



Universitatea
Transilvania
din Brașov

ȘCOALA DOCTORALĂ INTERDISCIPLINARĂ

Facultatea de Silvicultură și exploatare forestiere

Gabriel Osei FORKUO

Aplicarea tehnicilor de învățare automată și viziune
computerizată computerizată pentru clasificarea posturală a
operațiilor forestiere utilizând metoda OWAS

Application of Deep Learning and Computer Vision
Techniques for Postural Classification of Forest Operations
Using the OWAS Method

REZUMAT

Conducător științific

Prof.dr. ing. Stelian Alexandru BORZ

BRAȘOV, 2025

Cuprins

Lista Figurilor	4
Lista Tabelelor.....	7
Lista abrevierilor și acronimelor	8
INTRODUCERE.....	10
Relevanța soluțiilor inteligente pentru evaluarea posturală în operațiile forestiere	10
Scop și obiective	11
Organizarea tezei	11
CAPITOLUL 1. O ANALIZĂ SISTEMATICĂ A METODELOR DE EVALUARE POSTURALĂ CONVENȚIONALE ȘI NOI.....	13
1.1. MATERIALE ȘI METODE	13
1.2. REZULTATE ȘI DISCUȚII.....	14
1.3. CONCLUZII	15
CAPITOLUL 2. DEZVOLTAREA ȘI EVALUAREA MODELELOR AUTOMATIZATE DE CLASIFICARE POSTURALĂ ÎN OPERAȚIILE FORESTIERE UTILIZÂND VIZIUNEA COMPUTERIZATĂ BAZATĂ PE ÎNVĂȚAREA PROFUNDĂ.....	16
2.1. MATERIALE ȘI METODE	16
2.2. REZULTATE.....	17
2.3. DISCUȚII	22
2.4. CONCLUZII.....	22
CAPITOLUL 3. ATINGEREA ACURATEEI DE CLASIFICARE MAXIME PRIN ÎNVĂȚARE PROFUNDĂ ȘI VIZIUNE COMPUTERIZATĂ ÎN CLASIFICAREA POSTURALĂ OWAS: UN EXEMPLU PRIVIND MODUL ÎN CARE PUNCTELE CHEIE ALE CORPULUI GENERATE DE COMPUTER POT ÎMBUNĂȚĂȚI ÎNVĂȚAREA PROFUNDĂ BAZATĂ PE DATE 2D CONVENȚIONALE.....	23
3.1. MATERIALE ȘI METODE	23
3.2. REZULTATE.....	24
3.3. DISCUȚII	28
3.4. CONCLUZII.....	29
CAPITOLUL 4. CLASIFICAREA POSTURALĂ PRIN REPREZENTAREA VECTORIALĂ A IMAGINILOR ȘI ÎNVĂȚAREA PRIN TRANSFER: UN EXEMPLU DE UTILIZARE A METODEI OWAS ÎN MUNCA CU FERĂSTRAIE MECANICE PENTRU AUTOMATIZAREA PROCESULUI ȘI ECONOMISIREA RESURSELOR	30
4.1. MATERIALE ȘI METODE	30
4.2. REZULTATE.....	31
4.3. DISCUȚII	38
4.4. CONCLUZII.....	38

CAPITOLUL 5. FIABILITATEA UMANĂ ȘI COMPUTERIZATĂ ÎN EVALUAREA POSTURALĂ A OPERAȚIILOR FORESTIERE PRIN METODA OWAS: NIVEL DE CONCORDANȚĂ ȘI RESURSE DE TIMP	39
5.1. MATERIALE ȘI METODE	39
5.2. REZULTATE ȘI DISCUȚII.....	40
5.3. CONCLUZII.....	46
CAPITOLUL 6. CONCLUZII. CONTRIBUȚII ORIGINALE. DISEMINAREA REZULTATELOR	47
6.1. Concluzii	47
6.2. Contribuții originale	47
6.3. Diseminarea rezultatelor	48
6.3.1. Publicații științifice din tematica tezei de doctorat.....	48
6.3.2. Publicații științifice bazate pe rezultatele obținute prin participarea în echipe de cercetare externe tematicii tezei de doctorat	49
Bibliografie selectivă	51
Mulțumiri	54

Lista Figurilor

Figura 1.1. Diagrama de flux PRISMA a fazelor metodologice ale analizei literaturii pentru acest studiu. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 13

Figura 2. 1. Fluxul de lucru utilizat pentru dezvoltarea modelului inteligent de clasificare OWAS. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 16

Figura 2.2. Acuratețea clasificării (a) și pierderea (b) a modelelor în timpul etapelor de antrenare și validare. Legendă: G – GoogLeNet, R – ResNet-50, M – MobileNet-v2, S – ShuffleNet Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei..... 18

Figura 2.3. Performanța de clasificare în timpul testării pentru cele patru modele pre-antrenate. Legendă: G – GoogLeNet, R – ResNet-50, M – MobileNet-v2, S – ShuffleNet Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei..... 18

Figura 2.4. Acuratețea clasificării (a) și pierderea (b) a modelului ResNet-50 în funcție de rata de învățare în timpul etapelor de antrenare și validare. Notă: dimensiunea lotului a fost menținută la 10. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 19

Figura 2.5. Performanța de clasificare a modelului ResNet-50 în timpul testării. Notă: dimensiunea seriei de date a fost menținută la 10; elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 20

Figura 2.6. Acuratețea clasificării (a) și pierderea (b) modelului ResNet-50 în funcție de dimensiunea seriei de date în timpul etapelor de antrenare și validare. Notă: rata de învățare a fost menținută la 0.0001; elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 20

Figura 2.7. Performanța de clasificare a modelului ResNet-50 în timpul testării. Notă: rata de învățare a fost menținută la 0.0001; elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei..... 21

Figura 2.8. Acuratețea predicției pe date externe: a – predicții pe clase cu dominanță în număr de imagini, b - predicții pe clase cu un număr mediu de imagini, c - predicții pe clase cu un număr redus de imagini, d - predicții pe clase cu imagini generate de AI. 22

Figura 3.1. Harta României care arată locațiile colectării datelor de teren. Notă: hartă elaborată în QGIS 3.32.1 „Lima” utilizând QuickMapServices, OSM Standard 23

Figura 3.2. Diagrama logică care arată etapele de colectare a datelor, adnotare, dezvoltare și evaluare a modelelor. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei..... 24

Figura 3. 3. Acuratețea (a) și pierderea (b) modelelor ResNet-50 pre-antrenate în timpul fazelor de antrenare și validare. Legendă: PO - PictureOnly, SO - SkeletonOnly, PS – PictureWithSkeleton. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 25

Figura 3.4. Performanța de clasificare în timpul testării pentru modelele ResNet-50 pre-antrenate pe cele trei seturi de date. Legendă: PO - PictureOnly, SO - SkeletonOnly, PS – PictureWithSkeleton. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 26

Figura 3.5. Acuratețea predicției modelului dezvoltat cu PS pe date externe: a - predicții privind operațiile cu dominanță în numărul de imagini, b - predicții privind operațiile cu un număr mediu de imagini, c - predicții privind operațiile cu un număr redus de imagini, d – predicții privind clasele cu imagini generate de AI. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei..... 26

Figura 3.6. Acuratețea predicției modelului dezvoltat cu SO pe date externe: a - predicții privind operațiile cu dominanță în numărul de imagini, b - predicții privind operațiile cu un număr mediu de imagini, c - predicții privind operațiile cu un număr redus de imagini, d - predicții privind clasele cu imagini generate de AI. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei..... 27

Figura 3.7. Acuratețea predicției modelului dezvoltat cu PO pe date nevăzute: a - predicții privind operațiile cu dominanță în numărul de imagini, b - predicții privind operațiile cu un număr mediu de imagini, c - predicții privind operațiile cu un număr redus de imagini, d - predicții privind clasele cu imagini generate de AI. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei..... 28

Figura 4.1. Un exemplu de imagine utilizată pentru modelare (stânga) și locația studiului (dreapta). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 30

Figura 4.2. Acuratețea clasificării (CA) pe setul de date Postură în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 32

Figura 4.3. Scorul F1 (F1) pe setul de date Postură în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 32

Figura 4.4. Precizia (PREC) pe setul de date Postură în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 33

Figura 4.5. Recall (REC) pe setul de date Postură în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 34

Figura 4.6. Acuratețea clasificării (CA) pe setul de date Acțiune în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 34

Figura 4.7. Scorul F1 (F1) pe setul de date Acțiune în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă

numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 35

Figura 4.8. Precizia (PREC) pe setul de date Acțiune în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 35

Figura 4.9. Recall (REC) pe setul de date Acțiune în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 36

Figura 5.1. Rezultatele scalării multidimensionale privind acordul evaluatorilor umani. Legendă: R1 – evaluator 1, R2 – evaluator 2, R3 – evaluator 3, r1 – date din prima replicare, r2 – date din a doua replicare. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei..... 41

Figura 5.2. Rezultatele scalării multidimensionale privind acordul dintre evaluatorii umani și model. Legendă: R1 - evaluator 1, R2 – evaluator 2, R3 – evaluator 3, RM – evaluarea modelului de învățare profundă, r1 – date din prima replicare, r2 – date din a doua replicare. Notă: pentru RM a fost utilizată o singură evaluare. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei. 41

Lista Tabelelor

Tabelul 2.1. Caracteristicile rețelelor pre-antrenate selectate pentru studiu. Sursa: MathWorks, Inc., 2024b	17
Tabelul 4.1. Frecvența categoriilor de acțiuni identificate în setul de date utilizat pentru învățarea automată.	31
Tabelul 4.2. Performanța modelelor pe date externe.....	37
Tababelul 5.1. Descrierea codurilor și categoriilor OWAS utilizate în studiu.....	39
Tabelul 5.2. Descrierea seturilor de date utilizate în evaluare	40
Tabelul 5.3. Rezultatele fiabilității intra-evaluator pentru cei trei evaluatori umani	42
Tabelul 5.4. Rezultatele fiabilității inter-evaluator între cei trei evaluatori umani	43
Tabelul 5.5. Rezultatele acordului pe perechi între evaluatorii umani și modelul de învățare profundă	44
Tabelul 5.6. Rezultatele acordului general între cei trei evaluatori umani și modelul ResNet-50	45
Tabelul 5.7. Rezultatele testelor de comparație pentru datele privind consumul de timp	45

Lista abrevierilor și acronimelor

1. AC: Categorie de acțiune (Action Category)
2. AI: Inteligență Artificială (Artificial Intelligence)
3. APM: Analiza posturii și a mișcării (Analysis of Posture and Motion)
4. CNN: Rețea Neuronală Convoluțională (Convolutional Neural Network)
5. CV: Vizune Computerizată (Computer Vision)
6. DCNN: Rețea Neuronală Convoluțională Profundă (Deep Convolutional Neural Network)
7. DL: Învățare Profundă (Deep Learning)
8. DT: Arbori de Decizie (Decision Trees)
9. EMG: Electromiografie (Electromyography)
10. HMM: Model Markov Ascuns (Hidden Markov Model)
11. HOG: Histograma Gradientilor Orientați (Histogram of Oriented Gradients)
12. HRNet: Rețea de Înaltă Rezoluție (High-Resolution Network)
13. IMU: Dispozitiv de Măsurare Inerțială (Inertial Measurement Unit)
14. KNN: K-cei mai apropiați vecini (K-Nearest Neighbors)
15. LCNN: Rețea Neuronală Convoluțională Simplificată (Lightweight Convolutional Neural Network)
16. MDS: Scalare Multidimensională (Multi-dimensional Scaling)
17. ML: Învățare Automată (Machine Learning)
18. MSD: Afecțiune Musculo-Scheletică (Musculoskeletal Disorder)
19. MSDs: Afecțiuni Musculo-Scheletice (Musculoskeletal Disorders)
20. OWAS: Sistemul de Analiză a Posturii de Lucru Ovako (Ovako Working Posture Analysing System)
21. PO: Doar Imagine (Picture Only)

22. PRISMA: Elemente de Raportare Preferate pentru Recenzii Sistemate și Meta-Analize (Preferred Reporting Items for Systematic Reviews and Meta-Analyses)
23. PS: Imagine Originală cu Puncte Cheie și Conectori (Picture With Skeleton)
24. REBA: Evaluarea Rapidă a Întregului Corp (Rapid Entire Body Assessment)
25. RF: Pădure Aleatorie (Random Forest)
26. RM: Evaluările Modelului DL (Ratings of the DL model)
27. RNN: Rețea Neuronală Recurentă (Recurrent Neural Network)
28. RULA: Evaluarea Rapidă a Membrului Superior (Rapid Upper Limb Assessment)
29. SIFT: Transformarea Caracteristicilor Invariantă de Scară (Scale-Invariant Feature Transform)
30. SO: Imagine cu Puncte Cheie și Conectori (Skeleton Only)
31. SVM: Mașină cu Vectori Suport (Support Vector Machine)
32. TL: Învățare prin Transfer (Transfer Learning)
33. YOLO: O Singură Privire (You Only Look Once)

INTRODUCERE

Relevanța soluțiilor inteligente pentru evaluarea posturală în operațiile forestiere

Operațiile forestiere cuprind o gamă largă de activități legate de gestionarea, cultivarea și recoltarea pădurilor și a resurselor de lemn (Rummer et al., 2002). Aceste operații sunt importante pentru utilizarea sustenabilă a ecosistemelor forestiere, având ca scop reconcilierea nevoilor economice cu obiectivul fundamental de reducere a deșeurilor și a emisiilor, minimizând în același timp impactul asupra structurilor și funcțiilor mediului (Heinimann, 2007; Marchi et al., 2018). Cu toate acestea, activitățile forestiere rămân unele dintre cele mai solicitante și periculoase ocupații din punct de vedere fizic. Muncitorii sunt frecvent obligați să efectueze sarcini repetitive (Sibiya et al., 2021), să se angajeze în ridicarea de greutate (Paini et al., 2020) și să mențină posturi incomode pentru perioade lungi de timp (Yovi și Prajawati, 2015). Acești factori cresc semnificativ riscul de a dezvolta afecțiuni musculo-scheletice (MSDs) (Calvo, 2009; Punnett și Wegman, 2004), care includ o gamă largă de afecțiuni inflamatorii și degenerative care afectează mușchii, tendoanele, ligamentele și articulațiile. Potrivit lui Da Costa și Vieira (2010), practicile ergonomice deficitare și lipsa de atenție acordată sănătății posturale sunt principalii factori care contribuie la MSD, care reprezintă una dintre cele mai frecvente probleme de sănătate la locul de muncă la nivel mondial și o cauză semnificativă a incapacității de muncă (Bevan, 2015; Enez și Nalbantoğlu, 2019; Pascual și Naqvi, 2008). În consecință, necesitatea unei evaluări posturale eficiente, precise și eficace în operațiile forestiere este atât urgentă, cât și critică pentru atenuarea acestor riscuri și pentru prescrierea intervențiilor adecvate. Timp de decenii, domeniul ergonomiei s-a bazat pe metode tradiționale de evaluare pentru a identifica și cuantifica riscurile posturale. Metodologii precum Evaluarea Rapidă a Membrului Superior (RULA) (McAtamney și Corlett, 1993), Evaluarea Rapidă a Întregului Corp (REBA) (Hignett și McAtamney, 2000) și Sistemul de Analiză a Posturii de Lucru Ovako (OWAS) (Karhu et al., 1977) au fost utilizate pe scară largă. Aceste metode sunt larg adoptate pentru capacitatea lor de a clasifica sistematic posturile și de a atribui niveluri de risc. Cu toate acestea, ele se bazează în mare măsură pe tehnici de observație care sunt adesea subiective, consumatoare de timp și nepractice pentru implementarea la scară largă sau continuă (Gomez-Galan et al., 2017; Takala et al., 2010). Natura lor statică, bazată pe instantanee, nu reușește adesea să surprindă schimbările posturale dinamice, în timp real, inerente mediilor solicitante precum silvicultura (Bačić et al., 2024). În timp ce tehnologiile moderne, cum ar fi senzorii portabili și sistemele de captură a mișcării, oferă date cantitative mai obiective, ele sunt adesea costisitoare și necesită medii controlate, limitându-le aplicabilitatea în condițiile dificile, mobile și de mediu specifice operațiilor forestiere (Nadeem et al., 2021). Progresele recente în învățarea automată (ML), învățarea profundă (DL) și viziunea computerizată (CV) oferă oportunități transformatoare pentru a depăși aceste provocări (Roggio et al., 2024; Yang et al., 2024). Aceste „soluții inteligente” pot analiza posturile din date video sau imagini, permițând o evaluare neinvazivă, scalabilă și rentabilă. Modelele DL, în special Rețelele Neuronale Convoluționale (CNN) precum ResNet-50 (He et al., 2016), au demonstrat un succes remarcabil în clasificarea imaginilor și estimarea posturii umane, permițând urmărirea precisă a articulațiilor și unghiurilor corpului (Cao et al., 2017). Această capacitate este foarte relevantă pentru evaluarea riscurilor ergonomice, unde DL poate identifica abaterile posturale și poate prezice riscurile potențiale din datele vizuale. În mod similar, tehnologiile CV, bazate pe algoritmi precum OpenPose (Cao et al., 2019) și arhitecturi avansate precum Rețeaua de Înaltă Rezoluție (HRNet) (Sun et al., 2019), pot detecta și clasifica în prezent posturile umane cu o precizie ridicată, chiar și în medii complexe și dinamice. Integrarea acestor tehnologii avansate în fluxurile de lucru de evaluare ergonomică promite

să sporească eficiența, acuratețea și aplicabilitatea în timp real a analizei posturale. Această teză a urmărit să dezvolte și să evalueze astfel de soluții inteligente, adaptate pentru evaluarea posturală în operațiile forestiere, abordând rolul critic al ergonomiei în minimizarea riscurilor legate de muncă prin valorificarea potențialului imens al acestor tehnologii avansate.

Scop și obiective

Scopul acestei teze a fost de a îmbunătăți metodele existente de evaluare posturală prin selectarea, testarea, adaptarea și validarea tehnicilor inovatoare de ML, DL și CV, pentru a susține prevenirea bolilor profesionale și îmbunătățirea ergonomiei muncii, economisirea resurselor și analiza unor seturi de date mari în evaluarea posturală a operațiilor forestiere. Prin integrarea metodelor ergonomice consacrate cu tehnologiile ML și CV, această cercetare va acoperi lacunele metodelor existente și va oferi un nou cadru pentru o evaluare ergonomică posturală eficientă. Obiectivele specifice ale tezei au fost următoarele: O1. De a realiza o analiză cuprinzătoare a metodelor existente de evaluare ergonomică pentru a identifica lacunele și limitările actuale; O2. De a colecta date reprezentative privind tipurile de operații forestiere manuale, moto-manuale și parțial mecanizate sub formă de fișiere media, care să acopere și variabilitatea factorilor operaționali care afectează starea posturală; O3. De a selecta și testa algoritmi de clasificare ML și CV prin integrarea lor în cadrul conceptual al metodelor de evaluare posturală pentru operațiile manuale, moto-manuale și parțial mecanizate implementate în special în Europa; O4. De a identifica și optimiza cei mai promițători algoritmi de ML și CV în termeni de performanță prin ajustarea fină a hiperparametrilor lor de operare; O5. De a disemina rezultatele cercetărilor.

Organizarea tezei

Teza de doctorat este organizată în capitole de tip manuscris, fiecare concentrându-se pe un subiect specific:

Capitolul 1: Analiza sistematică a metodelor de evaluare posturală convenționale și noi. Acest capitol prezintă o analiză sistematică a literaturii de specialitate care identifică lacunele din metodele existente de evaluare ergonomică posturală, punând bazele pentru cercetări viitoare. Examinează tehnicile contemporane de evaluare ergonomică, în special în silvicultură, contrastând metodele tradiționale cu abordările moderne care utilizează învățarea automată și viziunea computerizată.

Capitolul 2: Dezvoltarea și evaluarea modelelor de clasificare posturală automată în operațiile forestiere utilizând viziunea computerizată bazată pe învățarea profundă. Acest capitol se concentrează pe dezvoltarea și evaluarea modelelor DL pentru automatizarea evaluărilor ergonomice folosind metoda OWAS. Detaliază crearea unui set de date mare, adnotat, și performanța comparativă a patru modele CNN pre-antrenate, culminând cu selecția și reglarea fină a modelului cu cele mai bune performanțe.

Capitolul 3: Atingerea preciziei complete prin învățare profundă și viziune computerizată în clasificarea posturală OWAS. Acest capitol explorează modul în care îmbunătățirea imaginilor 2D convenționale cu puncte cheie și conectori generați de computer poate îmbunătăți acuratețea clasificării posturale bazate pe DL. Compară performanța unui model ResNet-50 pe trei abordări diferite de analiză a imaginilor: imagini obișnuite, imagini ce conțin doar puncte cheie și conectori, și imagini obișnuite ce includ puncte cheie și conectori.

Capitolul 4: Clasificarea posturală prin reprezentarea vectorială a imaginilor și învățare prin transfer.

Acest capitol investighează utilizarea reprezentării vectoriale a imaginilor și a învățării prin transfer pentru a automatiza metoda OWAS pentru evaluarea posturilor în operația de secționare cu ferăstraie mecanice. Analizează performanța modelelor Google Inception V3 și SqueezeNet și discută provocările generate de diferențele de domeniu și utilizarea algoritmilor asupra unor date noi.

Capitolul 5: Fiabilitatea umană și a algoritmilor în evaluarea posturală a operațiilor forestiere prin metoda OWAS. Acest capitol evaluează fiabilitatea evaluărilor posturale comparând evaluările a trei experți umani cu predicțiile unui model de învățare profundă. Analizează fiabilitatea intra- și inter-evaluator, acordul cu datele de referință ale modelului și consumul de timp al evaluărilor umane și a celor automate.

Capitolul 6: Concluzii. Contribuții originale. Diseminarea rezultatelor. Acest capitol final sintetizează constatările din capitolele precedente, subliniază contribuțiile originale ale tezei în domeniu și oferă o listă de publicații științifice și prezentări care au susținut activitatea de diseminare a rezultatelor cercetărilor.

CAPITOLUL 1. O ANALIZĂ SISTEMATICĂ A METODELOR DE EVALUARE POSTURALĂ CONVENȚIONALE ȘI NOI

1.1. MATERIALE ȘI METODE

Scopul acestui studiu a fost de a explora cercetările existente privind aplicațiile ML și CV în evaluarea posturală. Această analiză urmează o metodologie sistematică bazată pe ghidurile PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) (Moher et al., 2015; Page et al., 2021) pentru a identifica, selecta, evalua, sintetiza și raporta studiile relevante din diverse baze de date. A fost elaborat un protocol care a conturat obiectivele, domeniul de aplicare și metodologia analizei. Au fost alese baze de date academice adecvate (de exemplu, PubMed, Scopus, ScienceDirect, Google Scholar, Elsevier, Web of Science, IEEE Xplore, Springer Link) și a fost dezvoltată o listă cuprinzătoare de cuvinte cheie și sinonime legate de tema de cercetare (de exemplu, afecțiuni musculo-scheletice, OWAS, RULA, REBA, ML, DL, CV, evaluare posturală). Căutarea a fost limitată la articole publicate în limba engleză, fără limită de an. Un total de 182 de articole au fost selectate pentru a fi incluse în această analiză, pe baza relevanței lor pentru subiect și a calității metodologice. Criteriile de includere au luat în considerare studiile care au fost publicate pe tema evaluării posturale indiferent de moment, inclusiv cercetările efectuate cu subiecți umani, legate de aplicațiile ML și CV în evaluarea posturală, care au fost disponibile în limba engleză. Pentru a extrage și analiza informațiile relevante, a fost creat un cadru de colectare a datelor pentru a documenta sistematic informațiile cheie din articolele selectate, cum ar fi obiectivele cercetării, metodologia, constatările, limitările și lacunele existente. Diagrama de flux PRISMA din **Figura 1.1** ilustrează etapele metodologice ale analizei literaturii.




Figura 1.1. Diagrama de flux PRISMA a fazelor metodologice ale analizei literaturii pentru acest studiu. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

1.2. REZULTATE ȘI DISCUȚII

O mare varietate de metodologii utilizate în evaluarea posturală au fost identificate și grupate în trei categorii: măsurători directe, abordări observaționale și auto-raportări (David, 2005; Gomez-Galan et al., 2017; Li și Buckle, 1999). Auto-raportările muncitorilor (de exemplu, jurnale, interviuri, chestionare) sunt valoroase pentru colectarea de informații privind expunerea la pericolele legate de muncă, dar pot fi vagi și subiective (David, 2005; Kolgiri et al., 2017). Metodele observaționale sunt esențiale pentru evaluarea expunerii muncitorilor dar pot fi subiective (de exemplu, hărți corporale, scale de evaluare) sau sistematice (de exemplu, înregistrarea posturilor și mișcărilor) (Lorenzini et al., 2023). Tehnicile observaționale mai simple, cum ar fi OWAS, REBA și RULA, utilizează fișe pro-forma pentru a înregistra expunerea la locul de muncă și pentru a prioritiza intervențiile. Metodele avansate utilizează colectarea și analiza computerizată a datelor pentru a oferi o evaluare mai obiectivă a factorilor de risc postural. Măsurarea directă a variabilelor de expunere se realizează prin atașarea de senzori subiectului, inclusiv instrumente portabile, cum ar fi goniometrele electronice, sau sisteme care utilizează markeri optici, acustici sau electromagnetici pentru a urmări mișcările corpului (David, 2005; Kolgiri et al., 2017). Deși aceste metode oferă date de înaltă precizie, ele pot fi costisitoare, necesită expertiză tehnică și pot fi inconfortabile pentru subiect.

Algoritmii formează nucleul sistemelor ML și CV. Progresele recente în algoritmii ML și DL au permis dezvoltarea unor metode CV eficiente și precise pentru evaluarea posturii din indicii vizuale, cum ar fi imaginile și videoclipurile (Debnath et al., 2022; Jiang et al., 2023). Algoritmii ML tradiționali utilizați în CV pentru evaluarea posturală includ Transformarea de Caracteristici Invariantă la Scară (SIFT), Histograma Gradientilor Orientați (HOG), Mașina cu Vectori Suport (SVM) și Modelul Markov Ascuns (HMM) (Ding et al., 2020; Jiang et al., 2023). Alți algoritmi de clasificare includ Pădurea Aleatorie (RF), Arborii de Decizie (DT) și k-Cei Mai Aproiați Vecini (KNN). În ultimii ani, cercetătorii au propus mai mulți algoritmi și arhitecturi de Rețele Neuronale Convoluționale (CNN), cum ar fi rețelele de tip clepsidră stivuite, rețelele de estimare a posturii în mai multe etape, mașinile de postură convoluționale (CPM) și rețelele de înaltă rezoluție (Jiang et al., 2023). Modelele bazate pe DL, cum ar fi ResNet-50, YOLO și OpenPose, au demonstrat un succes remarcabil în evaluarea și identificarea posturală, obținând o precizie ridicată prin extragerea automată a caracteristicilor complexe din imagini.

Utilizarea instrumentelor ML și CV oferă mai multe beneficii pentru analiza datelor, dar există și dezavantaje, inclusiv cerințele computaționale, necesitatea datelor de înaltă calitate și costul software-ului (Alpaydin, 2020; Imbeault-Nepton et al., 2022). Învățarea profundă este o nouă tendință care implică antrenarea algoritmilor folosind seturi mari de date și rețele neuronale. Cu toate acestea, algoritmii CV se confruntă încă cu provocări precum ocluzia, variațiile condițiilor de iluminare, scalabilitatea și timpul de procesare (Russakovsky et al., 2015). Cercetările viitoare vizează dezvoltarea de noi arhitecturi de rețea, rafinarea și adaptarea tehnicilor ML/CV pentru scenarii specializate, îmbunătățirea interpretabilității modelului și abordarea provocărilor legate de antrenarea și implementarea modelelor la scară largă. Un domeniu promițător este aplicarea algoritmilor ML sofisticată pentru a îmbunătăți acuratețea și fiabilitatea evaluărilor posturale în operațiile forestiere.

1.3. CONCLUZII

Evaluarea posturală este un aspect cheie al ergonomiei. Atât metodele convenționale, cât și cele noi pot fi utilizate și pot fi eficiente în îmbunătățirea condițiilor ergonomice. Algoritmii ML sunt utili, deoarece pot învăța din mediul lor și se pot adapta la schimbări, în timp ce CV este un domeniu în evoluție rapidă pentru analiza și interpretarea datelor vizuale. Pe măsură ce ML și CV continuă să avanseze, ele dețin un potențial imens de a transforma numeroase industrii. Cercetările viitoare ar trebui să se concentreze pe rafinarea acestor modele, îmbunătățirea protocoalelor de antrenament, extinderea seturilor de date adnotate și optimizarea tehnicilor de preprocesare a datelor pentru a îmbunătăți acuratețea și aplicabilitatea în diverse medii.

CAPITOLUL 2. DEZVOLTAREA ȘI EVALUAREA MODELELOR AUTOMATIZATE DE CLASIFICARE POSTURALĂ ÎN OPERAȚIILE FORESTIERE UTILIZÂND VIZIUNEA COMPUTERIZATĂ BAZATĂ PE ÎNVĂȚAREA PROFUNDĂ

2.1. MATERIALE ȘI METODE

Din cunoștințele autorilor, la momentul acestui studiu nu erau disponibile seturi de date adnotate specifice industriei. O campanie de teren a fost desfășurată între februarie și aprilie 2024 pentru a colecta înregistrări video ale muncitorilor forestieri. Aceasta a fost completată cu videoclipuri din proiecte anterioare, rezultând 157 de fișiere video și 174.231 de imagini statice. După o etapă manuală de eliminare a imaginilor similare, setul de date a acoperit 229 din cele 252 de clase OWAS posibile. Pentru a genera imagini pentru cele 23 de clase rămase, a fost utilizată o aplicație de conversie a textului în imagine (Freepik). Un subset final conținând 23.000 de imagini a fost reținut pentru dezvoltarea modelului, inclusiv 115 imagini generate artificial.

Dezvoltarea și evaluarea modelelor a implicat mai mulți pași realizați cu ajutorul software-ului MATLAB R2023b. Fluxul de lucru, prezentat în Figura 2.1, a inclus pre-procesarea datelor, adnotarea imaginilor, crearea unei baze de date de imagini, partiționarea și augmentarea datelor, selectarea modelelor CNN pre-antrenate, antrenarea, validarea și testarea.




Figura 2. 1. Fluxul de lucru utilizat pentru dezvoltarea modelului inteligent de clasificare OWAS. Notă: elementele și denumirile sunt redată în limba engleză, exact ca în textul tezei.

Definițiile etichetelor au fost formulate folosind codurile posturale OWAS, rezultând 252 de etichete specifice. Datele au fost partiționate în seturi pentru antrenare, validare și testare într-un raport de 70:15:15%. Patru modele CNN—GoogLeNet, ResNet-50, MobileNet-v2 și ShuffleNet—au fost selectate pentru studiu (Tabelul 2.1). Învățarea prin transfer a fost utilizată pentru a ajusta modelele la cele 252 de clase din setul de date.

După evaluarea celor patru modele pre-antrenate, cel cu cea mai mare acuratețe de clasificare și scor F1 (ResNet-50) a fost selectat pentru reglaj fin. Performanța modelului a fost optimizată prin testarea a trei seturi de opțiuni de antrenament pentru rata de învățare (0,01, 0,001, 0,00001) și dimensiunea seriilor de date (32, 64, 128). Modelul final a fost selectat pe baza unei evaluări cuprinzătoare a indicatorilor de performanță în diverse configurații de reglaj fin.

Tabelul 2.1. Caracteristicile rețelelor pre-antrenate selectate pentru studiu. Sursa: MathWorks, Inc., 2024b

Rețea pre-antrenată	Nr. de straturi	Adâncime	Dimensiune (MB)	Parametri (M)	Total învățabile (M)	Dimensiune intrare
GoogLeNet (Szegedy et al., 2015)	144	22	27.0	7.00	6.200	224×224×3
ResNet-50 (He et al., 2016)	177	50	96.0	25.60	24.000	224×224×3
MobileNet-v2 (Sandler et al., 2018)	155	53	13.0	3.50	2.500	224×224×3
ShuffleNet (Zhang et al., 2018)	50	50	5.20	1.40	0.999	224×224×3

Un set de date separat, format din 20 de imagini externe, a fost utilizat pentru a verifica calitatea clasificării și capacitatea de generalizare a modelului final. Funcția „classify” din MATLAB a fost utilizată pentru a produce etichete și scoruri de probabilitate pentru imagini.

2.2. REZULTATE

Figura 2.2 sintetizează principalele rezultate privind antrenarea și validarea modelelor. Modelul cu cele mai bune performanțe a fost ResNet-50, cu o acuratețe de 90,0% și 91,0% în timpul antrenării și, respectiv, al validării. Toate modelele au prezentat pierderi mai mici în timpul validării în comparație cu antrenarea, indicând o generalizare eficientă. **Figura 2.3** sintetizează indicatorii de performanță din etapa de testare. În ceea ce privește performanța clasificării, ResNet-50 a prezentat cea mai mare acuratețe, de 91,2%, și un scor F1 de 77,9%.





Figura 2.2. Acuratețea clasificării (a) și pierderea (b) a modelelor în timpul etapelor de antrenare și validare. Legendă: G – GoogLeNet, R – ResNet-50, M – MobileNet-v2, S – ShuffleNet Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.




Figura 2.3. Performanța de clasificare în timpul testării pentru cele patru modele pre-antrenate. Legendă: G – GoogLeNet, R – ResNet-50, M – MobileNet-v2, S – ShuffleNet Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

Rezultatele pentru modelul ResNet-50 ajustat fin (Figurile 2.4 și 2.5) dezvăluie o relație clară între ratele de învățare și performanța modelului. O rată de învățare de 0.001 a condus la cea mai mare acuratețe (95.70%) și scor F1 (91.17%) în timpul testării. Rezultatele din Figurile 2.6 și 2.7 arată o relație distinctă între dimensiunea seriei de date și performanța modelului. O dimensiune seriei de date de 32 a produs cea mai bună performanță generală, atingând cea mai mare acuratețe de 95.70% și un scor F1 de 91.17% în timpul testării. Configurația finală cu o rată de învățare de 0.001 și o dimensiune a seriei de date de 32 a atins o acuratețe de 96.34% și un scor F1 de 96.47% în faza finală de testare.




Figura 2.4. Acuratețea clasificării (a) și pierderea (b) a modelului ResNet-50 în funcție de rata de învățare în timpul etapelor de antrenare și validare. Notă: dimensiunea lotului a fost menținută la 10. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.




Figura 2.5. Performanța de clasificare a modelului ResNet-50 în timpul testării. Notă: dimensiunea seriei de date a fost menținută la 10; elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.





Figura 2.6. Acuratețea clasificării (a) și pierderea (b) modelului ResNet-50 în funcție de dimensiunea seriei de date în timpul etapelor de antrenare și validare. Notă: rata de învățare a fost menținută la 0.0001; elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.





Figura 2.7. Performanța de clasificare a modelului ResNet-50 în timpul testării. Notă: rata de învățare a fost menținută la 0.0001; elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

Figura 2.8 prezintă scorurile de predicție pe mai multe exemple de imagini externe. Modelul a obținut probabilități foarte mari pentru mai multe imagini din toate clasele posturale, indicând o încredere puternică în predicțiile sale. Modelul a performat bine și pe imaginile generate de AI, cu probabilități generale depășind 50%.



Prediction: postural class = 4142, action category = 4
Probability = 98.94%



Prediction: postural class = 4152, action category = 4
Probability = 99.70%



Prediction: postural class = 3111, action category = 1
Probability = 99.97%



Prediction: postural class = 4171, action category = 2
Probability = 99.03%



Prediction: postural class = 4171, action category = 2
Probability = 99.94%



Prediction: postural class = 2121, action category = 2
Probability = 99.81%

a

b

c



Prediction: postural class = 4263, action category = 4
Probability = 96.50%



Prediction: postural class = 2373, action category = 4
Probability = 71.38%

d

Figura 2.8. Acuratețea predicției pe date externe: a – predicții pe clase cu dominanță în număr de imagini, b – predicții pe clase cu un număr mediu de imagini, c – predicții pe clase cu un număr redus de imagini, d – predicții pe clase cu imagini generate de AI.

2.3. DISCUȚII

Scopul acestui studiu a fost dezvoltarea unui model inteligent OWAS care utilizează CV bazat pe învățare profundă pentru a clasifica posturile de lucru. ResNet-50, un model DCNN, s-a dovedit a fi cel mai robust model, fiind caracterizat de performanță superioară. Procesul de ajustare fină a dus la un model care a atins o acuratețe de peste 96%, demonstrând eficacitatea abordării. Predicțiile pe date externe reflectă nivelurile de încredere ale modelului, cu probabilități ridicate indicând o antrenare robustă. Cu toate acestea, variabilitatea probabilităților sugerează importanța cantității și calității datelor. Studiul a avut și limitări, inclusiv dezechilibrul numărului de instanțe pe clase și natura intensivă din punct de vedere computațional a tehnicilor DL. Cercetările viitoare ar putea explora învățarea de ansamblu și aborda subiectivitatea în evaluarea posturilor din imagini statice.

2.4. CONCLUZII

OWAS este o metodă larg utilizată pentru clasificarea posturilor de lucru. Automatizarea acesteia folosind tehnici CV bazate pe învățare profundă oferă numeroase beneficii. Rezultatele acestui studiu demonstrează că patru modele de învățare profundă utilizate în mod obișnuit au fost extrem de precise în clasificarea posturală bazată pe învățarea prin transfer. După ajustarea fină, ResNet-50 a obținut rezultate impresionante, cu peste 96% în acuratețea clasificării și scorul F1. Îmbunătățiri potențiale ale performanței de clasificare pot fi obținute folosind învățarea de ansamblu, precum și folosind rețele neuronale recurente.

CAPITOLUL 3. ATINGEREA ACURATEȚII DE CLASIFICARE MAXIME PRIN ÎNVĂȚARE PROFUNDĂ ȘI VIZIUNE COMPUTERIZATĂ ÎN CLASIFICAREA POSTURALĂ OWAS: UN EXEMPLU PRIVIND MODUL ÎN CARE PUNCTELE CHEIE ALE CORPULUI GENERATE DE COMPUTER POT ÎMBUNĂȚĂȚI ÎNVĂȚAREA PROFUNDĂ BAZATĂ PE DATE 2D CONVENȚIONALE

3.1. MATERIALE ȘI METODE

O campanie de teren a fost executată între februarie și aprilie 2024 în diverse locații din România (**Figura 3.1**) pentru a documenta posturile și mișcările muncitorilor forestieri. Setul de date a fost extins cu videoclipuri din campanii de teren anterioare, rezultând un set rafinat de 23.000 de imagini pentru dezvoltarea și testarea modelului.




Figura 3.1. Harta României care arată locațiile colectării datelor de teren. Notă: hartă elaborată în QGIS 3.32.1 „Lima” utilizând QuickMapServices, OSM Standard

Trei seturi de date au fost utilizate în acest studiu: PictureOnly (PO), care conține imaginile originale; PictureWithSkeleton (PS), care conține imaginile originale, inclusiv punctele cheie ale corpului și conectorii lor suprapuși pe imaginea originală; și SkeletonOnly (SO), care conține doar punctele cheie ale corpului și conectorii lor. Un subset de 1.260 de imagini a fost selectat pentru dezvoltarea modelului. Detectorul de obiecte YOLOv4 a fost utilizat pentru a detecta chenarele de delimitare în jurul persoanelor, iar detectorul de puncte cheie ale obiectelor HRNet a fost utilizat pentru a identifica punctele cheie.

Modelele au fost dezvoltate pe un computer desktop folosind IDE-ul Python PyCharm Community Edition și TensorFlow. Fluxul de lucru este prezentat în **Figura 3.2**. Pentru fiecare model, arhitectura ResNet-50 pre-antrenată pe setul de date ImageNet a fost folosită ca model de bază. Modelul a fost compilat folosind optimizarea Adam, entropia încrucișată pentru date de tip clase, și metrici precum acuratețea, precizia și recall.




Figura 3.2. Diagrama logică care arată etapele de colectare a datelor, adnotare, dezvoltare și evaluare a modelelor. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

Evaluarea s-a făcut în două etape. În primul rând, performanța pe datele de testare a fost evaluată folosind metrici precum acuratețea, precizia, recall și scorul F1. În al doilea rând, evaluarea a fost efectuată folosind un nou set de date conținând 200 de imagini externe.

3.2. REZULTATE

Figura 3.3 rezumă principalele constatări legate de antrenarea și validarea modelelor ResNet-50. Modelul bazat pe setul de date PS a avut o performanță constantă, cu o acuratețe de 99,5% la antrenare și 99,8% la validare. În contrast, modelul cu SO a prezentat o scădere semnificativă a performanței de la antrenare (99,6%) la validare (66,7%). Modelul cu PO a menținut o performanță ridicată (100,0% la antrenare la 98,0% la validare). **Figura 3.4** prezintă metricile de performanță în timpul fazei de testare. Modelul cu PS a atins o acuratețe finală și un scor F1 de 99,8%. Modelul cu PO a avut o performanță bună, cu o acuratețe de 97,8% și un scor F1 de 97,30%. Modelul cu SO a avut o performanță semnificativ mai scăzută, cu o acuratețe de 66,2% și un scor F1 de 64,3%.





Figura 3. 3. Acuratețea (a) și pierderea (b) modelelor ResNet-50 pre-antrenate în timpul fazelor de antrenare și validare. Legendă: PO - PictureOnly, SO - SkeletonOnly, PS - PictureWithSkeleton. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.




Figura 3.4. Performanța de clasificare în timpul testării pentru modelele ResNet-50 pre-antrenate pe cele trei seturi de date. Legendă: PO - PictureOnly, SO - SkeletonOnly, PS – PictureWithSkeleton. Notă: elementele și denumirile sunt redate în limba engleză, exact ca în textul tezei.

Figurile 3.5, 3.6 și 3.7 arată probabilitățile modelelor pe date externe. Modelele au afișat probabilități foarte mari în mai multe imagini pentru toate clasele posturale și operațiile forestiere, indicând o încredere puternică. Probabilitățile au depășit în general 55%.




Figura 3.5. Acuratețea predicției modelului dezvoltat cu PS pe date externe: a - predicții privind operațiile cu dominantă în numărul de imagini, b - predicții privind operațiile cu un număr mediu de imagini, c - predicții privind operațiile cu un număr redus de imagini, d – predicții privind clasele cu

imagini generate de AI. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

True: OWAS_CODE_RISK_1141_2
Predicted: OWAS_CODE_RISK_1141_2
Probability: 99.23%



True: OWAS_CODE_RISK_1142_2
Predicted: OWAS_CODE_RISK_1142_2
Probability: 60.82%




a

True: OWAS_CODE_RISK_1253_2
Predicted: OWAS_CODE_RISK_1253_2
Probability: 92.81%




True: OWAS_CODE_RISK_1311_1
Predicted: OWAS_CODE_RISK_1311_1
Probability: 85.28%



b

True: OWAS_CODE_RISK_4322_3
Predicted: OWAS_CODE_RISK_4322_3
Probability: 84.00%



True: OWAS_CODE_RISK_4332_3
Predicted: OWAS_CODE_RISK_4332_3
Probability: 55.07%



c

True: OWAS_CODE_RISK_4352_4
Predicted: OWAS_CODE_RISK_4352_4
Probability: 88.29%



True: OWAS_CODE_RISK_4262_4
Predicted: OWAS_CODE_RISK_4262_4
Probability: 73.00%



d

Figura 3.6. Acuratețea predicției modelului dezvoltat cu SO pe date externe: a - predicții privind operațiile cu dominanță în numărul de imagini, b - predicții privind operațiile cu un număr mediu de imagini, c - predicții privind operațiile cu un număr redus de imagini, d - predicții privind clasele cu imagini generate de AI. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

True: OWAS_CODE_RISK_4131_2
Predicted: OWAS_CODE_RISK_4131_2
Probability: 99.75%



True: OWAS_CODE_RISK_3271_1
Predicted: OWAS_CODE_RISK_3271_1
Probability: 99.37%



a

True: OWAS_CODE_RISK_2273_4
Predicted: OWAS_CODE_RISK_2273_4
Probability: 99.92%



True: OWAS_CODE_RISK_4141_4
Predicted: OWAS_CODE_RISK_4141_4
Probability: 99.82%



b

True: OWAS_CODE_RISK_1171_1
Predicted: OWAS_CODE_RISK_1171_1
Probability: 99.88%



True: OWAS_CODE_RISK_3111_1
Predicted: OWAS_CODE_RISK_3111_1
Probability: 99.99%



c

True: OWAS_CODE_RISK_4233_4
Predicted: OWAS_CODE_RISK_4233_4
Probability: 99.89%



True: OWAS_CODE_RISK_3243_4
Predicted: OWAS_CODE_RISK_3243_4
Probability: 99.90%



d

Figura 3.7. Acuratețea predicției modelului dezvoltat cu PO pe date nevăzute: a - predicții privind operațiile cu dominantă în numărul de imagini, b - predicții privind operațiile cu un număr mediu de imagini, c - predicții privind operațiile cu un număr redus de imagini, d - predicții privind clasele cu imagini generate de AI. Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

3.3. DISCUȚII

Arhitectura ResNet-50 a demonstrat o performanță excepțională în diverse sarcini de CV. În acest studiu, modelul a fost evaluat pe trei seturi de date distincte. Rezultatele indică faptul că modelul ResNet-50 antrenat pe setul de date PO a depășit constant performanța celor antrenate pe setul de

date SO. În mod special, modelul dezvoltat folosind PS a atins cea mai înaltă performanță de clasificare. Prezența caracteristicilor de fundal cuprinzătoare în PO ajută la capturarea informațiilor contextuale suplimentare. Scorurile de probabilitate ridicate din predicțiile modelului oferă informații importante despre încrederea și fiabilitatea modelului. Studiul a avut și limitări, inclusiv dimensiunea redusă a seturilor de date și subreprezentarea unor categorii de posturi.

3.4. CONCLUZII

Acest studiu demonstrează că modelul ResNet-50 antrenat pe setul de date PS a atins cea mai înaltă performanță de 99,8% acuratețe și scor F1 în timpul fazei de testare. Acest lucru subliniază importanța informațiilor complete despre schelet și context în antrenarea modelelor robuste. Integrarea OWAS cu învățarea profundă este o alternativă promițătoare pentru o evaluare și atenuare mai eficientă a riscurilor ergonomice.

CAPITOLUL 4. CLASIFICAREA POSTURALĂ PRIN REPREZENTAREA VECTORIALĂ A IMAGINILOR ȘI ÎNVĂAREA PRIN TRANSFER: UN EXEMPLU DE UTILIZARE A METODEI OWAS ÎN MUNCA CU FERĂSTRAIE MECANICE PENTRU AUTOMATIZAREA PROCESULUI ȘI ECONOMISIREA RESURSELOR

4.1. MATERIALE ȘI METODE

Studiul de teren a inclus colectarea de materiale media care documentează operația de secționare cu ferăstraie mecanice în cazul lemnului de tec (*Tectona grandis* L.f.), în provincia Kanchanaburi, Thailanda (Figura 4.1). Au fost colectate în total 14 videoclipuri, rezultând peste 5000 de imagini statice considerate valide pentru analiza detaliată.



Figura 4.1. Un exemplu de imagine utilizată pentru modelare (stânga) și locația studiului (dreapta).
Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

Toate imaginile au fost evaluate vizual și clasificate conform sistemului de clasificare posturală OWAS. În urma evaluării vizuale, imaginile au fost stocate în foldere conform codurilor de patru cifre (set de date Postură) și categoriilor de acțiune corespunzătoare (set de date Acțiune). Setul de date final pentru analiză a cuprins 5001 de imagini. **Tabelul 4.1** prezintă distribuția imaginilor pe categorii de acțiuni.

Tabelul 4.1. Frecvența categoriilor de acțiuni identificate în setul de date utilizat pentru învățarea automată.

Cod Categorie Acțiune	Descriere	Frecvență Absolută (n)	Frecvență Relativă (n/N×100)
1	Nu este necesară nicio acțiune corectivă.	80	1.6
2	Sunt necesare acțiuni corective în viitorul apropiat.	1849	36.9
3	Sunt necesare acțiuni corective cât mai curând posibil.	125	2.5
4	Sunt necesare acțiuni corective imediat.	2951	59.0
Total (N)	-	5001	100

Notă: n reprezintă frecvența absolută a categoriei de acțiune, iar N reprezintă dimensiunea eșantionului de date.

Software-ul Orange Visual Programming a fost utilizat pentru a dezvolta, antrena și testa modelele de învățare automată. Două arhitecturi, Google's Inception V3 și SqueezeNet, au fost utilizate pentru a obține reprezentarea vectorială a imaginilor. O rețea neuronală artificială a fost utilizată pentru clasificare locală. Modelele au fost antrenate și testate folosind o gamă de arhitecturi (de la 1 la 10 straturi) și număr de neuroni (10, 100, 1000). Un set separat de 406 de imagini externe a fost pregătit pentru testare.

4.2. REZULTATE

Principalele rezultate ale metricilor de acuratețe a clasificării sunt prezentate în Figurile 4.2-4.5. Modelele cu cele mai bune performanțe pentru rețeaua Inception V3 au atins o acuratețe maximă de clasificare de 0,836. Pentru SqueezeNet, acuratețea maximă de clasificare a fost de 0,820. În general, arhitecturile de rețele neuronale care conțin 100 și 1000 de neuroni au avut performanțe mai bune.




Figura 4.2. Acuratețea clasificării (CA) pe setul de date Postură în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redate în limba engleză, exact ca în textul tezei.




Figura 4.3. Scorul F1 (F1) pe setul de date Postură în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă

numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.



Figura 4.4. Precizia (PREC) pe setul de date Postură în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

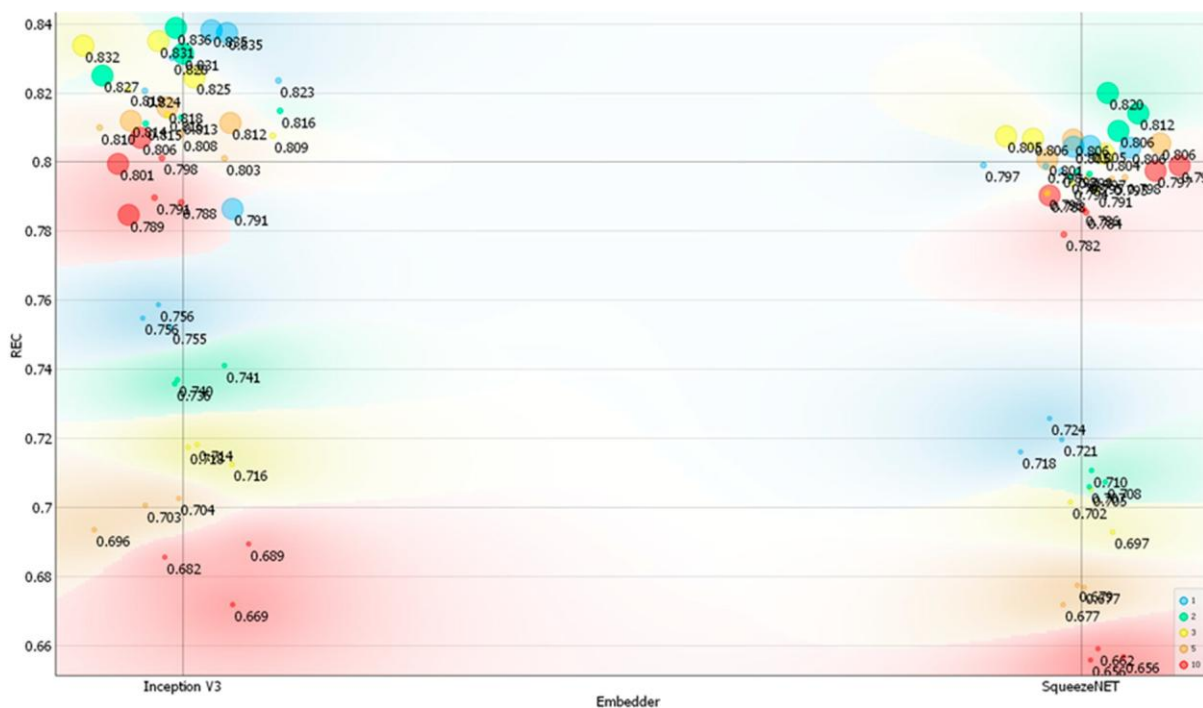


Figura 4.5. Recall (REC) pe setul de date Postură în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

Acuratețea clasificării modelelor pe setul de date Acțiune este prezentată în Figurile 4.6–4.9. Cele două rețele au avut performanțe similare, atingând acurateți de clasificare și recall de top de 0.888–0.889 și un scor F1 și precizie de 0.886. Acuratețea de clasificare îmbunătățită pe setul de date Acțiune poate fi atribuită complexității sale de clasificare mai scăzute.




Figura 4.6. Acuratețea clasificării (CA) pe setul de date Acțiune în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.




Figura 4.7. Scorul F1 (F1) pe setul de date Acțiune în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.




Figura 4.8. Precizia (PREC) pe setul de date Acțiune în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul).

numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.




Figura 4.9. Recall (REC) pe setul de date Acțiune în funcție de rețeaua utilizată, numărul de straturi și numărul de neuroni pe strat. Legendă: dimensiunea punctelor de date reprezintă numărul de neuroni utilizați (mic—10 neuroni, mediu—100 neuroni și mare—1000 neuroni) iar culoarea reprezintă numărul de straturi utilizate (roșu—zece, portocaliu—cinci, galben—trei, verde—două și albastru—unul). Notă: elementele și denumirile sunt redactate în limba engleză, exact ca în textul tezei.

Tabelul 4.2 prezintă rezultatele aplicării modelelor antrenate pe date externe. Performanța clasificării a scăzut, cu acurateți de clasificare prezise variind de la 49% la 52% pentru datele de postură și de la 51% la 60% pentru datele de tip categorie de acțiune. Acest lucru sugerează că seturile de date de antrenare și validare s-ar putea să nu fi fost pe deplin reprezentative pentru distribuția datelor din lumea reală.

Tabelul 4.2. Performanța modelelor pe date externe.

Model	Descriere & parametri principali	Categorie Postură sau Acțiune	Număr de instanțe	Predicții corecte	Acuratețe clasificare
1	Inception V3, Date posturale, 2 straturi ascunse, 1000 neuroni fiecare, și $\alpha = 0.0001$	1131	3	0	0.0
		2141	7	2	28.6
		2171	76	4	5.3
		2271	11	0	0.0
		3121	4	0	0.0
		3141	14	0	0.0
		3171	8	0	0.0
		4131	20	0	0.0
		4141	203	174	85.7
		4151	21	0	0.0
		4171	30	15	50.0
		Total	397	195	49.1
2	SqueezeNet, Date posturale, 2 straturi ascunse, 1000 neuroni fiecare, și $\alpha = 0.001$	1131	3	0	0.0
		2141	7	0	0.0
		2171	76	19	25.0
		2271	11	0	0.0
		3121	4	0	0.0
		3141	14	0	0.0
		3171	8	0	0.0
		4131	20	0	0.0
		4141	203	161	79.3
		4151	21	6	28.6
		4171	30	21	30.0
		Total	397	207	52.1
3	Inception V3, Date de acțiune, 1 strat ascuns, 1000 neuroni fiecare, și $\alpha = 0.001$	1	24	0	0.0
		2	137	44	32.1
		3	21	0	0.0
		4	224	161	71.9
		Total	406	205	50.5
4	SqueezeNet, Date de acțiune, 3 straturi ascunse, 1000 neuroni fiecare, și $\alpha = 0.001$	1	24	0	0.0
		2	137	102	74.5
		3	21	2	1.0
		4	224	139	62.1
		Total	406	243	59.9

4.3. DISCUȚII

Acest studiu a evaluat eficacitatea încorporării imaginilor și a învățării prin transfer în facilitarea clasificării posturale precise. Performanța modelelor pe date externe a arătat o gamă de acuratețe a clasificării de 49% până la 52% pentru datele de postură și de 51% până la 60% pentru datele de categorie de acțiune. Studiile anterioare au evidențiat punctele forte ale modelelor de învățare profundă. O comparație a acestor studii cu studiul actual relevă rezultate de performanță mai scăzute, evidențiind domenii pentru îmbunătățiri potențiale. Constatările subliniază importanța dimensiunii și diversității setului de date în îmbunătățirea eficienței modelului de învățare automată.

4.4. CONCLUZII

Acest studiu propune o metodă nouă pentru automatizarea procesului de clasificare posturală în munca cu ferăstraie mecanice prin intermediul OWAS, economisind în același timp resurse. Constatările demonstrează că i) clasificarea problemelor complexe, cum ar fi cele de evaluare posturală, poate fi realizată cu o acuratețe remarcabilă (84%-89%), ii) este posibilă reconfigurarea rețelelor de învățare profundă cu mai puțin efort și iii) reprezentările de imagini învățate pot fi mai puțin eficiente pe date externe (50%-60%). Metoda propusă poate reduce potențial costul evaluărilor ergonomice.

CAPITOLUL 5. FIABILITATEA UMANĂ ȘI COMPUTERIZATĂ ÎN EVALUAREA POSTURALĂ A OPERAȚIILOR FORESTIERE PRIN METODA OWAS: NIVEL DE CONCORDANȚĂ ȘI RESURSE DE TIMP

5.1. MATERIALE ȘI METODE

Modelul ResNet-50 (He et al., 2016), o rețea neuronală convoluțională profundă, a fost utilizat ca referință pentru acest studiu datorită eficacității sale dovedite în sarcinile de clasificare a imaginilor. Selecția sa s-a bazat pe rezultatele experimentale anterioare (Forkuo și Borz, 2024) care au demonstrat acuratețea superioară a clasificării și echilibrul favorabil cu eficiența computațională în comparație cu alte modele precum GoogLeNet, MobileNet-v2 și ShuffleNet.

Un set de date separat de 100 de imagini a fost compilat pentru a reflecta cu acuratețe diversele posturi și mișcări ale muncitorilor forestieri. Trei evaluatori umani experți (R1, R2 și R3) au fost selectați pentru a evalua aceste imagini folosind metoda OWAS (**Tabelul 5.1**). Pentru a asigura fiabilitatea, procesul de evaluare a fost efectuat în două replicări separate (r1 și r2), cu un interval de o lună între ele.

Tababelul 5.1. Descrierea codurilor și categoriilor OWAS utilizate în studiu

Caracteristică	Abreviere în studiu	Număr de categorii conform OWAS	Descriere
Spate	B	4	Describe postura spatelui, începând de la o postură dreaptă neutră și terminând cu spatele fiind îndoit și răsucit
Brațe	A	3	Describe postura brațelor, începând de la o postură neutră cu ambele brațe sub nivelul umerilor și terminând cu ambele brațe fiind la sau deasupra nivelului umerilor
Picioare	L	7	Describe postura picioarelor prin șapte categorii, începând de la o postură așezată neutră și terminând cu picioarele angajate în mers sau mișcare
Efort de forță	F	3	Describe nivelul de efort de forță, începând cu manipularea sarcinilor sau exercitarea forțelor mai mici de 10 kg și terminând cu manipularea sarcinilor sau exercitarea forțelor de peste 20 kg
Categorie acțiune	AC	4	Indică nivelul de risc postural prin urgența intervențiilor ergonomice necesare, începând de la nicio intervenție necesară și terminând cu intervenție necesară imediat

Fiabilitatea a fost evaluată folosind mai multe seturi de date, așa cum este detaliat în **Tabelul 5.2**. Fiabilitatea intra-evaluator a fost determinată prin compararea celor două replicări ale unui evaluator (de exemplu, R1r1 vs. R1r2). Fiabilitatea inter-evaluatori a implicat comparații între diferiți evaluatori

pentru aceeași replicare. Modelul de învățare profundă a fost utilizat pentru a genera un set de date de referință (RM), considerat a conține datele de referință, față de care a fost evaluată și fiabilitatea evaluatorilor umani.

Tabelul 5.2. Descrierea seturilor de date utilizate în evaluare

Nr. evaluator	Replicare Nr.	Abrevierea setului de date	Descrierea setului de date
R1	r1	R1r1	Evaluările primului evaluator în prima replicare
R1	r2	R1r2	Evaluările primului evaluator în a doua replicare
R2	r1	R2r1	Evaluările celui de-al doilea evaluator în prima replicare
R2	r2	R2r2	Evaluările celui de-al doilea evaluator în a doua replicare
R3	r1	R3r1	Evaluările celui de-al treilea evaluator în prima replicare
R3	r2	R3r2	Evaluările celui de-al treilea evaluator în a doua replicare
RM	-	RM	Evaluarea modelului de învățare profundă

Indicele Kappa propus de Cohen (Cohen, 1960) și indicele kappa propus de Fleiss (Fleiss, 1971) au fost metricile principale pentru evaluarea fiabilității. Eficiența sub raportul consumului de timp a fost evaluată prin înregistrarea timpului necesar fiecărui evaluator uman pentru a clasifica o imagine și compararea acestuia cu timpul de evaluare programatică a modelului DL. Analizele statistice, inclusiv scalarea multidimensională (MDS) pentru acordul vizual și testele non-parametrice pentru datele de consum de timp, au fost efectuate folosind software-ul Orange Visual Programming și Python.

5.2. REZULTATE ȘI DISCUȚII

Analiza MDS (**Figura 5.1**) a relevat un anumit grad de acord între evaluatorii umani, deși cu o dispersie considerabilă. Când au fost incluse evaluările modelului DL (**Figura 5.2**), s-a observat un nivel mai ridicat de dezacord, punctele de date ale modelului fiind adesea poziționate distinct față de cele ale evaluatorilor umani, indicând un model de clasificare diferit.




Figura 5.1. Rezultatele scalării multidimensionale privind acordul evaluatorilor umani. Legendă: R1 – evaluator 1, R2 – evaluator 2, R3 – evaluator 3, r1 – date din prima replicare, r2 – date din a doua replicare. Notă: elementele și denumirile sunt redată în limba engleză, exact ca în textul tezei.




Figura 5.2. Rezultatele scalării multidimensionale privind acordul dintre evaluatorii umani și model. Legendă: R1 - evaluator 1, R2 – evaluator 2, R3 – evaluator 3, RM – evaluarea modelului de învățare profundă, r1 – date din prima replicare, r2 – date din a doua replicare. Notă: pentru RM a fost utilizată o singură evaluare. Notă: elementele și denumirile sunt redată în limba engleză, exact ca în textul tezei.

Acordul intra-evaluator (**Tabelul 5.3**) a fost ridicat, cu valori ale indicelui kappa propus de Cohen variind de la 0,48 la 1,00, indicând o consistență moderată spre aproape perfectă pentru evaluatorii individuali între replica ii.

Tabelul 5.3. Rezultatele fiabilității intra-evaluator pentru cei trei evaluatori umani

Seturi de date comparate		# Evaluări	P_o	P_e	k	% Acord	Interpretarea kappa
BR1r1	BR1r2	100	0.69	0.29	0.56	69	Acord moderat
AR1r1	AR1r2	100	0.93	0.71	0.76	93	Acord substanțial
LR1r1	LR1r2	100	0.68	0.26	0.57	68	Acord moderat
FR1r1	FR1r2	100	0.90	0.62	0.74	90	Acord substanțial
ACR1r1	ACR1r2	100	0.61	0.25	0.48	61	Acord moderat
BR2r1	BR2r2	100	0.97	0.33	0.96	97	Acord aproape perfect
AR2r1	AR2r2	100	1.00	0.73	1.00	100	Acord aproape perfect
LR2r1	LR2r2	97	0.99	0.25	0.99	99	Acord aproape perfect
FR2r1	FR2r2	100	0.95	0.51	0.90	95	Acord aproape perfect
ACR2r1	ACR2r2	97	0.95	0.26	0.93	95	Acord aproape perfect
BR3r1	BR3r2	100	0.96	0.39	0.93	96	Acord aproape perfect
AR3r1	AR3r2	100	0.98	0.84	0.88	98	Acord aproape perfect
LR3r1	LR3r2	100	0.99	0.32	0.99	99	Acord aproape perfect
FR3r1	FR3r2	100	0.98	0.48	0.96	98	Acord aproape perfect
ACR3r1	ACR3r2	100	0.96	0.32	0.94	96	Acord aproape perfect

Notă: P_o denotă acordul observat; P_e denotă acordul așteptat din întâmplare; k denotă statistica kappa a lui Cohen, B denotă postura spatelui, A denotă postura brațelor, L denotă postura picioarelor, F denotă nivelul de exercitare a for ei, AC denotă categoria de acțiune. Abrevierile complete au fost compuse folosind tipul de caracteristică sub evaluare (B, A, L sau AC, **Tabelul 5.2**) și seturile de date prezentate în **Tabelul 5.1**.

În contrast, fiabilitatea inter-evaluator (**Tabelul 5.4**) a fost semnificativ mai scăzută și mai variabilă, cu valori kappa de la 0,02 (ușor) la 0,64 (substanțial), evidențiind subiectivitatea inerentă a evaluării manuale.

Tabelul 5.4. Rezultatele fiabilității inter-evaluator între cei trei evaluatori umani

Seturi de date comparate		# Evaluări	P_o	P_e	k	% Acord	Interpretarea kappa
BR1r1	BR2r1	100	0.46	0.24	0.29	46	Acord acceptabil
BR1r1	BR3r1	100	0.62	0.36	0.41	62	Acord moderat
BR2r1	BR3r1	100	0.34	0.29	0.07	34	Acord scăzut
AR1r1	AR2r1	100	0.91	0.70	0.70	91	Acord substanțial
AR1r1	AR3r1	100	0.89	0.75	0.56	89	Acord moderat
AR2r1	AR3r1	100	0.88	0.78	0.46	88	Acord moderat
LR1r1	LR2r1	97	0.57	0.21	0.45	57	Acord moderat
LR1r1	LR3r1	100	0.64	0.26	0.52	64	Acord moderat
LR2r1	LR3r1	100	0.60	0.25	0.46	60	Acord moderat
FR1r1	FR2r1	100	0.74	0.52	0.46	74	Acord moderat
FR1r1	FR3r1	100	0.70	0.53	0.37	70	Acord acceptabil
FR2r1	FR3r1	100	0.72	0.48	0.46	72	Acord moderat
ACR1r1	ACR2r1	100	0.54	0.24	0.40	54	Acord acceptabil
ACR1r1	ACR3r1	100	0.52	0.27	0.34	52	Acord acceptabil
ACR2r1	ACR3r1	97	0.40	0.23	0.22	40	Acord acceptabil
BR1r2	BR2r2	100	0.58	0.28	0.41	58	Acord moderat
BR1r2	BR3r2	100	0.41	0.30	0.15	41	Acord scăzut
BR2r2	BR3r2	100	0.32	0.30	0.02	32	Acord scăzut
AR1r2	AR2r2	100	0.90	0.73	0.62	90	Acord substanțial
AR1r2	AR3r2	100	0.92	0.79	0.63	92	Acord substanțial
AR2r2	AR3r2	100	0.86	0.78	0.37	86	Acord acceptabil
LR1r2	LR2r2	100	0.56	0.24	0.42	56	Acord moderat
LR1r2	LR3r2	100	0.75	0.31	0.64	75	Acord substanțial
LR2r2	LR3r2	100	0.58	0.25	0.44	58	Acord moderat
FR1r2	FR2r2	100	0.79	0.55	0.53	79	Acord moderat
FR1r2	FR3r2	100	0.73	0.55	0.40	73	Acord acceptabil
FR2r2	FR3r2	100	0.75	0.48	0.52	75	Acord moderat
ACR1r2	ACR2r2	100	0.56	0.25	0.42	56	Acord moderat
ACR1r2	ACR3r2	100	0.41	0.25	0.22	41	Acord acceptabil
ACR2r2	ACR3r2	100	0.40	0.23	0.22	40	Acord acceptabil

Notă: P_o denotă acordul observat; P_e denotă acordul așteptat din întâmplare; k denotă statistica kappa a lui Cohen, B denotă postura spatelui, A denotă postura brațelor, L denotă postura picioarelor, F denotă nivelul de exercitare a forței, AC denotă categoria de acțiune. Abrevierile complete au fost compuse folosind tipul de caracteristică sub evaluare (B, A, L sau AC, Tabelul 5.2) și seturile de date prezentate în Tabelul 5.1.

Acordul dintre evaluatorii umani și modelul DL ca referință (Tabelul 5.5) a fost în general slab spre ușor, cu valori kappa variind de la -0,03 la 0,34. Acest lucru sugerează o diferență sistematică între interpretarea umană individuală și modelele bazate pe datele învățate de model.

Tabelul 5.5. Rezultatele acordului pe perechi între evaluatorii umani și modelul de învățare profundă

Seturi de date comparate		# Evaluări	P_o	P_e	k	% Acord	Interpretarea kappa
BR1r1	BRM	100	0.43	0.34	0.13	43	Acord ușor
BR1r2	BRM	100	0.34	0.30	0.06	34	Acord ușor
BR2r1	BRM	100	0.32	0.30	0.03	32	Acord ușor
BR2r2	BRM	100	0.30	0.30	0.00	30	Acord slab
BR3r1	BRM	100	0.57	0.37	0.32	57	Acord acceptabil
BR3r2	BRM	100	0.57	0.38	0.31	57	Acord acceptabil
AR1r1	ARM	100	0.75	0.76	-0.03	75	Acord slab
AR1r2	ARM	100	0.79	0.79	-0.02	79	Acord slab
AR2r1	ARM	100	0.78	0.78	-0.02	78	Acord slab
AR2r2	ARM	100	0.78	0.78	-0.02	78	Acord slab
AR3r1	ARM	100	0.85	0.84	0.04	85	Acord ușor
AR3r2	ARM	100	0.85	0.84	0.04	85	Acord ușor
LR1r1	LRM	100	0.38	0.24	0.18	38	Acord ușor
LR1r2	LRM	100	0.46	0.28	0.25	46	Acord acceptabil
LR2r1	LRM	97	0.44	0.25	0.26	44	Acord acceptabil
LR2r2	LRM	100	0.43	0.24	0.25	43	Acord acceptabil
LR3r1	LRM	100	0.50	0.29	0.29	50	Acord acceptabil
LR3r2	LRM	100	0.49	0.30	0.28	49	Acord acceptabil
FR1r1	FRM	100	0.60	0.47	0.24	60	Acord acceptabil
FR1r2	FRM	100	0.59	0.49	0.20	59	Acord ușor
FR2R1	FRM	100	0.53	0.44	0.16	53	Acord ușor
FR2r2	FRM	100	0.56	0.44	0.21	56	Acord acceptabil
FR3r1	FRM	100	0.61	0.44	0.31	61	Acord acceptabil
FR3r2	FRM	100	0.63	0.44	0.34	63	Acord acceptabil
ACR1r1	ACRM	100	0.32	0.26	0.08	32	Acord ușor
ACR1r2	ACRM	100	0.38	0.25	0.18	38	Acord ușor
ACR2r1	ACRM	97	0.35	0.24	0.15	35	Acord ușor
ACR2r2	ACRM	100	0.36	0.24	0.16	36	Acord ușor
ACR3r1	ACRM	100	0.50	0.29	0.29	50	Acord acceptabil
ACR3r2	ACRM	100	0.51	0.30	0.30	51	Acord acceptabil

Notă: P_o denotă acordul observat; P_e denotă acordul așteptat din întâmplare; k denotă statistica kappa a lui Cohen, B denotă postura spatelui, A denotă postura brațelor, L denotă postura picioarelor, F denotă nivelul de exercitare a forței, AC denotă categoria de acțiune. Abrevierile complete au fost compuse utilizând tipul de caracteristică aflată în evaluare (B, A, L sau AC, Tabelul 5.2) și seturile de date prezentate în Tabelul 5.1.

Acordul general, luând în considerare toți evaluatorii umani față de modelul DL utilizând indicele kappa propus de Fleiss (Tabelul 5.6), s-a îmbunătățit, indicând un nivel acceptabil până la moderat (kappa =

0,28–0,49). Acest lucru indică faptul că, deși rezultatele evaluărilor individuale pot fi divergente, rezultatele evaluării colective sunt mai aliniate cu predicțiile modelului.

Tabelul 5.6. Rezultatele acordului general între cei trei evaluatori umani și modelul ResNet-50

Evaluări sub comparație				# Evaluări	P_o	P_e	k	% Acord	Interpretarea kappa
BR1R1	BR2R1	BR3R1	BRM	100	0.53	0.34	0.28	53	Acord acceptabil
AR1R1	AR2R1	AR3R1	ARM	100	0.88	0.77	0.49	88	Acord moderat
LR1R1	LR2R1	LR3R1	LRM	97	0.52	0.23	0.37	52	Acord acceptabil
FR1R1	FR2R1	FR3R1	FRM	100	0.66	0.47	0.37	66	Acord acceptabil
ACR1R1	ACR2R1	ACR2R1	ACRM	97	0.52	0.26	0.35	52	Acord acceptabil
BR1R2	BR2R2	BR3R2	BRM	100	0.49	0.31	0.26	49	Acord acceptabil
AR1R2	AR2R2	AR3R2	ARM	100	0.89	0.79	0.47	89	Acord moderat
LR1R2	LR2R2	LR3R2	LRM	100	0.53	0.25	0.38	53	Acord acceptabil
FR1R2	FR2R2	FR3R2	FRM	100	0.68	0.47	0.37	68	Acord acceptabil
ACR1R2	ACR2R2	ACR2R2	ACRM	100	0.51	0.27	0.33	51	Acord acceptabil

Notă: P_o denotă acordul observat; P_e denotă acordul așteptat prin hazard; k denotă statistica kappa a lui Fleiss, B denotă postura spatelui, A denotă postura brațelor, L denotă postura picioarelor, F denotă nivelul de exercitare a forței, AC denotă categoria de acțiune. Abrevierile complete au fost compuse utilizând tipul de caracteristică aflată în evaluare (B, A, L sau AC, **Tabelul 5.2**) și seturile de date prezentate în **Tabelul 5.1**.

În termeni de eficiență temporală (**Tabelul 5.7**), modelul DL a fost net superior, efectuând, în medie, evaluări de 19 până la 53 de ori mai rapid decât evaluatorii umani. O variabilitate semnificativă a timpului de evaluare a fost observată și între evaluatorii umani, subliniind în continuare beneficiile legate de eficiență și consistență ale abordării automate.

Tabelul 5.7. Rezultatele testelor de comparație pentru datele privind consumul de timp

Variabile sub comparație	Valori mediane (s)	Rezultatele testului de normalitate ¹	Rezultatele testului de comparație ²
TR1r1-TR1r2	30.0 – 24.0	Nu, $p < 0.001$ -No, $p < 0.001$	Da, $p < 0.001$
TR2r1-TR2r2	52.5 – 44.0	Nu, $p < 0.001$ -No, $p < 0.001$	Da, $p < 0.001$
TR3r1-TR3r2	19.0 – 20.0	Nu, $p < 0.001$ -No, $p < 0.001$	Nu, $p = 0.608$
TR1r1-TR2r1	30.0 – 52.5	Nu, $p < 0.001$ -No, $p < 0.001$	Da, $p < 0.001$
TR1r1-TR3r1	30.0 – 19.0	Nu, $p < 0.001$ -No, $p < 0.001$	Da, $p < 0.001$
TR2r1-TR3r1	52.5 – 19.0	Nu, $p < 0.001$ -No, $p < 0.001$	Da, $p < 0.001$
TR1r2-TR2r2	24.0 – 44.0	Nu, $p < 0.001$ -No, $p < 0.001$	Da, $p < 0.001$
TR1r2-TR3r2	30.0 – 20.0	Nu, $p < 0.001$ -No, $p < 0.001$	Da, $p = 0.003$
TR2r2-TR3r2	44.0 – 20.0	Nu, $p < 0.001$ -No, $p < 0.001$	Da, $p < 0.001$

Notă: 1 – Conform testului Shapiro-Wilk; 2 – diferențe semnificative conform testului bi-direc ional non-parametric Mann-Whitney, T reprezintă setul de date privind consumul de timp.

5.3. CONCLUZII

Acest studiu arată că modelele DL prezintă avantaje semnificative pentru efectuarea evaluărilor posturale bazate pe OWAS, oferind îmbunătățiri remarcabile ale vitezei, atingând în același timp niveluri de fiabilitate comparabile cu metodele tradiționale care implică evaluatori umani. Constatările au arătat că, deși evaluatorii umani au prezentat o fiabilitate intra-evaluator moderată spre aproape perfectă, acordul lor inter-evaluator a fost considerabil mai scăzut. Modelul DL servește nu numai ca o alternativă extrem de eficientă din punct de vedere al resurselor, ci și ca un punct de referință stabil pentru evaluarea evaluărilor OWAS.

CAPITOLUL 6. CONCLUZII. CONTRIBUȚII ORIGINALE. DISEMINAREA REZULTATELOR

6.1. Concluzii

Această teză de doctorat subliniază importanța evaluării posturale în ergonomie, în special în cadrul operațiilor forestiere, unde identificarea posturilor cu risc ridicat este esențială pentru dezvoltarea unor intervenții eficiente. Cercetarea demonstrează că atât metodele convenționale, cât și cele inovatoare, inclusiv învățarea automată (ML) și viziunea computerizată (CV), îmbunătățesc semnificativ acuratețea și eficiența clasificării posturale. Automatizarea metodei OWAS folosind tehnici CV bazate pe învățarea profundă produce performanțe de clasificare impresionante, modelul ResNet-50 dovedindu-se cea mai eficientă opțiune în aplicațiile din lumea reală. Mai mult, integrarea informațiilor generate artificial cu cele contextuale complete se dovedește a optimiza fiabilitatea și eficacitatea modelului. Introducerea unei noi abordări care utilizează încorporarea imaginilor și învățarea prin transfer permite o clasificare posturală precisă cu o dependență redusă de expertiza în programare. În plus, constatările relevă că modelele de învățare profundă oferă avantaje substanțiale față de evaluările umane tradiționale, oferind soluții eficiente din punct de vedere al resurselor, care scad timpul de evaluare și sporesc consistența. În ciuda provocărilor, cum ar fi variabilitatea evaluărilor umane și limitările privind performanța la utilizarea datelor externe, această cercetare evidențiază potențialul transformator al ML și CV în avansarea metodelor de evaluare posturală. Cercetările viitoare ar trebui să prioritizeze rafinarea acestor modele, îmbunătățirea protocoalelor de antrenament al algoritmilor, extinderea seturilor de date adnotate și optimizarea tehnicilor de preprocesare a datelor pentru a îmbunătăți în continuare acuratețea și aplicabilitatea în diverse medii. Prin aceste eforturi, se poate atinge obiectivul final de a îmbunătăți sănătatea, siguranța și eficiența operațională a muncitorilor din domeniul forestier și nu numai.

6.2. Contribuții originale

Această teză de doctorat a adus contribuții semnificative în domeniul evaluării ergonomice în operațiile forestiere prin dezvoltarea și evaluarea unor metode noi și a unor seturi de date extinse. Contribuțiile originale cheie includ:

Crearea unui set de date cuprinzător și nou: A fost creat un set de date cuprinzând 23.000 de imagini adnotate pentru clasificarea OWAS în domeniul forestier. Integrarea inovatoare a datelor colectate pe teren cu imagini generate de AI asigură o acoperire completă a tuturor celor 252 de combinații posturale OWAS, abordând provocarea persistentă a deficitului de date.

Dezvoltarea unui flux de lucru automatizat: A fost stabilit un nou flux de lucru pentru clasificarea automată OWAS, identificând hiperparametri optimi (rata de învățare de 0,001, dimensiunea seriei de date de 32) prin reglare fină sistematică, creând un cadru robust pentru aplicații viitoare.

Îmbunătățirea datelor de intrare cu puncte cheie: A fost implementată o strategie inovatoare care a îmbunătățit imaginile de intrare convenționale cu puncte cheie corporale și conectori generate de computer, care s-a dovedit a îmbunătăți semnificativ acuratețea clasificării cu 2-2,5% și a atinge o acuratețe aproape perfectă de 99,8%.

Prima evaluare a DL pentru OWAS în domeniul forestier: Această teză reprezintă prima dezvoltare și evaluare a tehnicilor de viziune computerizată bazate pe învățare profundă pentru automatizarea clasificării posturale OWAS în domeniul forestier, testând patru modele CNN pre-antrenate și stabilind noi standarde de performanță, cu modelul ResNet-50 reglat fin atingând o acuratețe de clasificare de peste 96%.

Avansarea automatizării prin reprezentarea vectorială a imaginilor: Automatizarea evaluării posturii a fost avansată prin aplicarea tehnicilor de reprezentare vectorială a imaginilor și a învățării prin transfer, atingând rate de acuratețe între 84% și 89% fără a fi nevoie de senzori specializați sau de cunoștințe extinse de programare.

Analiză de pionierat a fiabilității umane în comparație cu cea a algoritmilor DL: A fost efectuată o analiză de pionierat a evaluărilor posturale generate de oameni și algoritmi, cuantificând fiabilitatea intra- și inter-evaluator și stabilind o comparație cu modelul ResNet-50 ca referință, evidențiind viteza și consistența superioare ale modelului DL.

6.3. Diseminarea rezultatelor

6.3.1. Publicații științifice din tematica tezei de doctorat

A. Lucrări publicate în reviste BDI

Forkuo, G.O., 2023. A systematic survey of conventional and new postural assessment methods. *Revista Pădurilor*, 138(3), 34p. Available online at: http://revistapadurilor.com/wp-content/uploads/2024/01/RP_138-3-2023.-BT.pdf.

B. Lucrări publicate în reviste indexate de Clarivate Analytics (fostul ISI Web of Science)

Forkuo, G.O., Borz, S.A., Kaakkurivaara, T., Kaakkurivaara, N., 2025. Postural classification by image embedding and transfer learning: An example of using the OWAS method in motor-manual work to automate the process and save resources. *Forests*, 16(3), 492. <https://doi.org/10.3390/f16030492>

Forkuo, G.O., Marcu, M.V., Kaakkurivaara, N., Kaakkurivaara, T., Borz, S.A., 2025. Human and machine reliability in postural assessment of forest operations by OWAS method: Level of agreement and time resources. *Forests*, 16(5), 759. <https://doi.org/10.3390/f16050759>.

6.3.1.1. Lucrări prezentate la conferințe științifice naționale

Forkuo, G.O., 2023. A systematic survey of conventional and new postural assessment methods. In: *Book of Abstracts, Proceedings of the 6th Edition of the Integrated Management of Environmental Resources Conference Suceava – Romania, 23-24 November 2023*. Available online at: https://silvic.usv.ro/imer2023/proceedings_imer_2023.pdf (accessed 4 March 2025)

Forkuo, G.O., Borz, S.A., 2024. Evaluation and development of smart ovako working posture analysis system (OWAS) solutions for postural classification in forest operations using deep learning-based computer vision. *Graduates in Front of Companies (AFCO) 2024*. Available online at: https://afco.unitbv.ro/2024/images/Documente/AFCO_2024_Lucrari_inscrise_.pdf (accessed 5 March 2025).

Forkuo, G.O., Borz, S.A., 2024. Evaluation and development of smart ovako working posture analysis system (owas) solutions for postural classification in forest operations using deep learning-based computer vision. *DoCo2024*. Available online at: https://www.unitbv.ro/documente/cercetare/Detailed_Programme.pdf (accessed 2 March 2025).

6.3.1.2. Lucrări prezentate la conferințe științifice internaționale

Forkuo, G.O., 2023: A systematic survey of conventional and new postural assessment methods. In: *Book of Abstracts, Proceedings of the 6th Edition of the Integrated Management of Environmental Resources Conference Suceava - Romania. Session: Forest Ecosystems and Climate*. Available online at: https://ibn.idsi.md/sites/default/files/imag_file/Book_of_abstracts_IMER_23_Suceava.pdf (accessed 1 April 2025).

Forkuo, G.O., Borz, S.A., 2024. Development and evaluation of automated postural classification models in forest operations using deep learning-based computer vision. In: *Book of Abstracts, Proceedings of the 11th International Symposium on Forest and Sustainable Development, FSD 2024*. Available online at: https://silvic.unitbv.ro/images/conferinte/fsd2024/Book_of_abstracts_FSD_2024c.pdf. (accessed 1 April 2025).

6.3.2. Publicații științifice bazate pe rezultatele obținute prin participarea în echipe de cercetare externe tematicii tezei de doctorat

A. Lucrări publicate pe servere de preprint

Forkuo, G.O., Borz, S.A., Proto, A.R., 2024. Accuracy of low-cost mobile lidar technology in estimating the severity and extent of soil disturbance in forest operations. SSRN Preprint SSRN-4685980. <http://dx.doi.org/10.2139/ssrn.4685980>. Submitted to Croatian Journal of Forest Engineering. Status: Accepted.

Forkuo, G.O., Borz, S.A., 2024. Intra-and inter-rater reliability in log volume estimation based on lidar data and shape reconstruction algorithms: A case study on poplar logs. SSRN Preprint SSRN-4948247. <http://dx.doi.org/10.2139/ssrn.4948247>. Submitted to Frontiers in Remote Sensing. Status: Under Review.

B. Lucrări publicate în reviste indexate de Clarivate Analytics (fostul ISI Web of Science)

Borz, S.A., **Forkuo, G.O.,** Oprea-Sorescu, O., Proto, A.R., 2022. Development of a robust machine learning model to monitor the operational performance of fixed-post multi-blade vertical sawing machines. *Forests*, 13(7), 1115. <https://doi.org/10.3390/f13071115>

Forkuo, G.O., Borz, S.A., 2023. Accuracy and inter-cloud precision of low-cost mobile LiDAR technology in estimating soil disturbance in forest operations. *Front. For. Glob. Change*, 6, 1224575. <https://doi.org/10.3389/ffgc.2023.1224575>

Forkuo, G.O., Marcu, M.V., Iordache, E., Borz, S.A., 2024. Timber extraction by farm tractors in low-removal-intensity continuous cover forestry: a simulation of operational performance and fuel consumption. *Forests*, 15(8), 1422. <https://doi.org/10.3390/f15081422>

Borz, S.A., Morocho Toaza, J.M., **Forkuo, G.O.,** Marcu, M.V., 2022. Potential of measure app in estimating log biometrics: A comparison with conventional log measurement. *Forests*, 13(7), 1028. <https://doi.org/10.3390/f13071028>

Presecan, M.F., **Forkuo, G.O.**, Borz, S.A., 2024. Soil compaction induced by three timber extraction options: A controlled experiment on penetration resistance on silty-loamy soils. *Appl. Sci.*, 14(12), 5117. <https://doi.org/10.3390/app14125117>

6.3.2.1 Lucrări prezentate la conferințe științifice naționale

Forkuo, G.O., Borz, S.A., 2023. Accuracy and inter-cloud precision of low-cost mobile LiDAR technology in estimating soil disturbance in forest operations. In: *Book of Abstracts, Proceedings of the VIIIth edition of the National Session of Student Scientific Communications on Forestry and Environmental Protection, May 26-27, 2023, Suceava - Vatra Dornei*. Available online at: http://silvic.usv.ro/avizier/2023_mai_simoz_national.pdf (accessed 4 March 2025).

6.3.2.2. Lucrări prezentate la conferințe științifice internaționale

Forkuo, G.O., Elias, M., Borz, S.A., 2023. Forwarding by farm tractors in low removal intensity, continuous cover forestry: A simulation of operational performance and fuel consumption. In: *Book of Abstracts, Proceedings of the 55th International Symposium on Forest Mechanization (FORMEC) and the 7th Forest Engineering Conference (FEC), Florence, Italy, September 20-22, 2023*. Available online at: https://www.formec.org/images/proceedings/2023/Book_of_abstract_FORMEC_FEC_23.pdf (accessed 4 March 2025).

Forkuo, G.O., Borz, S.A., 2024. Intra-and inter-rater reliability in log volume estimation based on lidar data and shape reconstruction algorithms: A case study on poplar logs. In: *Book of Abstracts, Proceedings of the 56th International Symposium on Forest Mechanization (FORMEC), Gdańsk, Poland, June 11 - 14, 2024*. Available online at: https://www.formec.org/images/proceedings/2024/Proceedings_FORMEC_2024_Gdansk_02.pdf (accessed 4 March 2025).

Bibliografie selectivă

1. Alpaydin, E., 2020. Introduction to Machine Learning, 4th ed. MIT Press, Cambridge, MA.
2. Bačić, M., Landekić, M., Pandur, Z., Šušnjar, M., Šporčić, M., Nevečerel, H., Lepoglavec, K., 2024. Forestry ergonomics publications in the last decade: A review. *Forests*, 15(4), 616.
3. Bevan, S., 2015. Economic impact of musculoskeletal disorders (MSDs) on work in Europe. *Best Pract. Res. Clin. Rheumatol.* 29, 356-373.
4. Calvo, A., 2009. Musculoskeletal disorders (MSD) risks in forestry: A case study to propose an analysis method. *Agric. Eng. Int. CIGR J.*, 11, 1-9.
5. Cao, Z., Simon, T., Wei, S.E., Sheikh, Y., 2017. Realtime multi-person 2d pose estimation using part affinity fields, in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 7291-7299.
6. Cao, Z., Hidalgo, G., Simon, T., Wei, S.E., Sheikh, Y., 2019. OpenPose: realtime multi-person 2d pose estimation using part affinity fields, *arXiv preprint arXiv:1812.08008*.
7. Cohen, J., 1960. A coefficient of agreement for nominal scales. *Educ. Psychol. Meas.*, 20(1), 37-46.
8. Da Costa, B.R., Vieira, E.R., 2010. Risk factors for work-related musculoskeletal disorders: a systematic review of recent longitudinal studies. *Am. J. Ind. Med.*, 53(3), 285-323.
9. David, G.C., 2005. Ergonomic methods for assessing exposure to risk factors for work-related musculoskeletal disorders. *Occup. Med.*, 55(3), 190-199.
10. Debnath B., O'Brien M., Yamaguchi M., Behera A., 2022. A review of computer vision-based approaches for physical rehabilitation and assessment. *Multimed. Syst.*, 28(1), 209-239.
11. Ding, Z., Li, W., Yang, J., Ogunbona, P., Qin, L., 2024. An attention-based CNN for automatic whole-body postural assessment. *Expert Syst. Appl.*, 238, 122391.
12. Enez, K., Nalbantoğlu, S.S., 2019. Comparison of ergonomic risk assessment outputs from OWAS and REBA in forestry timber harvesting. *Int. J. Ind. Ergon.*, 70, 51-57.
13. Fleiss, J.L., 1971. Measuring nominal scale agreement among many raters. *Psychol. Bull.*, 76(5), 378-382.
14. Forkuo, G.O., Borz, S.A., 2024. Development and evaluation of automated postural classification models in forest operations using deep learning-based computer vision. Preprint SSRN 4875562.
15. Gomez-Galan, M., Perez-Alonso, J., Callejón-Ferre, Á.J., López-Martínez, J., 2017. Musculoskeletal disorders: OWAS review. *Ind. Health*, 55(4), 314-337.
16. He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep residual learning for image recognition, in: *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, pp. 770-778.
17. Heinimann, H.R., 2007. Forest operations engineering and management-the ways behind and ahead of a scientific discipline. *Croat. J. For. Eng.*, 28(1), 107-121.
18. Hignett, S., McAtamney, L., 2000. Rapid entire body assessment (REBA). *Appl. Ergon.*, 31(2), 201-205.

19. Imbeault-Nepton T., Maitre J., Bouchard K., Gaboury S., 2022. Filtering data bins of UWB radars for activity recognition with random forest. *Procedia Comput. Sci.*, 201, 48-55.
20. Jiang X., Hu Z., Wang S., Zhang Y., 2023. A survey on artificial intelligence in posture recognition. *CMES-Comp. Model. Eng. Sci.*, 137(1), 35.
21. Karhu, O., Kansi, P., Kuorinka, I., 1977. Correcting working postures in industry: A practical method for analysis. *Appl. Ergon.*, 8(4), 199-201.
22. Kolgiri S., Bansode S., Hiremath R., 2017. A literature review on work-related body part discomfort with respect of postures and movements. *IAETSD J. Adv. Res. Appl. Sci.*, 4(5).
23. Li, G., Buckle, P., 1999. Current techniques for assessing physical exposure to work-related musculoskeletal risks, with emphasis on posture-based methods. *Ergonomics*, 42(5), 674-695.
24. Lorenzini, M., Lagomarsino, M., Fortini, L., Gholami, S., Ajoudani, A., 2023. Ergonomic human-robot collaboration in industry: a review. *Front. Robot. AI*, 9, 262.
25. Marchi, E., Chung, W., Visser, R., Abbas, D., Nordfjell, T., Mederski, P.S., McEwan, A., Brink, M., Laschi, A., 2018. Sustainable Forest Operations (SFO): A new paradigm in a changing world and climate. *Sci. Total Environ.*, 634, 1385-1397.
26. McAtamney, L., Corlett, E.N., 1993. RULA: a survey method for the investigation of work-related upper limb disorders. *Appl. Ergon.*, 24(2), 91-99.
27. Moher, D., Shamseer, L., Clarke, M., Ghersi, D., Liberati, A., Petticrew, M., Shekelle, P., Stewart, L.A., 2015. Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015 statement. *Syst. Rev.*, 4(1), 1-9.
28. Nadeem, M., Elbasi, E., Zreikat, A.I., Sharsheer, M., 2021. A review of wearable technology for posture monitoring. In: 2021 international conference on information technology (ICIT), pp. 848-853.
29. Page, M.J., McKenzie, J.E., Bossuyt, P.M., Boutron, I., Hoffmann, T.C., Mulrow, C.D., Shamseer, L., Tetzlaff, J.M., Akl, E.A., Brennan, S.E., Chou, R., 2021. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *Int. J. Surg.*, 88, 105906.
30. Paini, A.D.C., Lopes, E.D.S., Fiedler, N.C., de Souza, A.P., Rodrigues, C.K., 2020. Postural analysis and repetitive motions of skidder operators in wood extraction. *Sci. For.*, 48(125), e3095.
31. Pascual, S. A., Naqvi, S., 2008. An investigation of ergonomics analysis tools used in industry in the identification of work-related musculoskeletal disorders. *Int. J. Occup. Saf. Ergon.*, 14, 237-245.
32. Punnett, L., Wegman, D.H., 2004. Work-related musculoskeletal disorders: The epidemiologic evidence and the debate. *J. Electromyogr. Kinesiol.*, 14(1), 13-23.
33. Roggio, F., Trovato, B., Sortino, M., Musumeci, G., 2024. A comprehensive analysis of the machine learning pose estimation models used in human movement and posture analyses: A narrative review. *Heliyon*, 10(21), e39977.
34. Rummer, B., Wear, D.N., Greis, J., 2002. Forest operations technology. Southern Forest Resource Assessment. General Technical Report. SRS-53, USDA-Forest Service, Southern Research Station, Asheville, NC, pp. 341-353.

35. Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C., Fei-Fei, L., 2015. ImageNet large scale visual recognition challenge. *Int. J. Comput. Vis.*, 115, 211-252.
36. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.C., 2018. MobileNetV2: Inverted residuals and linear bottlenecks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4510-4520. <https://doi.org/10.48550/arXiv.1801.04381>
37. Sibiya, Z., Ackerman, P., Ntinga, N., Ackerman, S., 2021. An ergonomics risk assessment of manual and motor-manual pruning of pinus patula at two different lifts. *For. Eng. Family-Growing Forward Together*, p.12.
38. Sun, K., Xiao, B., Liu, D., Wang, J., 2019. Deep high-resolution representation learning for human pose estimation, in: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 5693-5703.
39. Szegedy, C., Wei Liu, Yangqing Jia, Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A., 2015. Going deeper with convolutions. In: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Presented at the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, Boston, MA, USA, pp. 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>
40. Takala, E.P., Pehkonen, I., Forsman, M., Hansson, G.Å., Mathiassen, S.E., Neumann, W.P., Sjøgaard, G., Veiersted, K.B., Westgaard, R.H., Winkel, J., 2010. Systematic evaluation of observational methods assessing biomechanical exposures at work. *Scand. J. Work Environ. Health*, 3-24.
41. Yovi, E.Y., Prajawati, W., 2015. High risk posture on motor-manual short wood logging system in Acacia mangium plantation. *J. Manaj. Hutan Tropika*, 21(1), 11-18.
42. Zhang, X., Zhou, X., Lin, M., Sun, J., 2018. ShuffleNet: An extremely efficient convolutional neural network for mobile devices, in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 6848-6856.

Mulțumiri

Aș dori să-mi exprim sincera recunoștință conducătorului meu de doctorat, Prof. dr. ing. Stelian Alexandru Borz, pentru îndrumarea sa neprețuită, feedback-ul pertinent și sprijinul constant pe parcursul acestei cercetări. Mentoratul său a fost instrumental în modelarea direcției și profunzimii acestui studiu. Sunt, de asemenea, profund îndatorat membrilor Comisiei mele de Îndrumare și integritate academică: Prof. dr. ing. Petrișan Ion Cătălin, Conf. dr. Marcu Marina Viorela, Conf. dr. ing. Iordache Eugen și Conf. dr. ing. Nicușor Boja, pentru feedback-ul lor constructiv și întrebările provocatoare care au îmbogățit această lucrare. Această cercetare a fost posibilă datorită sprijinului financiar din partea Competiției de Proiecte de Teze de Doctorat a Universității Transilvania din Brașov (Ediția 2023) și a fost parțial finanțată de Ministerul Educației și Cercetării din România prin CNCS – UEFISCDI. În cele din urmă, îmi exprim recunoștința Facultății de Silvicultură și exploatare forestiere pentru furnizarea echipamentului necesar, precum și companiilor forestiere, administratorilor și participanților la cercetare care au oferit sprijin logistic și și-au atribuit generos timpul și cunoștințele la acest proiect.