Lucrarea 1

Detecţia obiectelor cu algoritmul Viola-Jones

1.1 Punerea problemei

Algoritmul de detecţie a obiectelor propus de către Viola-Jones[1] combină cu succes mai multe tehnici elementare. În continuare vom studia pe rând aceste aspecte, urmând ca în final să vedem ansamblul funcţional. Aceste concepte sunt:

- *Imaginea Integrală*;
- *Descriptori (caracteristici sau trăsături) primitivi (de tip Haar)*;
- *Antrenare de tip AdaBoost*;
- *Calibrare prin maximizare ratei de detecţie sa minimizare Falsurilor negative.*

Pe baza Imaginii Integrale se pot calcula rapid sume pe zone rectangulare într-o imagine. Astfel putem calcula rezultatele unor descriptori de tip Haar aplicate pe diferite rezoluţii ale imaginilor, căutând astfel obiecte (sau în cel mai cunoscut caz, feţe umane) de diferite dimensiuni (scalări). Rezultatele clasificatorilor simpli sunt combinate cu ajutorul algoritmului AdaBoost, astfel încât să rezulte un complex capabil să detecteze în timp real obiecte.

1.2 Descriptori Haar

Caracteristicile utilizate în varianta originala a algoritmului Viola-Jones amintesc de funcţiile baza de tip Haar folosite de catre Papageorgiou et al.[2]. Mai precis, Viola şi Jones au folosi trei tipuri de caracteristici (vezi figura 1.1):

1. Caracteristici de două dreptunghiuri în care se calculează diferenta dintre suma pixelilor din cele două regiuni dreptunghiulare. Regiunile au aceeaşi mărime şi forma şi sunt orizontal sau vertical adiacente (a se vedea figura 1.1, punctele A şi B).
2. O caracteristică de trei dreptunghiuri (punctul C) unde se calculează suma celor două dreptunghiuri din afară minus dreptunghiul central.
3. O caracteristică de patru dreptunghiuri (punctul D din figură) unde se diferenta dintre suma elementelor de pe diagonala prinicipală şi suma elementelor din dreptunghiurile de pe diagonala secundară .

Fereastra de bază este una de 24×24 pixeli. În această fereastră se vor considera toate caracteristicile posibile de tipurile menţionate: cele care încep în pixelul $(0, 0)$, în pixelul $2, 2$, de laţime 2, de latime 4, şi asa mai departe.

ACTIVITATE: `Implementaţi, utilizând conceptul de Imagine Integrală tipurile de caracteristici de tip Haar menţionate. Aplicaţi-le pentru matricea b=([[3,2,1,1], [1,2,3,4]] si a=([[1,1,1,1],[2,2,2,2],[3,3,3,3],[4,4,4,4]]).` .

- *Pentru matricea a Haar 1(0,0,4,4) rez este (zn,za,H1) : 12 28 16*;

[1] P.Viola, M.Jones, "Robust real time object-detection", Second Internationsl Workshop on Statistical and Computational Theories of Vision Modeling, Learning, Computing and Sampling, Vancouver, Canada, July 13, 2001

[2] C. Papageorgiou, M. Oren, and T. Poggio. "A general framework for object detection". In Proceedings of International Conference on Computer Vision, 1998.

- *Pentru matricea b, Haar 2(0,0,2,2) rez este(zn1,zn2,za1,H4): 4 4 0;*
- *Pentru matricea b, Haar 3(0,0,2,3) rez este(zn1,zn2,za1,H4): 4 4 4 -4;*
- *Pentru matricea a, Haar 4(0,0,4,4) rez este(zn1,zn2,za1,za2,H4): 6 14 6 14 0*

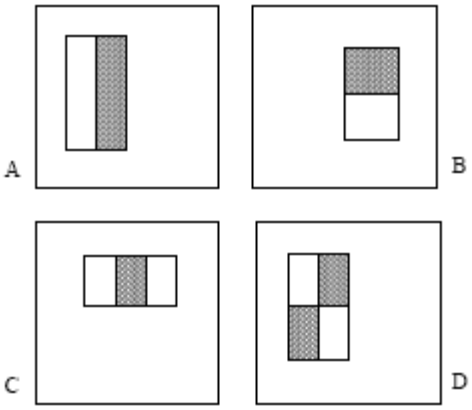


Figura 1.1: Caracteristicile de tip Haar utilizate de către Viola şi Jones în algoritmul original.

Caracteristicile de tip Haar sunt oferite unui algoritm de tip Ada-Boost, în urma căruia se realizează un proces de selecţie, ale celor mai utile trăşături, precum şi a ponderii lor in algoritmul final.

1.2.1 Cascadă de clasificatori şi calibrarea

Deşi conform variantei originale ale algoritmului AdaBoost antrenarea s-a terminat, pentru detecţia cu metoda propusă de către Viola şi Jones se utilizează o abordare diferită. În acest caz clasificatorul final este obţinut nu ca o sumă ponderată ci ca o cascadă de clasificatori. Din procesul de antrenare se extrage un număr limitat de clasificatori (de exemplu 100). În pasul de calibrare, se va hotărî ordinea acestor clasificatori, precum şi pragurile fiecăruia.

Pentru aceasta se recomanda folosirea unui nou set de date, diferit de cel de antrenare, numit set de calibrare. Clasificatorul final se obţine ca o cascadă de clasificatori, în care fiecăruia i se atribuie o pondere din valoare tinta a detectiei sau a fals pozitivelor. Pentru o cascadă de K clasificatori cu rate de detecţie individuale d_i, rata de detecţie totală este:

$$D = \prod_{i=1}^{K} d_i \tag{1.1}$$

Distribuţia ratelor de detecţie se poate face în mod uniform sau neuniform. Noi vom opta pentru primul caz.Trăsăturile Haar cele mai potrivite pentru detecţia de feţe sunt prezentate în figura 1.2

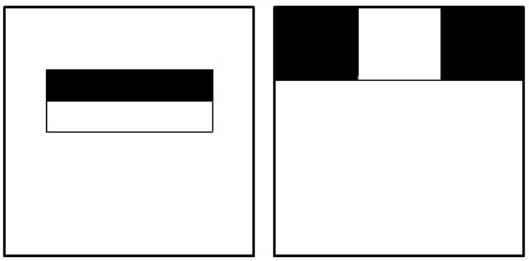


Figura 1.2: Caracteristicile de tip Haar determinate a fi cele mai eficiente. Caracteristica din stânga este în dreptunghiul $[6:11; 4:19]$, în timp ce cea din dreapta este în dreptunghiul $[0:7; 0:23]$.

ACTIVITATE: `Aplicaţi caracteristicile Haar menţionate pe setul de imagini oferit. Alegeti pragul astfel incat numarul de fee identificate(TP) s fie ct mai mare.?`

ACTIVITATE: Aplicaţi caracteristica 3 ca n figura 1.2, ct i n colul din dreapta jos al imaginilor. Care este cazul mai relevant? Reprezentai grafic cele 2 cazuri

1.3 Algoritmul Viola-Jones

După cum am mai menţionat în introducere, algoritmul Viola-Jones utilizează Imaginea Integrală pentru calculul eficient al trăsăturilor de tip Haar. În algorimul original autorii folosesc ferestre de bază de 24×24, ceea ce conduce la 45,396 de trăsături de bază. Dintre acestea în urma antrenării se utilizează 32 de clasificatori. În momentul căutării, se porneşte de la rezolutia de bază, care constituie nivelul minim şi se scalează în 11 niveluri consecutive, cu un factor relativ de scalare de 1.25. Paii pentru varianta simplificat a algoritmului ar fi urmtorii:

1. Pentru fiecare imagine din setul de date se calculeaz toate cele 4 tipuri de trsturi Haar(A-D) pentru fiecare dimensiune posibil a ferestrei
2. Se alege caracteristica Haar cea mai relevant(TP=1.0, FP=min)
3. Se construiete primul nod al ansamblului de arbori folosind caracteristica cea mai relevant i se elimin eantioanele care sunt non fee(TN)
4. Se caut urmtoarea cea mai relevant caracteristic i se repet procesul descris mai sus
5. Algoritmul se oprete dac eroarea scade sub un anumit prag impus(TP=ct mai mare) sau dac se atinge o adncime maxim setat a ansamblului de arbori

Andrei Racoviteanu
Ultima modificare: 26 septembrie 2019