

# TEMA: Aplicații ale vederii artificiale în robotică, tehnici de procesare în vederea artificială, sisteme de vedere artificială pentru conducerea roboților

## Introducere

Vederea artificială (sau computer vision) este un domeniu al inteligenței artificiale care se ocupă cu dezvoltarea algoritmilor și sistemelor capabile să proceseze, analizeze și înțeleagă imagini sau secvențe video pentru a extrage informații semnificative, similare percepției vizuale umane.

## I. Aplicații ale vederii artificiale în robotică

### 1. Navigație și localizare

Navigația și localizarea reprezintă unul dintre cele mai importante domenii în care vederea artificială își găsește aplicații esențiale în robotică. Tehnologii precum camerele stereo și senzorii LiDAR permit roboților să construiască hărți tridimensionale detaliate în timp real, facilitând detectarea și evitarea obstacolelor.

Aceste sisteme sunt integrate cu algoritmi avansați de SLAM (Simultaneous Localization and Mapping), care îmbunătățesc semnificativ precizia navigației în medii complexe, fie că este vorba despre clădiri aglomerate, fie despre spații exterioare cu obstacole imprevizibile. În plus, combinarea datelor vizuale cu informații de la senzori IMU ajută la dezvoltarea roboților autonomi capabili să exploreze medii necunoscute, adaptându-se rapid la schimbările de mediu și luând decizii în timp real.




Figura 1 - Detectarea și evitarea obstacolelor.




Figura 2 - Mapare și localizare simultană (SLAM - Simultaneous Localization and Mapping).




Figura 3 - Urmărirea traseelor în medii structurate sau nestructurate (de exemplu, roboți autonomi).

## 2. Manipulare și control

În domeniul **manipulării și controlului**, vederea artificială facilitează recunoașterea și manipularea obiectelor, indiferent de poziția sau orientarea lor. Sistemele avansate de învățare automată permit roboților să identifice cu precizie diferite tipuri de obiecte, adaptându-se la complexitatea mediului industrial. Brațele robotizate beneficiază de feedback vizual și senzorial în timp real, permițând ajustarea precisă a forței și poziției pentru a manipula componente delicate sau complexe.

Astfel, vederea artificială joacă un rol esențial în automatizarea proceselor industriale, cum ar fi identificarea și asamblarea pieselor, contribuind la eficiența și precizia producției.

*Implementarea sistemelor de învățare automată pentru a recunoaște diferite tipuri de obiecte, indiferent de poziția sau orientarea acestora*



Figura 4 - Asamblare automată în procese industriale (roboți colaborativi). Ajustarea poziției în timp real în funcție de feedback-ul vizual.

## 3. Inspecție și control de calitate

În ceea ce privește **inspecția și controlul de calitate**, vederea artificială revoluționează procesele de fabricație. Aceasta este utilizată pentru a detecta defecte invizibile cu ochiul liber, cum ar fi microfisurile sau variațiile subtile de textură. Integrarea rețelelor neuronale permite analizarea rapidă a imaginilor pentru a identifica neconformități și pentru a lua decizii în timp real.

Monitorizarea continuă a liniilor de producție contribuie la reducerea pierderilor și la creșterea calității produselor finite, eliminând necesitatea inspecțiilor manuale, care sunt adesea lente și inexacte.




Figura 5 - Detectarea defectelor în linii de producție (e.g., fisuri, suprafețe imperfecte). Verificarea dimensiunilor sau conformității produselor.

#### 4. Interacțiune om-robot (HRI - Human-Robot Interaction)

La nivelul **interacțiunii om-robot**, vederea artificială este un instrument cheie pentru dezvoltarea roboților capabili să interacționeze empatic și inteligent cu oamenii. Recunoașterea avansată a emoțiilor și gesturilor umane permite roboților să interpreteze intențiile și să răspundă adecvat, fiind de mare ajutor în asistența persoanelor cu dizabilități sau în medii sociale.

Totodată, aceste sisteme asigură navigația sigură în prezența oamenilor, prevenind coliziunile și facilitând utilizarea roboților în spitale, aeroporturi sau alte spații publice aglomerate.

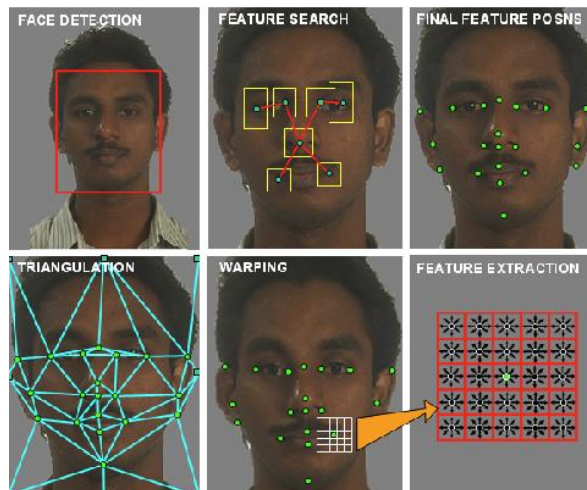


Figura 6 - Recunoașterea gesturilor și expresiilor faciale pentru interpretarea intențiilor umane.



Figura 7 - Detectarea și urmărirea persoanelor.






Figura 8 - Navigație sigură în prezența oamenilor.

## 5. Roboți mobili și vehicule autonome

În cazul **roboților mobili și vehiculelor autonome**, vederea artificială este esențială pentru recunoașterea rapidă a semnelor de circulație, obstacolelor și condițiilor de drum. Algoritmii avansați permit interpretarea în timp real a mediului, inclusiv detectarea gheții, a ploii sau a altor pericole.

Monitorizarea constantă a mediului înconjurător contribuie la siguranța traficului, reducând riscul accidentelor și îmbunătățind eficiența transportului autonom.



Figura 9 - Recunoașterea semnelor de circulație și a altor elemente de mediu.




Figura 10 - Detectarea pietonilor și a altor participanți la trafic. Monitorizarea drumului și interpretarea condițiilor ambientale.

## 6. Roboți agricoli

**Roboții agricoli** beneficiază de vederea artificială pentru a optimiza procesele agricole, cum ar fi identificarea și clasificarea culturilor, recoltarea fructelor și legumelor la maturitatea optimă sau monitorizarea sănătății plantelor. Detectarea timpurie a bolilor sau dăunătorilor este posibilă prin analiză vizuală avansată, contribuind la îmbunătățirea randamentului și reducerea pierderilor.




Figura 11 - Identificarea și recoltarea fructelor sau legumelor.

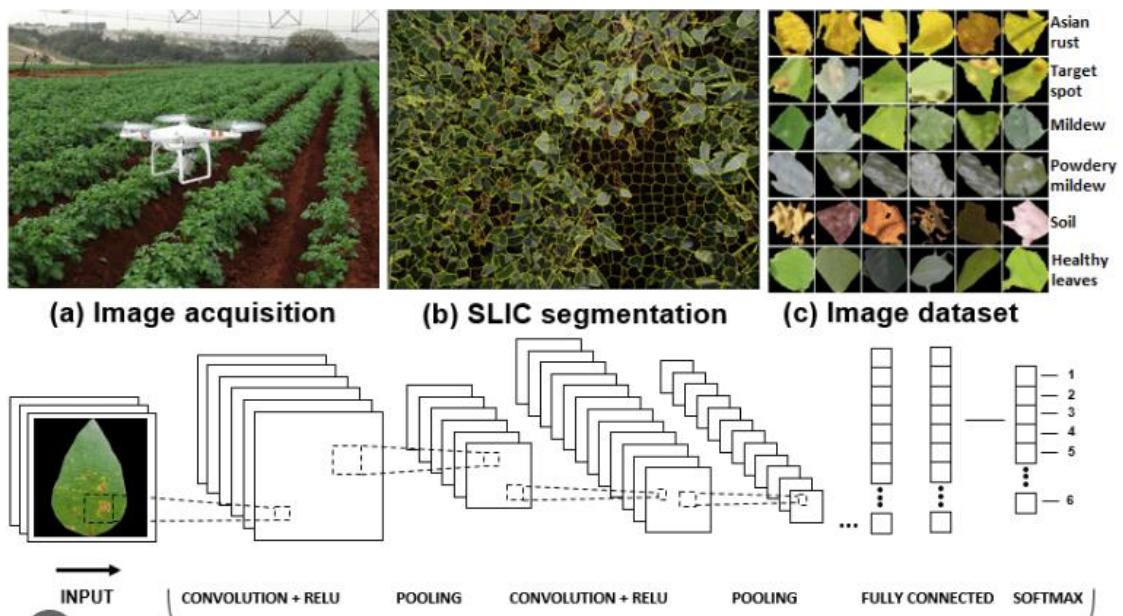


Figura 12 - Monitorizarea sănătății plantelor prin analiză vizuală.

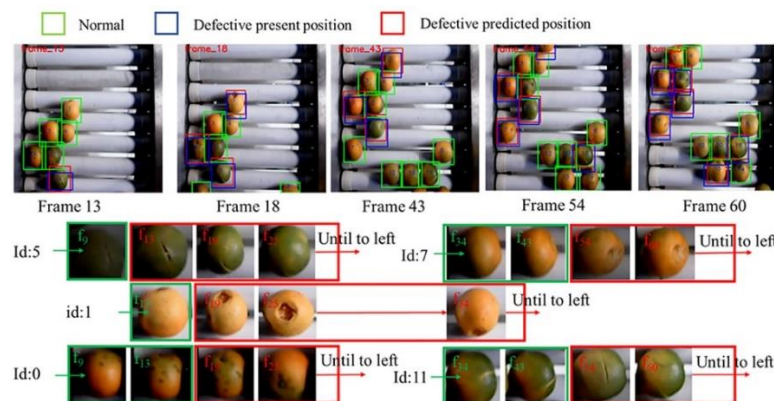


Figura 13 - Detectarea dăunătorilor sau a bolilor.

## 7. Sisteme de securitate și supraveghere





În domeniul roboților medicali, vederea artificială contribuie la ghidarea precisă a instrumentelor chirurgicale, reducând riscurile asociate intervențiilor complexe. Analiza imaginilor medicale, cum ar fi RMN-urile sau tomografiile, facilitează diagnosticarea rapidă, iar monitorizarea vizuală a pacienților permite detectarea timpurie a modificărilor stării lor de sănătate. Astfel, vederea artificială devine un pilon esențial al inovației în domeniul medical.




Figura 17 - Ghidarea roboților chirurgicali prin imagistică.

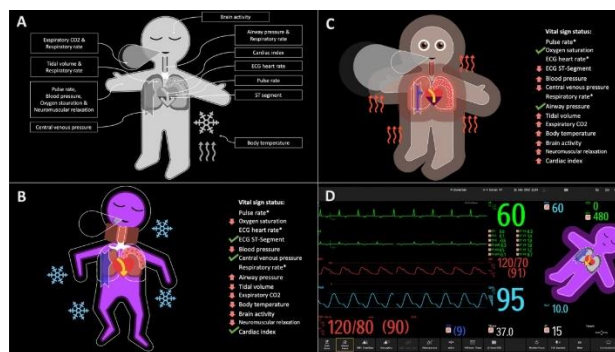


Figura 18 - Monitorizarea pacientului (e.g., analiză vizuală a rănilor).




Figura 19 - Diagnosticare automată prin analiză de imagini medicale.

## 9. Recunoaștere și clasificare de obiecte

**Recunoașterea și clasificarea de obiecte** implică identificarea și sortarea obiectelor pe baza caracteristicilor vizuale, cum ar fi forma, culoarea sau textura. În industrie, este utilizată pentru sortarea automată a materialelor, controlul calității și eficientizarea proceselor. În vehicule autonome, ajută la identificarea semnelor de circulație, pietonilor și altor obstacole, asigurând siguranța.

În robotică mobilă, facilitează manipularea obiectelor, iar în logistică optimizează procesele de inventariere și livrare. De asemenea, este folosită în agricultură pentru recoltare și monitorizarea culturilor, contribuind la productivitate și precizie.



Figura 20 - Identificarea tipurilor de materiale, forme sau culori.



Figura 21 - Clasificarea automată a produselor pe linii de sortare.

## 10. Explorare și operațiuni în medii extreme

**Explorare și operațiuni în medii extreme** reprezintă un domeniu crucial al roboticii, unde vederea artificială ajută roboții să analizeze și să interacționeze cu medii inaccesibile sau periculoase pentru oameni. Roboții subacvatici utilizează camere și senzori pentru a explora oceane, inspecta platforme petroliere sau monitoriza ecosistemele marine. În explorarea spațială, roboții echipați cu sisteme vizuale analizează suprafețele planetare, identificând resurse sau posibile riscuri.

În scenarii de salvare, cum ar fi după cutremure, roboții cu vedere artificială detectează supraviețuitori sau pericole ascunse sub dărâmături. Aceștia pot naviga prin spații înguste, capturând imagini și transmitând informații echipelor de intervenție. Astfel, vederea artificială este esențială pentru a extinde capacitățile umane în medii extreme, îmbunătățind siguranța și eficiența operațiunilor.





Figura 22 - Roboți subacvatici sau spațiali care analizează mediul necunoscut.

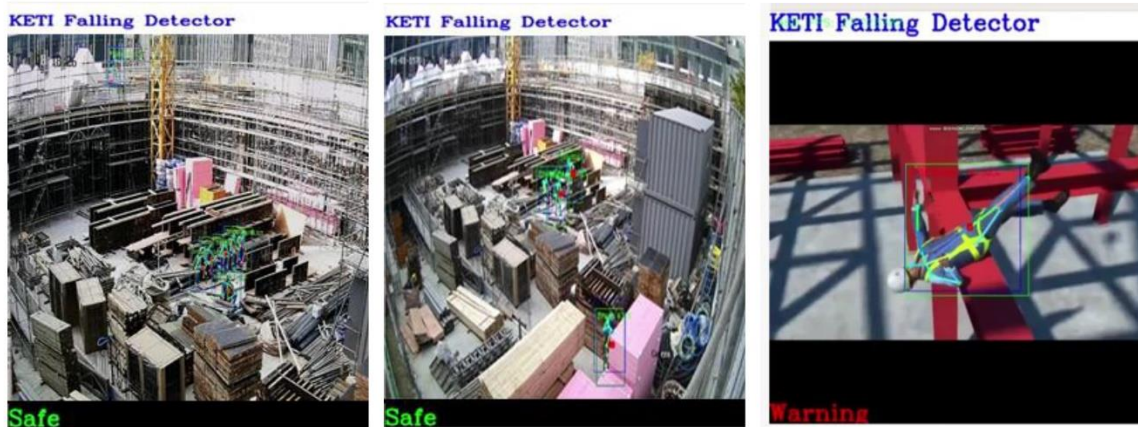


Figura 23 - Detectarea pericolelor sau a obiectivelor de interes în medii periculoase (e.g., salvare după cutremure).

## II. Tehnici de procesare în vederea artificială

### 1. Preprocesare a imaginilor

- **Filtrare spațială:** Aplicarea filtrelor (blur, sharpen, edge detection) pentru îmbunătățirea calității imaginii.




Figura 24 – Aplicarea filtrelor. A) – Sharpen. B) – Edge detection

Blurred Image



Figura 25 – Aplicarea filtrului Blurred Image

- **Transformarea în nivele de gri:** Reducerea imaginii color la o singură dimensiune (intensitate).




Figura 26 - Transformarea în nivele de gri

- **Normalizarea și scalarea:** Ajustarea valorilor pixelilor pentru a îmbunătăți contrastul.





Figura 27 - Normalizarea și scalarea



- **Binarizarea:** Conversia unei imagini în alb-negru pe baza unui prag (thresholding).




*Figura 28 - Binarizarea*

- **Corectarea distorsiunii:** Eliminarea erorilor optice din imagini.



*Figura 29 – Corectarea distorsiunii*

- **Reducerea zgomotului:** Tehnici precum filtrul mediu, gaussian sau median.



*Figura 30 – Reducerea zgomotului*

Pentru **detectarea marginilor** utilizează algoritmi precum Sobel, Prewitt și Canny pentru a identifica zonele cu schimbări bruște de intensitate în imagini, evidențiind contururile obiectelor. Sobel și Prewitt sunt metode simple bazate pe gradient, în timp ce Canny este mai complex, folosind o abordare multi-etapă pentru rezultate mai precise și mai puțin afectate de zgomot.




Figura 31 – Detectarea marginilor. A) – Sobel; B) – Prewitt



Figura 32 – Detectarea marginilor cu algoritmul Canny

**Detectarea colțurilor și punctelor de interes** este realizată prin algoritmi precum Harris Corner Detector și FAST, care identifică puncte distinctive în imagini, utile pentru alinierea și potrivirea între cadre. Harris detectează colțurile bazându-se pe variațiile de intensitate în jurul punctelor, iar FAST este mai rapid, fiind optimizat pentru aplicații în timp real.







Figura 33 - Detectarea colțurilor și punctelor de interes: Harris corner detector

FAST w/ NonmaxSuppression



FAST w/o NonmaxSuppression




Figura 34 - Detectarea colțurilor și punctelor de interes: FAST

**Detectarea caracteristicilor locale** implică metode avansate precum SIFT, SURF și ORB, care extrag detalii rezistente la schimbările de scară, rotație sau iluminare. SIFT și SURF se concentrează pe identificarea caracteristicilor complexe, utile în recunoaștere și urmărire, în timp ce ORB oferă o soluție mai rapidă și eficientă pentru aplicații care necesită viteză mare.




Figura 35 - Detectarea caracteristicilor locale: SIFT (Scale-Invariant Feature Transform)



Figura 36 - Detectarea caracteristicilor locale: SURF (Speeded-Up Robust Features)




Figura 37 - Detectarea caracteristicilor locale: ORB (Oriented FAST and Rotated BRIEF)

### 3. Segmentarea imaginii

**Segmentarea imaginii** este procesul prin care o imagine este împărțită în regiuni distincte pentru a identifica și analiza obiecte sau caracteristici. Metodele includ segmentarea bazată pe praguri, care separă regiuni în funcție de valori de intensitate, și segmentarea bazată pe regiuni, unde algoritmi precum growing regions sau watershed creează zone omogene.

Clustering-ul, prin tehnici precum K-means sau DBSCAN, grupează pixeli similari, iar segmentarea semantică, utilizând rețele neuronale, clasifică fiecare pixel pentru o segmentare precisă și detaliată, utilă în aplicații avansate.

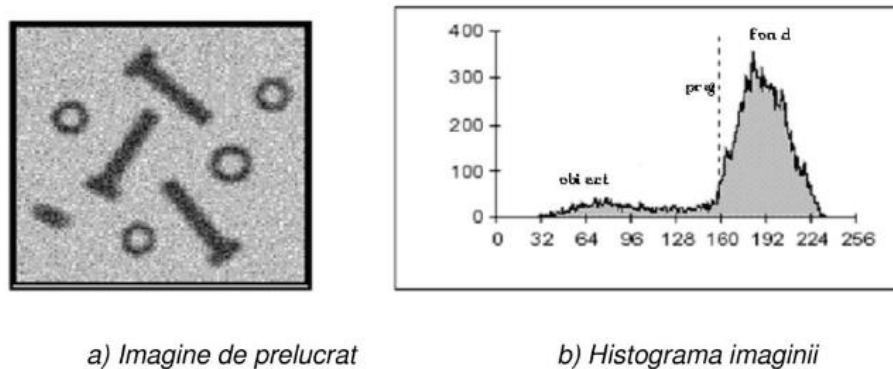


Figura 38 - Segmentare bazată pe praguri: Separarea obiectelor folosind praguri simple sau adaptative.




Figura 39 - Segmentare bazată pe regiuni: Algoritmi precum growing regions sau watershed.




Figura 40 - Segmentare prin clustering: K-means, Mean-shift, DBSCAN.




Figura 41 - Segmentare semantică: Utilizarea rețelelor neuronale pentru clasificarea pixelilor.  
Exemplul A.




Figura 42 - Segmentare semantică: Utilizarea rețelelor neuronale pentru clasificarea pixelilor.  
Exemplul B

#### 4. Transformări geometrice

Transformările geometrice sunt un set de operații aplicate imaginilor digitale pentru a schimba dimensiunile, poziția, orientarea sau perspectiva acestora, fără a afecta conținutul lor esențial. Aceste tehnici sunt fundamentale în procesarea imaginilor, fiind utilizate pentru ajustări, corectări și pregătirea datelor pentru analize ulterioare.

##### a) Redimensionare (Scaling):

Redimensionarea implică ajustarea dimensiunilor unei imagini, fie pentru a mări, fie pentru a micșora imaginea. Aceasta este realizată prin metode de interpolare, cum ar fi:

- **Interpolare nearest-neighbor:** Potrivită pentru imagini binare sau discrete, păstrează claritatea liniilor, dar poate produce artefacte vizuale la scări mai mari.
- **Interpolare biliniară:** Oferă tranziții mai netede între pixeli, fiind adecvată pentru imagini color sau cu detalii fine.
- **Interpolare bicubică:** Produce rezultate de o calitate superioară, fiind utilizată în aplicații care necesită un grad înalt de precizie, cum ar fi editarea profesională.

Redimensionarea este folosită în multiple scopuri, precum adaptarea imaginilor la dimensiuni predefinite pentru vizualizare, reducerea dimensiunii fișierelor sau pregătirea datelor pentru modele de învățare automată.

##### b) Translație și rotație:

- **Translația** reprezintă deplasarea unei imagini într-o anumită direcție, fără a modifica orientarea acesteia. Fiecare pixel este mutat cu o anumită distanță pe axele X și Y.
- **Rotația** presupune rotirea imaginii în jurul unui punct fix (de obicei, centrul imaginii) cu un anumit unghi specificat.

Aceste operații sunt utilizate pentru corectarea poziției obiectelor din imagini sau pentru a obține variații ale datelor, utile în augmentarea seturilor de date în machine learning.



c) **Transformări afine și perspective:**

- **Transformările afine** păstrează liniile drepte și proporțiile relative între puncte, dar pot modifica lungimile și unghiurile. Exemple comune includ:
  - **Shearing (deformare):** Strămutarea liniilor pentru a schimba forma imaginii.
  - **Scaling neuniform:** Modificarea proporțiilor pe axele X și Y separat.
- **Transformările perspective** schimbă perspectiva imaginii, oferind o iluzie tridimensională. Acestea sunt utilizate pentru corectarea imaginilor capturate din unghiuri diferite sau pentru a simula un punct de vedere specific.




Figura 43 - Corectarea distorsiunii perspectivei la imagini capturate cu lentile wide

d) **Transformări Fourier și Wavelet:**

Aceste metode sunt utilizate pentru analiza frecvențelor imaginii și sunt fundamentale în procesarea avansată:

- **Transformarea Fourier** decompune imaginea într-un set de frecvențe sinusoidale, separând componentele de frecvență joasă (detalii generale) și frecvență înaltă (detalii fine). Aceasta este folosită pentru:
  - Filtrare spațială (îndepărtarea zgomotului sau îmbunătățirea clarității).
  - Compresie de date (cum este JPEG).
  - Recunoașterea texturii.
- **Transformarea Wavelet** este o extensie a transformării Fourier, care analizează semnalele în domeniul timp-frecvență. Aceasta permite o analiză localizată, detectând variații la diferite niveluri de scalare și este folosită în:
  - Detectarea marginilor.
  - Compresie avansată de imagini.
  - Analiza detaliată a imaginilor medicale.

### III. Reprezentarea și descrierea imaginilor

Reprezentarea și descrierea imaginilor sunt procese esențiale în analiza imagistică, care permit extragerea de informații utile despre structura, caracteristicile și conținutul unei imaginii. Aceste tehnici sunt folosite în diverse aplicații, de la recunoașterea obiectelor până la clasificarea imaginilor și analiza texturii.

**Histograma** unei imaginii este o reprezentare grafică a distribuției intensităților pixelilor.

Aceasta indică numărul de pixeli pentru fiecare valoare de intensitate (de exemplu, de la 0 la 255 pentru imagini în tonuri de gri). Prin analizarea histogramei, pot fi identificate caracteristici precum contrastul, luminozitatea și distribuția culorilor.

Utilizări comune ale histogramelor includ:

- **Îmbunătățirea contrastului** prin metode precum egalizarea histogramei.
- **Detectarea iluminării neuniforme** în imagini.
- **Clasificarea imaginilor** pe baza caracteristicilor de intensitate.

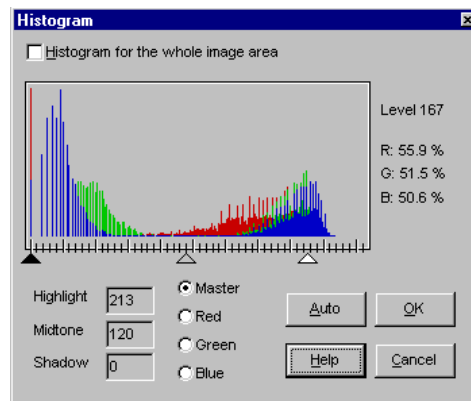


Figura 44 - Histogramă: Reprezentarea distribuției intensităților pixelilor.

**Descriere prin contur** presupune identificarea și extragerea conturilor sau formelor obiectelor dintr-o imagine. Aceasta se realizează prin tehnici de detectare a marginilor, cum ar fi algoritmi Sobel, Canny sau Prewitt. Conturile sunt utilizate pentru a descrie forma și structura obiectelor dintr-o imagine.

Aplicații comune:

- **Recunoașterea formelor** în imagini industriale.
- **Segmentarea obiectelor** pentru procesarea ulterioară.
- **Analiza morfologică**, cum ar fi calcularea perimetrului și ariei obiectelor.

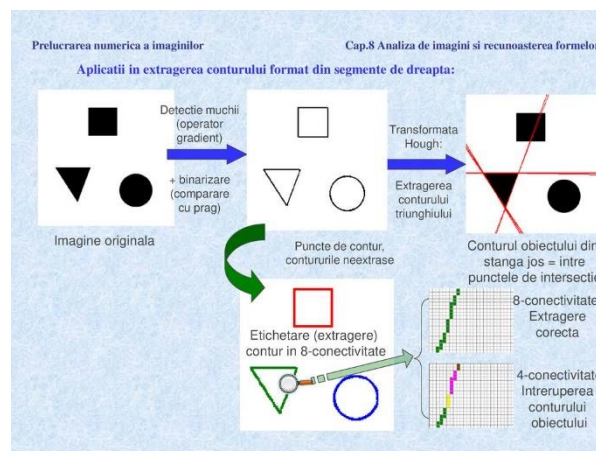


Figura 45 - Descriere prin contur: Extracția formelor și conturilor din imagini.

**Descriere prin momente.** Momentele sunt măsuri matematice care descriu distribuția spațială a intensităților pixelilor într-o imagine. Ele sunt utilizate pentru a caracteriza forma, orientarea și alte proprietăți geometrice ale obiectelor. Exemple de momente includ:

- **Momente geometrice**, utilizate pentru a determina proprietăți de bază, cum ar fi centrul de greutate sau orientarea.
- **Momente Zernike**, care sunt momente complexe utilizate pentru caracterizarea avansată a formelor. Acestea sunt rezistente la zgomot și permit o descriere detaliată a structurii imaginii.

Aplicații ale momentelor:

- **Recunoașterea obiectelor** pe baza formelor lor.
- **Analiza imaginilor medicale** pentru detectarea anomaliilor.
- **Clasificarea texturilor** sau a caracteristicilor detaliate.

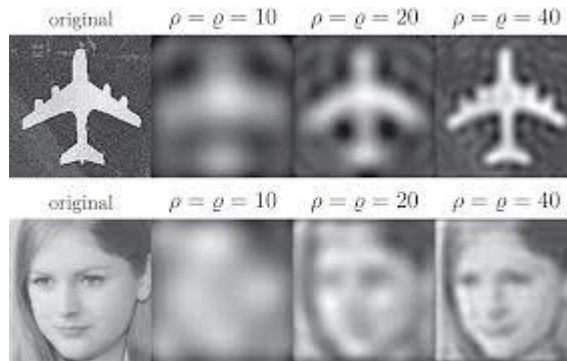


Figura 46 - Descriere prin momente: Momente geometrice sau momente Zernike pentru caracteristici avansate.

**Detectia și recunoasterea obiectelor** reprezintă procese fundamentale în procesarea imaginilor, utilizate pentru identificarea și localizarea obiectelor într-o scenă.

Metodele clasice, precum detectoarele Haar Cascade și HOG (Histogram of Oriented Gradients), se bazează pe caracteristici extrase manual pentru a identifica obiectele.

Tehnicile moderne bazate pe **deep learning** includ algoritmi precum R-CNN, Fast R-CNN, YOLO (You Only Look Once) și SSD (Single Shot Detector), care oferă o detecție rapidă și precisă folosind rețele neuronale convoluționale.

Pentru urmărirea obiectelor, algoritmi precum Kalman Filter, Mean-Shift și Optical Flow permit monitorizarea mișcării acestora în timp real, fiind esențiali în aplicații precum supravegherea video sau navigația roboților.

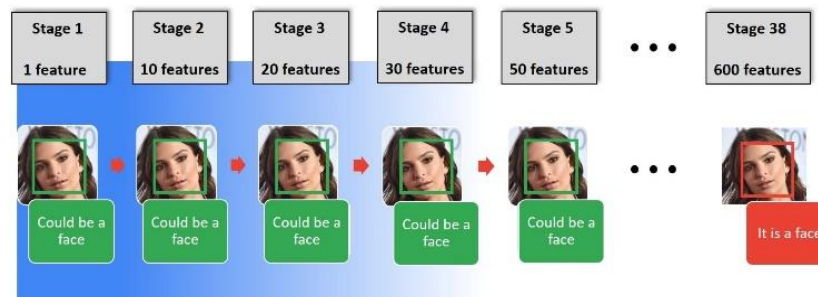


Figura 47 - Metode clasice: Detectoare Haar Cascade.




Figura 48 - Metode clasice: HOG (Histogram of Oriented Gradients). Exemplul 1

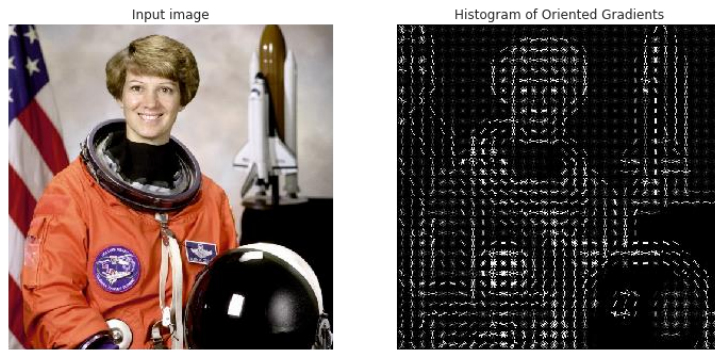


Figura 49 - Metode clasice: HOG (Histogram of Oriented Gradients). Exemplul 2




Figura 50 - Deep learning: R-CNN.

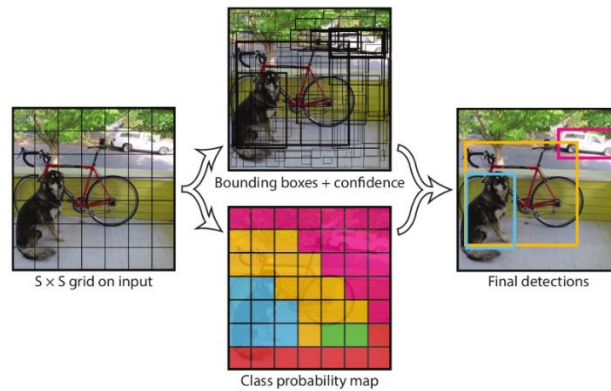


Figura 51 - Deep learning: Fast R-CNN.

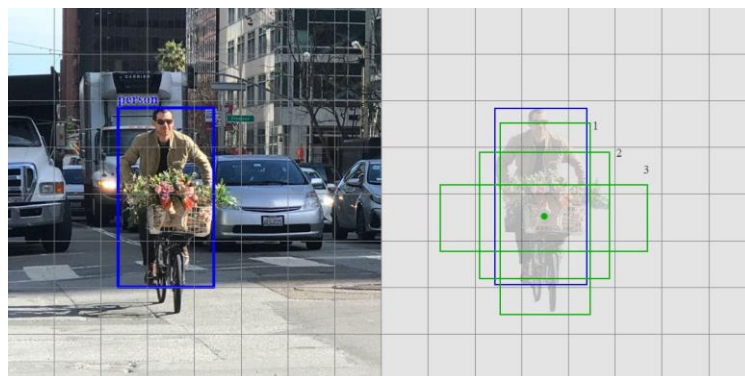


Figura 52 - Deep learning: YOLO (You Only Look Once), SSD (Single Shot Detector).



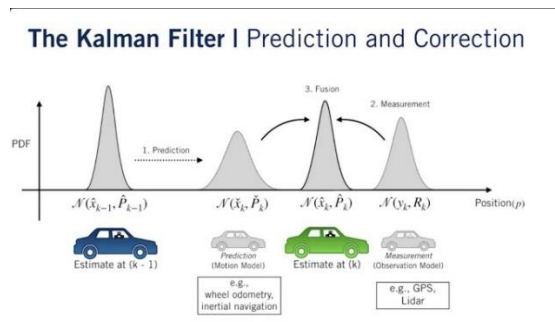


Figura 53 - Tracking de obiecte: Algoritmul Kalman Filter




Figura 54 - Tracking de obiecte: Algoritmul Mean-Shift




Figura 55 - Tracking de obiecte: Algoritmul Optical Flow

**Reconstrucție 3D** este procesul de creare a unui model tridimensional al unui obiect sau mediu din date vizuale.

- **Stereo vision** utilizează imagini stereoscopice pentru a calcula adâncimea și a genera modele 3D.
- **Structure from Motion (SfM)** reconstruiește structuri 3D din secvențe de imagini 2D capturate din unghiuri diferite.
- **Scanarea laser și LiDAR** oferă hărți 3D extrem de precise prin măsurarea distanțelor cu lasere.

Aceste tehnici sunt folosite în robotică, cartografie și realitate virtuală.




Figura 56 - Stereo vision: Generarea unui model 3D din imagini stereoscopice.




Figura 57 - Structure from Motion (SfM): Reconstrucție 3D dintr-o secvență de imagini 2D.




Figura 58 - Scanare laser și LiDAR: Generarea de hărți 3D detaliate.

**Analiză și clasificare** imaginilor implică utilizarea unor metode avansate pentru identificarea și separarea obiectelor sau caracteristicilor vizuale. **Clasificatorii tradiționali**, precum SVM, K-NN și Random Forests, sunt utilizați pentru sarcini de clasificare pe baza caracteristicilor extrase manual.

**Rețelele neuronale convoluționale (CNN)** reprezintă soluția modernă pentru clasificarea și recunoașterea imaginilor, oferind o performanță ridicată datorită învățării automate a caracteristicilor.

În **recunoașterea facială**, metode precum Eigenfaces și Fisherfaces, alături de modelele bazate pe deep learning, permit identificarea rapidă și precisă a fețelor în diverse aplicații.




Figura 59 - Clasificatori tradiționali: SVM (Support Vector Machines)




Figura 60 - Clasificatori tradiționali: K-NN (K-Nearest Neighbors)




Figura 61 - Clasificatori tradiționali: Random Forests.




Figura 62 - Rețele neuronale convoluționale (CNN): Folosite pentru clasificarea și recunoașterea imaginilor.

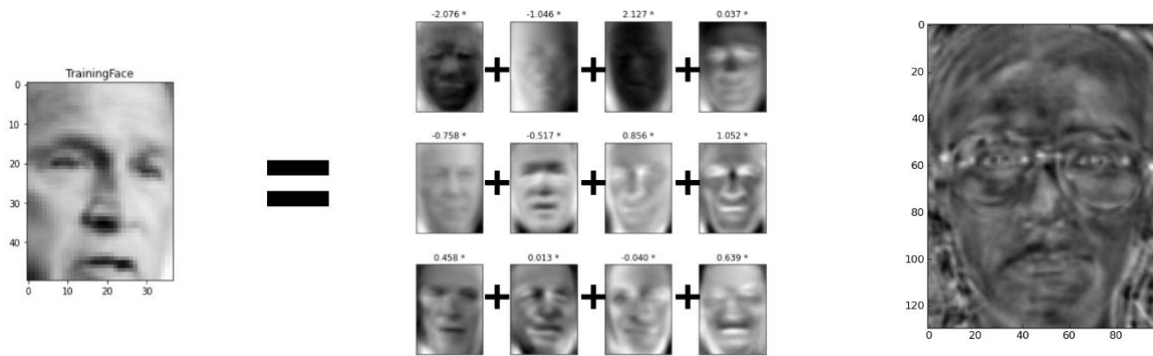


Figura 63 - Sisteme de recunoaștere facială: Eigenfaces, Fisherfaces, modele bazate pe deep learning.

#### IV. Tehnici avansate bazate pe inteligența artificială (IA)

Tehnicile avansate bazate pe inteligența artificială sunt utilizate pentru a rezolva probleme complexe în procesarea și analiza imaginilor, oferind soluții inovatoare și eficiente pentru sarcini precum clasificarea, generarea și restaurarea imaginilor.

##### 1. Învățarea supravegheată

**Învățarea supravegheată** este o metodă în care algoritmi sunt antrenați folosind un set de date etichetate, ceea ce înseamnă că fiecare imagine are asociată o etichetă (de exemplu, "pisică" sau "câine"). Modelul învață să recunoască modelele din imagini și să le clasifice corect pe baza acestor etichete. Această tehnică este utilizată în aplicații precum:

- Clasificarea obiectelor în imagini.
- Recunoașterea textelor (OCR).
- Identificarea bolilor în imagini medicale.

##### 2. Învățarea nesupravegheată

**Învățarea nesupravegheată** funcționează fără etichete, fiind orientată spre descoperirea automată a modelelor și caracteristicilor din date. Algoritmi precum clustering (K-Means, DBSCAN) sau auto-encoderii sunt utilizați pentru a grupa imagini similare sau pentru a învăța reprezentări compacte ale acestora. Aplicațiile includ:

- Segmentarea imaginilor pentru a separa regiunile de interes.
- Analiza datelor vizuale pentru detectarea anomaliilor.
- Reducerea dimensionalității datelor pentru vizualizare sau prelucrare ulterioară.

##### 3. Învățarea prin transfer

**Învățarea prin transfer** implică utilizarea modelelor pre-antrenate (cum ar fi ResNet, VGG sau Inception), care au fost deja antrenate pe seturi mari de date, cum ar fi ImageNet, pentru a rezolva noi sarcini cu un volum mic de date.

Această tehnică economisește timp și resurse, deoarece modelul poate fi ajustat doar pentru specificul noii sarcini. Este folosită în:


- Adaptarea algoritmilor de recunoaștere facială pentru scenarii noi.
- Clasificarea de imagini specializate, cum ar fi cele medicale sau industriale.
- Personalizarea modelelor pentru aplicații comerciale.

##### 4. Generative Adversarial Networks (GANs)



**Generative Adversarial Networks** reprezintă o abordare inovatoare, formată din două rețele neuronale: generatorul și discriminatorul. Generatorul creează imagini noi, iar discriminatorul le evaluează ca fiind reale sau false. Acest proces competitiv duce la generarea unor imagini foarte realiste. Aplicațiile GAN includ:

- Generarea de imagini noi, cum ar fi fețe umane realiste, peisaje sau obiecte.
- Restaurarea imaginilor deteriorate sau incomplete.
- Stilizarea imaginilor (de exemplu, transformarea fotografiilor în picturi în stilul unui artist specific).
- Crearea de date sintetice pentru antrenarea altor algoritmi de IA.




*Figura 64 - Generative Adversarial Networks (GANs):  
Generarea de imagini realiste sau completarea imaginilor.*

### 5. Analiza temporală în videoclipuri

**Analiza temporală în videoclipuri** se concentrează pe interpretarea și procesarea informațiilor din secvențe video pentru a înțelege mișcarea și comportamentul în timp.

**Detectarea mișcării**, folosind tehnici precum optical flow și diferențierea între cadre (frame differencing), permite identificarea zonelor cu activitate și a direcției mișcării în imagini consecutive.



*Figura 65 - Recunoașterea acțiunilor: Modele care analizează secvențe pentru a interpreta comportamente. Exemplul 1*




Figura 66 - Recunoașterea acțiunilor: Modele care analizează secvențe pentru a interpreta comportamente. Exemplul 2

**Tracking-ul de obiecte** implică urmărirea continuă a obiectelor identificate în secvențele video, utilizând algoritmi precum DeepSORT sau Tracker-KCF pentru a menține identitatea și poziția acestora în timp real.

**Recunoașterea acțiunilor** presupune utilizarea de modele care analizează secvențe întregi pentru a interpreta și clasifica comportamente sau activități specifice, fiind esențială în domenii precum supravegherea video, interacțiunea om-robot și analiza sportivă. Detectarea mișcării: Optical flow, frame differencing.




Figura 67 - Tracking de obiecte: Algoritmul precum DeepSORT.

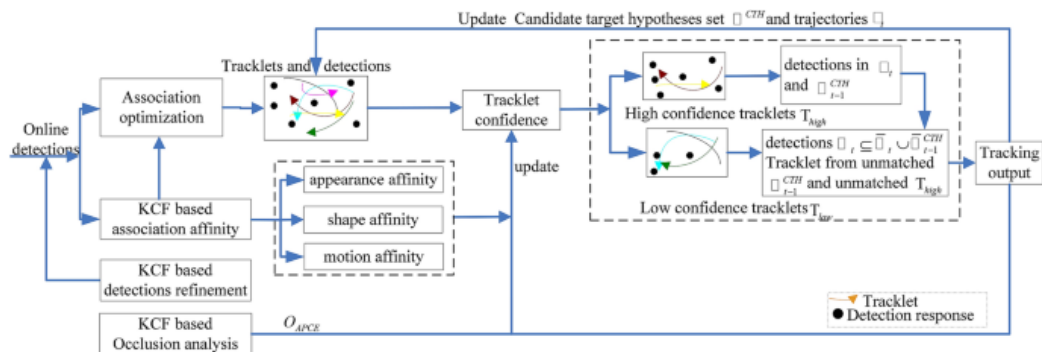


Figura 68 - Tracking de obiecte: Algoritmul Tracker-KCF.

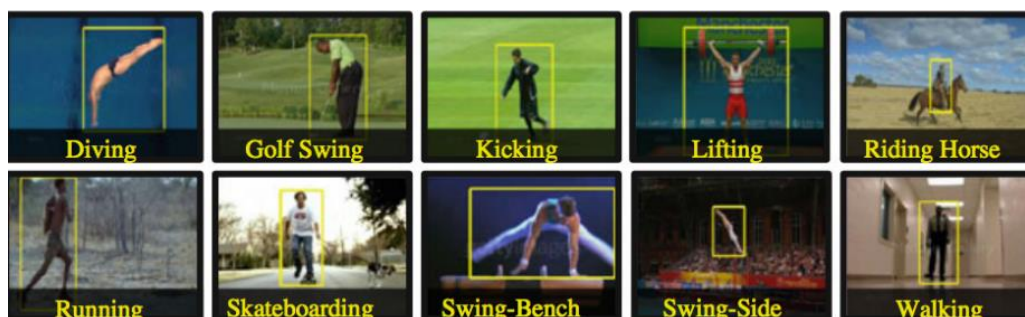


Figura 69 - Recunoașterea acțiunilor: Modele care analizează secvențe pentru a interpreta comportamente.

## V. Sisteme de vedere artificială pentru conducerea roboților

### 1. Sisteme bazate pe senzori de camera

Acestea folosesc camere pentru captarea imaginilor și videoclipurilor, procesate ulterior pentru a extrage informații relevante.

- **Sisteme monoculare:** Utilizează o singură cameră pentru navigație și recunoaștere a obiectelor, fiind dependente de tehnici de estimare a adâncimii, cum ar fi fluxul optic.
- **Sisteme stereoscopice:** Utilizează două camere pentru a calcula adâncimea prin diferențele de perspectivă (disparitate).
- **Sisteme multicameră:** Integrează mai multe camere pentru a oferi o vedere panoramică sau 360°, utile pentru roboți mobili și vehicule autonome.

### 2. Sisteme bazate pe senzori activi

Acestea folosesc senzori care emit semnale și detectează răspunsul pentru a analiza mediul.

- **LiDAR** (Light Detection and Ranging): Folosește lasere pentru a genera hărți 3D precise ale mediului.
- **ToF** (Time of Flight): Măsoară timpul necesar unui semnal (de obicei lumină) să se reflecte de pe suprafețe.




Figura 70 – Măsurarea timpului necesar ToF

- **Sonar/Ultrasunete:** Utilizează unde sonore pentru detectarea obiectelor, fiind comun în roboții subacvatici și cei industriali.
- **Senzori infraroșu:** Detectează distanțe și forme folosind radiații infraroșii.

### 3. Sisteme hibride

Combină mai mulți senzori pentru a oferi o percepție mai robustă.

- **LiDAR + Cameră:** Integrarea informațiilor vizuale și a celor de adâncime pentru o percepție mai precisă.
- **Stereocamere + Ultrasunete:** Folosite pentru navigație sigură și evitarea obstacolelor.
- **LiDAR + GPS + IMU:** Sistem utilizat frecvent în vehicule autonome pentru localizare și cartografiere.

### 4. Sisteme bazate pe algoritmi de procesare a imaginilor

Algoritmii permit interpretarea imaginilor capturate de senzori.

- **Detectarea și urmărirea obiectelor:** YOLO, SSD, Faster R-CNN.
- **Segmentarea semantică:** U-Net, DeepLab, pentru a clasifica pixelii individuali.

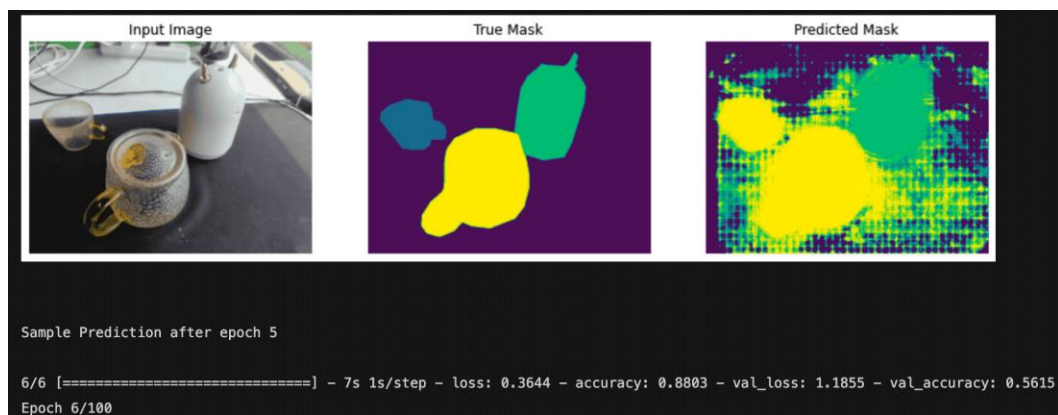


Figura 71 – Segmentarea semantică

- **Flux optic:** Analizează mișcarea între cadre pentru navigație.
- **Mapare și localizare simultană (SLAM):** Algoritmi precum ORB-SLAM sau RTAB-Map care permit construirea hărților 3D și localizarea robotului.

### 5. Sisteme bazate pe rețele neuronale și inteligență artificială

Aceste sisteme folosesc modele avansate de învățare profundă pentru percepție și luare de decizii.

- **Rețele neuronale convoluționale (CNN):** Clasificarea obiectelor și recunoaștere vizuală.
- **Rețele generative adversariale (GANs):** Reconstrucția imaginilor sau completarea lor.
- **Învățare prin întărire (Reinforcement Learning):** Navigație autonomă prin învățare directă din interacțiunea cu mediul.

### 6. Sisteme pentru navigație și evitarea obstacolelor

Sistemele pentru navigație și evitarea obstacolelor sunt esențiale în robotică și vehicule autonome, asigurând deplasarea sigură și eficientă în medii complexe.

**Navigația bazată pe informații vizuale (Vision-based Navigation)** utilizează date capturate de camere pentru a ghida mișcarea robotului, fără a necesita alte tipuri de senzori.

**Sistemele de navigație reactivă** detectează și evită obstacolele în timp real, adaptând traiectoria în funcție de schimbările din mediu prin tehnici precum Dynamic Window Approach (DWA).



**Sistemele de planificare a traseului**, folosind algoritmi precum A\*, Dijkstra sau RRT (Rapidly-Exploring Random Trees), calculează cele mai optime rute, ținând cont de obstacole și constrângeri spațiale. Aceste tehnologii permit roboților să navigheze eficient și să se adapteze la condiții imprevizibile.




Figura 72 - Vision-based Navigation: Navigație ghidată exclusiv de informațiile vizuale.




Figura 73 - Reactive Navigation Systems: Detectează și evită obstacolele în timp real (e.g., Dynamic Window Approach - DWA).

7	6	5	6	7	8	9	10	11		19	20	21	22	
6	5	4	5	6	7	8	9	10		18	19	20	21	
5	4	3	4	5	6	7	8	9		17	18	19	20	
4	3	2	3	4	5	6	7	8		16	17	18	19	
3	2	1	2	3	4	5	6	7		15	16	17	18	
2	1	0	1	2	3	4	5	6		14	15	16	17	
3	2	1	2	3	4	5	6	7		13	14	15	16	
4	3	2	3	4	5	6	7	8		12	13	14	15	
5	4	3	4	5	6	7	8	9		11	12	13	14	
6	5	4	5	6	7	8	9	10		10	11	12	13	14

Figura 74 - Path Planning Systems: Algoritm A\*

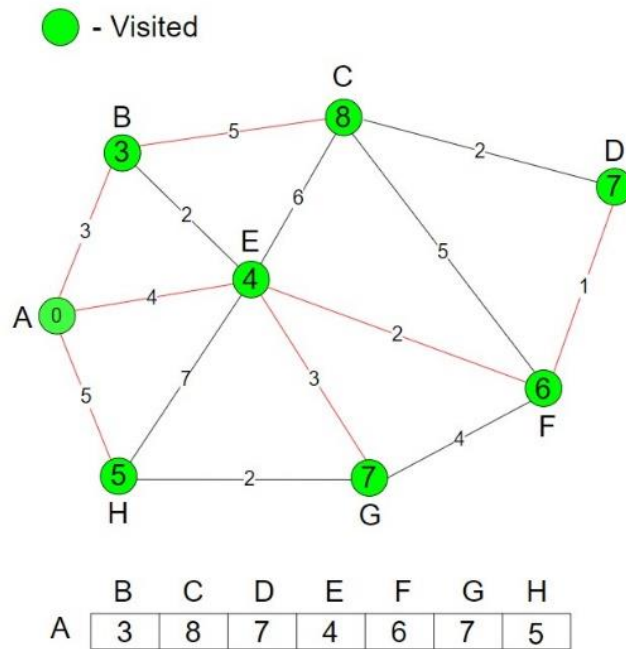


Figura 75 - Path Planning Systems: Algoritm Dijkstra.

## Random Trees, RRTs & RRT\*

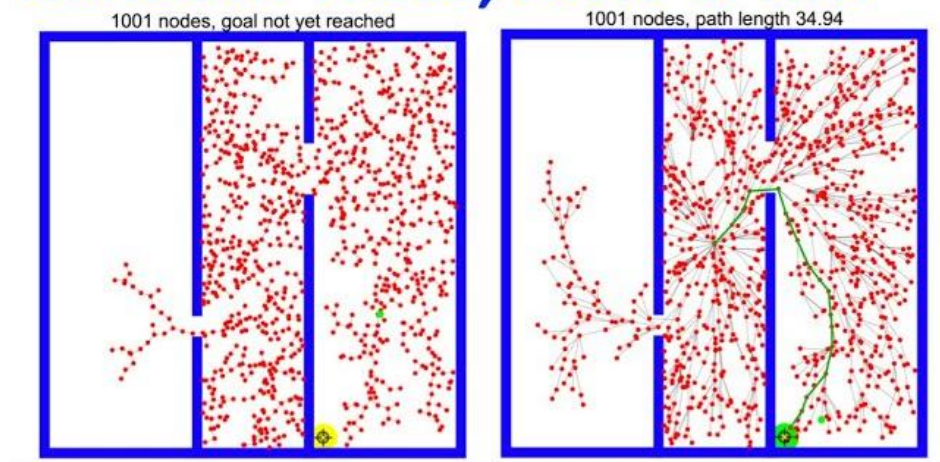


Figura 76 - Path Planning Systems: Algoritm RRT pentru planificarea traseului.

## 7. Sisteme specializate pentru roboți

Sistemele specializate pentru roboți sunt concepute pentru a îndeplini sarcini complexe și adaptate nevoilor din diverse domenii. Aceste sisteme folosesc tehnologii avansate, precum senzori, algoritmi de procesare a imaginilor și inteligență artificială, pentru a îmbunătăți eficiența, precizia și siguranța operațiunilor.

**Vehicule autonome** reprezintă una dintre cele mai avansate aplicații ale roboticii. Acestea sunt dotate cu sisteme precum **Autoware** și **Apollo**, care utilizează combinații de senzori LiDAR și camere pentru percepția mediului. LiDAR-ul generează hărți 3D detaliate, iar camerele asigură recunoașterea obiectelor și a semnelor de circulație.

Sistemele sunt integrate cu algoritmi de planificare a traseului și evitarea obstacolelor, permițând vehiculelor să navigheze în siguranță în medii dinamice și să răspundă la condiții imprevizibile, cum ar fi traficul intens sau schimbările de vreme.




Figura 77 - Vehicule autonome: Sisteme precum Autoware sau Apollo (bazate pe LiDAR și viziune).

**Roboți industriali** sunt utilizați pe scară largă în automatizarea proceselor de fabricație. Aceștia integrează sisteme de **inspecție vizuală**, care permit identificarea defectelor, verificarea dimensiunilor și controlul calității produselor. De asemenea, brațele robotizate sunt echipate cu tehnologii avansate de **manipulare a obiectelor**, fiind capabile să recunoască și să asambleze piese complexe cu o precizie ridicată. Aceste sisteme sunt esențiale pentru creșterea productivității și reducerea costurilor în industrii precum automotive, electronice și metalurgie.

**Roboți agricoli.** În agricultură, roboții specializați contribuie la optimizarea și modernizarea proceselor. Aceștia folosesc tehnologii de **detectare a plantelor** și de **recoltare automată**, asigurând culegerea fructelor și legumelor la maturitatea optimă. În plus, prin analiza vizuală și senzori avansați, roboții pot monitoriza sănătatea culturilor, detectând semne timpurii de boli sau dăunători. Aceste aplicații ajută fermierii să îmbunătățească randamentul, să reducă pierderile și să minimizeze utilizarea substanțelor chimice, contribuind la o agricultură sustenabilă.

**Roboții medicali** reprezintă o inovație revoluționară în domeniul sănătății. Aceste sisteme folosesc **tehnologii de imagistică avansată** pentru a ghida intervențiile chirurgicale cu o precizie extraordinară, reducând riscurile asociate și îmbunătățind recuperarea pacienților. De asemenea, roboții sunt utilizați în

diagnosticarea automată, analizând imagini medicale, precum RMN-uri sau tomografii, pentru a identifica anomalii cu o acuratețe ridicată. În plus, aceștia monitorizează pacienții în timp real, oferind feedback constant personalului medical.

## **Concluzie**

Referatul evidențiază complexitatea și diversitatea aplicațiilor sistemelor de vedere artificială în robotică, demonstrând impactul semnificativ al acestei tehnologii asupra dezvoltării și optimizării proceselor industriale, agricole, medicale și de navigație.

Prin analiza tehnicilor avansate de prelucrare a imaginilor și a algoritmilor de inteligență artificială, lucrarea subliniază importanța combinării senzorilor activi și pasivi pentru o percepție ambientală robustă și precisă. Utilizarea algoritmilor avansați de învățare profundă, cum ar fi CNN și GAN, împreună cu metodele de navigație autonomă, reflectă tendința actuală de a îmbunătăți capacitățile roboților în medii complexe și nestructurate.

Astfel, lucrarea oferă o perspectivă amplă asupra potențialului tehnologiei de vedere artificială de a transforma domeniul roboticii, deschizând noi oportunități pentru inovație și cercetare interdisciplinară.





## BIBLIOGRAFIE

1. **SONKA, M., HLAVAC, V., BOYLE, R.** Image Processing, Analysis and Machine Vision. 3rd ed. Boston: Thomson Learning, 2008. ISBN 978-0-495-08253-8.
2. **CORKE, P.** Robotics, Vision and Control: Fundamental Algorithms in MATLAB. 2nd ed. Berlin Heidelberg: Springer, 2017. ISBN 978-3-319-54412-0.
3. **GONZALEZ, R. C., WOODS, R. E.** Digital Image Processing. 3rd ed. Upper Saddle River: Pearson Prentice Hall, 2008. ISBN 978-0-13-505267-9.
4. **GONZALEZ, R. C., WOODS, R. E., EDDINS, S. L.** Digital Image Processing Using MATLAB. 2nd ed. Knoxville: Gatesmark Publishing, 2009. ISBN 978-0-9820854-0-0.
5. **SHAPIRO, L. G., STOCKMAN, G. C.** Computer Vision. New Jersey: Prentice Hall, 2001. ISBN 978-0130307966.
6. **HARTLEY, R., ZISSERMAN, A.** Multiple View Geometry in Computer Vision. 2nd ed. Cambridge: Cambridge University Press, 2004. ISBN 978-0521540513.
7. **GRIGORESCU, S. M., MĂCESANU, G., COCIAS, T. T.** Sisteme de vedere artificială utilizând OpenCV 3. Îndrumar de laborator. Braşov: Editura Universităţii Transilvania, 2016.
8. **TRUCCO, E., VERRI, A.** Introductory Techniques for 3D Computer Vision. New Jersey: Prentice Hall, 1998. ISBN 978-0132611085.
9. **BISHOP, C. M.** Pattern Recognition and Machine Learning. Berlin Heidelberg: Springer, 2006. ISBN 978-0387310732.
10. **RUSSELL, S., NORVIG, P.** Artificial Intelligence: A Modern Approach. 3rd ed. Upper Saddle River: Prentice Hall, 2010. ISBN 978-0136042594.
11. **LECUN, Y., BENGIO, Y., HINTON, G.** Deep Learning. In: *Nature*, 2015, vol. 521, pp. 436-444. DOI: 10.1038/nature14539.
12. **SZE, V., CHEN, Y. H., EMADI, A., et al.** Efficient Processing of Deep Neural Networks: A Tutorial and Survey. In: *Proceedings of the IEEE*, 2017, vol. 105(12), pp. 2295-2329. DOI: 10.1109/JPROC.2017.2761740.