

Metode de prelucrare a imaginilor

Preparator **Claudia Mihaela Mark**
Universitatea “Tibiscus” din Timișoara

ABSTRACT: In this paper is presented image processing concept and methods. Image processing, analysis and machine vision represents an exciting part of modern cognitive and computer science, which man kind has started to use for his own benefit. The methods presented here are the methods that are used today in image processing.

1 Generalități

Utilizarea pe scară largă a computerelor digitale în procesarea informației a dus la concepția greșită că atât informația cât și procesarea ei sunt dependente de acestea. Deoarece procesarea informației își are originea în modul de prelucrare a datelor de către creierul uman putem considera și posibilitatea procesării informației de către dispozitive diferite de computerele convenționale.

Prelucrarea (digitală) a imaginilor reprezintă un domeniu foarte larg, de sine stătător. Acest domeniu are la bază o teorie matematică riguroasă, bine pusă la punct, dar în general implementările pe diverse mașini de calcul sunt destul de mari consumatoare de resurse (putere de calcul, memorie), în special dacă ne referim la utilizarea în timp real a informațiilor extrase din imagini.

Într-un sens cât mai general, o imagine este o descriere a variației unui parametru pe o suprafață. De exemplu, imaginile (în sensul clasic) sunt rezultatul variației intensității luminii într-un plan bidimensional. Dar acest parametru nu este singurul folosit; de exemplu o imagine poate fi generată de temperatura unui circuit integrat, emisiile de radiații (cu diverse lungimi de undă) ale unor galaxii etc. Însă aceste tipuri de imagine sunt, de obicei, convertite în imagini clasice (prin pseudocolorare de exemplu) pentru ca

operatorul uman să poată face o evaluare vizuală a variației unor parametri. Din aceste considerente, pe parcursul lucrării toate referirile se vor face la imagini în sensul clasic.

O imagine este deci un semnal bidimensional; prin urmare prelucrarea imaginilor poate fi considerată și o ramură a prelucrării digitale de semnal (care mai include prelucrarea audio, telecomunicații etc.). După cum s-a menționat anterior, prelucrarea de imagine și în general prelucrarea digitală a semnalelor presupune un consum relativ mare de resurse de calcul și memorie. Implementarea algoritmilor specifici se poate face pe sisteme clasice (PC-uri, evoluția microprocesoarelor oferă puterea de calcul necesară), dar pentru sistemele dedicate, de timp real, se folosesc în general procesoare dedicate numite procesoare digitale de semnal (DSP = Digital Signal Processing). Aceste tipuri de procesoare au implementate hardware diverse optimizări și paralelisme pentru a oferi puterea de calcul necesară (de obicei la frecvențe mult mai mici decât microprocesoarele clasice); evident ele presupun și un consum mai mic de energie față de microprocesoare.

Prelucrarea imaginilor include mai multe discipline:

- preluarea, compresia și stocarea imaginilor;
- restaurarea și ameliorarea imaginilor prin corecții geometrice, radiometrice, ajustări de contrast, filtrarea zgomotului etc;
- fotogrammetrie, adică măsurători ale unor obiecte, fenomene făcute pe baza unor imagini;
- recunoașterea formelor (pattern matching, shape recognition, face recognition);
- vederea artificială (computer vision, robot vision);
- inteligența artificială;
- sinteza de imagini, imagini generate de calculator;

Inteligența artificială și prelucrarea imaginilor sunt domenii ce se întrepătrund. Un număr important din algoritmi performanți folosiți la prelucrarea imaginilor utilizează metode și tehnici din domeniul inteligenței artificiale: rețele neuronale, logica fuzzy. Pe de altă parte, inteligența artificială presupune proiectarea și construirea de sisteme capabile să realizeze funcții ale intelectului uman: învățarea prin experiență, înțelegerea limbajului natural, utilizarea unui raționament pentru rezolvarea unor probleme sau luarea unor decizii. Toate acestea presupun însă și acumularea unei anume cantități de informație (baza de cunoștințe, informații din mediu etc.).

Această informație este preluată de sistemele inteligente prin senzori și crează o imagine a mediului în momentul preluării datelor (snapshot). Din imaginea astfel obținută trebuie extrase informațiile utile.

Toate acestea țin de domeniul vederii artificiale (Computer Vision, Robot Vision); este o disciplină comună atât prelucrării de imagine cât și inteligenței artificiale și încearcă să răspundă la următoarele întrebări:

- ce informație trebuie extrasă din imaginile preluate?
- cum poate fi extrasă această informație?
- cum se reprezintă aceasta?
- cum poate fi utilizată pentru atingerea unui scop anume?

Domeniul prelucrării de imagini este dinamic; el a fost foarte bine sintetizat de către Pavlidis în [PAV82]:

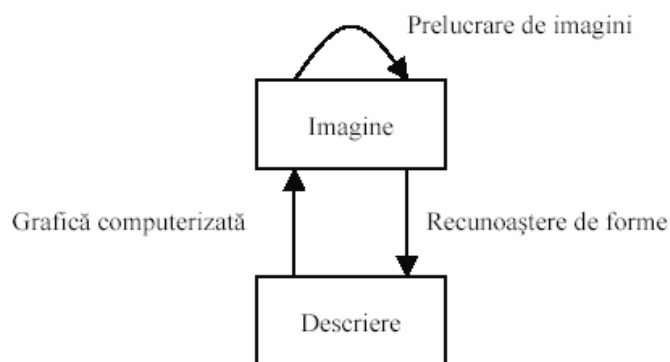


Figura 1.1. Domeniul prelucrării imaginilor

O structură generală a unui sistem de vedere artificială este descrisă în figura 1.2:




Figura 1.2. Structura generală a procesului

2 Achiziția imaginilor

Imaginile sunt formate prin înregistrarea de către un senzor a radiației ce reacționează cu un obiect fizic. Astfel imaginile sunt de mai multe tipuri,

cum ar fi: fotografie (lumina reflectată), distanțe, imagini în infraroșu. Un sistem (digital) de achiziție a imaginilor se compune din:

- un sistem optic (lentile, diafragmă);
- un senzor propriu-zis (CCD de obicei);
- un eventual etaj de amplificare și filtrare a semnalului de la senzor (informația este încă analogică);
- un convertor analog-numeric.

Toate aceste subsisteme influențează direct imaginea achiziționată în sensul că pot introduce diverse tipuri de distorsiuni. Un element foarte important în sistemul de achiziție a imaginii este subsistemul optic (parametri: tipul lentilelor, distanța focală, adâncimea de câmp): un sistem optic greșit proiectat sau utilizat duce la obținerea unor informații eronate. Unele din aceste erori pot fi însă corectate ulterior în blocul de preprocesare (corecții geometrice, ajustări de contrast).

Caracteristica ieșirii senzorului are forma din figura 2.1:

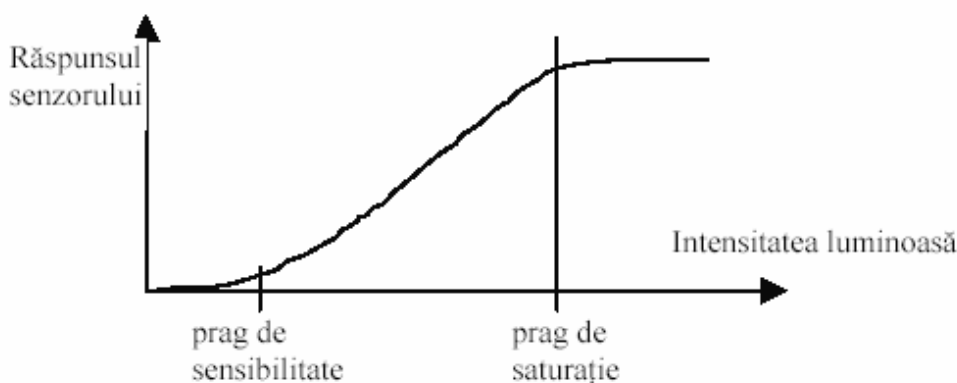


Figura 2.1. Caracteristica de ieșire a senzorului

După cum se observă, această caracteristică este neliniară, dar între cele două praguri ea poate fi considerată ca fiind liniară. Dacă intensitatea luminoasă este sub pragul de sensibilitate al senzorului, acesta nu o va sesiza și imaginea nu va fi preluată corect.

Celelalte două etaje ale sistemului de achiziție a imaginii pot influența și ele rezultatul achiziției (amplificatoarele au caracteristici liniare sau se pot satura, alegerea incorectă a convertorului poate duce la pierderea unor informații).

Trebuie de reținut însă că sistemul de achiziție a imaginii este o componentă esențială a lanțului de prelucrare de imagine și în proiectarea acestuia trebuie ținut cont de o serie de parametri:

- Parametri optici:
 - ◆ tipul lentilelor;
 - ◆ distanța focală;
 - ◆ adâncimea de câmp;
- Parametri fotometrici:
 - ◆ tipul, direcția și intensitatea iluminării;
 - ◆ proprietățile de reflecție a obiectelor analizate;
 - ◆ caracteristica ieșirii fotoreceptorului;
- Parametri geometrici:
 - ◆ tipul proiecției;
 - ◆ distorsiunile de perspectivă;
 - ◆ poziția și orientarea senzorului.

În final, sistemul de achiziție produce o imagine digitală, de fapt un tablou bidimensional, iar valorile din acest tablou pot reprezenta intensitatea luminii, distanțe sau alte mărimi fizice.

3 Clase de imagini

Pavlidis a propus o clasificare a imaginilor în patru clase:

- clasa 1 - include imagini color sau în niveluri de gri (televiziune, fotografie);
- clasa 2 - imagini binare (în două culori);
- clasa 3 - cuprinde imagini formate din linii și curbe continue;
- clasa 4 - include imagini compuse din puncte izolate și poligoane;

Această clasificare are în vedere și complexitatea imaginilor; o dată cu numărul clasei scade complexitatea imaginii și, implicit, volumul de date necesar stocării lor.

De exemplu, o imagine de clasa 1 poate fi o imaginea unui obiect oarecare (fotografie). Aceasta în urma unei operații de binarizare (ce va fi descrisă ulterior) va rezulta o imagine de clasă 2. Prin aplicarea unor algoritmi de extragere de contur sau a unor operatori morfologici (dilatare, eroziune) se obține o imagine de clasă 3. În final, prin extragerea punctelor critice, a zonelor de interes se va forma o imagine din ultima clasă.

4 Prelucrări grafice

Prin prelucrări grafice ne referim la operațiile de preprocesare ce se efectuează asupra imaginilor achiziționate. Aceste operații au rolul de a elimina zgomotele sau informațiile inutile din imagine sau sunt operații de restaurare.

Astfel de prelucrări sunt necesare pentru a îmbunătăți atât timpii de execuție cât și rezultatele diversilor algoritmi (clasificare, recunoaștere forme, recunoaștere fețe umane etc.).

4.1 Filtrarea

Operația de filtrare este utilizată pentru eliminarea zgomotelor și la evidențierea muchiilor. În general se folosesc următoarele trei tipuri de filtre:

- filtru *trece-jos*: utilizat pentru eliminarea zgomotelor; spectrul imaginii este uniformizat;
- filtru *trece-bandă*: folosit de obicei pentru prelucrarea imaginilor provenite din teledetecție (imagini preluate din satelit, avion etc);
- filtru *trece-sus*: este utilizat pentru evidențierea conturilor datorită comportării de derivator.

Observație: Prin analogie cu semnalele unidimensionale (un parametru ce variază în timp), imaginile reprezintă semnale bidimensionale (un parametru ce variază pe o suprafață) și pot fi descompuse în sume de semnale sinusoidale.

Deci aplicându-se transformata Fourier bidimensională se obține spectru imaginii. Astfel noțiunile referitoare la filtrare și la analiza spectrală valabile pentru semnalele unidimensionale sunt valabile (evident cu anumite modificări datorate naturii semnalelor bidimensionale) și pentru imagini.

4.2 Restaurarea imaginilor

La ieșirea blocului de achiziție a imaginilor, rezultatul poate fi o distorsionată, distorsiuni ce se datorează unor fenomene fizice cunoscute. O posibilă sursă de distorsiuni este sistemul optic. Imaginile achiziționate pot prezenta distorsiuni de tip perna sau butoi sau trapez.

Aceste erori se pot corecta printr-o operație de reeșantionare: pentru aceste tipuri de distorsiuni geometrice se pot determina relațiile

matematice necesare corecției și folosind aceste relații, se calculează valoarea fiecărui eșantion (pixel) din noua imagine pe baza unui număr de eșantioane din imaginea distorsionată. De asemenea, tot datorită sistemului optic, imaginile pot avea iluminări diferite pe porțiuni.

Unui punct luminos îi corespunde pe suprafața senzorului un cerc luminos, numit cerc de confuzie (se datorează lentilelor). Pentru obiectivele normale, acest cerc este uniform. Dar există producători de sisteme optice care, din diferite motive (creștere aparentă a rezoluției etc.) produc obiective subcorectate (cercul este mai luminos în centru) sau supracorectate (cercul este mai luminos pe margine).

Aceste operații de restaurare se folosesc, în general, pentru a corecta erorile de proiectare sau implementare a sistemelor când nu mai este posibilă refacerea sistemului respectiv.

4.3 Segmentarea

Segmentarea este un proces de partiționare a imaginii digitizate în submulțimi, prin atribuirea pixelilor individuali la aceste submulțimi (denumite și clase), rezultând obiecte distincte din scenă.

Algoritmii de segmentare au la bază, în general, două principii:

- discontinuitate, având ca principală metodă detecția conturului;
- similitudine, cu metoda pragului și metoda regiunilor.

Detecția conturilor

Un operator de contur este un operator matematic, cu extindere spațială mică, construit pentru a determina existența unui contur local în funcția imagine. Există multe tipuri de operatori de contur, principiul care-i unește fiind faptul că ei determină modulul și uneori direcția schimbării intensității nivelului de gri într-o imagine digitală. Modulul furnizat de acești operatori caracterizează severitatea schimbării nivelului de gri de la o vecinătate la alta a imaginii.

Cei mai simpli și cei mai rapizi asemenea operatori de detecție a conturului se bazează pe utilizarea măștilor de convoluție spațială care baleiază întreaga imagine pixel cu pixel, calculând o imagine proporțională cu discontinuitatea existentă în porțiunea de imagine corespunzătoare poziției curente a măștii.

Metoda pragului

Pentru multe aplicații, datorită diferențelor semnificative între nivelurile de gri ale pixelilor aferenți obiectului și respectiv fondului, criteriul de segmentare care poate fi folosit este valoarea nivelului de gri. Metoda care se utilizează în acest caz, foarte rapidă, este denumită segmentare cu prag și ea implementează o transformare punctuală simplă.

Pixelul din punctul de coordonate (i,j) este etichetat ca fiind pixel obiect dacă valoarea sa $f(i,j)$ este mai mare decât un prag. Obținerea unor bune rezultate cu această metodă depinde de modalitatea de alegere a pragului, care poate fi o valoare pentru o imagine dată sau o funcție netedă dependentă de poziția pixelului curent.

Metoda regiunilor

Segmentarea iterativă sau segmentarea prin tehnici de relaxare este o metodă care folosește procedee probabilistice de clasificare, în paralel și în fiecare punct, la fiecare iterație. Procesul de relaxare este conceput pentru a aduce nivelurile de gri spre capetele opuse ale scării de gri astfel încât pragul T să devină o problemă banală.

Acest tip de procesare este fundamental în analiza automată a scenelor și în recunoașterea de modele, unde scopul principal este de a extrage în mod automat date detaliate despre conținutul imaginii la nivel obiect. Deci, obiectivul tehnicii de segmentare este de a partiționa o imagine dată în regiuni sau componente. De exemplu, pentru o imagine derivată dintr-o scenă tridimensională, obiectivul segmentării poate fi identificarea regiunilor corespunzătoare obiectelor din scenă.

Se remarcă din analiza precedentă faptul ca putem considera segmentarea fie ca o problemă punctuală fie ca una regională. În prima categorie intră metodele care se bazează pe examinarea imaginilor pixel cu pixel. În a doua categorie, așa cum implică și denumirea, intră metodele care se bazează pe utilizarea informațiilor din imagine în prescrierea vecinătăților. În ambele cazuri putem vedea problema ca o luare de decizie în procesul de recunoaștere a modelelor, ale carui obiective sunt stabilite în limitele unor regiuni.

Segmentarea scenelor diferă de celelalte probleme de recunoaștere prin câteva proprietăți. Una din cele mai importante diferențe este că după ce am obținut soluția, regiunile dintr-o imagine pot fi vizualizate, iar apoi verificate la un mare nivel de acuratețe. În mod uzual există oricând posibilitatea să suprapunem rezultatele segmentării cu originalul pentru a verifica eficacitatea metodei.

Prima operație este de a localiza granițele sau marginile regiunilor. A doua operație este de a grupa punctele în regiuni similare, cu alte cuvinte determinarea hotarelor. Cele două metode sunt similare și se pot defini ca exprimate în puncte sau ca intersecție între două suprafețe.

Histograma. Operații

Histograma unei imagini este o funcție care indică câți pixeli au un anumit nivel de gri. De obicei, numărul de niveluri de gri este 255 (un pixel este reprezentat pe 1 byte).

$$f(g) = p,$$

unde: g =nivel de gri, g între 0 și 255; p =numărul de pixeli ce au valoarea g .

La o analiză a histogramei diverselor tipuri de imagini, se constată că, de obicei, o imagine are mai multe niveluri de gri și prezintă două maxime locale. Folosind această caracteristică se poate face o segmentare cu prag a imaginii inițiale, alegând pragul ca fiind, de regulă, minimul local dintre cele două puncte de maxim. Astfel, pixelii cu nivel de gri mai mic decât pragul ales pot fi considerați ca fiind, de exemplu, fundalului (li se atribuie valoarea corespunzătoare negrului), iar cei pentru care nivelul de gri este mai mare decât pragul sunt pixelii obiectului.

Datorită iluminării slabe, neuniforme, sau situată la valori în jurul pragului de sensibilitate a senzorului CCD, pot rezulta imagini cu contrast scăzut, imagini pentru care pixelii nu iau valori în întreaga gamă de niveluri de gri. Pentru a corecta aceste defecte se folosesc de regulă: egalizarea histogramei sau extinderea liniară la întreaga gamă de niveluri de gri. Prin aceste operații, unui pixel din noua imagine i se atribuie o valoare de gri calculată pe baza unei funcții (liniare sau exponențiale), funcții ce se determină pe baza imaginii inițiale.

Extragerea conturului

Există mai mulți operatori pentru extragerea conturului. Ca referință în multe cărți de specialitate sunt prezentați trei operatori "clasici": Sobel, Kirsch și pseudo-Laplace. Acești operatori sunt de tipul fereastră glisantă. Extragerea conturului prin acești operatori constă într-o succesiune de convoluții dintre imaginea inițială și nucleul (masca) operatorului.

Opțional, pentru fiecare operator, la finalul convoluțiilor se poate face o segmentare cu prag pentru a obține o imagine binară a hărții muchiilor. Pentru operatorul Sobel prima convoluție se realizează cu masca:

+1	+2	+1
0	0	0
-1	-2	-1

iar pentru a doua convoluție nucleul este rotit cu 90° . Rezultatul operatorului Sobel este suma sau maximum dintre cele două convoluții.

Primul nucleu este folosit pentru muchiile orizontale, iar al doilea pentru cele verticale; fiecare mască corespunde unei derivări pe o direcție perpendiculară pe direcția muchiei. În același timp, operatorul Sobel are și un efect de reducere (într-o anumită măsură) a zgomotului.

Aplicarea operatorului Kirsch constă într-o succesiune de opt convoluții, din care prima se realizează cu următoarea mască:

-3	+5	+5
+3	0	+5
-3	-3	-3

Pentru celelalte șapte convoluții masca este rotită cu 45° . Fiecare convoluție poate fi văzută ca o reprezentare a modelului unui contur ideal pe unde din cele opt direcții de bază. (vecinătate de 87 într-o matrice pătratică). În același timp se face și o oarecare reducere a zgomotului pe fiecare direcție.

Al treilea operator se bazează pe valoarea absolută a Laplace-ianului imaginii, însă este sensibil la zgomot. În general acesta nu este folosit, ci este prezentat în literatura de specialitate doar ca referință.

Detecția muchiilor se poate face și folosind o filtrarea gaussiană. Operatorul constă în combinarea derivatei a doua bidimensională a imaginii și o filtrare pentru reducerea zgomotului folosind un filtru Gaussian trece-jos. Pixelii corespunzători conturilor sunt detectați la trecerile prin zero din rezultatul convoluției finale. Alți operatori utilizați pentru extragerea/detecția muchiilor sunt Deriche și Canny.

5. Operatori morfologici

Identificarea obiectelor dintr-o imagine este de multe ori dificil de realizat. O metodă de a simplifica această operație este binarizarea imaginilor în niveluri de gri și apoi aplicarea unor operatori morfologici.

Fundamentele prelucrării morfologice a imaginilor are un suport matematic riguros, însă în practică acest grad de *sofisticare* nu este

întotdeauna necesar. Marea majoritate a algoritmilor din această categorie sunt operații simple.

Cei mai folosiți operatori morfologici sunt *erodarea* și *dilatarea*. Pentru definirea lor, considerăm o imagine binară. Aceasta conține obiectul de interes și fundalul (ceea ce nu interesează); de exemplu fundalul este alb și obiectul este negru. Prin *erodare* fiecare pixel al obiectului care “atinge” fundalul este transformat în pixel-fundal. La *dilatare* fiecare pixel din fundal aflat în contact cu obiectul este transformat în pixel-obiect. Astfel, erodarea face obiectele mai mici și poate “sparge” un obiect mai mare în mai multe obiecte mici; dilatarea face obiectele mai mari și poate uni mai multe obiecte.

Pe baza acestor operatori s-au *deschiderea* (o erodare urmată de o dilatare) și *închiderea* (dilatare urmată de erodare). Prima operație este folosită pentru a elimina din imagine micile “insule” din pixelii obiectului (acestea apar de obicei la binarizare datorită alegerii inadecvate a pragului). Asemănător, închiderea elimină astfel de “insule” din cadrul fundalului. Aceste tehnici sunt utile în prelucrarea imaginilor zgomotoase unde o parte din pixeli pot avea o valoare binară eronată. De exemplu, se poate și că un obiect nu are găuri sau că marginile obiectului nu prezintă asperități. Un alt exemplu de procesare morfologică este analiza unei amprente.

6. Detecția mișcării

Detecția mișcării și urmărirea diferitelor obiecte aflate în mișcare este o operație frecvent utilizată în sistemele de securitate și supraveghere video. Nu există în general o abordare generică, ci algoritmi sau soluțiile găsite sunt de obicei particulare problemei. În principiu, se face comparație/diferență între cadre succesive și/sau între cadrul curent și un cadru referință. Una din problemele ce apar este separarea obiectului aflat în mișcare de restul scenei (denumit generic fundal). O posibilă soluție ar fi:

- calculul diferenței între cadre;
- segmentare cu prag;
- filtrarea zgomotelor;
- crearea unei imagini a mișcării.

O altă abordare ar fi folosirea unei segmentări prin metoda regiunilor pentru identificarea blocurilor contigui de mișcare ce se găsesc în diferența dintre două cadre succesive. Valoarea absolută a diferenței a două cadre succesive este supusă unei operații cu prag rezultând o imagine brută a

mișcării. Din aceasta se obține o hartă a mișcării în care fiecărei celule (pixel) îi corespunde o fereastră 3x3, din imaginea anterior obținută, pentru care fiecare pixel din fereastră este deasupra unui prag.

Această reducere a dimensiunilor imaginilor oferă o mai mare toleranță la zgomot și scade timpul necesar procesării. Din noua imagine a mișcării astfel obținută se alege cel mai mare bloc contiguu de mișcare. Acest sistem este funcțional și a fost implementat la *The Cog Shop, MIT Artificial Intelligence Laboratory*.

Un domeniu în care detecția mișcării este cel al *Sistemelor Inteligente de Supraveghere a Traficului*. Pentru exemplificare se va prezenta un astfel de sistem realizat de Departamentul de Știința Calculatoarelor al Universității din California, SUA. Sistemul de vedere artificială implementat constă dintr-un modul de urmărire și un model pentru mișcare ce folosește un filtru Kalman pentru a extrage traiectoriile vehiculelor dintr-o secvență de imagini preluate. Pentru inferențele referitoare la evenimentele din trafic, cum ar fi blocajele sau vehicule care schimbă benzile, s-a folosit un model bazat pe rețele dinamice de încredere (modelul dezvoltat de realizatorii proiectului).

Sistemul este deci împărțit în două module: un modul *low-level* de supraveghere video, bazat pe un sistem de vedere artificială, și un modul *high-level* de decizie bazat pe rețele de încredere. Astfel, analiza scenelor din trafic se compune din procesarea *low-level* a imaginilor din trafic, urmată de o descriere simbolică, de nivel înalt, a situațiilor din trafic.

Având dată o secvență de imagini din trafic, sistemul de supraveghere trebuie să identifice vehiculele aflate în cadru și să le urmărească evoluția pe parcursul unei secvențe de imagini. Aceasta presupune atât estimarea formei și poziției vehiculelor aflate în mișcare, cât și asocierea acestor estimări de la o imagine la alta. Operația de urmărire (*tracking*) se face într-un sistem de coordonate a *lumii*; aceasta se realizează prin proiectarea punctelor din imagine pe planul străzii, ceea ce implică doar o simplă transformare liniară, deoarece șoseaua poate fi considerată plană pentru domeniul imaginilor preluate. Pentru detecția mișcării se folosește ca metodă de bază analiza diferenței dintre două imagini succesive din care vor rezulta *obiecte* în mișcare și fundalul. După identificarea obiectelor în mișcare se încearcă o estimare a formei, pentru a se identifica tipul vehiculului (camion, autoturism etc.).

Modulul de urmărire propriu-zisă a vehiculelor folosește rețele de încredere dinamice pentru fiecare vehicul de urmărit. Rețelele de încredere reprezintă grafuri orientate aciclice, în care nodurile reprezintă variabile

aleatoare (de obicei discrete), iar arcele sunt conexiunile cauzale dintre variabile; fiecare nod are asociat un tabel de probabilități pentru diferitele stări în care poate ajunge nodul în funcție de stările posibile ale părinților. Rețelele dinamice de încredere permit inferențele pentru domenii unde variabilele se modifică în timp.

7 Recunoașterea formelor

Recunoașterea formelor reprezintă o modalitate des folosită de a extrage informațiile din imaginile achiziționate. Este un domeniu larg, ce include: recunoașterea scrisului, recunoașterea feței umane, recunoașterea amprentelor etc. Recunoașterea formelor constă într-o clasificare și/sau o descriere a conținutului imaginii.

Clasificarea constă în atribuirea unei forme necunoscute din imaginea preluată la o clasă dintr-un set predefinit de clase; operația de clasificare va produce la ieșire o nouă imagine care reprezintă o *hartă* a obiectelor aflate în scenă. În noua imagine, valorile pixelilor reprezintă de fapt codurile asociate claselor corespunzătoare.

Clasificarea folosește metode matematice numite metode de recunoaștere teoretic-decizionale sau statistice, metode ce se bazează pe elemente din teoria deciziilor statistice. Clasificatoarele se împart în două categorii: supervizate (semiautomate) - presupun prezența unui operator uman la începutul procesului de clasificare care va specifica câte clase vor rezulta la finalul operației, o serie de caracteristici etc.; nesupervizate (automate) - se face o clasificare a imaginii, dar fără a ști ce reprezintă fiecare clasă.

Algoritmii de clasificare se bazează în extragerea caracteristicilor (*features*) pe o măsură a similarității (o distanță, de exemplu). Un pas important în proiectarea sistemelor de clasificare automată este selecția caracteristicilor, aceasta deoarece componentele vectorului de caracteristici presupune prezența unei cantități destul de mari de informație. Această selecție este o problemă dependentă de numărul de clase și de formele analizate.

Un clasificator conține, în general, trei module: modulul de clasificare propriu-zis, un modul de învățare (presupune prezența unui set de eșantioane/imagini de antrenare) și un modul de selecție și extragere a caracteristicilor. Setul de antrenare poate conține de exemplu o bază de date

cu diferite caracteristici ale obiectelor ce pot apare în scenă (semnături spectrale de exemplu sau semnături geometrice).

Învățarea presupune existența acestui set de antrenare, set ce cuprinde eșantioane pentru care se știe apartenența claselor; prezența setului de antrenare este necesară în cadrul clasificării supervizate.

8 Exemplu de aplicație. Amprenta digitală

O amprentă este un șablon de creștături pe suprafața degetului. Fiecare individ are o amprentă unică. Unicitatea amprentei este exclusiv determinată de caracteristicile creștăturilor locale. Figura 8.1. reprezintă detaliile unei amprente. Două dintre cele mai remarcabile creștături sunt: frânte și bifurcate.




Figura 8.1. Detaliile unei amprente

Potrivirea automată a amprentelor depinde de comparația dintre caracteristicile creștăturilor și relațiile între ele pentru a face o identificare personală, și în plus de calitatea achiziției amprentei.

Un exemplu de amprentă de calitate slabă, în care structura creștăturilor este complet coruptă, este ilustrat în figura 8.2:



Figura 8.2. Ampreună de calitate slabă

În general, pentru o imagine digitală a unei amprente date, regiunea de interes poate fi divizată în cele 3 categorii prezentate în figura 8.3.




Figura 8.3. Deficiențele amprentelor

a. regiune clară

b. regiune coruptă recuperabilă

c. regiune coruptă nerecuperabilă, cu zgomote și distorsiuni

Diagrama algoritmului de îmbunătățire a imaginii unei amprente este prezentat în figura 8.4:

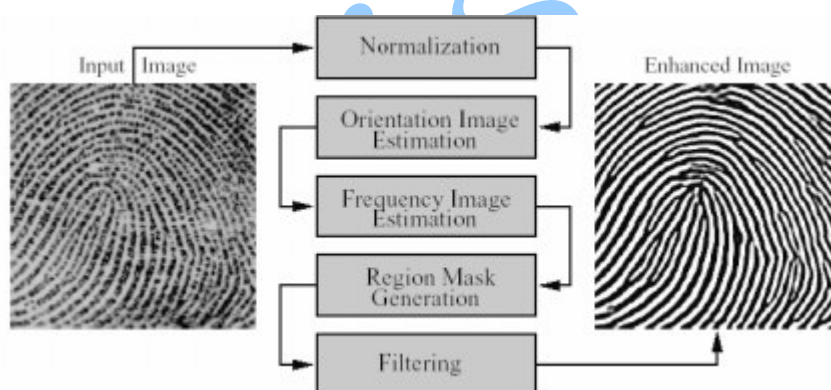


Figura 8.4. Algoritmul de procesare al amprentelor

Algoritmul cuprinde următorii pași:

- *normalizarea* : imaginea amprente este normalizată.
- *estimarea orientării locale* : sensul imaginii este evaluat din imaginea amprente normalizată.
- *estimarea frecvenței locale* : frecvența imaginii este calculată din imaginea amprente normalizată și estimarea sensului.

- *estimarea regiunii de măști*: regiunea de măști este obținută prin clasificarea fiecărui bloc din imaginea amprentei normalizată într-un bloc recuperabil sau nerecuperabil.
- *filtrare* : un grup de filtre *Gabor* care sunt acordate pe sensul și frecvența creșterilor este aplicat pentru îmbunătățirea amprentei.

9 Concluzii

Prelucrarea imaginilor este un domeniu complex, dinamic, cu numeroase aplicații în diverse domenii. Noile tehnologii folosite în industria circuitelor integrate (s-au creat circuite integrate dedicate pentru achiziție de imagine sau pentru o serie de prelucrări) au permis aplicarea a noi algoritmi și metode pentru extragerea informațiilor utile din imagine: algoritmi paraleli, clasificatoare bazate pe rețele neuronale etc.

Există acum diverse implementări de sisteme de timp real, bazate pe prelucrarea de imagini, sisteme utilizate în industria militară, medicină, sisteme de control automat a proceselor industriale. S-au adus diverse îmbunătățiri pentru sisteme de procesare a amprentelor digitale, recunoașterea feței, a scrisului. Pentru zonele aglomerate sau de interes strategic au fost proiectate și implementate sisteme de securitate și supraveghere bazate pe vederea artificială (*machine-vision*).

De asemenea, prelucrarea computerizată a imaginilor are un rol foarte important în medicină, în domeniul tehnicii medicale: tomografia asistată de calculator, analiza și interpretarea imaginilor microscopice celulare. În centrele de cercetare din universități s-au creat sisteme autonome mobile (roboți mobili) și care folosesc pentru deplasare sau luarea diverselor tipuri de decizii subsisteme de vedere artificială.

Bibliografie

[Bul98] **Mihai Bulea**, *Structuri și algoritmi paraleli pentru prelucrearea imaginilor și recunoașterea formelor*, 1998

[Cam02] **Octavia I. Camps**, *Computer Vision*, 2002

- [Pav82] **T. Pavlidis**, *Algorithms for Graphics and Image Processing*, Computer Science Press, 1982
- [Smi97] **S. Smith**, *The Scientist and Engineer.s Guide to Digital Signal Processing*, Technical Publishing, 1997
- [YGV02] **I. T. Young, J. J. Gerbrands, L. J. van Vliet**, *Fundamentals of Image processing*, 2002

Tibiscus