

Sistem mecatronic de poziționare pentru procese de înșurubare automată utilizând algoritmi de Computer Vision

Autori: Zanfîr Maria, Grămescu Irina, Coporan Teodor-Cristian, Hrabac Alex-Teodor

Profesor coordonator: Conf. Dr. Ing. Cartal Laurențiu-Adrian

Rezumat

Această lucrare prezintă proiectarea unui sistem mecatronic destinat automatizării procesului de montare a roților prin ghidarea uneltei de strângere pe poziția șuruburilor. Problema principală abordată este alinierea precisă a unui pistol pneumatic utilizând algoritmi de Computer Vision, pentru a evita erorile de poziționare. Sistemul utilizează algoritmul YOLO pentru a identifica în timp real coordonatele șuruburilor, necesare poziționării mecanice ale ansamblului.

Cuvinte cheie: Computer vision, YOLO, Înșurubare automată, Modularitate, Mecatronică

1. Introducere

În industria automotive, eficiența liniilor de asamblare este direct dependentă de gradul de automatizare și precizia proceselor repetitive. Unul din pașii critici în asamblarea finală, dar și în activitățile de mentenanță din cadrul vulcanizărilor și al service-urilor, este fixarea roților. Acest proces necesită o forță de strângere controlată și o aliniere geometrică riguroasă, astfel că, integrarea unei soluții automate în mediul de service poate să reducă considerabil efortul fizic al operatorului, dar și riscul de eroare umană.

Lucrarea de față prezintă cercetarea și dezvoltarea unui sistem mecatronic ce are ca scop strângerea autonomă a șuruburilor de prindere ale ansamblului roată-butuc, realizând alinierea automată a pistolului pneumatic de impact cu prezoanele roții, având în vedere variațiile de poziționare și orientarea unghiulară aleatorie a formei hexagonale a prezonului. O aliniere incorectă poate duce la deteriorarea filetului sau la întreruperi ale fluxului de producție.

Importanța acestei lucrări este definită de capacitatea sistemului de a utiliza algoritmi de Computer Vision pentru a oferi un răspuns în timp real al coordonatelor pentru poziționarea corectă ansamblului de înșurubat, prin identificarea precisă a roții și a prezoanelor. Acești algoritmi sunt tot mai des utilizați în aplicații de automatizare industrială, eliminând eroarea umană. Iar în cadrul soluției propuse, a fost dezvoltat un algoritm bazat pe modelul YOLOv8, și cu ajutorul unei camere video, sistemul identifică în timp real coordonatele centrului roții și orientarea fiecărui prezon, ajustând poziția mecanică.

2. Literatura de specialitate

Automatizarea proceselor utilizând algoritmi de detecție reprezintă o direcție de cercetare esențială, în care abordările actuale au evoluat de la simple filtre de imagine la arhitecturi complexe bazate pe inteligență artificială și sisteme de control hibrid, după cum este evidențiat în literatura de specialitate și în aplicațiile industriale.

2.1. Detecția în timp real a roților și clasificare jantelor în producția automotive

În mediul industrial, identificarea rapidă și precisă a componentelor auto aflate pe liniile de asamblare este o necesitate fundamentală. Cercetările recente, precum studiul realizat de Staněk et. Al. [1], subliniază tranziția de la tehnicile de vedere tradițională la rețele neuronale complexe. Soluția propusă de aceștia adoptă arhitecturi bazate pe rețele neuronale convoluționale, în special modelele din familia YOLO (You Only Look Once), capabile să localizeze simultan anvelopele și jantele cu o viteză de interferență adecvată procesării în timp real. Dincolo de simpla detecție a ariei de etichetare, datele sunt vizualizate pentru a reconstitui parametrii geometrici ai asamblării. Algoritmii moderni estimează diametrul jantei, dar și diametrul cercului de prindere al șuruburilor (PCD – Pitch Circle Diameter) prin detectarea individuală a centrelor șuruburilor și crearea unei elipse sau a unui cerc peste aceste coordonate.




Fig. 1 – Detecția jantei și a cercului de prindere ale șuruburilor [1]

2.2. Metodă bazată pe Computer Vision pentru detecția cantitativă a șuruburilor slăbite din îmbinările cu șuruburi ale structurilor metalice

Odată cu identificarea pozițiilor globale ale șuruburilor, alinierea sculelor automatizate de înșurubare necesită cunoașterea exactă a unghiului de rotație al hexagonului. În articolul [2], autorii au demonstrat că utilizarea exclusivă a extragerii de muchii pentru suprafețele metalice este inefficientă, deoarece reflexiile puternice ascund contururile reale ale piesei. Pentru a obține o precizie în determinarea acestor unghiuri, studiul propune detecția punctelor cheie (keypoints), realizându-se o arhitectură în care rețeaua neuronală YOLO izolează mai întâi șurubul, iar mai apoi, o a doua rețea specializată (PIPNet) identifică în mod direct coordonatele celor șase vârfuri ale hexagonului, ignorând fundalul și zgomotul optic.




Fig. 2 – Ilustrarea datelor etichetate pentru (a) YOLOv5 și (b) PIPNet [2]

2.3. RoboTire

Trecerea de la validarea algoritmică la implementarea practică presupune integrarea metodelor de Computer Vision în arhitectura de control a sistemelor mecanice. Un exemplu relevant pentru lucrarea aceasta este chiar Robotire [3], un sistem destinat schimbării roților de la mașini în mai puțin de 25 minute, fiind alcătuit dintr-un braț robotic cu șase grade de libertate și cu o cheie dinamometrică, iar cu ajutorul inteligenței artificiale și a vederii computerizate procesul este complet automatizat. Acesta poate manipula roți cu diametre diferite și se poate adapta la diferite cupluri de strângere, pentru asamblarea optimă a prezoanelor.

Sistemul de detecție vizuală este format dintr-o cameră 3D aflată pe robot, fiind un element important pentru realizarea mișcării acestuia și realizează hărți 3D pentru recunoașterea tipului de șuruburi utilizate și pentru poziționarea lor cu o precizie submilimetrică. Cu ajutorul inteligenței artificiale, procesul poate să fie automatizat fie cu ajutorul sistemului de detecție sau, pentru a eficientiza procesul, poate să fie scanat codul de identificare al autovehiculului și cu ajutorul unei baze de date, robotul primește parametrii de care are nevoie. Modelele de inteligență artificială sunt reantrenate în mod constant, astfel robotul nu va întâmpina obstacole în timpul operațiunii.



Fig. 3 – Robotul RoboTire [3]

3. Soluția propusă

Soluția propusă a fost concepută pentru a fi integrată atât în cadrul activităților de mentenanță, precum vulcanizări și unități service, dar și în liniile de producție, datorită caracteristicii sale principale, modularitatea. Astfel că, schimbarea ansamblului jantă-anvelopă necesită operația de prindere, respectiv desfacere a prezoanelor care fixează janta de butucul autovehiculului, iar pentru a automatiza acest proces a fost proiectat un sistem care acționează un pistol pneumatic cu impact și îl poziționează astfel încât să corespundă cu poziția prezonului.

3.1. Subsistemul mecanic

Proiectarea mecanică a sistemului a pornit cu realizarea schemei cinematice, datorită reprezentării simpliste a structurii și pentru a determina cuplele cinematice necesare mișcării pe care aceasta trebuie să le îndeplinească. În Fig. 4 este ilustrată schema cinematică a soluției proprii.




Fig. 4 – Schema cinematică a soluției propuse

Structura este realizată din mișcări de translație pe axa Z, Y, respectiv X (Fig. 4 – 0, 1 și 2) pentru a genera traiectoria de poziționare a acestuia pe cercul imaginar pe care se află prezoanele. Orientarea dispozitivului de înșurubat se realizează cu ajutorul mișcării de rotație în jurul axei X (Fig. 4 – 3).

Ansamblul este alcătuit din două subansamble principale: cel de poziționare al dispozitivului de înșurubat și cel care acționează pistolul pneumatic cu impact cu care prezonul este strâns. În Fig. 5 sunt prezentate imaginile de ansamblu ale soluției propuse, în care se observă unitățile de translație pentru fiecare axa (X, Y, Z) formate din axe liniare, și mecanismele șurub-piuliță acționate de motoare pas-cu-pas: 1 – mișcarea liniară pe axa X, 2 – mișcarea liniară pe axa Y, 3 – mișcarea liniară pe axa Z.




Fig. 5 – Ansamblul dispozitivului de înșurubat

Pistolul trebuie să realizeze mișcări de translație pe direcția filetului prezonului, de rotație pentru a poziționa pistolul în funcție de orientarea acestuia, deoarece capul șuruburilor este hexagonal, acestea pot fi rotite cu până la 60°, iar poziția lor este una variabilă de la caz la caz. [4]

Așadar, pentru a realiza această rotație, a fost proiectat un mecanism de rotire, utilizând un reductor planetar, pentru a crește cuplul oferit de motor, dar și a dimensiunilor sale compacte. Este format dintr-o roată dințată cu dantură interioară (32 dinți), patru sateliți (12 dinți), un soare (8 dinți) și un braț port-satelit, configurația descrisă creează un raport de transmitere 5:1. Pentru a evita încărcarea arborelui motor, brațul port-satelit al reductorului transmite mișcarea flanșei pistolului pneumatic prin intermediul unui arbore, așa cum se poate observa în Fig. 6, în care: 1 – motorul, 2 – reductor planetar, 3 – arbore, 4 – flanșa dispozitivului de înșurubat, 5 – dispozitivul de înșurubat.





Fig. 6 – Secțiunea ansamblului de orientare a pistolului pneumatic [4]


Pistolul pneumatic cu impact este acționat manual, utilizatorul apasă pe butonul de acționare care alimentează cu presiune motorul pneumatic rotativ cu palet. Arborele de ieșire al motorului este ulterior conectat la un subansamblu de tip ciocan-nicovală. Acest subansamblu ne permite să avem pe arborele de ieșire al pistolului pneumatic o mișcare de rotație continuă împreună cu o succesiune de șocuri axiale. Schimbarea sensului de rotație se realizează prin apăsarea tijei care comută camera distribuitorului din alcătuirea pistolului, schimbând căile de curgere ale fluidului de lucru – aerul comprimat. Automatizarea proceselor descrise mai sus a fost realizată utilizând un servomotor care să apese butonul de acționare și un cilindru pneumatic cu o cursă mică (15 mm), care realizează mișcarea de translația asupra tijei distribuitorului. Fig. 7 și Fig. 8 ilustrează soluția propusă descrisă în paragrafele anterioare.




a. Mecanismul în poziția neacționată

b. Mecanismul în poziția acționată

Fig. 7 – Acționarea butonului de acționare [4]



a. Mecanismul în poziția neacționată



b. Mecanismul în poziția acționată

Fig. 8 – Acționarea distribuitorului pistolului pneumatic [4]

Ansamblul pistolului pneumatic cu elementele de acționare adăugate sunt montate în cadrul unei carcase de plastic. În Fig. 9 este prezentată o vedere a acestuia în care se pot observa componente: 1 - carcasă, 2 – servomotor, 3 – cilindru pneumatic, 4 – suport în formă de „U” pentru prinderea pistolului de carcasă, 5 – pistolul pneumatic cu impact și 6 – flanșa dispozitivului de înșurubat.[4]




Fig. 9 – Vedere a ansamblului de acționare al pistolului cu impact [4]

3.2. Subsistemul electronic

În Fig. 10 este ilustrată schema de funcționare a circuitului electric utilizat pentru soluția propusă. Aceasta este alcătuită din componente de intrare (limitatoarele de capăt de cursă, camera și butoanele de comandă), unitatea de comandă și componentele de ieșire (driverul de motoare, motoarele pas-cu-pas, distribuitorul pneumatic, cilindrul pneumatic și servomotorul).




Fig. 10 – Schema bloc a circuitului electric

Limitatoarele de cursă sunt senzorii de poziție care transmit către unitatea de comandă semnale în momentul în care elementele mobile ale sistemului ajung în poziția extremă.

Pentru a detecta poziția, numărul și pentru a determina valoarea PCD-ului pe care sunt situate prezoanele de pe roată, este utilizat un modul cu cameră Raspberry Pi Rev. 1.3. care transmite datele computerului prin intermediul conectorului CSI integrat ce se regăsește și pe minicomputerul Raspberry Pi 4. Aceasta are o rezoluție de 5MP și poate înregistra video cu un format de 1080 pixeli, potrivit pentru soluția propusă.

Unitatea de comandă (computer) este alcătuită dintr-un minicomputer Raspberry Pi 4 și placa de dezvoltare Arduino MEGA 2560 Rev.3., acest ansamblu primește și procesează informațiile de la senzori, și comandă funcționarea elementelor de acționare în funcție de sistemul de comandă implementat. Combinația a fost aleasă pentru introducerea mai multor pini digitali care pot fi folosiți pentru interfațarea cu diferite dispozitive periferice. Raspberry Pi este folosit pentru ca sistemul să poată fi controlat de la distanță, prin modulul său de Wi-Fi integrat, dar și pentru a putea interfața cu camera. Placa de dezvoltare Arduino MEGA 2560 oferă un număr ridicat de pini. Comunicarea între cele două dispozitive se realizează prin interfața serială UART (USB).

Microcontrolerul de pe placa de dezvoltare trimite semnale digitale către driverul de motoare, care va transforma semnalele logice în semnale de putere pentru acționarea motoarelor pas-cu-pas bipolare. Driverul utilizat pentru motoarele pas cu pas sunt TB6600, datorită protecțiilor la supracurent, scurtcircuit, și supraîncălzire, dar și curentului suportat, care este de până la 4 A. [5]

Pentru a apăsa butonul pistolului pneumatic cu impact, este utilizat servomotorul MG90S, datorită cuplului ridicat pe care îl generează, dar și precizia de poziționare a acestuia. Servomotorul primește semnal de tip PWM și va executa mișcările de rotație în funcție de comanda primită. [6]

4. Metodologia de dezvoltare și optimizare a algoritmului de CV

Pentru proiectarea, implementarea și optimizarea algoritmului de vedere computerizată, fiind componenta decizională a sistemului de înșurubare automată, a fost urmată o metodologie formată din achiziția și preprocesarea datelor vizuale și selectarea arhitecturii optime de detecție, urmată de antrenarea și evaluarea modelului ales. Obiectivul principal al acestei abordări a fost obținerea unui sistem autonom, capabil să proceseze fluxul video în timp real și să extragă precis caracteristicile geometrice ale prezoanelor, respectând totodată constrângerile mecanice.

4.1. Construirea setului de date

Setul de date reprezintă unul dintre cei mai importanți pași pentru realizarea unui algoritm de Computer Vision, deoarece calitatea predicțiilor oferite de rețeaua neuronală este direct proporțională cu relevanța și acuratețea datelor de antrenare. În contextul unei aplicații industriale, cum este înșurubarea automată, setul de date nu trebuie să fie doar un volum mare de informație, ci o reprezentare fidelă a realității din spațiul de lucru.

În cazul soluției propuse, setul de date realizat este alcătuit din 215 imagini, necesare pentru a acoperi o gamă largă de scenarii: roți vizibile parțial, prezoane murdare, sau prezența capacelor de roată. Pentru a asigura o evaluare corectă a performanței modelului și pentru a evita fenomenul de supra-antrenare, imaginile au fost împărțite în trei subseturi distincte. Astfel, 70% din date au fost alocate setului de antrenare, unde modelul învață trăsăturile geometrice ale componentelor, 20% reprezintă setul de validare, utilizat pentru ajustarea parametrilor în timpul procesului de învățare, iar restul de 10% au format setul de testare, folosit exclusiv pentru verificarea finală a acurateței. În Fig. 11 sunt câteva imagini din setul de date creat, se pot observa că sunt prezente diferite scenarii, precum: iluminare diferită, număr divers de prezoane și orientarea camerei.



Fig. 11 – Imagini din setul de date creat pentru soluția propusă

Accentul deosebit s-a pus pe etichetarea corectă, deoarece într-un proces repetitiv, o adnotare precisă este mai valoroasă decât un număr mare de imagini slab etichetate, iar pentru o eficiență sporită a fost utilizată platforma online Roboflow, ce permite etichetarea automată a imaginilor, urmată de verificarea manuală a acestora, dar care tot economisește foarte mult timp. Astfel că, au

fost alese ca și etichete: „tire” (anvelopă) și wheel bolts (prezoane), nu doar pentru localizarea punctelor de înșurubare, ci și pentru a crea o siguranță sistemului, în cazul în care nicio instanță din clasa „wheel bolts” nu este identificată, dar este detectată clasa „tire”, sistemul poate fi programat să anunțe operatorul uman despre existența unui capac de roată, prevenind astfel erorile de execuție. În Fig. 12 sunt ilustrate câteva imagini etichetate, în care zonele evidențiate cu mov reprezintă detectarea roții, iar cele cu verde marchează prezoanele.




Fig. 12 – Etichetarea imaginilor din setul de date

4.2. Procesul de antrenare și performanțele modelului

După finalizarea etapei de pregătire a datelor, următorul pas a constat în antrenarea propriu-zisă a modelului utilizând arhitectura YOLOv8n (YOLO Nano). Această versiune a fost selectată pentru eficiența sa demonstrată pe platforme cu resurse hardware limitate [7][8] asigurând un echilibru între precizia detecției și viteza de execuție necesară în timp real.

În terminologia specifică învățării automate, procesul de antrenare se desfășoară pe parcursul mai multor epoci. O epocă reprezintă un ciclu complet în care algoritmul parcurge întregul set de date de antrenare pentru a extrage caracteristici și a învăța să asocieze pixelii cu etichetele definite. În cadrul acestei lucrări, antrenarea a fost configurată pentru un număr de 100 de epoci, acest număr de iterații permite modelului să își îmbunătățească succesiv capacitatea de a recunoaște: în primele epoci, eroarea este mare, dar pe măsură ce procesul avansează, algoritmul își ajustează parametrii interni pentru a minimiza diferența dintre predicția sa și realitatea imaginilor etichetate.

Antrenarea a fost realizată prin furnizarea setului de date către rețeaua neuronală YOLOv8, care a gestionat automat procesul de învățare. Rezultatele obținute la finalul celor 100 epoci confirmă eficiența modelului pentru aplicația propusă. Pentru integrarea pe Raspberry Pi, fișierul rezultat „best.pt” a fost convertit în format ONNX, optimizând astfel viteza de procesare, din cauza limitărilor de performanță [9]. În Fig. 13 sunt imagini din timpul antrenării, în care algoritmul a identificat obiectele cerute.



Fig. 13 – Imagini etichetate de model în timpul antrenării acestuia

5. Dezvoltarea algoritmilor pentru procesarea geometrică

Nu este suficientă doar procesarea datelor obținute prin modelul de detecție antrenat, ci acestea trebuie transformate în comenzi de mișcare pentru a acționa mecanic sistemul. Astfel că, este necesar implementarea unor algoritmi personalizați pentru a poziționa sistemul în mod precis, prin interpretarea detecțiilor vizuale. Procesarea geometrică este integrată direct cu logica de control pentru a asigura un flux continuu, de la captarea imaginii până la finalizarea procesului de înșurubare.

Un pas esențial este calcularea PCD-ului, acest centru geometric, determinat pe baza poziției tuturor prezoanelor identificate, este utilizat ca punct de referință pe suprafața roții. Implementarea acestui calcul are ca scop fluidizarea mișcării sistemului mecatronic. Această metodă permite parcurgerea roții într-un mod organizat, reducând timpii morți de deplasare între axe și asigurând un traseu predictibil pentru sistemul mecanic. Astfel, eficiența procesului este maximizată, iar uzura mecanică este minimizată prin optimizarea traiectoriilor X, Y, respectiv Z.

Următorul pas este detectarea orientării prezoanelor, deoarece aceasta este variabilă, iar pistolul trebuie rotit pentru a coincide cu geometria hexagonală a piesei. Astfel că, a fost creat un program care procesează imaginea decupată a prezonului, aplicând filtre de contrast pentru a evidenția muchiile hexagonului, eliminând reflexiile ce pot perturba vizual. Sunt identificate vârfurile hexagonului și calculează unghiul de rotație față de poziția de referință a pistolului. Datorită simetriei de 60° a hexagonului, nu este necesară o rotație completă, algoritmul determinând cea mai scurtă cale pentru aliniere.

Funcțiile de detecție, calcul geometric și rotație sunt introduse într-un program bazat pe un număr finit de stări, care gestionează tranzițiile între diferite etape ale procesului, asigurând siguranța și rigoarea execuției. Așa cum este prezentat și în schema bloc a programului (Fig. 14), sistemul începe cu căutarea mediului de lucru, pentru început se detectează roata, apoi se identifică șuruburile, dacă acestea nu există, sistemul se oprește și așteaptă intervenția operatorului uman, dar dacă prezoanele sunt identificate se calculează centrul PCD, iar coordonatele sunt transmise către microcontroller, este activat algoritmul de aliniere a pistolului, acesta fiind rotit conform datelor primite de la camera video, ultima stare fiind cea de acționare, în care se realizează avansul până la contact, se activează pistolul, ulterior sistemul revine în stare de căutare pentru următorul punct de lucru.




Fig. 14 – Schema bloc a algoritmului de control al sistemului

6. Rezultate experimentale

Validarea sistemului propus a fost realizată prin testarea modelului de detecție antrenat cu setul de date creat, dar și testarea procesării geometrice utilizând captarea imaginilor în timp real.

6.1. Testarea modelului de detecție

Prima etapă de testare a constat în rularea modelului YOLOv8 antrenat pe un flux video în timp real al camerei, cu o roată reală în fața acesteia. Scopul a fost verificarea comportamentului sistemului în condiții reale de iluminare și la distanțe variabile, diferite de condițiile din setul de date. Atât testarea, cât și antrenarea modelului, au fost efectuate pe computerul personal, pentru a beneficia de o putere de procesare superioară, validarea acestuia fiind mult mai rapidă, urmat apoi de implementarea acestuia pe Raspberry Pi4.

În Fig. 15 a. este prezentat un cadru reprezentativ din aplicația de detecție, în care se pot observa: etichetele de culoare turcoaz asociate celor cinci prezoane detectate, cele de culoare albastru închis ale roții (clasa „tire”). Sistemul a detectat corect toate cele cinci șuruburi în condiții normale de iluminare, la o distanță de aproximativ 30-40 cm între cameră și roată. În Fig. 15 b. și c. sunt prezentate cadre din situații diferite: prezența unui capac ce acoperă prezoanele, iluminare mai slabă și diferite tipuri de jantă. În Fig. 15 c. se poate observa cum diferența de iluminare și tipul de jantă pot să aducă erori în detecție, identificând un prezon în plus, dar acuratețea detecției este mai scăzută în comparație cu cele reale, așadar adăugarea unui prag de toleranță este necesar în crearea unor algoritmi care utilizează sisteme de detecție.




Fig. 15 – Testarea modelului YOLO după antrenarea acestuia


6.2. Testarea algoritmului de procesare geometrică

A doua etapă de testare a constat în evaluarea algoritmilor de calcul geometric pentru determinarea centrului PCD, coordonatele X-Y de poziție ale prezoanelor și detecția unghiului hexagonal. Acestea sunt date critice, deoarece acestea determină comenzile acționare ale sistemului mecanic.

În Fig. 16 sunt prezentate capturi de ecran din timpul rulării programului, din fiecare stare posibilă, a., c. g. i.: starea „Centrare” pentru prezoanele P1 – P5, afișează abaterea de poziție față de șurubul țintă. Evoluția acestor parametrii este detaliată în Tabelul 1. Analiza datelor confirmă stabilizarea centrului PCD și convergența abaterilor către zero pe măsură ce sistemul se aliniază cu ținta.

Testarea în condiții statice a relevat o ușoară instabilitate a datelor vizuale brute, în special pentru detecția unghiului de rotație al hexagonului (Fig. 16. b., d., f. h. și j.), care este afectat de reflexiile metalului, modificând modul în care marginile hexagonului sunt percepute de camera video la fiecare cadru. Această limitare sugerează necesitatea utilizării unor metode de filtrare mai avansate sau a schimbării metodologiei de etichetare, folosind adnotări de tip „puncte cheie” (keypoints), recomandate aplicațiilor de identificare de poziție, dar care necesită mult mai mult timp de execuție.

În configurația actuală, stabilitatea centrului PCD rămâne într-o marjă de $\pm$ cinci pixeli, ceea ce este considerat acceptabil pentru etapa de testare, însă impune utilizarea unor praguri de toleranță în mașina de stări pentru a evita oscilațiile motoarelor pas-cu-pas în timpul etapei de centrare.




a.




b.




c.




d.




e.




f.



g.



h.



i.



j.

Fig. 16 – Ciclul complet de poziționare și procesare geometrică

Tabel 1 – Date extrase din timpul testării

Cadru (Frame)	Starea sistemului	Nr. şurub	Centru PCD estimat (X, Y) [px]	Abatere poziție axa X [px]	Abatere poziție axa Y [px]	Unghi prezon [°]
740	CAUTARE	1/2	-	-	-	-
760	CENTRARE	1/5	(642.5, 358.0)	+290.5	+71.5	-
1640	CENTRARE	1/5	(640.5, 360.0)	+2.5	+11.5	-
1660	ALINIERE	1/5	(640.0, 361.0)	< prag toleranță	< prag toleranță	33.7
1780	ALINIERE	1/5	(639.0, 360.5)	< prag toleranță	< prag toleranță	22.8
1800	CENTRARE	2/5	(641.0, 359.5)	-4.0	+131.5	-
2520	CENTRARE	2/5	(639.5, 361.5)	+4.0	+8.0	-
2540	ALINIERE	2/5	(640.5, 360.0)	< prag toleranță	< prag toleranță	29.3
2680	ALINIERE	2/5	(640.0, 360.0)	< prag toleranță	< prag toleranță	42.1
2700	CENTRARE	3/5	(638.5, 359.0)	-138.5	+65.5	-
2980	CENTRARE	3/5	(641.5, 361.0)	+3.0	+10.5	-
3000	ALINIERE	3/5	(640.0, 359.5)	< prag toleranță	< prag toleranță	2.9
3120	ALINIERE	3/5	(639.0, 360.5)	< prag toleranță	< prag toleranță	1.1
3140	CENTRARE	4/5	(641.0, 358.5)	-79.0	-73.5	-
3520	CENTRARE	4/5	(640.5, 360.0)	+19.5	+7.0	-
3540	ALINIERE	4/5	(640.0, 361.5)	< prag toleranță	< prag toleranță	10.9
3700	CENTRARE	5/5	(638.5, 361.0)	+59.5	-101.0	-
4040	CENTRARE	5/5	(641.0, 359.5)	+9.0	-20.5	-
4060	ALINIERE	5/5	(640.0, 360.0)	< prag toleranță	< prag toleranță	56.9
4180	ALINIERE	5/5	(639.5, 360.5)	< prag toleranță	< prag toleranță	47.4
4200	GATA	5/5	(640.0, 360.0)	-	-	-

În final, s-a validat răspunsul sistemului la scenarii de eroare, precum este ilustrat în Fig. 17, roata este acoperită de un capac decorativ. Soluția propusă deduce obstacolul prin detecția roții, dar nu și a prezoanelor, într-un interval de cinci secunde, apoi comută în starea de siguranță, blocând acționarea mecanică și solicitând un operator uman.



a. b.

Fig. 17 – Testarea algoritmului în situația prezenței unui capac

7. Concluzii

Lucrarea de față a prezentat proiectarea și implementarea unui sistem mecatronic pentru poziționarea automată pentru procese de înșurubare, demonstrând că integrarea tehnologiei de vedere artificială cu algoritmi de procesare reprezintă o soluție viabilă chiar și pentru sisteme cu resurse de calcul reduse. S-a validat ipoteza conform căreia un set de date compact de 215 imagini, este suficient pentru a asigura o detecție cu randamente crescute, datorită etichetării atente a acestora. Modelul antrenat reușește să identifice lipsa prezoanelor, chiar și identificarea acestora în condiții de iluminare redusă.

Totuși, în cadrul testelor experimentale, s-au identificat anumite limitări, în special în ceea ce privește stabilitatea valorilor unghiulare calculate din cauza reflexiilor metalice. Pentru remedierea acestor aspecte, pe viitor se dorește re-etichetarea setului de date utilizând puncte cheie (keypoints) în locul ferestrelor de delimitare clasice, această abordare fiind superioară și recomandată pentru determinările de poziții, chiar dacă necesită un timp de adnotare mult mai mare. Și pentru reducerea dependenței de lumină ambientală, se va implementa un sistem de iluminare integrat, standardizând contrastul la nivelul prezoanelor, eliminând umbrele care pot duce la oscilații ale valorilor calculate.

De asemenea, se vizează optimizarea mecanismului de rotație a pistolului de impact, prin înlocuirea reductorului planetar cu un angrenaj de tip melc-roată melcată, pentru modificarea considerabilă a gabariturii ansamblului, prin modificarea centrului de greutate al ansamblului. Dar, un alt aspect important în alegerea unui nou angrenaj, este caracteristica acestuia de auto-blocare, odată oprit motorul, poziția unghiulară rămâne fixă sub acțiunea forțelor externe, eliminând necesitatea menținerii sub tensiune a motorului pas-cu-pas în timpul procesului de strângere.

8. Bibliografie

1. R. Staněk, T. Kerepecký, A. Novozámský, F. Šroubek, B. Zitová, and J. Flusser, “Real-Time Wheel Detection and Rim Classification in Automotive Production,” *2023 IEEE International Conference on Image Processing (ICIP)*, pp. 1410–1414, Oct. 2023, doi: <https://doi.org/10.1109/icip49359.2023.10223161>.
2. W. Lao, C. Cui, D. Zhang, Q. Zhang, and Y. Bao, “Computer Vision-Based Autonomous Method for Quantitative Detection of Loose Bolts in Bolted Connections of Steel Structures,” *Structural control & health monitoring*, vol. 2023, pp. 1–17, May 2023, doi: <https://doi.org/10.1155/2023/8817058>.
3. <https://robotire.com/the-robot/> - Accesat în data de 24.11.2024
4. M. Zanfîr, „Studii și cercetări asupra unui sistem mecatronic de schimbare a roților”, Proiect de diplomă, Fac. De Inginerie Mecanică și Mecatronică, Univ. Națională de Știință și Tehnologie Politehnica București, Îndrumător științific: Ș.l. Dr. Ing. L.A. Cartal, București 2025
5. <https://www.handsontec.com/dataspecs/module/TB6600-Motor-Driver.pdf> - accesat în data de 14.05.2026
6. <https://towerpro.com.tw/product/mg90s-3/> - accesat în data de 14.05.2026
7. A. Wong, M. Famuori, M. J. Shafiee, F. Li, B. Chwyl, and J. Chung, “YOLO Nano: a Highly Compact You Only Look Once Convolutional Neural Network for Object Detection,” *arXiv:1910.01271 [cs]*, Oct. 2019
8. L. Rey *et al.*, “A Performance Analysis of You Only Look Once Models for Deployment on Constrained Computational Edge Devices in Drone Applications,” *Electronics*, vol. 14, no. 3, pp. 638–638, Feb. 2025, doi: <https://doi.org/10.3390/electronics14030638>.
9. I. J. Ratul, Y. Zhou, and K. Yang, “Accelerating Deep Learning Inference: A Comparative Analysis of Modern Acceleration Frameworks,” *Electronics*, vol. 14, no. 15, p. 2977, Jul. 2025, doi: <https://doi.org/10.3390/electronics14152977> .