: Calculul fitness populație și ordonarea indivizilor în funcție de performanțe;

Pasul 3: Se păstrează cel mai bun individ. Dacă acesta nu s-a schimbat timp de un număr predefinit de generații atunci algoritmul se oprește (Pasul 7);

Pasul 4: Aplicarea operatorilor genetici (mutație și încrucișare / crossover);

Pasul 5: Înlocuirea indivizilor din populația curentă cu cei nou generați;

Pasul 6: Dacă s-a ajuns la un număr maxim de iterații / generații algoritmul se oprește, altfel se revine la Pasul 2;

Pasul 7. Se afișează cea mai bună potrivire a șablonului dată de cel mai bun individ.

Procesul de extragere a caracteristicilor formelor cuprinde următoarele etape:

- binarizare imagine, segmentare folosind un prag pe histogramă;
- aplicare operatori morfologici: dilatare, erodare;
- implementarea unui algoritm de urmărire contur;
- implementarea unui algoritm de extragere semnătură;
- determinare formă, dimensiune, simetrie.

O semnătură este o reprezentare a unei suprafețe care poate fi generată în mai multe moduri, s-a ales de a trasa **distanța dintre centroid** (media coordonatelor x și y ale tuturor pixelilor de pe contur) și **contur**.

Definirea mulțimilor fuzzy pentru variabile de intrare. Fuzificarea intrărilor constă în determinarea gradului în care datele de intrare aparțin mulțimilor fuzzy, prin funcția de apartenență.

Variabila de intrare *Dimensiune* se definește prin patru mulțimi fuzzy trapezoidale: Mica, Medie, Mare și FoarteMare),

având ca univers de discurs intervalul $[0, 0.5]$. Se consideră că obiectele de dimensiune foarte mare pot ocupa maxim 50% din spațiul de vizualizare, de unde și limita superioară a universului de discurs. Un obiect de dimensiune mare ocupă circa 10%-15% din spațiul de vizualizare..




Fig. 3. Mulțimile fuzzy pentru variabila de intrare *Dimensiune*

Conform Fig.3, atunci când un obiect ocupă între 15% și 20% din spațiul de vizualizare acesta poate fi considerat ca aparținând și mulțimii fuzzy „mare” și mulțimii fuzzy „foarte mare” dar cu grade de apartenență diferite.




Fig. 4. Mulțimile fuzzy pentru variabila de intrare *Forma*

Variabila de intrare *Simetrie* se definește prin trei mulțimi fuzzy trapezoidale: Mica, Medie și Mare. Este exprimată pe baza corelației dintre semnătura normalizată a obiectului pe intervalele $[0,90]^\circ$, $[90,180]^\circ$, $[180,270]^\circ$, $[270,360]^\circ$.

Mulțimile fuzzy pentru variabila de intrare *Simetrie* sunt reprezentate în Fig. 5.




Fig. 5. Mușimile fuzzy pentru variabila de intrare *Simetrie*

Definirea mușimilor fuzzy pentru variabile de ieșire

Sistemul fuzzy clasifică deșeurile în trei clase: *periculoase* (toxice, inflamabile, dăunătoare mediului), *reciclabile* și *nedeterminate*.

Variabila de ieșire *TipObiect* se definește prin mușimi fuzzy ca în Fig.6, creând astfel un sistem de tip Mamdani. Funcțiile de apartenență triunghiulare, au baza triunghiului de valoare mică (simbolică), din acest motiv sistemul poate fi considerat mai apropiat de un sistem fuzzy de tip Sugeno.




Fig. 6. Reprezentare ieșiri fuzzy

Alegerea tipului sistem Mamdani și nu Sugeno este dată de funcția de defuzificare de tip MoM (Moment of Maximum). Valorile bazei celor trei mușimi fuzzy se aleg astfel: in jur de valoarea 0 pentru Periculos, ~ 0.5 pentru Nedeterminat și ~1 pentru Reciclabil.

Regulile de inferență sunt acele reguli care leagă variabilele fuzzy de intrare a unui sistem cu variabile fuzzy de ieșire a aceluiași sistem. Aceste reguli sunt prezentate sub

forma: DACĂ condiție / premisa1 ȘI / SAU condiție/premisa2 (ȘI / SAU ...), ATUNCI acțiune. Totalitatea regulilor formează baza de reguli, numită și baza de cunoștințe.

Exemple de reguli de inferență aplicate:

IF *Forma* alungita and *Dimensiune* Mica and *Simetrie* Mare then Tip Obiect is Periculos (1)

IF *Forma* alungita and *Dimensiune* Medie and *Simetrie* Mare then TipObiect is Periculos (1)

IF *Forma* alungita and *Dimensiune* Mica and *Simetrie* Medie then TipObiect is Periculos (0.7)

IF *Forma* alungita and *Dimensiune* Medie and *Simetrie* Mica then TipObiect is Nedeterminat (1)

IF *Forma* alungita and *Dimensiune* Mica and *Simetrie* Mica then TipObiect is Nedeterminat (1)

IF *Forma* alungita and *Dimensiune* FoarteMare and *Simetrie* Mare then TipObiect is Nedeterminat (1) etc.

Intersecția a două mulțimi fuzzy este echivalentă cu operația “ȘI logic”, reprezentând minimumul dintre două grade de apartenență. Între premisele regulilor se aplică operatorul „min”, valoare rezultată fiind folosită la trunchierea variabilei de ieșire. Atunci când avem mai multe reguli active se aplică o reuniune a mulțimilor fuzzy trunchiate rezultate la aplicare fiecărei reguli.

Sistemul fuzzy de detecție a tipului de ambalaj aplică la defuzificare operatorul de MOM, selectează din mulțimile fuzzy active doar pe cea cu grad de apartenență maxim.

Randamentul acestui sistem este de 95%. Unele ambalaje din grupa *Nedeterminate* au fost identificate ca *Periculoase*. Un procent din ambalajele *Periculoase* au fost clasificate *Nedeterminate* și ~1.5% din *Reciclabile* a fost clasificat greșit la *Nedeterminate*. Important este ca aceste ambalaje să nu fie clasificate drept *Reciclabile*, dar pentru asigurarea unei clasificări automate corecte, obiectele din clasa *Reciclabile* sunt verificate la etapa următoare prin identificarea semnăturii forme.

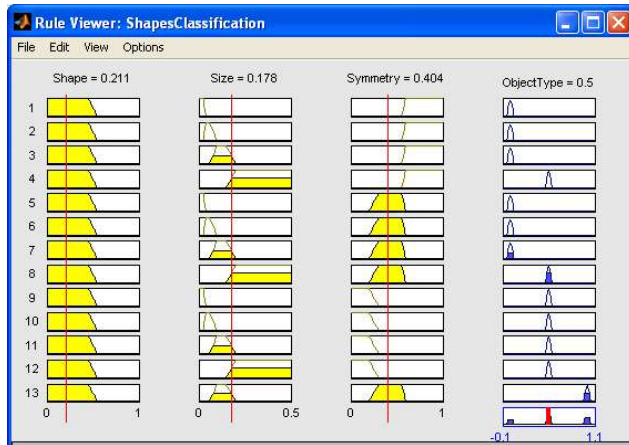


Fig. 7. Exemplu de defuzificare

Identificarea formei prin semnături. Baza de date conține semnăturile tuturor formelor (reciclabile, nedeterminate și periculoase) pentru a putea fi identificat un obiect nereciclabil dacă a fost clasificat greșit. Au fost testate și obiecte care nu sunt incluse în BD, rezultatul e satisfăcător, s-a obținut un randament de recunoaștere de 97%.

Sistemul fuzzy vs. metoda de clasificare kNN. Atât sistemul fuzzy, cât și algoritmul kNN (cu numărul de vecini $k=1$ și $k=2$) au o acuratețe de clasificare de peste 90%. ~1.5% din reciclabile a fost clasificat greșit de ambele metode la nedeterminate, ~3% din nedeterminate au fost clasificate – periculoase, iar knn a clasificat ~3% din ambalajele periculoase drept nedeterminate. ~1.5% ambalaje din clasa periculoase algoritmul kNN clasifică ca reciclabile, dacă nu ar urma un pas de verificare, ar fi o eroare cu consecințe neadmisibile.

Pentru un set de 63 obiecte, Sistemul Fuzzy a avut un F-score de 94%, pe când kNN pentru $k=1$ și $k=2$ a avut un F-score de 87%. Odată cu creșterea valorii k , acuratețea și F-scorul descrește.

Tabelul 1. Evaluarea performanței sistemului Fuzzy și kNN

Metrică	Fuzzy	kNN
Acuratetea	95,24%	90,48%
Rata de eroare	4,76%	9,52%
Precizia	88,89%	90,91%
Recall	100,00%	83,33%
Fscore	94,12%	86,96%

Sistemul elaborat poate fi adaptat și la sortarea altor obiecte. S-a ales sortarea deșeurilor pentru a accentua faptul că trierea lor corectă ar fi o soluție pentru diminuarea poluării, un factor important în zilele noastre.

CONCLUZII GENERALE ȘI RECOMANDĂRI

Sintetizând munca din perioada cercetării pot fi prezentate următoarele rezultate științifice:

1) S-a elaborat un algoritm de segmentare bazat pe G-U-MM.

Au fost analizate mai multe metode de segmentare. S-a elaborat un algoritm de segmentare bazat pe Modelul de Mixturi Gaussiene și Uniforme (G-U-MM). În conformitate cu faptul că histograma imaginii poate fi utilizată pentru a reprezenta caracterul statistic al funcției densitate de probabilitate, G-U-MM este folosit pentru a estima PDF a imaginii cu nivele de gri (poate fi adaptat și la imagini color). Pragurile optime au fost determinate ca limitele intervalelor normale și uniforme de pe histogramă. A fost prezentată o explicație detaliată pentru rațiunea modelelor de mixturi Gaussiene și uniforme propuse ca un fundament al procesului de segmentare. Rezultatele experimentale arată că metoda propusă poate obține rezultate mai bune și este mai robustă.

Majoritatea metodelor cunoscute de segmentare necesită introducerea de către utilizator a unor parametri, de obicei numărul de segmente dorit. În cazul segmentării bazate pe histogramă acestea ar putea fi numărul de maxime

gaussiene, în cazul unui algoritm de clusterizare – numărul de centroizi, ceea ce înseamnă de fapt indicarea a câte obiecte sunt reprezentate în imagine. S-a optat pentru o metodă de segmentare mai robustă, adică are loc detectarea automată a numărului de segmente (a pragurilor pe histogramă) utilizând cunoștințe despre obiecte precum intensitatea pixelilor.

2) S-a făcut o analiză comparativă a algoritmilor de segmentare și a rezultatelor obținute, demonstrând eficacitatea algoritmului propus. Pentru a putea aprecia calitatea rezultatelor obținute, au fost calculate unele funcții propuse pentru evaluarea cantitativă și au fost comparate rezultatele cu unele din literatură considerate drept referință: metoda Otsu și metoda bazată pe histogramă (se determină vârfurile Gaussienelor – maxime globale, iar pragurile sunt determinate ca minimumul între două vârfuri Gaussiene).

Estimarea obiectivă a calității segmentării poate fi elaborată doar în cazul când numărul de segmente este același. Analizând graficele prezentate în capitolul doi se poate confirma că rezultatele obținute sunt apropiate celor două metode de referință, rezultând astfel eficacitatea segmentării, respectiv cea a algoritmului.

3) S-a făcut o analiză a metodelor de extragere a punctelor de interes și de corelare a lor: SIFT și ASIFT, cât și a algoritmului Template Matching observând avantajele și dezavantajele fiecărei metode. Primele două metode reprezintă algoritmi complecși de recunoaștere a imaginilor pe baza potrivirii punctelor de interes.

4) A fost îmbunătățit algoritmul Template Matching prin completarea programului cu un algoritm genetic pentru generarea a noi valori folosite de coeficientul de corelație normalizat (CCN) la potrivirea imaginii cu un șablon. A fost implementată această metodă hibridă pentru a elimina problemele observate la rotire, scalare folosind doar CCN. Coeficientul de corelație determină potrivirea sau nu a două imagini, iar algoritmul genetic generează noi dimensiuni ale

imaginii căutate de la $1/3$ până la 3.0 și cu valori pentru rotire de la 1 până la 359 grade.

5) A fost propusă o îmbunătățire a implementării metodei de clasificare automată SVM. S-au abordat trei modele ale separării liniare. Pentru unul din aceste modele s-a propus reformularea condițiilor de optimalitate Karush-Kuhn-Tucker pentru problema de programare pătratică într-un sistem echivalent de ecuații neliniare (cubice) netede.

6) A fost elaborat un sistem de recunoaștere și clasificare automată a formelor bazat pe logica fuzzy. Etapele de recunoaștere se completează, dând astfel un randament mare de reușită. Pe un set de 63 de imagini, s-a obținut o acuratețe de 95%. S-a propus o etapă de verificare a rezultatelor clasificării prin identificarea semnăturii.

Pașii sistemului și rezultatele preliminare au fost prezentate la simpozionul *Information in Image and Video Analysis Theory and Applications* (IIVA) 2016, Iasi- Romania.

Sistemul poate fi adaptat ușor și pentru alte forme decât cele din lucrare.

7) S-au comparat rezultatele obținute la fiecare etapă a procesării imaginilor cu metode respective de referință (segmentare, recunoaștere forme). Rezultatele recunoașterii imaginii, aplicând algoritmul hibrid – Coeficientul de Corelație Normalizat (CCN) + Algoritm Genetic –, au fost comparate cu rezultatele obținute la recunoașterea imaginii utilizând doar CCN, demonstrându-se astfel avantajul algoritmului hibrid. În comparație cu rezultatele metodelor SIFT și ASIFT, algoritmul hibrid dă rezultate satisfăcătoare chiar și atunci când rezoluția imaginii este mică și când imaginile sunt asemănătoare, dar nu identice.

Rezultatele obținute în urma clasificării au o acuratețe a algoritmului de 95%. Algoritmul de referință kNN, pentru $k=1$ și $k=2$ are o acuratețe de 90.5%, care scade odată cu creșterea numărului de vecini (k). Sistemul Fuzzy elaborat are un F-

score de 94%, pe când kNN pentru $k=1$ și $k=2$ are un F-score de 87%.

Observații generale în urma cercetărilor efectuate:

1) metodele de procesare se aleg în dependență de setul de imagini și informația ce necesită extrasă;

2) este dificil de apreciat rezultatele segmentării (compararea cu un șablon segmentat manual este minuțioasă și necesită timp);

3) clasificarea automată (nesupravegheată) a produselor în timp real (sau chiar mai rapid decât ar face o persoană) e posibilă doar pentru un număr redus de forme sau de același tip dar cu anumite defecte.

Direcții de cercetare pentru viitor. Ca viitoare direcții de cercetare se propune îmbunătățirea abordărilor prezentate în teză, extinderea evaluărilor algoritmilor elaborați și investigarea sau dezvoltarea altor metode și modele în recunoașterea formelor.

Direcțiile viitoare de cercetare ar fi următoarele:

1) cercetarea posibilității de a simplifica pașii algoritmului de recunoaștere a simbolurilor de pericol prin recunoașterea textului și ștergerea lui de pe etichetă, rămânând astfel doar simbolurile de atenționare. Acest algoritm ar putea fi implementat și la detectarea logourilor de pe un document;

2) implementarea unui sistem hibrid GA Fuzzy pentru identificarea altor obiecte decât cele existente în BD;

3) aplicarea logicii Fuzzy și în alte domenii decât procesarea imaginilor.

LISTA LUCRĂRILOR PUBLICATE LA TEMA TEZEI

1. Teodorescu HN., **Rusu M.**, “Yet Another Method for Image Segmentation based on Histograms and Heuristics”, Computer Science Journal of Moldova, vol.20, no.2(59), pp. 163-177, 2012
2. Teodorescu HN., **Rusu M.**, “Image Segmentation Based on G-UN-MMs and Heuristics - Theoretical Background and

- Results –” Proceedings of the Romanian Academy, Series A, Vol. 14, No. 1/2013, pp. 78–85, 2013
3. Teodorescu HN., **Rusu M.**, Improved Heterogeneous Gaussian and Uniform Mixed Models (G-U-MM) and Their Use in Image Segmentation, Romanian Journal of Information Science and Technology, Volume 16, Number 1, 2013, pp. 29-51
 4. **Rusu M.**, „Thresholding methods and quantitative evaluation of results”, Meridian Ingineresc, No. 2, pp. 18-25, 2013
 5. Moraru V., **Rusu M.**, „Algorithm for linear pattern separation”, Meridian Ingineresc, No. 2, pp. 26-29, 2013
 6. **Rusu M.**, Zbancioc M.-D., Fuzzy Rule-based System for Pattern Recognition and Automated Classification, Computer Science Journal of Moldova, Vol. 25, No. 1(73), pp. 88-107, 2017
 7. **Rusu M.**, Zbancioc M.-D., Automated identification of objects based on Normalized Cross-Correlation and Genetic Algorithm, IEEE Int. Conf. on E-Health and Bioengineering, Iasi, Romania, 4 p., 2015
 8. **Rusu M.**, „Computerized visual inspection applied to identification and classification of labeled chemicals”, International Conference 7th Edition Electronics, Computers and Artificial Intelligence, IEEE Conference Publications, Bucharest – Romania, Vol. 7, No. 2, 6p., 2015
 9. **Rusu M.**, Horia-Nicolai L. Teodorescu, “A Method for Image Segmentation based on Histograms – Preliminary Results”, 4th International Conference Telecommunications, Electronics and Informatics, pp.351-354, UTM, 2012
 10. **Rusu M.**, Teodorescu HN., „Quality Analysis of Image Segmentation based on G-UN-MMs”, 2nd International Conference on Nanotechnologies and Biomedical Engineering, Chisinau, pp. 620-624, April 18-20, 2013.

ADNOTARE

la teza „Analiză și recunoaștere de forme pentru aplicații cu imagini digitale”, prezentată de către Rusu Mariana pentru conferirea gradului științific de doctor în informatică, Chișinău 2019

Teza de doctor este structurată pe 3 capitole, urmate de bibliografie din 188 titluri și 4 anexe. Lucrarea conține 60 figuri, 25 tabele, text de bază pe 116 pagini. Rezultatele obținute sunt publicate în 10 lucrări științifice.

Cuvinte cheie: procesare imagini, GMM, GUMM, recunoaștere forme, coeficient de corelație, template matching, clasificare automată.

Domeniul de cercetare: analiza și recunoașterea formelor în aplicații cu imagini digitale.

Scopul lucrării constă în elaborarea unor metode, algoritmi ce ar permite recunoașterea și clasificarea automată a formelor/obiectelor din imagini digitale.

Obiectivele lucrării: implementarea și elaborarea algoritmilor de procesare a imaginilor în scopul recunoașterii și clasificării formele în aplicații cu imagini digitale și realizarea unei comparații obiective a algoritmilor implementați.

Noutatea și originalitatea științifică: Au fost identificate și argumentate: un algoritm euristic de segmentare, o metodă de separare liniară a două mulțimi de date și o metodă hibridă de recunoaștere și clasificare a formelor.

Problema științifică și de cercetare soluționată constă în elaborarea unei metode de segmentare bazată pe histogramă ce nu necesită indicarea numărului de praguri. S-a descris un model matematic de separare liniară a două mulțimi de date. S-a elaborat un sistem de clasificare automată care unește diverși algoritmi din inteligența artificială (algoritm genetic, sistem fuzzy) și definește combinația particulară care poate oferi o mai bună soluție pentru clasificarea automată a formelor/obiectelor.

Semnificația teoretică și valoarea aplicativă a lucrării constă în elaborarea algoritmului de segmentare bazat pe GUMM, a modelului de separare liniară, a metodei de clasificare automată bazat pe logica fuzzy și algoritmi de identificare/recunoaștere a imaginilor bazați pe coeficientul de corelație. Algoritmul de segmentare propus poate fi implementat și la alte tipuri de imagine, la fel și metoda hibridă formată din CCN și AG. Metodele de recunoaștere automată propuse pot fi readaptate și la alte seturi de forme.

ABSTRACT

to thesis „Analysis and pattern recognition for applications with digital images”, presented by Rusu Mariana for conferring a PhD Degree in Computer Science, Chisinau, 2019.

The thesis is divided into three chapters, followed by bibliography of 188 titles and 4 appendices. The paper contains 60 figures, 25 tables, 116 pages of basic text. The number of published papers on the topic of thesis is 10.

Keywords: image processing, GMM, G-U-MM, forms recognition, correlation, template matching, automatic classification.

Field of research is image processing in order to pattern/objects recognition and detection in the image.

The purpose of this paper is to develop methods, algorithms that would allow the recognition and automatic classification of forms / objects in digital images.

The objectives are to analyze, implement and develop image processing algorithms for recognition of forms for digital images applications and make an objective comparison of implemented algorithms.

Scientific novelty and originality of the results: there were identified and justified an heuristic segmentation algorithm, a linear separation method for two data sets and a hybrid method of automatic classification of forms / objects.

The theoretical importance consists in the development of a histogram-based segmentation method that does not require to indicate the number of thresholds. A mathematical model of linear separation of two sets data has been described. An automatic classification system has been developed that combines different algorithms from artificial intelligence (genetic algorithm, fuzzy system) and defines the particular combination that can provide a better solution for templates / objects classification.

The applied value of the thesis: it demonstrated the practical effectiveness of of the proposed segmentation algorithm and the advantage of the hybrid method CCN + AG against the application of individual CCN. Also has been shown effectiveness and advantages of automatic sorting system.

The research results can be applied to automatic classification of waste, this area was chosen to emphasize that them correctly sorting would be a solution for reducing pollution. The system can be adapted and developed to classify other objects.

АННОТАЦИЯ
диссертации на соискание ученой степени доктора наук
в информатике
„Анализ и распознавание форм для приложений с
цифровыми изображениями”,
автор: Русу Мариана, Кишинэу, 2019.

Диссертация состоит из 3 глав, а также последующей биографией содержащей 188 названий и 4 приложения. Диссертация содержит 60 фигур, 25 таблиц, главное текстовое содержание – 116 страниц. Количество опубликованных работ на данную тему – 10.

Ключевые слова: обработка изображений, сегментация изображений, распознавание форм, идентификация подписи, извлечение ключевых точек, сопоставление шаблонов, GMM, G-U-MM, автоматическая классификация.

Область исследования – обработка изображения с целью распознавания форм.

Цель работы состоит в разработке способов и алгоритмов для распознавания и автоматической классификации предметов/форм из изображения.

Задачи работы: анализ, проектирование и разработка алгоритмов обработки изображений с целью распознавания форм для приложений с цифровыми изображениями.

Инновационность и оригинальность работы: были идентифицированы и аргументированы эвристический алгоритм сегментации, метод линейного разделения двух наборов данных, а также гибридный метод автоматической классификации форм/ объектов.

Теоретическая значимость заключается в разработке метода сегментации на основе гистограммы, который не требует указания количества порогов и гибридный метод автоматической системы классификации,

который объединяет различные алгоритмы из искусственного интеллекта (генетический алгоритм, нечеткая система) и определяет конкретную комбинацию которая может обеспечить лучшее решение для автоматической классификации форм / объектов.

Практическая значимость работы было доказано эффективность предлагаемого алгоритма сегментации, преимущество гибридного метода CCN+AG в сравнении с индивидуальным применением CCN. Также было продемонстрирована эффективность и преимущества системы автоматической классификации.

Результаты исследования могут быть использованы для автоматической сортировки отходов. Таким образом, правильное применение результатов исследования для сортировки отходов может снизить загрязнение среды. Разработанная система может быть приспособлена и для классификации других объектов.

RUSU MARIANA

**Analiză și recunoaștere de forme pentru
aplicații cu imagini digitale**

**122.03 – MODELARE, METODE
MATEMATICE, PRODUSE PROGRAM**

Autoreferatul tezei de doctor

Aprobat spre tipar: 09.04.19

Hârtie ofset. Tipar ofset.

Coli de tipar.: 2,0

Formatul hârtiei 60x84 1/16

Tiraj 50 ex.

Comanda nr. 39

UTM, 2019, Chișinău, bd. Ștefan cel Mare, 168

Editura „Tehnică UTM”,

MD 2045, mun. Chișinău, str. Studenților 9/9

@U.T.M. 2019

