

UNIVERSITATEA TEHNICĂ "GHEORGHE ASACHI" DIN IAȘI



CONTRIBUȚII LA DEZVOLTAREA INTERFEȚELOR OM-MAȘINĂ PE BAZA DETECȚIEI PRIVIRII

REZUMATUL TEZEI DE DOCTORAT

Doctorand: ing. Bonteanu Petronela

Conducător de doctorat : prof. dr. ing. Bozomitu Radu Gabriel

IAȘI, 2025

UNIVERSITATEA TEHNICĂ "GHEORGHE ASACHI" DIN IAȘI
R E C T O R A T U L

Către

Vă facem cunoscut că, în ziua de 24.09.2025 la ora 10.00 în Aula Magna „Carmen Sylva” a Universității Tehnice „Gheorghe Asachi” din Iași, va avea loc susținerea publică a tezei de doctorat intitulată:

“Contribuții la dezvoltarea interfețelor om-mașină pe baza detecției privirii”

elaborată de doamna **Dămoc (căs. Bonteanu) Petronela** în vederea conferirii titlului științific de doctor.

Comisia de doctorat este alcătuită din:

1. Prof. univ. dr. ing. Tărniceriu Daniela,

Universitatea Tehnică „Gheorghe Asachi” din Iași

președinte

2. Prof. univ. dr. ing. Bozomitu Radu Gabriel,

Universitatea Tehnică „Gheorghe Asachi” din Iași

conducător de doctorat

3. Prof. univ. dr. ing. Grigore Ovidiu,

Universitatea Națională de Știință și Tehnologie, Politehnica, București

referent oficial

4. Prof. univ. dr. ing. Pop Ovidiu Aurel,

Universitatea Tehnică din Cluj-Napoca

referent oficial

5. Cercetător științific gr. I dr. ing. Apopei Vasile,

Institutul de Informatică Teoretică, Academia Română, Filiala Iași

referent oficial

Cu această ocazie vă invităm să participați la susținerea publică a tezei de doctorat.

RECTOR,

.....

Secretar universitate,

.....

Cuprins

Capitolul I	1
1.1 Introducere	1
1.2 Scurt istoric	1
1.3 Categorii de algoritmi utilizați în detecția privirii	1
1.4 Obiective	3
Capitolul II - Algoritmi definitorii pentru evoluția domeniului detecției direcției privirii	4
2.1 Algoritmul Starburst	4
2.2 Algoritmul bazat pe analiza conturului pentru detectarea irisului și a pupilei	4
2.3 Algoritmul bazat pe metoda proiecției integrale pentru detectarea irisului și a pupilei	4
2.4 Algoritmul bazat pe modelul gaussian pentru estimarea parametrilor irisului	4
2.5 Algoritmul bazat pe transformata Hough circulară pentru localizarea irisului	4
2.6 Algoritmul bazat pe transformata Hough eliptică	4
2.7 Algoritmul RANSAC	4
2.8 Algoritmul de potrivire a elipsei prin metoda minimizării erorii pătratice	4
2.9 Algoritmul Swirski: detecția robustă a pupilei în imagini off-axis	5
2.10 Algoritmul ExCuSe pentru detectarea robustă a pupilei în scenarii reale	5
2.11 Algoritmul ElSe: detecția robustă a pupilei în medii reale	5
2.12 Algoritmul PuRe: detecția robustă a pupilei pentru eye-tracking în timp real	5
2.13 Procesare clasică de imagine versus tehnici bazate pe învățare automată	5
2.14 Algoritmul Zhang pentru estimarea privirii bazată pe aspect	5
2.15 Algoritmul PupilNet v2.0: Detecția robustă a pupilei în timp real	5
2.16 Algoritm de urmărire a privirii bazat pe rețele neuronale convoluționale compacte	5
Capitolul III - Contribuții la dezvoltarea algoritmilor bazați pe caracteristici	6
3.1 Algoritm robust de detecție a pupilei construit în jurul unui mecanism de feedback negativ, care rafinează iterativ pragul de binarizare pe baza unei matrice de circularitate aplicate conturilor candidate- Algoritmul ThresholdRef	6
3.2 Algoritm ce propune o tehnică nouă de binarizare, în care pragul optim este determinat prin analiza proprietăților funcției percentilă, cu scopul de a obține o segmentare cât mai precisă a regiunii pupilei- Algoritmul PercentileEdge	8
3.3 Soluție extinsă care combină abordările anterioare și introduce o nouă buclă de reacție negativă, menită să asigure selecția conturului cu gradul maxim de circularitate drept candidat final pentru pupila detectată- Algoritmul DualFeedback	11
3.4 Algoritm inovator bazat pe funcții de proiecție integrală unghiulară multiple, menit să evidențieze trăsături geometrice relevante pentru localizarea pupilei într-o varietate de condiții- Algoritmul MultiAngleProjection	13
3.5 Algoritm care combină analiza funcției percentilă cu aplicarea transformatei Hough, obținând astfel o detecție robustă a pupilei prin integrarea metodelor statistice cu tehnici geometrice clasice - Algoritmul HoughPercentile	16
3.6 Algoritm bazat pe analiza descriptorilor Fourier ai conturului, care utilizează semnătura frecvențială a formei pentru a identifica pupila pe baza caracteristicilor sale de simetrie și regularitate- Algoritmul FourierContour	19
Capitolul IV - Contribuții la dezvoltarea algoritmilor de detecție a pupilei bazați pe machine learning	21
4.1 Elaborarea unui algoritm hibrid pentru detecția pupilei în aplicații de urmărire în timp real a direcției privirii - HybridPercentile	21
4.2 Detecția centrului pupilei în imagini de mică rezoluție utilizând metode de inteligență artificială (AI4LowRes)	23
4.3 Detecția centrului pupilei pe imagini de înaltă rezoluție folosind tehnici de inteligență artificială - XY-Classifer	27
Capitolul V - Concluzii	31
5.1 Privire generală asupra structurii lucrării	31
5.2 Contribuții originale	31
5.3 Direcții de cercetare viitoare	33
Lista lucrărilor științifice publicate	34
Bibliografie	35

Capitolul I

1.1 Introducere

Oamenii au fost mereu motivați să creeze interfețe om-mașină (Human Machine Interface) din dorința de a face tehnologia mai accesibilă, mai sigură și mai eficientă. De-a lungul timpului, s-a simțit tot mai acut nevoia de a automatiza procesele, de a reduce efortul uman și de a crește productivitatea, iar interfețele intuitive au devenit cheia acestei evoluții. În industria auto, medicină, aplicații militare, publicitate, HMI-urile au fost esențiale pentru prevenirea accidentelor și eliminarea erorilor, oferind utilizatorilor un control mai precis asupra sistemelor complexe.

1.2 Scurt istoric

Primele încercări de urmărire a privirii datează de la începutul secolului al XIX-lea, dar abia în a doua jumătate a secolului XX, odată cu dezvoltarea tehnologiei, s-au putut construi sisteme mai precise și mai puțin intruzive. În anii '70 - '80, primele sisteme ce detectau privirea erau mari, greoaie și adesea necesitau contact fizic cu ochiul. Acestea erau folosite mai ales în cercetări academice pentru a studia comportamentul vizual al oamenilor. În anii '90, odată cu creșterea puterii de calcul și miniaturizarea componentelor, au apărut primele sisteme bazate pe fluxuri video. Acestea erau mai puțin intruzive și permiteau urmărirea privirii de la distanță. Fitzgibbon [1] a pus bazele teoretice pentru potrivirea elipselor în imaginile oculare, o tehnică fundamentală în detectarea pupilei. Apoi, în anii 2000, această perioadă a fost marcată de progrese semnificative în acuratețe și robustețe. Algoritmi precum Starburst [2] au combinat abordări bazate pe caracteristici și pe model pentru a urmări privirea în condiții mai puțin ideale. Asadifard și Shanbezadeh [3] au propus metode adaptive pentru a localiza centrul pupilei. Urmează anii 2010 când, odată cu popularizarea camerelor web și a dispozitivelor mobile, urmărirea privirii a devenit mai accesibilă. Swirski [4] a dezvoltat metode robuste pentru urmărirea pupilei în imagini cu unghiuri mari. Cherabit [5] a aplicat transformata Hough pentru localizarea irisului.

Învățarea profundă a revoluționat domeniul în anii 2020. Rețelele neuronale convoluționale (CNN) au demonstrat o capacitate extraordinară de a detecta pupilele și de a estima direcția privirii cu o precizie fără precedent. Fuhl [6] a introdus PupilNet, un model de rețea neuronală pentru detectarea robustă a pupilei.

1.3 Categorii de algoritmi utilizați în detecția privirii

Clasificarea algoritmilor pentru detecția privirii poate fi realizată pe baza mai multor criterii, precum metoda de captare a datelor, tehnica de procesare sau aplicația specifică. Pe lângă aceste clasificări, există și alte criterii care pot fi luate în considerare, cum ar fi gradul de cooperare al utilizatorului, necesitatea calibrării prealabile sau costul sistemului de urmărire a privirii.

A. Clasificarea algoritmilor pentru detecția privirii în funcție de *metoda de captare a datelor* se poate face în principal pe două categorii:

1. *Metode bazate pe prelucrarea imaginilor video*: Utilizează camere video pentru a captura imagini ale ochilor. Sunt cele mai comune datorită accesibilității și costului redus.
2. *Metode non-video*: Utilizează alte tehnologii pentru a detecta mișcările ochilor. Sunt mai puțin comune, dar pot fi utile în anumite situații.

B. Algoritmii de detecție a privirii pot fi clasificați în funcție de *tehnica de procesare a imaginilor* utilizată pentru a identifica și urmări pupila și, ulterior, pentru a detecta direcția privirii. Iată o clasificare generală:

1. *Metode bazate pe caracteristici* („Feature-based Methods”): Utilizează caracteristici specifice ale imaginii pentru a identifica pupila.
2. *Metode bazate pe model* („Model-based Methods”): Utilizează modele 3D ale ochiului sau ale pupilei pentru a ghida procesul de detecție.
3. *Metode bazate pe învățare automată* („Machine learning-based Methods”): Utilizează algoritmi de învățare automată, cum ar fi rețelele neuronale, pentru a detecta pupila și a estima direcția privirii.
4. *Metode hibride*: Combină elemente din diferitele categorii menționate mai sus.

C. Clasificarea algoritmilor pentru detecția privirii în sistemele de interfață om-mașină poate fi realizată și în funcție de *aplicația specifică*.

1. În funcție de mediul de interacțiune
 - *Aplicații de birou*
 - *Aplicații mobile*
 - *Realitate virtuală și augmentată*
2. În funcție de tipul de interacțiune
 - *Selectarea elementelor vizuale*
 - *Navigarea prin meniuri*
 - *Controlul cursorului*
3. În funcție de cerințele de performanță
 - *Sisteme cu procesare în timp real*
 - *Aplicații offline*

D. Algoritmii de detecție a privirii pot fi clasificați în funcție de *gradul de cooperare al utilizatorului*, adică de cât de mult trebuie să se implice sau să colaboreze acesta în procesul de urmărire a privirii. Această clasificare distinge între:

1. *Metode cooperative*: Utilizatorul trebuie să coopereze activ cu sistemul de urmărire a privirii.
2. *Metode semi-cooperative*: Utilizatorul trebuie să coopereze într-o anumită măsură cu sistemul de urmărire a privirii.

3. *Metode necooperative*: Utilizatorul nu trebuie să coopereze activ cu sistemul de urmărire a privirii.

E. Clasificarea algoritmilor pentru detecția privirii în funcție de *necesitatea calibrării prealabile* distinge între:

1. *Algoritmi care necesită calibrare*
2. *Algoritmi care nu necesită calibrare*

F. Clasificarea algoritmilor pentru detecția privirii în funcție de *costul sistemului de urmărire a privirii* este o clasificare importantă, deoarece costul poate fi un factor decisiv în alegerea unui dispozitiv de urmărire a privirii pentru o anumită aplicație. În general, putem distinge între:

1. *Sisteme de urmărire a privirii cu cost redus*
2. *Sisteme de urmărire a privirii cu cost mediu*
3. *Sisteme de urmărire a privirii cu cost ridicat*

1.4 Obiective

Obiective principale pe care le-am propus în cadrul acestei teze sunt următoarele:

- Îmbunătățirea preciziei și robusteții algoritmilor de detecție a pupilei bazați pe caracteristici: dezvoltarea de algoritmi noi, inovatori, care să depășească limitările metodelor tradiționale bazate pe caracteristici, în special în ceea ce privește variațiile de iluminare, mișcările capului și alte zgomote din imagine.
- Explorarea și aplicarea tehnicilor de învățare automată("machine learning") în detectarea pupilei: s-a investigat modul în care tehnicile de învățare automată, în special rețelele neuronale, pot fi utilizate pentru a îmbunătăți detectarea pupilei.
- Dezvoltarea unor dispozitive de urmărire a privirii performante și adaptabile:
- Evaluarea riguroasă a performanței algoritmilor propuși: s-a evaluat riguros performanța algoritmilor dezvoltați, utilizând seturi de date relevante și metrici de evaluare standard în domeniu.
- Identificarea de noi direcții de cercetare în domeniul urmăririi privirii.

Capitolul II

Algoritmi definitorii pentru evoluția domeniului detecției direcției privirii

În această secțiune se trece în revistă o suită de realizări din domeniul detecției direcției privirii asigurând performanțe notabile la vremea publicării în literatura de specialitate.

2.1 Algoritmul Starburst

Algoritmul Starburst [2] reprezintă una dintre metodele utilizate pentru detectarea privirii, având ca scop identificarea precisă a poziției pupilei și a reflexiilor corneene.

2.2 Algoritmul bazat pe analiza conturului pentru detectarea irisului și a pupilei

Algoritmul bazat pe analiza conturului [27] este o tehnică de detectare a irisului și a pupilei prin identificarea conturului acestora în imagini, utilizând detecția marginilor.

2.3 Algoritmul bazat pe metoda proiecției integrale pentru detectarea irisului și a pupilei

Algoritmul bazat pe Metoda Proiecției Integrale, prezentat în [28], este o tehnică eficientă pentru localizarea irisului și a pupilei în imagini.

2.4 Algoritmul bazat pe modelul Gaussian pentru estimarea parametrilor irisului

Algoritmul bazat pe modelul Gaussian, menționat [29], utilizează o abordare probabilistică pentru a localiza irisul în imagini.

2.5 Algoritmul bazat pe transformata Hough circulară pentru localizarea irisului

Algoritmul bazat pe transformata hough circulară (CHT), prezentat în [30], este o tehnică eficientă pentru localizarea irisului în imagini. Aceasta se bazează pe capacitatea CHT de a detecta forme circulare în imagini, utilizând proprietățile specifice ale irisului pentru a-l identifica.

2.6 Algoritmul bazat pe transformata Hough eliptică

Transformata Hough (HT) este o tehnică populară în procesarea imaginilor pentru detectarea formelor geometrice, cum ar fi linii, cercuri și elipse.

2.7 Algoritmul RANSAC

Un alt algoritm esențial care a influențat semnificativ metodele moderne de detecție a pupilei și, implicit, de urmărire a privirii este RANSAC (Random Sample Consensus), introdus de Fischler și Bolles în 1981 [76]. Random Sample Consensus (RANSAC) este o metodă robustă de estimare a parametrilor unui model geometric pe baza unui set de date ce conține un număr semnificativ de valori aberante (outliers).

2.8 Algoritmul de potrivire a elipsei prin metoda minimizării erorii pătratice

În articolul [1], Pilu și Fisher prezintă un algoritm eficient pentru potrivirea elipselor la un set de puncte date, utilizând metoda minimizării erorii pătratice. Această metodă este preferabilă

metodelor tradiționale, deoarece evită complexitatea calculului iterativ și oferă o soluție directă, rapidă și robustă.

2.9 Algoritmul Swirski: detecția robustă a pupilei în imagini off-axis

Algoritmul Swirski este o metodă avansată de detectare a pupilei, concepută special pentru imagini obținute din sisteme de “eye-tracking” montate pe cap.

2.10 Algoritmul ExCuSe pentru detectarea robustă a pupilei în scenarii reale

Algoritmul ExCuSe („Exclusive Curve Selector”) [18] a fost dezvoltat pentru detectarea robustă a pupilei în imagini din scenarii reale, unde alte metode pot eșua din cauza condițiilor de iluminare variabilă, reflexiilor sau interferențelor cauzate de gene și lentile de contact.

2.11 Algoritmul ElSe: detecția robustă a pupilei în medii reale

Algoritmul ElSe (“Ellipse Selection”) [19] este o metodă avansată de detecție a pupilei în imagini obținute din scenarii reale.

2.12 Algoritmul PuRe: detecția robustă a pupilei pentru eye-tracking în timp real

Algoritmul PuRe („Pupil Reconstructor”) [43] este o metodă avansată de detecție a pupilei, dezvoltată pentru a îmbunătăți precizia și robustețea în scenarii de „eye-tracking” în timp real.

2.13 Procesare clasică de imagine versus tehnici bazate pe învățare automată

Înțelegerea direcției privirii umane a reprezentat dintotdeauna un deziderat important în interacțiunea om-mașină (IOM), oferind posibilitatea de a crea sisteme intuitive și adaptabile.

2.14 Algoritmul Zhang pentru estimarea privirii bazată pe aspect

Algoritmul propus de Zhang în [15] introduce o metodă de estimare a privirii bazată pe aspect, utilizând *rețele neuronale convoluționale multimodale* pentru a analiza imaginile ochilor și poziția capului.

2.15 Algoritmul PupilNet v2.0: Detecția robustă a pupilei în timp real

PupilNet v2.0 [14] este un algoritm avansat de detectare a pupilei, bazat pe rețele neuronale convoluționale (CNN), conceput pentru a funcționa în timp real pe CPU-uri standard. Acesta îmbunătățește detectarea pupilei în medii variabile, abordând provocări precum schimbările rapide de iluminare, ocluziuni și poziții off-axis ale ochiului.

2.16 Algoritm de urmărire a privirii bazat pe rețele neuronale convoluționale compacte

Algoritmul folosește o rețea neuronală convoluțională compactă (slim - CNN), numită PONet (Pupil Orientation Net) [15], optimizată pentru a detecta pupila în imagini de rezoluție redusă. Spre deosebire de metodele tradiționale care se bazează pe transformata Hough sau ajustarea elipsei, acest model CNN este antrenat să identifice poziția pupilei cu o acuratețe ridicată, chiar în condiții de iluminare slabă sau parțială ocluzie.

Capitolul III

Contribuții la dezvoltarea algoritmilor bazați pe caracteristici

Prima etapă a studiului doctoral a vizat crearea unor algoritmi capabili să identifice cu acuratețe pupila în imagini perturbate de zgomot, reflexia corneei fiind principala sursă de interferență. Astfel, în acest capitol, se prezintă algoritmi dezvoltati pentru detecția centrului pupilei, abordând metodele tradiționale bazate pe tehnici de procesare a imaginilor.

În cadrul acestor algoritmi s-a utilizat tehnica pupilei întunecate, ceea ce presupune captarea imaginii ochilor utilizând o cameră video în infraroșu. Astfel, pupila apare ca cel mai întunecat obiect din imagine.

Funcționarea algoritmilor propuși este analizată pe imagini oculare din trei baze de date. Precizia detecției algoritmilor propuși a fost apreciată prin distanța euclidiană dintre coordonatele centrului pupilei determinate manual și cele estimate automat. Performanța acestora a fost evaluată prin rata de detecție, calculată ca fiind raportul dintre un număr de imagini în care eroarea euclidiană a detecției a fost sub pragul k și numărul total al imaginilor din setul de date:

3.1 Algoritm robust de detecție a pupilei construit în jurul unui mecanism de feedback negativ, care rafinează iterativ pragul de binarizare pe baza unei metrice de circularitate aplicate conturilor candidate- Algoritmul ThresholdRef

Etapile propuse de algoritm sunt ilustrate în organigrama Figura 3.1.1.




Figura 3.1.1 Organigrama algoritmului ThresholdRef




Figura 3.1.2 Iterații ale algoritmului: a) - f) - prima iterație, g) - l) - a doua iterație; a), g) imaginea binarizată folosind pragul evaluat / redus; b), h) Imaginea rezultată după operațiile morfologice dilatare / erodare; c), i) Imaginea rezultată prin aplicarea Laplacianului; d), j) Contururi detectate pe imagine; e), k) contur ce a beneficiat de închiderea convexă selectat drept pupilă; f), l) Elipsa potrivită pe conturul pupilei.

Atât algoritmul ExCuSe, cât și algoritmul propus au fost rulați pe aceeași mașină în condiții identice. Pentru evaluare, am folosit implementarea C / C ++ a algoritmului ExCuSe. Algoritmul propus a fost implementat folosind interfața Python 3 pentru OpenCV.




Figura 3.1.4 Rata de detecție obținută de ExCuSe și de algoritmul ThresholdRef

Figura 3.1.5 ilustrează eroarea în pixeli rezultată pentru fiecare imagine din ambele baze de date analizate.




Figura 3.1.5 Distanța euclidiană obținută de algoritmul propus pentru cele două seturi de date

În Tabelul 3.1.1 sunt prezentate, acuratețea detecției în limita a 5 pixeli, valoarea medie și deviația standard a distanței euclidiene precum și numărul mediu de cadre pe secundă.

Tabelul 3.1.1 – Rezultate experimentale ThresholdRef

Parametrul măsurat	ExCuSe			Algoritmul ThresholdRef		
	DB ₁	DB ₂	DB _{1&2}	DB ₁	DB ₂	DB _{1&2}
DR_s [%]	77,5	73,75	75,62	88,00	98,50	93,25
$\bar{d}$ [px]	11,56	14,68	13,12	2,75	2,12	2,44
σ_d [px]	68,87	50,69	60,49	1,99	1,69	1,87
Frame rate [fps]	19,05	19,03	19,04	42,11	47,06	44,44

3.2 Algoritm ce propune o tehnică nouă de binarizare, în care pragul optim este determinat prin analiza proprietăților funcției percentilă, cu scopul de a obține o segmentare cât mai precisă a regiunii pupilei- Algoritmul PercentileEdge




Figura 3.2.1 Organigrama algoritmului PercentileEdge

Considerând că pupila este zona cea mai întunecată parte a imaginii, există pragul, notat cu Th , pentru care o binarizare cu prag global va izola pupila de restul imaginii.




Figura 3.2.2 Determinarea pragului de binarizare funcție de prima scădere a pantei graficului funcției percentilă.




Figura 3.2.3 Poziția pragului de binarizare pe histograma imaginii ochiului.

Sucesiunea etapelor de procesare realizate de algoritmul PDA este prezentată în Figura 3.2.4.




Figura 3.2.4 Etape de procesare ale algoritmului PercentileEdge : a) Imaginea în tonuri de gri; b) Imaginea binarizată; c) Imagine rezultată după operația morfologică de dilatare; d) Imagine rezultată după operația morfologică de erodare; e) Imagine rezultată după aplicarea operatorului Laplacian; f) Contururi detectate în imagine; g) Conturul ce a beneficiat de închiderea convexă desemnat drept pupilă; h) Elipsa potrivită pe pupilă.

Figura 3.2.5 ilustrează rata de detecție (DR) a algoritmului propus. Figura 3.2.6 și Figura 3.2.7 ilustrează distanța euclidiană, percentila și valorile pragului.

Tabelul 3.2.1 Rezultate experimentale PercentileEdge

Parametrul măsurat	ExCuSe			Algoritmul PercentileEdge		
	DB ₁	DB ₂	DB _{1&2}	DB ₁	DB ₂	DB _{1&2}
DR_5 [%]	77,5	73,75	75,62	88,5	96,5	92,5
$\bar{d}$ [px]	11,56	14,68	13,12	2,72	2,18	2,45
σ_d [px]	68,87	50,69	60,49	2,14	1,72	1,96
Frame rate [fps]	19,05	19,03	19,04	29,67	35,27	32,23




Figura 3.2.5 Rata de detecție obținută de ExCuSe și de algoritmul PercentileEdge




Figura 3.2.6 Distanța euclidiană, percentila și pragul de binarizare determinate pentru fiecare dintre imaginile din DB₁




Figura 3.2.7 Distanța euclidiană, percentila și pragul de binarizare determinate pentru fiecare dintre imaginile din DB_2

3.3 Soluție extinsă care combină abordările anterioare și introduce o nouă buclă de reacție negativă, menită să asigure selecția conturului cu gradul maxim de circularitate drept candidat final pentru pupila detectată - Algoritmul DualFeedback

Figura 3.3.1 ilustrează organigrama algoritmului DualFeedback [22]. Figura 3.3.2 ilustrează ratele de detecție de la 1 la 10 pixeli calculate prin utilizarea algoritmului propus față de cele ale algoritmului state-of-the-art ExCuSe [18]. Figura 3.3.3 prezintă eroarea obținută de algoritmul propus pentru imaginile incluse în bazele de date.




Figura 3.3.1 Organigrama algoritmului DualFeedback

În Figura 3.3.4 este reprezentată percentila utilizată prin metoda ce stabilește pragul de binarizare optim pentru fiecare dintre imaginile oculare. Figura 3.3.5 prezintă valoarea finală a pragului utilizat pentru a binariza fiecare imagine a ochiului. Figura 3.3.6 prezintă valoarea toleranței de compactanță obținută de bucla de reacție care asigură că cel mai compact contur este selectat ca pupilă.




Figura 3.3.2 Rata de detecție obținută de ExCuSe și de algoritmul propus DualFeedback




Figura 3.3.3 Distanța euclidiană in fiecare dintre imaginile din DB_1 și DB_2




Figura 3.3.4 Cuantila pentru fiecare dintre imaginile din DB_1 și DB_2




Figura 3.3.5 Pragul de binarizare utilizat pentru fiecare dintre imaginile din DB_1 și DB_2




Figura 3.3.6 Pragul de compactanță rezultat pentru fiecare dintre imaginile din DB_1 și DB_2

Tabelul 3.3.1 – Rezultate experimentale DualFeedback

Parametrul măsurat	ExCuSe [7]		ThresholdRef		PercentileEdge		DualFeedback	
	DB_1	DB_2	DB_1	DB_2	DB_1	DB_2	DB_1	DB_2
DR_5 [%]	77,5	73,75	88,00	98,50	88,5	96,5	91,75	98,5
$\bar{d}$ [px]	11,56	14,68	2,75	2,12	2,72	2,18	2,56	2,05
σ_d [px]	68,87	50,69	1,99	1,69	2,14	1,72	1,73	1,18
frame rate [fps]	19,05	19,03	42,11	47,06	29,67	35,27	28,12	35,93

3.4 Algoritm inovator bazat pe funcții de proiecție integrală unghiulară multiple, menit să evidențieze trăsături geometrice relevante pentru localizarea pupilei într-o varietate de condiții - Algoritmul MultiAngleProjection

Pentru a calcula poziția centrului pupilei, sunt luate în considerare următoarele cazuri:

- (1) mai întâi, sunt utilizate doar funcțiile de proiecție orizontală și verticală (HVIPF) pe imaginea binarizată a ochiului pentru a calcula histogramele corespunzătoare orizontale și verticale, ilustrate în Figurile 3.4.2 (a) și (b);

- (2) sunt utilizate șase unghiuri ale razelor distribuite uniform pentru a calcula, folosind AIPF, histograma corespunzătoare celor șase unghiuri de orientare θ (Fixed 6AIPF);

- (3) sunt utilizate șase unghiuri ale razelor distribuite aleatoriu (prin rotirea celor șase raze distribuite uniform cu o valoare de offset aleatorie) pentru a calcula, folosind AIPF, histograma corespunzătoare celor șase unghiuri de orientare θ (RandOff 6AIPF);




Figura 3.4.1 Determinarea liniilor într-o anumită direcție ($\theta = 30^\circ$) din punctele de ancorare

În Tabelele 3.4.1 – 3.4.3 sunt prezentate acuratețea detecției în limita a 5 pixeli (DR_5), valoarea medie ($\bar{d}$) și deviația standard (σ_d) a distanței Euclidiene.

Tabelul 3.4.1 Rezultate experimentale MultiAngleProjection obținute pe baza de date DB_1

Parametrul măsurat	DB_1					
	<i>ExCuSe</i>	<i>HVIPF</i>	<i>Fixed 6AIPF3i</i>	<i>Fixed 6AIPF2i</i>	<i>RandOff 6AIPF3i</i>	<i>RandOff 6AIPF2i</i>
DR_5 [%]	77,50	84,75	86,50	86,75	86,75	87,00
$\bar{d}$ [px]	11,5600	3,2166	3,0827	3,1406	3,0889	3,1064
σ_d [px]	68,8700	3,0309	2,5776	2,6547	2,5653	2,5515

Tabelul 3.4.2 Rezultate experimentale MultiAngleProjection obținute pe baza de date DB_2

Parametrul măsurat	DB_2					
	<i>ExCuSe</i>	<i>HVIPF</i>	<i>Fixed 6AIPF3i</i>	<i>Fixed 6AIPF2i</i>	<i>RandOff 6AIPF3i</i>	<i>RandOff 6AIPF2i</i>
DR_5 [%]	73,75	87,00	90,25	89,25	89,50	89,50
$\bar{d}$ [px]	14,6800	3,2113	3,1292	3,1315	3,1290	3,1378
σ_d [px]	50,6900	2,2406	2,1582	2,0965	2,1703	2,0702

Tabelul 3.4.3 Rezultate experimentale MultiAngleProjection obținute pe baza de date DB_3

Parametrul măsurat	DB_3					
	<i>ExCuSe</i>	<i>HVIPF</i>	<i>Fixed 6AIPF3i</i>	<i>Fixed 6AIPF2i</i>	<i>RandOff 6AIPF3i</i>	<i>RandOff 6AIPF2i</i>
DR_5 [%]	79,9600	83,7786	84,9237	83,9695	83,2061	82,2519
$\bar{d}$ [px]	12,3800	6,0002	5,9987	5,9735	5,9856	5,9999
σ_d [px]	38,1000	20,7455	20,9648	21,0183	20,9487	20,8906




Figura 3.4.2 Histogramele rezultate din procesarea AIPF pe șase orientări distribuite uniform pe imaginea binarizată a ochiului ($\theta = 0^\circ, 90^\circ, 30^\circ, 120^\circ, 60^\circ, 150^\circ$)




Figura 3.4.3 Raze fixe optime care rezultă din procesarea AIPF pe șase valori distribuite uniform ale unghiului θ ($\theta = 0^\circ, 30^\circ, 60^\circ, 90^\circ, 120^\circ, 150^\circ$)




Figura 3.4.4 Raze optime care rezultă din procesarea AIPF pe șase valori ale unghiului θ , prin rotirea celor șase direcții distribuite uniform cu un offset aleator




Figura 3.4.5 Rata de detecție pentru PDA-urile propuse și ExCuSe, rulând pe trei seturi de date ce conțin imagini oculare: DB₁ a), DB₂ b) și DB₃ c)

3.5 Algoritm care combină analiza funcției percentilă cu aplicarea transformatei Hough, obținând astfel o detecție robustă a pupilei prin integrarea metodelor statistice cu tehnici geometrice clasice - Algoritmul HoughPercentile

Algoritmul de detecție a pupilei utilizează transformarea Hough circulară pentru a realiza o detecție precisă a centrului pupilei în situații de iluminare neuniformă și variabilă.

În Figura 3.5.1a este prezentată imaginea ochiului în tonuri de gri, în stare brută. În Figura 3.5.1b se arată imaginea de ochi cu efect de blur, obținută prin filtrarea imaginii brute cu un filtru Gaussian de blur cu $\sigma = 3$. În Figura 3.5.1c este ilustrată imaginea oculare binarizată, iar în Figura 3.5.1d este prezentată imaginea oculare obținută după aplicarea operațiilor de dilatare și eroziune. În Figura 3.5.1e este prezentată imaginea oculare rezultată după aplicarea detectorului de margini LoG asupra imaginii din Figura 3.5.1d. În Figura 3.5.1f este ilustrat conturul și centrul pupilei detectate în imaginea de ochi în tonuri de gri, prin efectuarea transformatei Hough circulare (CHT) pe imaginea de contur din Figura 3.5.1e. În Figura 3.5.3 este prezentată rata de detecție în funcție de erorile de pixeli pentru ambii algoritmi rulați pe fiecare din cele trei baze de date ce conțin imagini oculare. În Figura 3.5.4 sunt ilustrate distanțele euclidiene, d_{DB_i} ($i = 1, 2, 3$) (cunoscute ca eroare în pixeli), obținute de algoritmul propus bazat pe transformata Hough circulară pentru fiecare imagine din setul de date ce conțin imagini oculare.




Figura 3.5.1 Etapele de prelucrare pentru detectarea centrului pupilei utilizând algoritmul HoughPercentile:
a) imaginea ochiului în tonuri de gri brută; b) imaginea ochiului cu efect de blur; c) imaginea ochiului binarizată;
d) imagine rezultată după aplicarea operațiilor morfologice; e) detecția conturului prin aplicarea operatorului Laplace; f) detecția pupilei în imaginea ochiului în tonuri de gri.

Legendă: Linia verde – poziția ideală a centrului; Linia roșie – centrul și conturul pupilei detectate.




Figura 3.5.3 Rata de detecție în funcție de eroarea în pixeli obținută de algoritmi ExCuSe și HoughPercentile propus pentru fiecare imagine din baza de date ce conține imagini oculare




Figura. 3.5.4. Distanța Euclidiană obținută de algoritmul HoughPercentile propus pentru cele 3 baze de date

În Figura 3.5.5 sunt prezentate valorile razei, rad_{DB_i} ($i = 1, 2, 3$), detectate de algoritmul propus bazat pe transformata Hough circulară pentru imagine din baza de date, cu imagini oculare.




Figura 3.5.5 Valorile razei detectate de algoritmul propus HoughPercentile pentru cele trei baze de date

În Tabelul 3.5.1 sunt prezentați comparativ câțiva indicatori statistici (DR_5 , valoarea medie a distanței euclidiene ($\bar{d}$) și deviația standard (σ_d) precum și valoarea medie a razei pupilei detectate, $\overline{rad}$) furnizați de ambii algoritmi analizați.

Tabelul 3.5.1 Rezultate experimentale ale algoritmului HoughPercentile propus

Parametrul măsurat	ExCuSe			Algoritmul HoughPercentile propus		
	DB ₁	DB ₂	DB ₃	DB ₁	DB ₂	DB ₃
DR_5 [%]	77,50	73,75	79.96	87,00	91,00	82,44
$\bar{d}$ [px]	11,56	14,68	12,38	3,37	2,91	3,53
σ_d [px]	68,87	50,69	38,10	3,47	3,89	4,57
$\overline{rad}$ [px]	-	-	-	24,74	31,59	24,27

3.6 Algoritm bazat pe analiza descriptorilor Fourier ai conturului, care utilizează semnătura frecvențială a formei pentru a identifica pupila pe baza caracteristicilor sale de simetrie și regularitate- Algoritmul FourierContour

Pragul optim al metricii THD utilizate este rafinat printr-un mecanism de tip *feedback loop*, prezentat în diagrama de flux din Figura 3.6.1.




Figura 3.6.1 Diagrama algoritmului FourierContour

Rezultatele experimentale obținute se compară cu cele realizate de algoritmul de referință ExCuSe [18] și, de asemenea, cu cele obținute de algoritmul CHT propus în [23].




Figura 3.6.2 Rata de detecție în funcție de erorile de pixel obținută de ExCuSe și de algoritmul propus pentru bazele de date ce conțin imagini ale ochilor




Figura. 3.6.3 Rata de detecție în funcție de erorile de pixel obținută de HoughPercentile și de algoritmul propus pentru cele trei baze de date ce conțin imagini ale ochilor




Figura. 3.6.4 Distanța euclidiană obținută de PDA-ul propus pentru cele trei baze de date

Tabelul 3.6.1 Rezultatele experimentale ale algoritmului FourierContour

Parametrul măsurat	ExCuSe [12]			Algoritmul FourierContour		
	DB ₁	DB ₂	DB ₃	DB ₁	DB ₂	DB ₃
DR_5 [%]	77,50	73,75	79,96	85,75	86,5	85,87
$\bar{d}$ [px]	11,56	14,68	12,38	2,87	3,40	3,10
σ_d [px]	68,87	50,69	38,10	2,39	4,62	2,51

În Tabelul 3.6.1 sunt prezentați mai mulți indicatori statistici, cum ar fi acuratețea detecției în limita a 5 pixeli, valoarea medie și deviația standard a distanței euclidiene pentru toți algoritmii analizați.

Capitolul IV

Contribuții la dezvoltarea algoritmilor de detecție a pupilei bazați pe machine learning

4.1 Elaborarea unui algoritm hibrid pentru detecția pupilei în aplicații de urmărire în timp real a direcției privirii - HybridPercentile

Această subsecțiune prezintă un algoritm hibrid inovator [26] (HybridPercentile) pentru identificarea pupilei, care îmbină avantajele tehnologiilor AI cu metode tradiționale de prelucrare a imaginilor.




Figura 4.1.1 Structura rețelei neuronale convoluționale proiectate pentru estimarea automată a pragului de binarizare în procesul de detecție a pupilei

Diagrama detaliată a algoritmului PDA este ilustrată în Figura 4.1.2.




Figura 4.1.2 Schema funcțională a algoritmului folosit pentru validarea tehnicii de binarizare




Figura 4.1.3 Ratele de detecție determinate pentru bazele de date DB₁ (simbol '^'), DB₂ (simbol 'o') și DSXII (simbol 'v')




Figura 4.1.4 Distanța Euclideană pentru imaginile incluse în setul de date DB₁




Figura 4.1.5 Distanța Euclideană pentru imaginile incluse în setul de date DB₂




Figura 4.1.6 Distanța Euclideană pentru imaginile incluse în baza de date DSXII

Performanța algoritmului propus a fost evaluată prin comparație cu algoritmul de referință ExCuSe.

Tabelul 4.1.1 Rezultate experimentale ale algoritmului HybridPercentile

Parametrul măsurat	ExCuSe			Algoritmul HybridPercentile		
	DB ₁	DB ₂	DS XII	DB ₁	DB ₂	DS XII
DR_5 [%]	77,5	73,75	79,96	89,75	96,0	85,87
$\bar{d}$ [px]	11,56	14,68	12,38	2,71	2,23	3,10
σ_d [px]	68,87	50,69	38,10	2,26	1,85	2,61
Frame rate [fps]	19,05	19,03	19,01	59,17	95,69	127,18

4.2 Detecția centrului pupilei în imagini de mică rezoluție utilizând metode de inteligență artificială (AI4LowRes)

Figura 4.2.1 ilustrează arhitectura sistemului propus în [77] pentru detecția centrului pupilei, optimizat pentru imagini ale ochiului de rezoluție redusă.



Figura 4.2.1 Organigrama algoritmului AI4LowRes

Primul pas în cadrul unei aplicații de găsire a centrului pupilei utilizând un clasificador este adunarea și marcarea seturilor de date.




Figura 4.2.2 Imaginea ochiului în forma sa originală versus imaginea procesată la rezoluție scăzută

Fiecare poziție posibilă a centrului pupilei în imaginea de 20×15 pixeli este tratată ca o clasă separată, rezultând un total de 300 de clase.

Arhitectura rețelei, prezentată în Figura 4.2.4, pornește de la un strat de intrare care codifică intensitățile normalizate ale pixelilor în tonuri de gri.




Figura 4.2.4 Diagrama arhitecturală a clasificatorului bazat pe rețea neuronală

Figura 4.2.5 prezintă evoluția acurateței pe seturile de validare și testare în funcție de numărul epocilor, iar Figura 4.2.6 ilustrează modificarea valorii funcției de cost de-a lungul antrenamentului.




Figura 4.2.5 Evoluția acurateței pe seturile de validare (▲) și testare (●) în funcție de numărul epocilor




Figura 4.2.6 Modificarea valorii funcției de cost de-a lungul antrenamentului

Pentru evaluarea acurateții sistemului propus, s-a efectuat inferența pe aproximativ 39000 de imagini provenite din 18 seturi de date.




Figura 4.2.7 a) Distanța Euclideană pe imaginile din DSI b) Rata de detecție pe imaginile din DSI




Figura 4.2.8 a) Distanța Euclideană pe imaginile din DSII b) Rata de detecție pe imaginile din DSII




Figura 4.2.24 a) Distanța Euclideană pe imagini din DS SWIRSKI și b) Rata de detecție pe imaginile din DS SWIRSKI




Figura 4.2.25 a) Distanța Euclidiană pe fiecare imagine oculară din cele 18 seturi de date; b) Rata de detecție pe cele 18 seturi de date

Tabelul 4.2.1 Rezultatele inferenței AI4LowRes

Set de date	Numărul de imagini	DR ₀	DR ₂	σ	Descrierea imaginilor
DSI	6554	81,85	99,86	0,41	Reflexii
DSII	505	82,17	99,60	0,44	Reflexii, iluminare slabă
DSIII	9799	86,60	99,83	0,40	Iluminare slabă erori de înregistrare, reflexii
DSIV	2655	88,51	99,88	0,34	Lentile contact, iluminare proastă
DSV	2135	86,79	99,90	0,35	Lentile de contact alunecate
DSVI	4400	88,00	99,81	0,37	Iluminare slabă, rimel
DSVII	4890	83,47	99,73	0,43	Iluminare slabă, rimel, tuș
DSVIII	630	81,58	93,80	1,08	Iluminare slabă, gene
DSIX	2831	83,43	99,61	0,44	Reflexii, puncte negre suplimentare
DSX	840	86,78	99,87	0,47	Iluminare slabă, pupilă în marginea imaginii
DSXI	655	88,24	100	0,33	Reflexii, iluminare slabă, puncte negre
DSXII	524	82,44	100	0,41	Iluminare slabă
DSXIII	491	73,52	99,59	0,49	Iluminare slabă, gene
DSXIV	469	78,25	99,78	0,48	Iluminare slabă
DSXV	363	82,64	98,89	0,45	Lentile deplasate
DSXVI	392	77,55	100	0,44	Gene, rimel, tuș
DSXVII	268	84,70	100	0,39	Iluminare slabă, gene
SWIRSKI	600	89,83	99,5	0,39	Imagini dezaxate, gene
TOTAL	39001	84,96	99,70	0,42	Toate bazele de date

4.3 Detecția centrului pupilei pe imagini de înaltă rezoluție folosind tehnici de inteligență artificială - XY-Classifier

În continuare se prezintă implementarea unui sistem AI - XY-Classifier pentru detecția centrului pupilei [78,79], proiectat să funcționeze în timp real și să se adapteze la variații de iluminare. Soluția se bazează pe o arhitectură paralelă cu doi clasificatori independenți, fiecare construit ca o rețea neuronală „slim” ale cărei clase corespund pozițiilor posibile ale pupilei în cadrul imaginii oculare. Pentru a menține complexitatea redusă, cei doi clasificatori procesează simultan imaginea de intrare și furnizează coordonatele pupilei, combinându-și rezultatele pentru o estimare finală robustă.

Pentru a depăși aceste constrângeri, se propune un sistem eficient în ceea ce privește consumul de resurse pentru imagini oculare de 320×240 pixeli. După conversia în tonuri de gri și redimensionarea la rezoluție înaltă, fiecare cadru este procesat de doi clasificatori independenți, construiți ca rețele neuronale „slim”, care estimează separat coordonatele pe orizontală și pe verticală ale centrului pupilei (Figura 4.3.1).




Figura 4.3.1 Structura sistemului XY-Classifier

Principiul descris anterior este reprezentat schematic în Figura 4.3.2, pentru o imagine cu dimensiunile h pixeli pe orizontală și v pixeli pe verticală. Valorile de intensitate ale pixelilor în tonuri de gri din imaginea ochiului sunt transmise simultan către cei doi clasificatori.




Figura 4.3.2 Arhitectura sistemului XY-Classifier

Arhitectura CNN dezvoltată pentru detecția coordonatei x este prezentată în Figura 4.3.3:




Figura 4.3.3 Arhitectura clasificatorului CNN utilizat pentru estimarea abscisei centrului pupilei

Arhitectura clasificatorului utilizat pentru detectarea coordonatei y este prezentată în Figura 4.3.4.






Figura 4.3.4 Arhitectura clasificatorului utilizat pentru detecția ordonatei centrului pupilei

Procesul de antrenare a folosit coborârea în gradient stocastic, după cum se ilustrează în Figurile 4.3.5a și 4.3.5b.




a)




b)

Figura 4.3.5 Acuratețea pe seturile de validare (^) și testare (o) pe parcursul antrenamentului pentru Clasificatorul X a) și Clasificatorul Y b)


Rezultatele inferenței pe fiecare set de date sunt ilustrate în Figura 4.3.6.




a1)




b1)



c1)



p2) q2) r2)
Figura 4.3.6 Distanța Euclideană pentru imaginile din bazele de date: a1) ... t1) - DB₁ ... DSXVII. Rata de detecție în imaginile oculare din bazele de date: a2) ... t2) - DB₁ ... DSXVII



a) b)
Figura 4.3.7 Rezultatele inferenței pentru cele 20 de seturi de date: a) distanța euclidiană pentru fiecare imagine din cele aproximativ 40000 și b) rata de detecție pentru imaginile din toate seturile de date

XY-Classifier a fost comparat cu alte soluții de clasificare după numărul de parametri ai rețelei neuronale, așa cum se arată în Tabelul 4.3.2.

Tabelul 4.3.2 Număr parametri antrenabili ai XY-Classifier în comparație cu alte implementări bazate pe inteligență artificială

Model	Nr. de parametri
LeNet5 [6]	1742431
AlexNet [7]	15906511
DenseNet [8]	9860431
ResNet [9]	42530895
Vgg16 [10]	15120975
VIT [11]	1073485056
Convnext [12]	27810255
Swin-T [13]	28265032
SqueezeNet [14]	1248424
MobileNet [15]	3222351
Shufflenet [16]	911529
PONet [5]	4950671
X -Classifier - propus	858990
Y - Classifier - propus	695150

Din rezultate prezentate în Tabelul 4.3.1, se poate observa că soluția propusă prezintă performanțe superioare.

Tabelul 4.3.1 Rezultatele obținute de XY-Classfier în comparație cu ExCuSe, ELSE, Świrski și PupilNet v2.0

Set de date	Nr. frameuri	DR ₅ [%]							Deviația standard [pixeli]	Descriere
		PDA ExCuSe	PDA ElSe	PDA Świrski	PupilNet v 2.0			Soluția propusă		
					SK_8P_8	$F_{CK_xP_y}$	$F_{SK_xP_y}$			
DB 1	400	82,25	-	-	-	-	-	99	1,95	Capturi cu diverse dispozitive locale
DB2	400	84,25	-	-	-	-	-	96	3,58	Iris Casia Lamp
DB3	600	86,17	82,00	77,17	-	-	-	97,66	2,77	Setul Świrski
DSI	6554	70,95	85,52	5,11	77	78	82	95,51	2,59	Reflexii
DSII	505	34,26	65,35	26,34	80	79	79	92,27	3,41	Reflexii, iluminare slabă
DSIII	9799	39,44	63,60	6,81	62	60	66	97,97	2,73	Reflexii, iluminare slabă, erori de înregistrare
DSIV	2655	81,58	83,24	34,54	90	90	92	97,36	3,37	Lentile de contact, iluminare slabă
DSV	2135	77,28	84,87	77,85	91	89	92	97,56	3,15	Lentile de contact ce sunt deplasate
DSVI	4400	53,18	77,52	19,34	73	78	79	96,88	3,1	Iluminare slabă, rimel, tuș
DSVII	4890	46,91	59,51	39,35	73	80	73	93,29	3,82	Iluminare slabă, rimel, fard
DSVIII	630	56,83	68,41	41,90	84	83	81	94,44	6,83	Iluminare slabă, gene
DSIX	2831	74,96	86,72	24,09	86	86	86	97,03	3,4	Reflexii, punct negru
DSX	840	79,76	78,93	29,88	80	78	81	95,87	2,58	Iluminare slabă, pupilă în marginea imaginii
DSXI	655	56,49	75,27	20,31	85	74	91	98,47	3,94	Reflexii, iluminare slabă, puncte negre suplimentar
DSXII	524	79,20	79,39	71,37	87	85	85	93,85	3,3	Iluminare slabă
DSXIII	491	70,26	73,52	61,51	79	81	83	91,64	8,22	Iluminare slabă, gene
DSXIV	469	57,57	84,22	53,30	91	94	95	94,66	5,28	Iluminare proastă
DSXV	363	52,34	57,30	60,88	81	71	81	96,41	1,94	Lentile de contact ce sunt deplasate
DSXVI	392	49,49	59,95	17,86	80	72	80	90,05	7,81	Rimel, gene
DSXVII	268	77,99	89,55	70,90	99	87	97	96,64	1,71	Iluminare slabă, gene

Capitolul V - Concluzii

Teza de față s-a născut din dorința de a aduce o contribuție reală și relevantă într-un domeniu de cercetare aflat într-o continuă expansiune: detecția privirii și utilizarea acesteia în interfețele om-mașină. Într-un context în care tehnologia devine din ce în ce mai prezentă în viața cotidiană, capacitatea sistemelor informatice de a interpreta intențiile și direcțiile de atenție ale utilizatorilor umani a căpătat o importanță deosebită. Detectarea automată și precisă a centrului pupilei reprezintă o componentă esențială în arhitectura acestor sisteme, fiind o punte între percepția vizuală și interacțiunea digitală.

5.1 Privire generală asupra structurii lucrării

Teza este structurată în mod logic în mai multe capitole care reflectă traseul parcurs de cercetare: de la fundamentele teoretice ale domeniului, până la propunerea și validarea unor soluții concrete, inovatoare, destinate utilizării în condiții reale, în sisteme cu procesare în timp real.

Primul capitol oferă un cadru introductiv amplu și bine documentat privind tehnologiile de „eye-tracking”.

Al doilea capitol este dedicat analizei critice a unor algoritmi definitorii pentru evoluția domeniului.

În al treilea capitol, sunt prezentate în detaliu o serie de algoritmi propuși de autor, care se bazează pe prelucrarea caracteristicilor imaginii și nu implică utilizarea metodelor de inteligență artificială.

Al patrulea capitol aduce în prim-plan componentele bazate pe inteligență artificială. Se propune o arhitectură originală, alcătuită din două clasificatoare „slim”, fiecare dedicat detecției unei coordonate (x sau y) a centrului pupilei.

Ultimul capitol sintetizează toate aceste realizări și deschide calea unor direcții viitoare de cercetare, care pornesc natural din experiența acumulată și rezultatele obținute.

5.2 Contribuții originale

Pe parcursul acestei cercetări, s-au realizat o serie de contribuții științifice semnificative, concretizate în algoritmi propuși, arhitecturi inovatoare și evaluări riguroase, recunoscute prin publicarea în conferințe și reviste de prestigiu. Printre aceste contribuții se numără:

1. **O abordare robustă pentru interfețele om-mașină**, bazată pe un sistem de detecție a pupilei tolerant la reflexii și condiții variabile – **ThresholdRef** [ISSCS 2019].
2. **Un algoritm ce propune o tehnică nouă de binarizare**, în care pragul optim este determinat prin analiza proprietăților funcției percentilă, cu scopul de a obține o segmentare cât mai precisă a regiunii pupilei - Algoritmul **PercentileEdge** [EHB 2019].
3. **Un algoritm robust de detecție a pupilei** centrat pe noua procedură de binarizare adaptivă, care utilizează o buclă de reacție negativă și o metrică de circularitate – **DualFeedback** [SIITME 2019].
4. **Un nou algoritm bazat pe proiecții integrale unghiulare multiple**, conceput pentru a depăși limitările metodelor clasice de proiecție – **MultiAngleProjection** [EHB 2021].
5. **Un algoritm de detecție bazat pe transformata Hough circulară**, care redefinește criteriile de selecție pentru cercurile candidate – **Algoritmul HoughPercentile** [SIITME 2019].
6. **O metodă originală de detecție a pupilei prin analiza descriptorilor Fourier ai conturului**, ce permite o identificare precisă chiar și în prezența deformărilor conturului – **FourierContour** [SIITME 2020].
7. **Un algoritm hibrid pentru detecția pupilei în aplicații de urmărire în timp real a direcției privirii**, **HybridPercentile** [EHB 2023].
8. **O arhitectură de rețea neuronală complet conectată**, antrenată pe imagini de mică rezoluție (20×15 px), cu un strat de ieșire softmax care identifică direct poziția centrului pupilei – **AI4LowRes** [BIPI – în curs de publicare].
9. **Un sistem AI complet cu două rețele convoluționale slim, capabile să detecteze separat coordonatele x și respectiv y ale centrului pupilei în imagini de înaltă rezoluție**, păstrând totodată un număr mic de parametri antrenabili – **XY-Classifier** [Sensors 2024].
10. **O evaluare experimentală riguroasă** pe 20 de seturi de date distincte, ce conțin imagini obținute cu interfețe și condiții extrem de variate (inclusiv reflexii, lentile de contact, machiaj, iluminare slabă, obstrucții).

Aceste contribuții nu doar că aduc îmbunătățiri semnificative față de metodele existente, dar oferă și o bază solidă pentru extinderea ulterioară a cercetării.

5.3 Direcții de cercetare viitoare

Pornind de la rezultatele obținute și de la experiența acumulată în timpul dezvoltării acestor sisteme, se conturează în mod natural mai multe direcții promițătoare de cercetare:

- **Extinderea și diversificarea bazelor de date** folosite pentru antrenament, prin includerea unor categorii mai variate de subiecți (vârstă, etnie, particularități fiziologice) și scenarii de utilizare (de exemplu, utilizatori cu afecțiuni neurologice sau în medii cu vibrații și mișcări bruște).
- **Integrarea cu module de detecție a privirii în spațiu 3D**, pentru aplicații mai avansate precum realitatea augmentată, vehicule autonome sau monitorizarea comportamentului utilizatorilor.
- **Implementarea pe platforme mobile sau embedded pe bază de edge-computing**, astfel încât algoritmi propuși să poată funcționa direct pe dispozitive cu resurse hardware limitate (telefoane, ochelari inteligenți, microcontrolere).
- **Adaptarea arhitecturii AI** pentru a permite sistemului să se ajusteze dinamic la fiecare utilizator, crescând astfel precizia și personalizarea.
- **Explorarea rețelilor de tip transformer** sau a rețelilor hibride CNN-RNN pentru captarea relațiilor temporale în secvențele de imagini oculare.
- **Determinarea stării cognitive a subiectului monitorizat** - Algoritmi propuși ar putea fi utilizați pentru estimarea încărcării cognitive percepute, pe baza tehnicilor de urmărire a privirii.

Această teză demonstrează că soluțiile ce se bazează pe inteligență artificială pot fi nu doar o alternativă, ci o soluție matură și scalabilă la provocările detecției pupilei în aplicațiile moderne de eye-tracking. Prin abordarea sistematică a problemelor de acuratețe, robustețe, viteză de procesare și portabilitate, se oferă o contribuție valoroasă la dezvoltarea tehnologiilor de interfață om-mașină și deschide drumul spre noi cercetări și aplicații, tot mai aproape de interacțiunea naturală dintre om și mașină.

Lista lucrărilor științifice publicate

1. **P. Bonteanu**, A. Cracan, R. G. Bozomitu and G. Bonteanu, “A New Robust Pupil Detection Algorithm for Eye Tracking Based Human- Computer Interface”, **ISSCS 2019** proc., Iasi, Romania, 2019, pp. 1-4;
2. **P. Bonteanu**, A. Cracan, R. G. Bozomitu and G. Bonteanu, “A Robust Pupil Detection Algorithm Based on a New Adaptive Thresholding Procedure”, **EHB 2019** proc., Iași, Romania, November 21-23, 2019;
3. **P. Bonteanu**, A. Cracan, G. Bonteanu, R. G. Bozomitu, “A High Detection Rate Pupil Detection Algorithm Based on Contour Circularity Evaluation”, **SIITME 2019**;
4. **P. Bonteanu**, R. G. Bozomitu, A. Cracan, G. Bonteanu, “A New Pupil Detection Algorithm Based on Circular Hough Transform Approaches”, **SIITME 2019** proc., pag. 171-172, Cluj-Napoca, October 23 – 26, 2019;
5. **P. Bonteanu**, A. Cracan, R. G. Bozomitu and G. Bonteanu, P. Bonteanu, R. G. Bozomitu, A. Cracan and G. Bonteanu, "A Pupil Detection Algorithm Based on Contour Fourier Descriptors Analysis," 2020 IEEE 26th International Symposium for Design and Technology in Electronic Packaging (**SIITME 2020**), Pitesti, Romania, 2020, pp. 98-101;
6. **P. Bonteanu**, A. Cracan, G. Bonteanu, R. G. Bozomitu, “A New Pupil Detection Algorithm Based on Multiple Angular Integral Projection Functions”, **EHB 2021**;
7. Bonteanu, G., **Bonteanu, P.**, Cracan, A., Bozomitu, R.G. (2024). A New Hybrid Pupil Detection Algorithm for Real Time Applications. **EHB 2023**. IFMBE Proceedings, vol 111. Springer;
8. G. Bonteanu, **P. Bonteanu**, A. Cracan and R. G. Bozomitu „Pupil detection system implementation for low-resolution eye images based on a fully-connected neural network classifier”, în curs de publicare, bipi.tuiasi.ro/ie/authorDashboard/submission/1092;
9. G. Bonteanu, **P. Bonteanu**, A. Cracan and R. G. Bozomitu, Implementation of a High-Accuracy Neural Network-Based Pupil Detection System for Real-Time and Real-World Applications. **Sensors 2024**, 24, 2548;
10. G. Bonteanu, **P. Bonteanu**, A. Cracan and R. G. Bozomitu, Implementation of a high accuracy pupil detection algorithm using neural networks”, IEEE 29th International Symposium for Design and Technology in Electronic Packaging (**SIITME 2023**), Craiova, Romania, 2023, pp. 147-150;
11. G. Bonteanu, **P. Bonteanu**, A. Cracan, R. G. Bozomitu, **ICDS 2023** – “Neural network classifier based gaze detector”;
12. **P. Bonteanu**, G. Bonteanu, A. Cracan, R. G. Bozomitu, **ICDS 2024** – “ Enhancing Vehicle Assembly with AI-driven Gaze Detection in Augmented Reality Systems”.

Bibliografie selectivă

- [1] A. W. Fitzgibbon, M. Pilu, and R. B. Fisher, "Direct least squares fitting of ellipses," in Proceedings of 13th International Conference on Pattern Recognition, Vienna, Austria, 1996, vol. 1, pp. 253–257;
- [2] D. Li and J. D. Parkhurst, "Starburst: A robust algorithm for video-based eye tracking," in Proceedings of the IEEE Vision for Human-Computer Interaction Workshop, 2005;
- [3] M. Asadifard and J. Shanbezadeh, "Automatic adaptive center of pupil detection using face detection and CDF analysis," in Proceedings of the international multiconference of engineers and computer scientists, 2010, vol. 1, p. 3;
- [4] L. Świrski, A. Bulling, and N. Dodgson, "Robust real-time pupil tracking in highly off-axis images," in Proceedings of the Symposium on Eye Tracking Research and Applications, Santa Barbara, California, 2012, pp. 173–176;
- [5] N. Cherabit, F. Z. Chelali, and A. Djeradi, "Circular hough transform for iris localization," Science and Technology, vol. 2, no. 5, pp. 114–121, 2012;
- [6] W. Fuhl, T. Santini, G. Kasneci, and E. Kasneci, "Pupilnet: Convolutional neural networks for robust pupil detection," arXiv preprint arXiv:1601.04902, 2016;
- [7] G. S. Robinson, "Edge detection by compass gradient masks," Computer graphics and image processing, vol. 6, no. 5, pp. 492–501, 1977;
- [8] J. Canny, "A computational approach to edge detection," IEEE Transactions on pattern analysis and machine intelligence, no. 6, pp. 679–698, 1986;
- [9] I. Sobel and G. Feldman, "An Isotropic 3x3 Image Gradient Operator for Image Processing," Mach. Vis. Three–Dimens. Scenes, no. June, pp. 376–379, 1968;
- [10] R. A. Kirsch, "Computer determination of the constituent structure of biological images," Computers and biomedical research, vol. 4, no. 3, pp. 315–328, 1971;
- [11] L. Roberts, Machine perception of 3-D solids, optical and electro-optical information processing. MIT press Cambridge (MA), 1965;
- [12] J. M. Prewitt, "Object enhancement and extraction," Picture processing and Psychopictorics, vol. 10, no. 1, pp. 15–19, 1970;
- [13] Santini, T.; Fuhl, W.; Kasneci, E. PuReST: Robust pupil tracking for real-time pervasive eye tracking. In Proceedings of the 2018 ACM Symposium on Eye Tracking Research & Applications, Warsaw, Poland, 14–17 June 2018; p. 61;
- [14] Fuhl, W.; Santini, T.; Kasneci, G.; Rosenstiel, W.; Kasneci, E. PupilNet v2.0: Convolutional Neural Networks for CPU based real time Robust Pupil Detection;
- [15] Xiong, J.; Zhang, Z.; Wang, C.; Cen, J.; Wang, Q.; Nie, J. Pupil localization algorithm based on lightweight convolutional neural network. Vis. Comput. 2024, 1–17;
- [16] M. Hnatiuc and G. Lamarque, "Implementation of neural network with approximations functions," in Signals, Circuits and Systems, 2003. SCS 2003. International Symposium on, 2003, vol. 2, pp. 553–556;
- [17] OpenCV, Open Source Computer Vision, <https://docs.opencv.org/3.4.1/>;
- [18] W. Fuhl, T. Kübler, K. Sippel, W. Rosenstiel, and E. Kasneci, "Excuse: Robust pupil detection in real-world scenarios," in Intern. Conference on Computer Analysis of Images and Patterns, 2015, pp. 39–51;

- [19] Fuhl, W.; Santini, T.C.; Kübler, T.; Kasneci, E. Else: Ellipse selection for robust pupil detection in real-world environments. In Proceedings of the 9th Biennial ACM Symposium on Eye Tracking Research & Applications, Charleston, SC, USA, 14–17 March 2016; pp. 123–130;
- [20] P. Bonteanu, A. Cracan, R. G. Bozomitu and G. Bonteanu, “A New Robust Pupil Detection Algorithm for Eye Tracking Based Human- Computer Interface”, ISSCS 2019 proc., Iasi, Romania, 2019, pp. 1-4;
- [21] P. Bonteanu, A. Cracan, R. G. Bozomitu and G. Bonteanu, “A Robust Pupil Detection Algorithm Based on a New Adaptive Thresholding Procedure”, EHB 2019 proc., Iași, Romania, November 21-23, 2019;
- [22] P. Bonteanu, A. Cracan, G. Bonteanu, R. G. Bozomitu, “A High Detection Rate Pupil Detection Algorithm Based on Contour Circularity Evaluation”, SIITME 2019;
- [23] P. Bonteanu, R. G. Bozomitu, A. Cracan, G. Bonteanu, “A New Pupil Detection Algorithm Based on Circular Hough Transform Approaches”, SIITME 2019 proc., pag. 171-172, Cluj-Napoca, October 23 – 26, 2019;
- [24] P. Bonteanu, A. Cracan, R. G. Bozomitu and G. Bonteanu, P. Bonteanu, R. G. Bozomitu, A. Cracan and G. Bonteanu, "A Pupil Detection Algorithm Based on Contour Fourier Descriptors Analysis," 2020 IEEE 26th International Symposium for Design and Technology in Electronic Packaging (SIITME), Pitesti, Romania, 2020, pp. 98-101;
- [25] P. Bonteanu, A. Cracan, G. Bonteanu, R. G. Bozomitu, “A New Pupil Detection Algorithm Based on Multiple Angular Integral Projection Functions”, EHB 2021;
- [26] Bonteanu, G., Bonteanu, P., Cracan, A., Bozomitu, R.G. (2024). A New Hybrid Pupil Detection Algorithm for Real Time Applications. In: Costin, HN., Magjarević, R., Petroiu, G.G. (eds) Advances in Digital Health and Medical Bioengineering. EHB 2023. IFMBE Proceedings, vol 111. Springer;
- [33] “Casia-Iris-Lamp“, <http://biometrics.idealtest.org/dbDetailForUser.do?id=4;>
- [51] Pupil detection, ExCuSe algorithm, Universitat Tübingen. Available online: <https://www.ti.uni-tuebingen.de/Pupil-detection.1827.0.html?&L=1;>
- [52] Learn DIP, “Digital image processing,” Laplace Operator, <https://www.tutorialspoint.com/dip/index.htm>;
- [77] G. Bonteanu, P. Bonteanu, A. Cracan and R. G. Bozomitu „Pupil detection system implementation for low-resolution eye images based on a fully-connected neural network classifier”, în curs de publicare, bipi.tuiasi.ro/ie/authorDashboard/submission/1092;
- [78] G. Bonteanu, P. Bonteanu, A. Cracan and R. G. Bozomitu, Implementation of a High-Accuracy Neural Network-Based Pupil Detection System for Real-Time and Real-World Applications. Sensors 2024, 24, 2548;
- [79] G. Bonteanu, P. Bonteanu, A. Cracan and R. G. Bozomitu, Implementation of a high accuracy pupil detection algorithm using neural networks”, IEEE 29th International Symposium for Design and Technology in Electronic Packaging (SIITME), Craiova, Romania, 2023, pp. 147-150.