



Universitatea
Transilvania
din Braşov

ŞCOALA DOCTORALĂ INTERDISCIPLINARĂ

Facultatea: Silvicultură și exploatarea forestieră

Ing. Marius CHEŢA

UTILIZAREA SENZORILOR ÎN APLICAȚII DE MĂSURARE A MUNCII ÎN
INGINERIA FORESTIERĂ

THE USE OF SENSORS FOR WORK MEASUREMENT APPLICATIONS IN
FOREST ENGINEERING

REZUMAT / ABSTRACT

Conducător științific

Prof.dr.ing. Stelian Alexandru BORZ

BRAȘOV, 2020



D-lui (D-nei)

COMPONENȚA

Comisiei de doctorat

Numită prin ordinul Rectorului Universității Transilvania din Braşov

Nr. din

PREȘEDINTE:	Prof.dr.ing. Alexandru Lucian CURTU
CONDUCĂTOR ȘTIINȚIFIC:	Prof.dr.ing. Stelian Alexandru BORZ
REFERENȚI:	C.Ș.dr.ing. Dănuț CHIRA
	Prof.dr.ing. Gheorghe Florian BORLEA
	Conf.dr.ing. Rudolf Alexandru DERCZENI

Data, ora și locul susținerii publice a tezei de doctorat:, ora, sala

Eventualele aprecieri sau observații asupra conținutului lucrării vor fi transmise electronic, în timp util, pe adresa [**marius.cheta@unitbv.ro**](mailto:marius.cheta@unitbv.ro)

Totodată, vă invităm să luați parte la ședința publică de susținere a tezei de doctorat.

Vă mulțumim.

MULTUMIRI

La finalul acestei etape din viața mea, doresc să le mulțumesc tuturor acelor oameni minunați care mi-au oferit consultanță științifică și care și-au rupt din timpul lor liber pentru a-mi oferi sprijin și ajutor.

Doresc să adresez conducătorului meu științific, domnului prof. dr. ing. Stelian Alexandru BORZ, sincere mulțumiri și sentimente de recunoștință pentru sprijinul acordat în elaborarea tezei de doctorat, pentru răbdarea, generozitatea și înțelegerea de care a dat dovadă, precum și pentru întreaga contribuție la formarea mea profesională. Îi mulțumesc pentru faptul că a acceptat să-mi împărtășască din bogata sa experiență profesională dobândită ca profesor și om de știință. Fără sprijinul său nu aș fi putut realiza această teză.

De asemenea, doresc să mulțumesc doamnei conf. dr. fiz. Marina Viorela MARCU pentru sprijinul moral și încurajările oferite pe toată perioada doctorală.

Îmi exprim mulțumirea față de distinșii membri ai comisiei de evaluare a lucrării, domnului prof. dr. ing. Alexandru Lucian CURTU - președintele comisiei și referenților științifici: domnului C.Ș. dr. ing. Dănuț CHIRA, domnului prof. dr. ing. Gheorghe Florian BORLEA și domnului conf. dr. ing. Rudolf Alexandru DERCZENI, pentru bunăvoința, efortul și disponibilitatea de a analiza această teză de doctorat.

Mulțumesc membrilor comisiei de îndrumare: prof dr. ing. Valentina Doina CIOBANU, conf. dr. ing. Maria Magdalena VASILESCU și conf. dr. ing. Rudolf Alexandru DERCZENI pentru timpul prețios acordat, pentru sfaturile științifice valoroase și pentru îndrumarea de calitate pe parcursul elaborării și realizării acestei teze de doctorat.

Mulțumesc întregului colectiv de cadre didactice al Facultății de Silvicultură și Exploatare Forestiere din Braşov pentru contribuția pe care au avut-o în formarea mea profesională prin intermediul disciplinelor studiate cât și prin sfaturile și îndrumările acordate.

De asemenea, mulțumesc Departamentului de Exploatare Forestiere, Amenajarea Pădurilor și Măsurători Terestre pentru ajutorul de natură logistică și materială pus la dispoziție pentru desfășurarea cercetărilor. Mulțumesc Universității Transilvania din Braşov pentru acordarea bursei pentru desfășurarea cercetărilor.

Pentru colectarea datelor din teren doresc să mulțumesc domnului ing. Paul Dima, deoarece cu ajutorul dânsului a fost posibilă colectarea unei părți din date. De asemenea, doresc să mulțumesc RNP Romsilva, Direcția Silvică Dolj. Totodată, doresc să mulțumesc domnului ing. Daniel Șerban și domnului ing. Arpad-Attila Lorincz pentru sprijinul acordat în colectarea datelor. Le mulțumesc și muncitorilor care au fost cooperanți și m-au ajutat cu tot ceea ce a fost nevoie pentru a duce la bun sfârșit etapa de cercetare desfășurată în teren.

Le mulțumesc colegilor mei doctoranzi, în special colegului meu drd. ing. Nicolae Talagai, prietenul cu care am plecat la drum în această provocare, fiind alături de mine în etapele de colectare a datelor și nu numai.

Mulțumesc familiei mele pentru dragostea necondiționată, suportul moral, financiar și încurajările oferite pe această perioadă.

Autorul

CUPRINS

	Pg.	Pg.
	Teză	rezumat
INTRODUCERE	16	8
CAPITOLUL 1. STADIUL ACTUAL AL CUNOȘTINȚELOR PRIVIND TEHNICILE TRADIȚIONALE ȘI CELE MODERNE, BAZATE PE SENZORI, UTILIZATE ÎN MĂSURAREA MUNCII	17	9
1.1. Aspecte generale privind metodele utilizate în măsurarea muncii	17	9
1.2. Concepte, terminologie și definiții	21	13
1.2.1. Concepte, terminologie și definiții privind știința muncii și măsurarea muncii	21	13
1.2.2. Concepte, terminologie și definiții cu privire la senzori	23	14
1.3. Măsurarea muncii prin tehnici tradiționale și moderne	25	15
1.3.1. Tipuri de studii implementate în măsurarea muncii	25	15
1.3.2. Echipamente și instrumente utilizate în studiile de măsurare a muncii	26	16
1.3.3. Măsurarea muncii prin tehnici moderne. Stadiul actual, posibilități și limitări	28	17
1.3.4. Tehnici ale inteligenței artificiale (AI) bazate pe rețele neuronale artificiale (ANN)	29	18
CAPITOLUL 2. SCOPUL ȘI OBIECTIVELE LUCRĂRII	31	20
CAPITOLUL 3. MATERIALE ȘI METODE	32	21
3.1. Locurile alese pentru colectarea datelor pentru studiile de caz și caracteristicile studiilor de caz	32	21
3.2. Descrierea echipamentelor utilizate pentru studiile de caz	36	22
3.3. Organizarea muncii și experiența muncitorilor	43	22
3.4. Colectarea datelor din teren pentru studiile de caz	44	24
3.4.1. Colectarea datelor din teren pentru studiile de caz SC1 și SC2	44	24
3.4.2. Colectarea datelor din teren pentru studiul de caz SC3	46	25
3.4.3. Colectarea datelor din teren pentru studiile de caz SC4, SC5 și SC6	46	25
3.4.4. Colectarea datelor din teren pentru studiul de caz SC7	49	26
3.4.5. Colectarea datelor pentru studiul de caz SC8	50	26
3.5. Procesarea datelor pentru studiile de caz	50	27
3.5.1. Procesarea datelor privind studiul de caz SC1	50	27
3.5.2. Procesarea datelor pentru studiul de caz SC2. Configurarea rețelei neuronale artificiale. Analiza datelor privind studiul de caz SC2	52	28
3.5.2.1. Procesarea datelor	52	28
3.5.2.2. Configurarea rețelei neuronale artificiale	53	29
3.5.2.3. Analiza datelor	54	30
3.5.3. Procesarea datelor și dezvoltarea algoritmului privind studiul de caz SC3	54	30
3.5.4. Procesarea datelor privind studiul de caz SC4	56	31
3.5.5. Procesarea datelor. Configurarea rețelei neuronale artificiale pentru studiul de caz SC5	56	32
3.5.5.1. Procesarea datelor	56	32
3.5.5.2. Configurarea rețelei neuronale artificiale	57	32
3.5.6. Procesarea datelor pentru studiul de caz SC6	58	33
3.5.7. Procesarea datelor pentru studiul de caz SC7	60	34
3.5.8. Procesarea datelor pentru studiul de caz SC8. Configurarea rețelei neuronale artificiale	61	35
3.5.8.1. Procesarea datelor	61	35
3.5.8.2. Configurarea rețelei neuronale artificiale	62	36
CAPITOLUL 4. REZULTATE ȘI DISCUȚII	64	37
4.1. Rezultate privind studiul de caz SC1	64	37
4.1.1. Aspecte generale	64	37
4.1.2. Setarea pragurilor de separare și performanța clasificării	64	37
4.2. Rezultate privind studiul de caz SC2	65	38

4.2.1. Indicatori de performanță	65	38
4.2.1.1. Aria de sub curbă	65	38
4.2.1.2. Precizia clasificării	71	44
4.2.1.3. Indicatorul REC	77	50
4.2.2. Performanța generală și implicații pentru monitorizarea operațiilor realizate cu ferăstrăul mecanic	83	56
4.3. Rezultate privind studiul de caz SC3	84	57
4.4. Rezultate privind studiul de caz SC4	87	60
4.5. Rezultate privind studiul de caz SC5	89	61
4.5.1. Statistici descriptive ale semnalului folosit și ale evenimentelor identificate	89	61
4.5.2. Rezultatele etapei de învățare și selectarea modelului ANN	90	62
4.5.3. Statistici descriptive privind performanța clasificării în etapa de testare a modelului	90	63
4.6. Rezultate privind studiul de caz SC6	91	64
4.6.1. Efortul fizic	91	64
4.6.2. Expunerea la zgomot	93	65
4.6.3. Analiza posturală	94	66
4.7. Rezultate privind studiul de caz SC7	96	67
4.8. Rezultate privind studiul de caz SC8	97	69
4.8.1. Statisticile descriptive ale semnalelor	97	69
4.8.2. Rezultatele învățării și selectarea modelului	99	71
4.8.3. Statistici descriptive și performanța clasificării în etapa de testare	100	72
4.9. Discuții	101	73
CAPITOLUL 5. CONCLUZII. RECOMANDĂRI ȘI DIRECȚII VIITOARE DE CERCETARE.		
CONTRIBUȚII PERSONALE. DISEMINAREA REZULTATELOR CERCETĂRII.	106	77
5.1. Concluzii	106	77
5.2. Recomandări și direcții viitoare de cercetare	108	79
5.3. Contribuții personale	109	79
5.4. Diseminarea rezultatelor cercetării	110	80
5.4.1. Rezultate produse în cadrul tezei de doctorat	110	80
5.4.2. Rezultate produse prin participarea în echipe de cercetare externe sferei de doctorat	110	81
Bibliografie	112	82
Anexa 3. Rezumat	125	91

CONTENTS

	Pg.	Pg.
	Teză	rezumat
INTRODUCTION	16	8
CHAPTER 1. STATE OF ART ON TRADITIONAL AND MODERN, SENSOR-BASED TECHNIQUES USED IN WORK MEASUREMENT	17	9
1.1. <i>General aspects regarding the methods used in work measurement</i>	17	9
1.2. <i>Concepts, terminology and definitions</i>	21	13
1.2.1. <i>Concepts, terminology and definitions regarding work science and work measurement</i>	21	13
1.2.2. <i>Concepts, terminology and definitions regarding sensors</i>	23	14
1.3. <i>Work measurement by traditional and modern techniques</i>	25	15
1.3.1. <i>Types of studies implemented in work measurement</i>	25	15
1.3.2. <i>Equipment and instruments used in work measurement studies</i>	26	16
1.3.3. <i>Work measurement by modern techniques. Current state, possibilities and limitations</i>	28	17
1.3.4. <i>Artificial Intelligence (AI) techniques based on artificial neural networks (ANN)</i>	29	18
CHAPTER 2: AIM AND OBJECTIVES	31	20
CHAPTER 3. MATERIALS AND METHODS	32	21
3.1. <i>Sites chosen to collect data for case studies and the characteristics of case studies</i>	32	21
3.2. <i>Description of the equipment used in case studies</i>	36	22
3.3. <i>Work organization and workers' experience</i>	43	22
3.4. <i>Field data collection for case studies</i>	44	24
3.4.1. <i>Field data collection for SC1 and SC2 case studies</i>	44	24
3.4.2. <i>Field data collection for the SC3 case study</i>	46	25
3.4.3. <i>Field data collection for SC4, SC5 and SC6 case studies</i>	46	25
3.4.4. <i>Field data collection for the SC7 case study</i>	49	26
3.4.5. <i>Field data collection for the SC8 case study</i>	50	26
3.5. <i>Data processing for case studies</i>	50	27
3.5.1. <i>Data processing for SC1 case study</i>	50	27
3.5.2. <i>Data processing for SC2 case study. Configuration of the artificial neural network. Data analysis of SC2 case study</i>	52	28
3.5.2.1. <i>Data processing</i>	52	28
3.5.2.2. <i>Configuration of the artificial neural network</i>	53	29
3.5.2.3. <i>Data analysis</i>	54	30
3.5.3. <i>Data processing and algorithm development of the SC3 case study</i>	54	30
3.5.4. <i>Data processing on SC4 case study</i>	56	31
3.5.5. <i>Data processing. Configuration the artificial neural network for the SC5 case study</i>	56	32
3.5.5.1. <i>Data processing</i>	56	32
3.5.5.2. <i>Configuration of the artificial neural network</i>	57	32
3.5.6. <i>Data processing for the SC6 case study</i>	58	33
3.5.7. <i>Data processing for the SC7 case study</i>	60	34
3.5.8. <i>Data processing for the SC8 case study. Configuration of the artificial neural network</i>	61	35
3.5.8.1. <i>Data processing</i>	61	35
3.5.8.2. <i>Configuration of the artificial neural network</i>	62	36
CHAPTER 4. RESULTS AND DISCUSSION	64	37
4.1. <i>Results of the SC1 case study</i>	64	37
4.1.1. <i>General aspects</i>	64	37
4.1.2. <i>Separation thresholds and classification performance</i>	64	37
4.2. <i>Results of the SC2 case study</i>	65	38
4.2.1. <i>Performance indicators</i>	65	38
4.2.1.1. <i>Area under curve</i>	65	38
4.2.1.2. <i>Precision of the classification</i>	71	44

4.2.1.3. REC indicator	77	50
4.2.2. Overall performance and implications for monitoring operations with chainsaws	83	56
4.3. Results of the SC3 case study	84	57
4.4. Results of the SC4 case study	87	60
4.5. Results of the SC5 case study	89	61
4.5.1. Descriptive statistics of the signal used and of the events identified	89	61
4.5.2. Results of the learning stage and the selection of the ANN model	90	62
4.5.3. Descriptive statistics on the performance of the classification in the model testing stage	90	63
4.6. Results of the SC6 case study	91	64
4.6.1. Physical effort	91	64
4.6.2. Exposure to noise	93	65
4.6.3. Postural analysis	94	66
4.7. Results of the SC7 case study	96	67
4.8. Results of the SC8 case study	97	69
4.8.1. Descriptive statistics of signals	97	69
4.8.2. Learning results and model selection	99	71
4.8.3. Descriptive statistics and classification performance in the testing stage	100	72
4.9. Discussion	101	73
CHAPTER 5. CONCLUSIONS. RECOMMENDATIONS AND FUTURE RESEARCH DIRECTIONS. PERSONAL CONTRIBUTIONS. DISSEMINATION OF RESEARCH RESULTS.	106	77
5.1. Conclusions	106	77
5.2. Recommendations and future research directions	108	79
5.3. Personal contributions	109	79
5.4. Dissemination of research results	110	80
5.4.1. Results produced in the doctoral thesis	110	80
5.4.2. Results produced by participating in research teams outside the doctoral thesis	110	81
References.	112	82
Appendix 3. Abstract	125	91

INTRODUCERE

Originea studiilor de timp este creditată lui Taylor, inginer american care era convins de faptul că, pentru orice sarcină există cel mai scurt timp în care aceasta poate fi realizată de către un om, fără ca acesta să îşi epuizeze capacitatea de muncă, în condițiile în care omul respectiv posedă atât abilitățile naturale și dobândite, cât și echipamentele necesare realizării sarcinii de muncă în cauză. Conceptele sale au fost introduse în domeniul forestier după anul 1910, unde au fost utilizate pentru a se descrie principalele legități ale producției, apoi pentru caracterizarea productivității și, mai târziu, pentru planificarea și optimizarea sistemelor tehnice forestiere. Abordările sale sunt utilizate și în prezent în domeniul științific și practic al operațiilor de exploatare a lemnului. Sub raport metodologic, pentru realizarea studiilor de măsurare a muncii, în timp, s-au dezvoltat și implementat mai multe abordări, începând cu cele tradiționale, care au păstrat în mare măsură metodele descrise de Taylor, și terminând cu cele parțial sau complet automatizate, care au fost facilitate de dezvoltarea tehnologică susținută. În principiu, abordările tradiționale presupun utilizarea unor instrumente de măsură precum ceasornicele de mână sau cronometrele specializate; în implementarea studiilor, acestea presupun utilizarea unor cantități însemnate de resurse precum timpul, capitalul financiar și oamenii instruiți. În acest context, a fost necesară dezvoltarea și introducerea unor metode moderne în colectarea datelor care, în general, au vizat minimizarea resurselor alocate pentru acest demers. În ceea ce privește colectarea datelor prin procedee automatizate, utilizarea unor senzori sau a unor sisteme de senzori prezintă un mare potențial, parțial explorat, de a rezolva problemele actuale legate de realizarea studiilor pe durate mari, reducerii costurilor de achiziție a datelor, precum și a monitorizării parametrilor relaționați cu ergonomia muncii. Aceste demersuri au fost susținute de dezvoltarea tehnologiei senzorilor, care a progresat într-un ritm susținut în ultima perioadă; astfel, senzorii capabili să detecteze, măsoare și să înregistreze date privind fenomene fizice cum ar fi mișcarea, vibrația, nivelul de presiune acustică etc. sunt disponibili, în prezent, la costuri de achiziție reduse. Pe lângă disponibilitatea acestora, tehnologiile de poziționare globală au înregistrat un real avânt, în prezent existând soluții disponibile la costuri reduse cu privire la receptoarele GPS. Acestea au un rol foarte important în detectarea parametrilor relaționați cu mișcarea muncitorilor și utilajelor în operațiile forestiere. O caracteristică comună a senzorilor descriși și a receptoarelor GPS este aceea că ele măsoară mărimile fizice sau parametrii de interes pe scară temporală, caracteristică ce este esențială în studiile de măsurare a muncii. Ca atare, lucrarea de față abordează probleme legate de posibilitatea automatizării efortului de colectare, analiză și interpretare a datelor prin utilizarea de senzori și receptare GPS pentru automatizarea colectării datelor și, respectiv, a unor praguri stabilite arbitrar și a tehnicilor inteligenței artificiale, prin dezvoltarea unor rețele neuronale artificiale, pentru automatizarea efortului de analiză și interpretare a datelor. Lucrarea începe prin prezentarea, la un nivel adecvat de detaliu, a conceptelor, terminologiei și definițiilor cu privire la știința muncii și la măsurarea muncii prin studii de timp, apoi dezvoltă problemele cu privire la tipurile de studii implementate, abordările utilizate, echipamentele și instrumentele folosite și cele cu privire la utilizarea semnalelor colectate de senzori și a algoritmilor Inteligenței Artificiale în implementarea de studii de timp. Pe baza celor constatate, lucrarea analizează posibilitatea automatizării efortului de colectare, analiză și interpretare a datelor printr-un număr de 8 studii de caz, prin care s-a urmărit aplicarea unor algoritmi de clasificare a consumului de timp, începând cu unii foarte simpli și terminând cu unii complecși, specifici inteligenței artificiale. Studiile de caz implementate în acest scop, au vizat atât operațiile tradiționale desfășurate în pădure, cât și operațiile specifice prelucrării lemnului. Problemele s-au abordat prin simularea operațiilor, și prin observarea acestora în condiții reale, iar tehnicile inteligenței artificiale, prin rețele neuronale artificiale, au fost testate atât pentru a pune în evidență capacitatea lor de a învăța, cât și pentru a rezolva cazuri specifice de clasificare. Din moment ce măsurarea muncii se referă și la aspectele fiziologice și ergonomice, printr-un studiu de caz s-a urmărit identificarea posibilității de a colecta concomitent date cu privire la mai mulți parametri ergonomici, ca demers de integrare a aspectelor legate de partea ergonomică și a celor legate de variabilitatea condițiilor de muncă, avându-se în vedere testarea unei metode care să permită colectarea de date pe termen lung cu privire la aceste probleme. Pentru acest demers, au fost evaluate condițiile ergonomice la locul de muncă în cazul operațiilor de doborâre și fasonare a arborilor cu ferăstrăul mecanic prin parametri colectați de senzori, cum ar fi ritmul cardiac și nivelul de expunere la zgomot.

CAPITOLUL 1. STADIUL ACTUAL AL CUNOȘTIINȚELOR PRIVIND TEHNICILE TRADIȚIONALE ȘI CELE MODERNE, BAZATE PE SENZORI, UTILIZATE ÎN MĂSURAREA MUNCII

1.1. Aspecte generale privind metodele utilizate în măsurarea muncii

Lemnul este unul dintre cele mai folosite materiale în industrie. Utilizarea sa prin industriile de profil și nu numai contribuie la dezvoltarea economiei și oferă, totodată, multe oportunități de angajare. Sectorul silvic și al prelucrării lemnului reprezintă 7% din economia Uniunii Europene, în această industrie fiind angajate 3,5 milioane de persoane (***, 2013). Pentru livrarea sa pe piață, din punct de vedere operațional, lemnul achiziționat este supus unor serii de transformări, care vizează modificarea formei și poziției sale; în urma acestor transformări, acesta poate fi livrat beneficiarilor sub forma unui produs intermediar sau final (Oprea 2008).

Pentru operațiile de exploatare a lemnului se pot utiliza numeroase sisteme tehnice, ce pot fi adaptate la anumite condiții operaționale, cu scopul general de a crește performanța globală a operațiilor specifice acestora (Oprea 2008). Un sistem tehnic de exploatare a lemnului este definit ca un ansamblu integrat de unelte, echipamente, mașini și oameni, care se implementează pentru desfășurarea operațiilor forestiere de exploatare a lemnului (Borz 2014a). Performanța unui sistem tehnic de exploatare a lemnului este direct legată de gradul mecanizării operațiilor (Oprea 2008), prin urmare nivelul mecanizării reprezintă un criteriu de clasificare a sistemelor tehnice de exploatare a lemnului, inclusiv a performanțelor productive ale acestora.

În operațiile de recoltare, mașinile multifuncționale, cum ar fi cele ce pot executa integrat operațiile de doborât, curățat de crăci și secționat, sunt mult mai performante prin comparație, de exemplu, cu ferăstraiele mecanice (Apăfaian et al. 2017, Oprea 2008). Cu toate acestea, utilizarea ferăstrăului mecanic în operațiile de recoltare a lemnului este încă foarte răspândită în România (Sbera 2007). Analizând numărul de studii publicate, cu privire la performanțele productive legate de utilizarea ferăstrăului mecanic, rezultă faptul că acesta este, de asemenea, răspândit pe întreg teritoriul Europei (Borz și Ciobanu 2013, Gerasimov și Seliverstov 2010, Montorselli et al. 2010, Zinkevičius et al. 2012), precum și la nivel mondial (Balimunsi et al. 2012, Behjou et al. 2009, Ghaffariyan et al. 2013, Mousavi et al. 2011, Nikooy et al. 2013, Wang et al. 2004). De fapt, circa 55% din operațiile de recoltare a lemnului din întreaga lume continuă să se realizeze utilizând ferăstrăul mecanic, în timp ce restul se execută prin folosirea de mașini multifuncționale (Ponsse 2005). Există mai mulți factori care determină utilizarea la scară largă a ferăstraielelor mecanice, cum ar fi: costurile de achiziție acceptabile, durata relativ lungă de viață (Calvo 2013), compatibilitatea cu terenul abrupt, adaptabilitatea la o gamă largă de dimensiuni și specii de arbori (Borz 2014b) precum și la intensități variabile de extracție (Borz și Ciobanu 2013). Operatorul ferăstrăului mecanic își desfășoară activitatea în teren descoperit, fiind expus în multe cazuri la temperaturi extreme (Yongang și Baojun 1998), ceea ce face ca astfel de operații să fie considerate dificile. Similar altor tipuri de operații desfășurate manual, în operațiile forestiere (Borz et al. 2015, Borz et al. 2014a, Borz et al. 2013) timpul petrecut în sarcinile care implică mișcarea este variabil (Borz și Ciobanu 2013, Jourgholami et al. 2013). Astfel, operatorii ferăstraielelor mecanice trebuie să acopere distanțe lungi în timpul unei zile de muncă și trebuie să lucreze, de multe ori, în teren accidentat. În astfel de condiții, cel puțin înclinarea terenului este cunoscută drept un factor care sporește dificultatea muncii (Magagnotti și Spinelli 2012). De asemenea, natura muncii în sine, prin sarcinile de muncă care trebuie realizate, presupune un efort fizic intens (Silayo et al. 2010). De asemenea, operațiile executate cu ferăstrăul mecanic expun operatorii la factori nocivi, cum ar fi dozele mari de zgomot (Cheța et al. 2018, Neitzel și Yost 2002) și vibrații (Rottensteiner și Stampfer 2013, Rottensteiner et al. 2012), precum și la riscuri crescute de afecțiuni ale sistemelor muscular și osos (Cheța et al. 2018, Gallis 2006, Grzywinski et al. 2016), datorită posturilor specifice de muncă, adoptate în timpul realizării acestor operații (Calvo 2009, Corella Justavino et al. 2015, Zanuttini et al. 2005). În timp, expunerea la zgomot poate duce la pierderea auzului (Fonseca et al. 2015, Tunay și Melemez 2008), iar expunerea la vibrații poate provoca tulburări vasculare (Bovenzi 2008). Mai mult decât atât, munca cu ferăstrăul

mecanic este cunoscută ca fiind una dintre ocupațiile ce cauzează probleme de sănătate frecvente sau chiar accidente mortale (Laschi et al. 2016, Lindroos și Burstrom 2010, Tsiaras et al. 2014), care sunt adesea asociate cu comportamentul muncitorilor, organizarea muncii (Melemez 2015, Montorselli et al. 2010) și cu riscurile inutile pe care muncitorii și le asumă prin nerespectarea procedurilor de siguranță (Borz et al. 2014c, Melemez 2015). Expunerea la astfel de factori dăunători, precum și dificultatea muncii cu care se confruntă operatorii, depind într-o mare măsură de particularitățile condițiilor operaționale, care variază foarte mult în domeniul forestier (Acuna et al. 2012). Recomandările și procedurile de lucru adoptate (Oprea 2008), precum și gestionarea specifică a timpului de muncă, contribuie la o anumită distribuție în timp a sarcinilor de muncă. Din acest punct de vedere, un ciclu de muncă la recoltarea cu ferăstrăul mecanic poate fi mai mult sau mai puțin complex (Oprea 2008). În același timp, durata utilizării motorului, care determină expunerea la zgomot și vibrații, variază destul de mult, ca efect al anumitor condiții operaționale, cum ar fi dimensiunile arborilor ce se recoltează; acestea pot genera mai mult sau mai puțin timp utilizat în acest regim de funcționare al motorului ferăstrăului, depinzând, în mare măsură, de caracteristicile dimensionale ale arborilor supuși recoltării, care variază de la valori mai mici, specifice răriturilor (e.g. Borz și Ciobanu 2013), până la valori foarte mari, specifice tăierilor finale (e.g. Jourholami et al. 2013).

În studiul timpului și a mișcărilor, precum și în evaluările cu privire la ergonomia muncii, ce se efectuează în operațiile forestiere, există multe variabile operaționale care pot influența variabilitatea rezultatelor ce se obțin (Acuna et al. 2012). Adesea, este dificil să se studieze concomitent mai mulți parametri ergonomici, acest lucru implicând un efort semnificativ de natură logistică și, ulterior, de prelucrare a datelor. De exemplu, evaluarea posturală a unui muncitor la locul de muncă este adesea efectuată pe baza datelor colectate și interpretate vizual, cum ar fi fișierele video care sunt folosite pentru extragerea imaginilor necesare analizei (Corella Justavino et al. 2015, Spinelli et al. 2016), iar în studiile de timp și mișcare, analiza datelor video poate dura de la 4 până la 6 ori mai mult în comparație cu durata reală a datelor colectate (Mușat et al. 2016). Există, de asemenea, mulți factori de natură ergonomică care pot să influențeze performanța muncii și sănătatea muncitorilor (Helander 2006). Analiza concomitentă a acestora, pe de altă parte, este dificilă. Cu toate acestea, un astfel de demers ar putea aduce multe beneficii relaționate cu înțelegerea dificultății muncii și a riscurilor asociate cu un anumit loc de muncă, deoarece problemele de natură ergonomică sunt privite, în prezent, ca fiind multi-variate. Luând în considerare variabilitatea condițiilor de exploatare a lemnului în care este folosit ferăstrăul mecanic, sunt puține studiile care au abordat condițiile ergonomice ale locului de muncă și a operațiilor executate cu acesta. De asemenea, multe dintre studii s-au concentrat asupra caracterizării unui singur parametru ergonomic (Potočník și Poje 2017). În operații forestiere parțial sau integral mecanizate se utilizează echipamente, unelte și utilaje forestiere care sunt echipate cu motoare cu ardere internă. Astfel de motoare sunt caracterizate de anumiți parametri mecanici care pot fi monitorizați intern sau extern, utilizând diferite tipuri de senzori. Este cunoscut faptul că ferăstraiele mecanice sunt echipate cu motoare cu ardere internă în doi timpi care emit niveluri semnificative de zgomot și vibrații (Rottensteiner et al. 2012). În timp ce magnitudinea acestor mărimi fizice cauzează probleme pentru muncitorii forestieri, ea oferă, în același timp, posibilitatea colectării de date, prin senzori externi, cu privire la anumite elemente de interes.

Operațiile de exploatare a lemnului în condiții de teren accidentat predomină în multe țări europene, inclusiv în România. În cazul României, ca efect al lipsei drumurilor, precum și a declivităților mari, există puține opțiuni tehnice de exploatare a lemnului aplicabile în astfel de medii operaționale (Oprea 2008). Chiar dacă tractoarele pot fi folosite și pe teren abrupt, există multe preocupări legate de gestionarea timpului, productivitate și performanțele de mediu, mai ales atunci când distanțele de colectare sunt excesiv de mari (Borz et al. 2015, Borz et al. 2013). Este recomandat ca tractoarele să fie utilizate când panta terenului nu depășește 40-45% (Oprea 2008), în timp ce pentru declivități mai mari se recomandă și se utilizează frecvent instalațiile cu cabluri (Heinimann et al. 2001, Oprea 2008). Instalațiile cu cabluri sunt echipamente forestiere care pot să

funcţioneze în condiţii destul de variabile cu privire la distanţa de montare. Unele dintre modelele existente au fost concepute pentru a acoperi distanţe de până la 2000 m (Oprea 2008). În mod obişnuit, ele asigură funcţii tehnice precum transportul, ridicarea-coborârea, tractarea, manipularea şi transferul de energie (Heinimann et al. 2001), funcţii ce susţin operaţiile de colectare şi cele desfăşurate în platformele primare. Studiile recente au subliniat direcţiile potenţiale, care trebuie abordate în ceea ce priveşte cercetarea, dezvoltarea şi utilizarea instalaţiilor cu cabluri; în special, utilizarea mecatronicii, pentru creşterea eficienţei muncii şi pentru îmbunătăţirea condiţiilor ergonomice, precum şi îmbunătăţirea metodelor computerizate legate de planificarea instalaţiilor cu cablu, sunt considerate direcţii viitoare esenţiale de cercetare (Cavalli 2012). Totodată, unele dintre aceste direcţii de cercetare necesită dezvoltarea cunoştinţelor, pentru a valida eficacitatea soluţiilor utilizate. În majoritatea cazurilor, problemele legate de creşterea eficienţei muncii, îmbunătăţirea ergonomică şi planificarea operaţională, sunt inter-relaţionate cu datele furnizate prin implementarea studiilor de măsurare a muncii. Pe fondul celor descrise anterior, rezultă faptul că studiile de măsurare a muncii sunt indispensabile în domeniul utilizării instalaţiilor cu cabluri şi, de asemenea, că implementarea unor astfel de studii va întâmpina anumite dificultăţi. De exemplu, atunci când se efectuează studii de timp pentru monitorizarea şi observarea operaţiilor efectuate de instalaţiile cu cabluri, cercetătorii se pot confrunta cu terenuri abrupte şi cu pericole, legate de necesitatea realizării de observaţii în apropierea unor cabluri de oţel care sunt tensionate. În plus, datorită configuraţiei specifice a instalaţiilor cu cabluri, prin urmare a modului specific în care multe dintre acestea operează, şi mai ales atunci când ele sunt montate pe distanţe foarte lungi, este adesea necesară prezenţa în teren a 2-3 cercetători, care ar trebui să fie echipaţi cu dispozitive de comunicare pentru a putea observa în mod adecvat succesiunea specifică de desfăşurare a operaţiilor. Acest lucru se datorează atât faptului că studiile în cauză trebuie să cuantifice concomitent consumul de timp şi producţia realizată, precum şi faptului că, de multe ori, între locurile esenţiale de realizare a observaţiilor nu există vizibilitate. Astfel de probleme au determinat dezvoltarea unor noi metode de colectare a datelor în studiile de timp, aplicate în scopul caracterizării performanţei productive a instalaţiilor cu cabluri. În special, studiile care au integrat sistemele GPS (Global Positioning System) şi GNSS (Global Navigation Satellite System) au constatat existenţa unui mare potenţial, legat de colectarea datelor şi de estimarea consumului de timp în operaţiile forestiere realizate cu instalaţii cu cabluri (Gallo et al. 20013, Nitami et al. 2011). Cu toate acestea, extragerea şi analiza datelor din fişierele generate de receptoarele GPS (Global Positioning System) poate fi dificilă din mai multe puncte de vedere, inclusiv datorită volumului mare de informaţii ce se pot obţine prin utilizarea acestor tipuri de colectori de date.

Operaţiile de exploatare a lemnului din România se caracterizează prin utilizarea unor sisteme tehnice ce integrează un nivel redus de mecanizare. De regulă, pentru operaţiile de doborâre şi fasonare a arborilor se utilizează ferăstraie mecanice, care sunt asociate cu atelajele sau cu tractoarele de tip skidder pentru colectarea lemnului (Borz şi Ciobanu 2013, Borz et al. 2015, Borz et al. 2013). Totodată, este rezonabilă presupunerea conform căreia acest grad redus de mecanizare este caracteristic şi industriei de prelucrare a lemnului - cazul instalaţiilor de prelucrare a lemnului - deoarece majoritatea companiilor de profil sunt configurate şi funcţionează ca întreprinderi mici şi mijlocii. Astfel, potrivit lui Sbera (2007), în România, la nivelul anului 2007, existau peste 7000 de instalaţii de prelucrare primară a lemnului, acestea având capacităţi fizice de prelucrare a lemnului cuprinse în intervalul de 8-10 m³ pe zi. O mare parte a industriilor orientate spre realizarea de produse utilizează echipamente şi utilaje ce sunt concepute pentru a satisface nevoile de producţie. Pentru a îndeplini şi a se adapta cerinţelor pieţei şi a celor relaţionate cu satisfacerea necesităţilor clienţilor, în general, persoanele care lucrează în managementul producţiei sunt preocupate de procesele de dezvoltare a produselor, de asigurarea calităţii producţiei şi de termenele de lansare a produselor pe piaţă. Similar operaţiilor de recoltare a produselor lemnoase ce se implementează la scară mică (Borz et al. 2018, Spinelli et al. 2012, Talagai et al. 2017), întreprinzătorii mici şi mijlocii care lucrează în industria prelucrării lemnului nu dispun de resursele necesare pentru achiziţionarea unor echipamente performante, caracterizate de un nivel ridicat de mecanizare sau chiar

automatizare, acestea fiind mult prea costisitoare pentru puterea lor economică și pentru segmentul lor de piață. La fel, o problemă reală o reprezintă și cooperarea, prin asociere, deoarece mulți dintre acești antreprenori sunt concurenți atât în cadrul industriei prelucrării lemnului, cât și pe piața valorificării produselor prelucrate din lemn. Acestea reprezintă și principalele motive pentru care majoritatea operatorilor economici utilizează utilaje și echipamente accesibile ca preț, în efortul de economisire a capitalului și a supraviețuirii pe piață. O altă problemă actuală a industriei forestiere în general (Rauch et al. 2015) și a celei procesatoare a lemnului o prezintă nivelul de pregătire tehnico-profesională a personalului, pe fondul lipsei sau a resurselor financiare limitate, alocate menținerii la locul de muncă a unor profesioniști cu înaltă pregătire în industrie, reprezentând, în același timp, și un efect al lipsei programelor de formare. Totodată, prezența forței de muncă bine pregătită în industrie poate aduce un aport de calitate, prin creșterea eficienței operaționale și printr-o mai bună gestionare a timpului la locul de muncă.

Fabricile de prelucrare a lemnului folosesc diferite echipamente și utilaje pentru transformarea buștenilor în cherestea și în alte produse din lemn prelucrat primar, în funcție de cerințele de comercializare pe piață. Printre opțiunile tehnice existente pentru astfel de operații se numără gaterile, ferăstraiele panglică și ferăstraiele circulare (Atanasov et al. 2018, Bariska și Pásztor 2015, Gligoraș și Borz 2015, Ištvanic et al. 2009). Ferăstraiele circulare sunt frecvent utilizate pentru a realiza tăieturi transversale, în scopul obținerii de piese de lemn mai scurte ce sunt integrate în obținerea diferitelor produse din lemn. Astfel de echipamente sunt folosite, adesea, ca utilaje auxiliare într-o fabrică de cherestea. Majoritatea uneltelor, echipamentelor și utilajelor folosite în fabricile de prelucrare a lemnului, utilizează energie electrică și, pentru optimizarea sistemului de producție specific fabricilor de prelucrare a lemnului, ar trebui să se urmărească economisirea de energie, acest aspect putând conduce la scăderea costurilor de producție. Economisirea de energie poate fi realizată inclusiv printr-o mai bună organizare a muncii, în special prin eliminarea întârzierilor și prin creșterea gradului de folosire a utilajelor.

Performanța unui sistem tehnic, echipament sau muncitor poate fi măsurată și estimată în mai multe moduri. Pentru abordările ce presupun măsurarea și estimarea, se pot folosi parametrii și indicatorii generali de performanță, specifici ingineriei sistemelor (*e.g.* Wasson 2015). În silvicultură, însă, cel mai adesea, performanța operațional-productivă este evaluată prin implementarea studiilor de timp, care este combinată cu măsurarea producției realizate. În prezent, studiul timpului se referă la toate modurile în care consumul de timp este măsurat și analizat în diferite situații de lucru, indiferent dacă munca este efectuată de oameni sau este automatizată (Groover 2007). Studiul timpului, ca metodă științifică, derivă din știința muncii, și anume dintr-o subdiviziune a acesteia care este cunoscută sub denumirea de măsurarea muncii (Borz 2014a). Astfel de studii sunt considerate a fi instrumente esențiale în încercarea de a optimiza sistemele tehnice de exploatare a lemnului. Ele ajută cercetătorii să înțeleagă dinamica unui sistem tehnic dat în raport cu condițiile operaționale în care acesta se implementează (Visser și Spinelli 2012) și oferă, adesea, statistici și modele care asigură suportul științific și practic în stabilirea productivității și a costurilor, precum și în evaluarea performanței echipamentelor și sistemelor utilizate (Acuna et al. 2012). Conceptul și metodele studiului timpului sunt utilizate pe scară largă în operațiile forestiere de exploatare a lemnului (Kořir et al. 2015). Abordările tradiționale, constând în utilizarea substanțială a unor metode manuale, au fost foarte utile în trecut și sunt încă considerate a reprezenta punctul de plecare cu privire la evaluarea productivității muncii în operațiile forestiere (Contreras et al. 2017). Cu toate acestea, ele se caracterizează printr-o serie de limitări, cum ar fi generarea de date eronate, datorate subiectivității observatorului, expunerii la accidente pentru cei care colectează date în apropierea unor mașini, caracterizate de un nivel ridicat de a produce accidente, terenului dificil și dificultății generale legate de munca în aer liber (Acuna et al. 2012, Borz et al. 2014b, Mușat et al. 2016); datele colectate în acest mod presupun, mai departe, utilizarea unor soluții mai puțin eficiente de procesare a datelor în etapa de birou a studiilor (Borz 2016). Este de menționat faptul că, chiar și în aceste condiții, abordările tradiționale sunt încă folosite pentru a valida eficacitatea și pentru a

compara rezultatele obținute prin metode moderne, precum și faptul că mulți dintre cercetătorii în domeniu întrevăd folosirea metodelor tradiționale și în viitor (Košir et al. 2015).

Abordările folosite recent în colectarea datelor cu privire la consumul de timp și la productivitatea muncii constau din (e.g. Borz 2014a): utilizarea ceasornicelor de mână, computerelor de buzunar, camerelor video, receptoarelor GPS și a sistemelor interne și externe de senzori. Utilizarea camerelor video prezintă marele avantaj de a facilita colectarea integrală a secvențelor operaționale în modul lor obișnuit de desfășurare (Borz et al. 2014b, Contreras et al. 2017, Mușat et al. 2016), acestea permițând, în etapa de birou, analiza și reverificarea datelor atunci când este necesar. Tehnicile de analiză a înregistrărilor sunt facilitate de programe software specifice (Acuna et al. 2011, Alam et al. 2013, Mușat et al. 2016) sau de folosirea unor programe software obișnuite de redare și de editare a fișierelor media colectate (Borz și Adam 2014). Astfel de abordări presupun un efort substanțial în etapa de prelucrare și analiză a datelor care se efectuează la birou, pentru extragerea consumului de timp la nivel de element sau fază de muncă (Borz și Adam 2014, Mușat et al. 2016). În comparație, abordările parțial sau total automatizate care utilizează sistemele GPS (Global Positioning System), GNSS (Global Navigation Satellite System), GIS (Geographic Information System) și alte sisteme ce integrează senzori, sunt caracterizate de un potențial de utilizare promițător în producție, logistică și în operații forestiere de exploatare a lemnului. Ele pot înlocui parțial sau total prezența în teren a cercetătorilor de specialitate (Borz 2016, Contreras et al. 2017) și, în unele cazuri, au și potențialul de a înlocui, într-o anumită măsură, inteligența umană. De exemplu, o clasă de astfel de metode și tehnici a fost utilizată cu succes, pentru a evalua performanța productivă în operațiile de recoltare în culturile de rotație scurtă (Bush et al. 2015, Eisenbies et al. 2014, Talagai et al. 2017), fiind, de asemenea, întrebuintate cu succes în monitorizarea operațiilor parțial mecanizate în astfel de culturi (Talagai și Borz 2016) precum și în silvicultura tradițională (Cheța și Borz 2017, Gallo et al. 2013, McDonald și Fulton 2005). Utilizarea unor astfel de metode ar putea conduce la economii substanțiale în ceea ce privește timpul, utilizarea personalului calificat și a capitalului financiar, producând rezultate similare cu cele obținute prin studii tradiționale (Borz 2016). Astfel de abordări ar putea rezolva și problema colectării de date pe termen lung, care să permită o acoperire statistică sporită a datelor colectate precum și dezvoltarea unor modele predictive mai precise (Talagai și Borz 2016).

Chiar dacă colectarea automată a datelor a devenit posibilă prin utilizarea senzorilor de diferite tipuri, semnalele colectate de aceștia nu au capacitatea de auto-analiză, motiv pentru care sunt necesare alte abordări pentru a extrage informațiile necesare. O abordare modernă care se folosește frecvent pentru a învăța din semnale și pattern-urile furnizate de acestea, precum și pentru a clasifica și categorisi anumite evenimente utilizând informația încorporată în semnale, este aceea a utilizării tehnicilor inteligenței artificiale (**AI**). Astfel de tehnici și metode sunt folosite frecvent în știința calculatoarelor și în tehnologia informației; în domeniul forestier, au fost folosite mult mai puțin, chiar dacă în ultimul timp ele au fost utilizate în clasificarea unor evenimente, caracterizând elemente și sarcini de muncă specifice recoltării lemnului cu ferăstraie mecanice (e.g. Keefe et al. 2019), precum și pentru rezolvarea unor probleme multivariate de natură cantitativă și calitativă (e.g. Proto et al. 2020). Dintre tehnicile și metodele **AI**, o clasă de tehnici de învățare, modelare și testare nonliniară este cea a rețelelor neuronale artificiale (**ANN**), care pot rezolva probleme de clasificare non-liniară multivariată (Haykin 2009) cu o acuratețe foarte mare.

1.2. Concepte, terminologie și definiții

1.2.1. Concepte, terminologie și definiții privind știința muncii și măsurarea muncii

Studiile de timp (studiul timpului), ca parte componentă a metodelor științei muncii, au fost descrise în premieră de Taylor (1895). În ciuda diverselor critici adresate conceptelor sale, filozofia sa originală a conturat știința muncii ca disciplină științifică, iar conceptele formulate de el au fost utilizate la mai mult de 100 de ani mai târziu (Nyland 1996) și continuă să fie utilizate și în zilele

noastre (Acuna et al. 2012). Prin urmare, conceptele, definițiile și terminologia specifice științei muncii au derivat din domeniul industrial și, la momentul respectiv, ele au schimbat viziunea conceptuală asupra muncii. În ceea ce privește conceptele lui Taylor, acestea au fost introduse în domeniul general al operațiilor forestiere în jurul anului 1910 (Heinimann 2007), fapt care, ulterior, a condus la prima descriere a legității piesă-volum (*eng. piece-volume law*), care exprimă principiul conform căruia, în diverse operații forestiere, consumul de timp pe unitatea de volum scade odată cu creșterea volumului obiectului muncii (Heinimann 2007). Ca ramuri de știință ce se adresează examinării (cercetării) muncii se remarcă cele relaționate cu studiului muncii, ce se realizează sub formă de studii organizatorice, studii de metodă sau ca măsurare a muncii. Măsurarea muncii include, cel mai adesea, un studiu de timp sau un studiu de mișcări (Björheden et al. 1995). Pentru domeniul operațiilor forestiere, printre primele încercări de a sistematiza conceptele relaționate cu știința muncii, în general, și cu studiul și măsurarea muncii, în particular, se numără lucrarea elaborată de Björheden et al. (1995) din care, în teza în extenso sunt prezentate principalele concepte.

1.2.2. Concepte, terminologie și definiții cu privire la senzori

În viața de zi cu zi, se folosesc diferiți senzori pentru diverse scopuri. Un senzor este un dispozitiv sau o parte a unui sistem care se utilizează pentru măsurarea parametrilor fizici, chimici, biologici sau a unor parametri de alt tip (Mukhopadhyay 2013). Un senzor este compus, de obicei, dintr-o componentă sensibilă, care răspunde direct la o mărime fizică ce se măsoară, o componentă de conversie și circuitele electronice aferente. Odată cu dezvoltarea tehnologiei electronice moderne, a tehnologiei micro-electronice și a tehnologiei comunicațiilor, s-a constatat faptul că semnalele electrice sunt cele mai convenabile pentru prelucrarea, afișarea și înregistrarea de date (Wang și Liu 2011). În mod ideal, senzorul trebuie să fie sensibil doar la parametrul pe care îl măsoară și nu ar trebui să fie influențat de alți parametri ce se manifestă în vecinătatea sa. De asemenea, parametrii mășurați nu trebuie să influențeze modul de măsurare al senzorilor. Raportul dintre semnalul de ieșire al senzorului și mărimea parametrului măsurat reprezintă și definește sensibilitatea senzorului. Ideal este ca senzorul să fie caracterizat de o relație liniară între semnalul de ieșire și parametrul măsurat. În multe dintre situații, însă, acest lucru poate să nu fie adevărat, iar rezultatul poate fi exprimat, matematic, sub forma unei funcții a parametrului măsurat. Tehnologia senzorilor a avut un impact enorm asupra industriei moderne. Există mulți senzori disponibili pe piață așa cum, în prezent, există numeroase cercetări pentru a dezvolta senzori noi, inteligenți, eficienți și de înaltă performanță (Mukhopadhyay 2013). Senzorii sunt proiectați și dezvoltați cu anumite limitări care sunt, în mare parte, legate de caracteristicile mediului în care trebuie să opereze, cum ar fi temperatura, presiunea, umiditatea și alte mărimi fizice. Aceste limitări sunt rezultatul tehnologiei și a materialului utilizat în proiectarea și construcția senzorilor, astfel că, pentru un același domeniu de utilizare, se pot obține senzori diferiți ale căror limite relaționate cu mediul lor de operare sunt diferite (Mukhopadhyay 2013).

În conformitate cu cele precizate de Cepișcă și Jula (1998), în cele ce urmează, se redau câteva dintre definițiile senzorilor. Astfel, senzorii rezistivi sunt acei senzori care fac parte din grupa senzorilor parametrici, al căror principiu de funcționare se bazează pe faptul că mărimea de măsurat produce o variație a rezistenței electrice. Senzorii inductivi fac parte din grupa senzorilor parametrici și se bazează pe proprietatea că mărimea de măsurat produce o variație a inductanței. Senzorii capacitivi fac parte din grupa senzorilor parametrici și convertesc mărimea neelectrică într-o variație de capacitate. Senzorii în care transformarea semnalului se face direct sunt cei în cazul cărora mărimea neelectrică este convertită direct în semnalul electric de la ieșire. Senzorii în care transformarea se face complex sunt cei în cazul cărora conversia semnalului neelectric se face în mai multe etape intermediare, iar structura lor se proiectează astfel încât să fie imunizată față de acțiunea factorilor perturbatori. Senzorii parametrici sunt cei în cazul cărora semnalul neelectric determină modificarea unei proprietăți electrice a senzorului (rezistență, capacitate, inductanță, coeficient de atenuare a

radiației etc.). Senzorii generatori sunt cei în cazul cărora semnalul neelectric determină generarea unei tensiuni electromotoare, a unui curent sau a unei sarcini electrice. Senzorii analogici sunt cei în cazul cărora un semnal analogic este preluat din mediu, convertit în semnal digital, căruia i se aplică o serie de algoritmi matematici în scopul extragerii informației conținute în el. Senzorii digitali sunt cei în cazul cărora semnalul se preia direct în formă digitală. Diferența dintre un instrument și un senzor constă din faptul că un instrument este un dispozitiv care măsoară și afișează magnitudinea unei variabile fizice, în timp ce un senzor este un dispozitiv care măsoară amplitudinea unei variabile fizice, dar nu oferă o indicație directă a valorii acesteia (Johnson 1982). Alegerea unui dispozitiv de măsurare este dificilă fără o bună înțelegere a procesului supus observației. Astfel, dispozitivele posibil de utilizat, se aleg cu discernământ. De asemenea, este importantă înțelegerea terminologiei relaționate cu instrumentul ce se utilizează. Chiar dacă senzorii reprezintă doar o mică parte în comparație cu alte elemente constituente ale unui instrument de măsurare, în componența unor mașini și aparate electronice mari, aceștia joacă un rol important (Mukhopadhyay 2013). În acest context, disponibilitatea senzorului este un parametru important, deoarece timpul de așteptare inutil pentru a beneficia de funcționarea unui senzor poate întârzia întregul proces sau sistem (Mukhopadhyay 2013).

1.3. Măsurarea muncii prin tehnici tradiționale și moderne

1.3.1. Tipuri de studii implementate în măsurarea muncii

Studiile ce se pot realiza pentru măsurarea muncii se clasifică în funcție de scopul, obiectivele și caracteristicile experimentale proprii (Acuna et al. 2012). Scopul studiilor de măsurare a muncii se poate descrie în urma stabilirii cu atenție a limitelor sistemului analizat sau luat în studiu. Un studiu dat se poate realiza asupra unui singur muncitor, unui singur utilaj sau asupra unui întreg sistem (Acuna et al. 2012). În funcție de obiectivele unui studiu, se disting studii de modelare și studii comparative. Studiile comparative se realizează pentru a pune în evidență diferențele dintre două sau mai multe alternative operaționale (Acuna et al. 2012) care se pot referi la tehnologia utilizată, condițiile operaționale sau forța de muncă. Studiile de modelare se realizează pentru a se dezvolta modele estimative sau predictive ce descriu performanțele echipamentelor și sistemelor tehnice utilizate în funcție de variația unor factori operaționali. În general, studiile de acest fel se pot utiliza pentru evaluarea performanțelor unor echipamente existente ce sunt supuse observării în medii de muncă nestudiate (pentru a se modela dinamica performanței productive a acestora relaționat cu noi factori operaționali) sau în cazul unor echipamente noi, nestudiate, operând în diverse medii operaționale (Visser și Spinelli 2012). Pentru a produce rezultate caracterizate de o validitate ridicată, astfel de studii trebuie să includă variabilitatea operațională generată de forța de muncă, tehnologia utilizată (Acuna et al. 2012), precum și de condițiile specifice unor arii geografice diferite (Hiesl și Benjamin 2013), cunoscându-se, de exemplu, faptul că doi operatori implicați în aceeași activitate și dispunând de același echipament vor genera performanțe diferite în muncă datorită altor factori externi, precum nivelul de pregătire și motivare. În conformitate cu unele caracteristici proprii de natură experimentală (inclusiv din punct de vedere statistic), se pot distinge studii observaționale și studii experimentale (Acuna et al. 2012). Studiile observaționale sunt adesea implementate în știința aplicată, în mod special în cea relaționată cu domeniul forestier, unde multe dintre variabilele mediului de muncă (operațional) nu pot fi controlate în avans. Acest fapt conduce la un design mai slab al studiilor, prin urmare, la rezultate care vor avea, mai degrabă, o natură indicativă (Acuna et al. 2012). Chiar și în condițiile date, studiile cu caracter observațional oferă informații valoroase cu privire la procesele sau sistemele studiate. Spre deosebire de studiile observaționale, studiile experimentale sunt acelea care permit controlul cu privire la anumite variabile și pot fi organizate și implementate în cadrul unui design experimental mult mai robust (Acuna et al. 2012), în sensul că pot pune în evidență efectul anumitor factori asupra performanței unui sistem, echipament sau muncitor. Datele generate de studiile din această categorie sunt mult mai robuste decât cele obținute în urma studiilor observaționale. În condițiile în care productivitatea

utilajelor forestiere depinde de numeroşi factori (Jirousek et al. 2007, Kärhä et al. 2004, Spinelli et al. 2002), conceptul de studiu de timp a căpătat o importanţă majoră în studiile de măsurare a muncii aplicate în sectorul forestier, acestea permiţând cercetătorilor obţinerea unor rezultate raţionale şi rezonabile, cu privire la performanţele sistemelor analizate (Palander et al. 2012). Astfel, studiile de timp sunt esenţiale pentru estimarea productivităţii (Contreras et al. 2017) şi, în timp, au fost realizate multe studii privind atât productivitatea utilajelor forestiere, cât şi a sistemelor tehnice de exploatare a lemnului (Kosir et al. 2015).

1.3.2. Echipamente şi instrumente utilizate în studiile de măsurare a muncii

De-a lungul timpului, echipamentele şi instrumentele utilizate în realizarea studiilor de măsurare a muncii s-au dezvoltat foarte mult. Primele instrumente folosite au fost ceasornicele de mână (e.g. Borz 2014a), apoi s-a recurs la utilizarea tehnologiei GPS (e.g. McDonald şi Fulton 2005), la senzori integraţi în utilajele forestiere moderne (e.g. Borz 2014a) şi la senzori externi utilizaţi în colectarea de date din teren (Borz 2016, Cheţa şi Borz 2017, Cheţa şi Talagai 2017, Cheţa et al. 2017).

În ceea ce priveşte utilizarea ceasornicelor de mână, acestea încă reprezintă o alternativă viabilă, atunci când sunt echipate cu funcţii de cronometrare. Principala limitare a acestor instrumente constă din aplicabilitatea lor restrânsă la implementarea studiilor de timp de complexitate mai redusă (Borz 2014a). Cronometrele specializate sunt dispozitive, de obicei electronice, construite şi utilizate pentru cronometrarea şi înregistrarea unor serii de date cronometrice. Acestea prezintă diferite funcţii, oferind precizii într-un domeniu foarte larg. Datele colectate se pot stoca în memoria internă, acestea putând fi preluate, manual, prin centralizare în baze de date electronice (Borz 2014a).

O altă metodă utilizată în studiile de măsurare a muncii a devenit posibilă odată cu apariţia computerelor de buzunar, acestea oferind posibilitatea unor măsurători mai detaliate şi mai precise. În ultimul timp, acestea au început să înlocuiască cronometrele şi carnetele de teren (Nuutinen et al. 2008). Computerele de buzunar sunt dispozitive inteligente (tablete, telefoane mobile) sau alte dispozitive dezvoltate în mod special pentru realizarea studiilor de timp, pe care sunt instalate programe software speciale ce permit crearea unei scheme de înregistrare a consumului de timp şi alocarea (divizarea) unor elemente de muncă, anterior realizării studiilor de teren. Acestea oferă posibilitatea procesării şi transferului datelor pe computere de birou în vederea prelucrării şi analizei statistice, şi pot fi utilizate pentru a înregistra, simultan, mai mulţi parametri şi statistici cu privire la consumul de timp în muncă cum ar fi timpul consumat pe elemente de muncă, timpul cumulată etc. (Nuutinen et al. 2008); astfel de dispozitive au fost utilizate cu o frecvenţă mare în deceniile trecute (e.g. Kärhä et al. 2004, Kellog şi Bettinger 1994, Eliasson 1998, Ovaskainen, 2009, Puttock et al. 2005, Spinelli şi Visser 2008).

O altă categorie de instrumente utilizate în studii de măsurare a muncii este cea a camerelor video (e.g. Nakagawa et al. 2007, Nurminen et al. 2006). Acestea pot fi utilizate atunci când se doreşte punerea în evidenţă a consumului de timp pentru anumite elemente de muncă, care sunt caracterizate de durate foarte scurte (Borz 2014a). În cazul utilizării camerelor video, consumul de timp se determină, în general, indirect, după organizarea corespunzătoare a fişierelor video colectate. În faza de birou, prelucrarea datelor înregistrate se realizează prin intermediul unor programe de calculator ce permit extragerea consumului de timp pe elemente de muncă, prin separarea acestora bazată pe vizualizarea înregistrărilor şi efectuarea diferenţelor între timpul de început şi cel de sfârşit al unui element de muncă. O limitare în realizarea studiilor de teren este cea legată de durata de funcţionare a bateriilor camerelor video.

Relativ recent, pentru studiile de măsurare a muncii s-au utilizat instrumente (receptoare) GPS şi senzori de vibraţie pentru colectarea datelor cu privire la consumul de timp la nivel de element de muncă (Hejazian et al. 2013, Odhiambo 2010, Strandgard şi Mitchell 2015). Această abordare poate

fi caracterizată de unele limitări în cazul utilizării de receptoare GPS. De exemplu, una din problemele obișnuite relaționate cu utilizarea acestui instrument o reprezintă cea legată de pierderea semnalului (Contreras et al., 2017, McDonald și Fulton 2005), mai ales în cazul operațiilor forestiere care se desfășoară pe terenuri abrupte și sub coronamentul arboretului. O altă limitare este cea legată de faptul că nu se pot colecta mărimile unor variabile care au o influență semnificativă asupra consumului de timp și a productivității, cum ar fi sarcina deplasată în cazul tractoarelor sau diametrul sau mărimea arborilor în cazul utilizării ferăstraielelor mecanice. În ceea ce privește gradul de identificare a unor elemente de muncă și măsurarea consumului de timp pentru acestea, abordarea prin colectarea de date GPS este destul de fezabilă (de Hoop și Dupre 2006, McDonald și Fulton 2005), dar ar putea fi îmbunătățită prin utilizarea camerelor video (Contreras et al. 2017).

Mașinile multifuncționale utilizate în recoltarea lemnului, cum ar fi cele de tip harvester, sunt echipate cu un sistem de monitorizare a producției. Multe dintre modelele existente integrează și operează în conformitate cu standardul *StanFord* (e.g. Olivera și Visser 2016). Acesta a fost dezvoltat în țările din nordul Europei precum Suedia, Finlanda și Norvegia, în 1988, și este utilizat acum în majoritatea țărilor în care se folosesc pe scară largă astfel de mașini în operațiile de exploatare a lemnului (Skogforsk, 2012).

Sistemele externe de gestiune și monitorizare a producției sunt sisteme ce oferă capacități similare sistemelor automate, integrate în mașini și utilaje, putând fi utilizate pentru colectarea datelor cu privire la consumul de timp și a celor cu privire la mobilitate și locomoție, putând să colecteze date specifice la diferite rezoluții (Borz 2014a). Astfel de sisteme pot fi deosebit de utile când se dorește urmărirea sau cuantificarea producției pe termen lung sau optimizarea producției. În cazul acestor sisteme, legătura dintre utilaj și sarcinile de muncă este realizată prin intermediul unor senzori amplasați sau integrați în diferite dispozitive active ale utilajului, putându-se realiza astfel comunicarea și transferul de date, precum și localizarea GPS a acestuia (Borz 2014a).

Sistemele automate sunt sisteme bazate pe senzori ce pot colecta automat date, în măsura în care o acțiune sau o secvență dintr-o acțiune ce definește începutul și sfârșitul unui element sau ciclu de muncă pot fi recunoscute de senzor. Acestea permit transferul de date într-un dispozitiv de stocare sau într-un computer (Acuna et al. 2012). Utilizarea unor astfel de sisteme este încă în stadiu incipient în operațiile forestiere (Borz 2014a).

1.3.3. Măsurarea muncii prin tehnici moderne. Stadiul actual, posibilități și limitări

Literatura de specialitate indică faptul că uneltele, echipamentele și utilajele folosite curent în operații forestiere sunt încă la nivel conceptual, similare celor originale, fiind caracterizate de îmbunătățiri minore, ultimele rezultând din evoluția tehnologică (Kosir et al. 2015). Prin urmare, chiar dacă unele echipamente au fost îmbunătățite, procedurile (metodele) de lucru au rămas neschimbate. Totodată, studiile de măsurare a muncii evidențiază diferențe substanțiale în modul în care diferiții cercetători tratează, sub raport conceptual, consumul de timp, efectele generate de experiența operatorilor și costurile de implementare a studiilor (Kosir et al. 2015). Acestea sunt aspecte mult dezbătute, care au făcut deja obiectul mai multor studii (e.g. Spinelli și Visser 2008 pentru întârzieri, Lindroos 2010, Purfürst și Lindroos 2011 pentru efectul operatorului și Ackerman et al. 2014 pentru costurile operaționale). Constatarea generală a fost aceea că studiile pot fi realizate diferit, în concordanță cu condițiile operaționale, prin urmare este extrem de dificilă elaborarea unui protocol standardizat pentru conducerea lor (Spinelli et al. 2013). Cu toate acestea, se fac eforturi de armonizare menite să faciliteze înțelegerea reciprocă, cu scopul final de a valorifica întregul potențial al cooperării internaționale (Magagnotti et al. 2013). Există deja multe studii de acest gen în domeniul forestier și cunoștințele generate sunt ample, dar majoritatea acestora rămân sub forma unor episoade unice, contribuind sub forma unui răspuns la o întrebare specifică.

Odată cu îmbunătățirea echipamentelor și instrumentelor utilizate în studiile de măsurare a muncii a devenit posibilă colectarea automată a datelor de interes. În acest context, McDonald și Fulton (2005) au sugerat că implementarea automată a studiilor de timp trebuie să îndeplinească o serie de cerințe, înainte de a putea fi folosită ca instrument de cercetare: instrumentele trebuie să fie ușor de instalat și să reducă la minim întreruperile generate de utilizarea lor, trebuie să ofere posibilitatea de a fi ușor de amplasat pe o întregă gamă posibilă de unelte și mașini fără a necesita o reconfigurare a sistemului de colectare a datelor pentru fiecare mașină, trebuie să reziste la condiții de exploatare dure și, respectiv, trebuie să producă date similare, indiferent de indivizii care colectează datele. Utilizarea acestor abordări automate pentru realizarea studiilor de măsurare a muncii ar putea să conducă la economii substanțiale în ceea ce privește consumul de timp, personalul calificat și capitalul financiar, fiind capabile să producă, în același timp, rezultate similare cu cele obținute prin abordări tradiționale (Borz 2016). Acestea permit colectarea datelor pe termen lung fără stânenirea muncitorilor de prezența unui observator (Acuna et al. 2012).

În ultima perioadă, computerele de bord ce colectează date în conformitate cu standardul **StanFord** (Skogforsk 2012) sunt integrate în majoritatea utilajelor forestiere moderne, acest lucru fiind evidențiat de un număr de studii publicate, folosind date provenite din acestea (Purfürst 2010, Strandgard et al. 2013). Totodată, abordări automate au fost utilizate pentru a colecta date privind performanțele mașinilor de recoltare moderne, utilizând sistemele TimberLink dezvoltat de John Deere (Gerasimov et al. 2012), CAN-Bus (Controller Area Network) (Nuutinen et al. 2008) și colectori de date precum cei dezvoltați de **FPI** (Forest Products Innovation) și MultiPat (Davis și Kellogg 2005). La fel, o serie de studii au utilizat date GPS pentru a interpreta activitățile utilajelor forestiere, în special a tractoarelor de tip skidder (e.g. Cordero et al. 2006, de Hoop și Dupré 2006, McDonald și Fulton 2005, Veal et al. 2001). O posibilă deficiență în utilizarea receptoarelor GPS în astfel de studii constă din consumul de timp mare necesar pentru analiza și prelucrarea datelor (Cheta și Borz 2017).

Dat fiind faptul că majoritatea utilajelor folosite în operațiile forestiere sunt echipate cu motoare cu ardere internă, se pot monitoriza anumite fenomene fizice precum vibrațiile și nivelul presiunii acustice (Cheța și Talagai, 2017), fenomene care pe baza unor senzori utilizați pot să indice anumite regimuri de funcționare specifice funcțiilor tehnice sau operațiilor realizate. În acest context, nivelul vibrațiilor poate fi monitorizat prin intermediul unor senzori integrați în instrumente specifice, aceștia putând înregistra șiruri de date etichetate temporal pentru una sau mai multe serii de înregistrări ale magnitudinii vibrațiilor (Talagai și Borz 2016). Un avantaj al acestor senzori îl reprezintă capacitatea de a colecta date la o precizie ridicată (Cheța și Talagai 2017) pe mai multe axe de referință (Borz et al. 2018). Un alt parametru ce poate fi monitorizat pentru motoarele cu ardere internă, utilizând senzori, este nivelul presiunii acustice. Similar senzorilor de vibrație, senzorii care măsoară nivelul de presiune acustică pot reda regimul de funcționare prin intermediul unor șiruri de date etichetate temporal (Cheța et al. 2017), în timp ce acești senzori pot fi configurați astfel încât să colecteze date la diferite rate de eșantionare (Cheța și Talagai 2017).

1.3.4. Tehnici ale inteligenței artificiale (AI) bazate pe rețele neuronale artificiale (ANN)

Inteligența artificială (AI) este abilitatea mașinilor sau a computerelor de a realiza atribuții și sarcini care sunt asociabile, în mod obișnuit, cu inteligența umană. Definiția cea mai des acceptată a inteligenței artificiale a fost dată în 1955, de omul de știință John McCarthy (Ertel 2017). În timp, s-au dezvoltat mai multe clase de algoritmi care pot să reproducă modul de învățare umană și care se pot utiliza pentru a învăța din diverse semnale. O clasă aparte a algoritmilor de învățare specifici inteligenței artificiale este cea constituită din rețelele neuronale artificiale (ANN). O rețea neuronală artificială reprezintă o abordare de învățare automată, care simulează modul de funcționare al creierului uman și care constă dintr-un număr de neuroni artificiali (Aggarwal 2018, Sheela și Deepa 2013). Neuronii din ANN tind să aibă și au mai puține conexiuni decât neuronii biologici; fiecare neuron din ANN este conectat (primește) la număr de intrări cărora li se aplică o funcție de activare,

pentru a produce o valoare de ieşire a neuronului (Panchal și Panchal 2014). Există mai multe clase (tipuri) de funcții de activare precum și alți parametri specifici ai funcționării **ANN** dintre care, o parte se redau și se tratează prin unele dintre studiile de caz prezentate în această lucrare. Dat fiind faptul că o rețea neuronală artificială îndeplinește, în anumite cazuri, o funcție de clasificare a datelor, evaluarea performanței clasificării se realizează prin anumiți indicatori de performanță specifici algoritmilor de clasificare. Aceștia se aplică atât etapei de învățare, cât și celei de testare a unei **ANN** și sunt descriși, în detaliu, în studii precum cel al lui Kamilaris și Prenafeta-Boldu (2018) și, respectiv, Fawcett (2006). Indicatorii de performanță utilizați în lucrarea de față au fost aria de sub curbă (**AUC**), acuratețea de clasificare (**CA**), precizia clasificării (**PREC**), recall (**REC**) și media armonică a **PREC** și **REC** (**F1**). Conform lui Fawcett (2006) abilitatea unui algoritm de clasificare de a identifica și categorisi corect instanțe în anumite clase se măsoară utilizând informațiile pe care le furnizează așa-numitele „matrici de confuzie, matrici ale confuziei”.

CAPITOLUL 2. SCOPUL ŞI OBIECTIVELE LUCRĂRII

Principalul scop al acestei lucrări a fost acela de a evalua utilitatea și limitările folosirii senzorilor și a tehnicilor inteligenței artificiale (**AI**), bazate pe rețele neuronale artificiale (**ANN**) în colectarea, analiza și interpretarea automată a datelor specifice studiilor de timp, aplicate în operațiile forestiere și în cele specifice industriei de prelucrare a lemnului. Un scop secundar al lucrării a fost acela de a evalua condițiile ergonomice specifice doborârii și fasonării arborilor cu ferăstraie mecanice prin intermediul unui studiu de caz dezvoltat la nivel de element de muncă, într-un arboret de plop în care s-a aplicat tratamentul tăierilor rase în parchete mici. Acest scop secundar a fost relaționat cu evaluarea posibilității de a colecta concomitent date cu privire la ritmul cardio-vascular și la expunerea la zgomot, prin folosirea unui set de senzori externi. Pentru îndeplinirea scopului cercetării, a fost elaborată o listă de obiective specifice. Prin urmare, obiectivele lucrării au fost următoarele:

- I. *De a documenta conceptele, terminologia și definițiile cu privire la știința și măsurarea muncii prin studii de timp, cât și pe cele cu privire la tipurile de studii implementate, abordările utilizate, echipamentele și instrumentele folosite, utilizarea semnalelor colectate de senzori și a algoritmilor inteligenței artificiale în implementarea de studii de timp;*
- II. *De a testa, prin studii de caz, posibilitățile de utilizare a semnalelor captate de senzori și a algoritmilor de clasificare în aplicații de măsurare a muncii specifice operațiilor forestiere;*
- III. *De a testa, prin studii de caz, posibilitățile de utilizare a semnalelor captate de senzori și a algoritmilor de clasificare, în aplicații de măsurare a muncii specifice operațiilor de prelucrare a lemnului;*
- IV. *De a evalua condițiile ergonomice la locul de muncă în cazul operațiilor de doborâre și fasonare a arborilor cu ferăstrăul mecanic, prin parametri colectați de senzori, precum ritmul cardiac și nivelul de expunere la zgomot.*

CAPITOLUL 3. MATERIALE ŞI METODE

3.1. Locurile alese pentru colectarea datelor pentru studiile de caz şi caracteristicile studiilor de caz

În **Figura 1** sunt prezentate judeţele alese pentru colectarea datelor din teren pentru studiile de caz menţionate în capitolul anterior. În locurile alese pentru studiu au fost realizate teste de teren atât pe mai multe tipuri de echipamente forestiere cât şi pe instalaţii de prelucrare a lemnului. O descriere completă a studiilor de caz este redată în teza în extenso. Se precizează încă de la început faptul că, desfăşurarea studiilor şi alegerea locurilor de studiu a fost condiţionată de disponibilitatea unor companii de a permite colectarea şi analiza datelor, precum şi de efortul întreprins pentru prelucrarea şi analiza datelor în faza de birou. Pentru această ultimă etapă, s-a anticipat documentarea datelor colectate, în mod obişnuit, la o rată de eşantionare de o secundă, prin utilizarea unor înregistrări video.



Figura 1. Localizarea studiilor la nivel naţional

Legendă: A - testele de teren realizate în judeţul Braşov, România, B - testul de teren realizat în judeţul Dolj, România, C - testul de teren realizat în judeţul Harghita, România.

În judeţul Braşov (**A**), au fost conduse testele din teren în trei locuri distincte (**LS1**, **LS2** şi **LS4**), prin luarea în considerare a observării unor echipamente distincte. Un prim loc de studiu din **A**, luat în considerare pentru testare, a fost **LS1** care a fost ales la baza didactică a Facultăţii de Silvicultură şi exploatare forestiere, localizată în Braşov, România, având setul de coordonate 45° 37' 00.89" 'N - 25° 37' 20.08" 'E, situată la o altitudine de aproximativ 660 m. Datele colectate din teren pentru acest

loc de studiu au furnizat baza dezvoltării studiilor de caz **SC1** și **SC2**. Al doilea loc de studiu din **A**, ales pentru testare a fost **LS2**. Pentru acesta, datele necesare pentru studiul de caz au fost colectate într-un arboret situat în apropiere de localitatea Zărnești, județul Braşov, România. Zona de amplasare a instalației cu cabluri a fost caracterizată de coordonatele geografice 45° 35' 05" N - 25° 11' 34" E, la o altitudine medie de circa 900 m. Pe baza datelor din **LS2** s-a realizat **SC3**. **LS4** a fost ales într-o unitate de prelucrare a lemnului localizată în Braşov, România. Societatea în cauză se ocupă cu producția cutiilor din lemn, care sunt vândute către diverși clienți ce le utilizează pentru depozitarea altor produse. Pe baza datelor colectate în **LS4**, s-a realizat **SC7**. În județul Dolj (**B**), a fost condus testul de teren din **LS3**, pe baza căruia au fost realizate studiile de caz **SC4**, **SC5** și **SC6**. Testul de teren din **LS3** s-a realizat în anul 2017, într-un arboret de plop hibrid (*Populus × Euroamericana*) de 30 de ani situat în unitatea amenajistică 89A, unitatea de producție IV Rast, lângă satul Rast, județul Dolj. Suprafața în care s-a realizat studiul este caracterizată de coordonatele geografice 43°51'17"N - 23°20'09"E, fiind localizată în vecinătatea fluviului Dunărea. Tot pe baza datelor colectate din această suprafață s-au realizat și studiile de caz **SC5** și **SC6**, privind testarea capacității senzorilor de măsurare a nivelului de presiune acustică de a colecta automat date și a tehnicilor inteligenței artificiale, prin utilizarea rețelelor neuronale artificiale, de a clasifica timpul de muncă și, respectiv, testarea capacității senzorilor de a colecta automat date cu privire la ergonomia muncii. În județul Harghita (**C**), au fost culese date în **LS5**, pe baza cărora a fost realizat studiul de caz **SC8**. Datele au fost colectate în 2018, într-o fabrică de prelucrare a lemnului de dimensiuni mici, aflată în județul Harghita (România).

3.2. Descrierea echipamentelor utilizate pentru studiile de caz

Testul de teren din **LS1** s-a realizat prin intermediul unui studiu efectuat asupra unui ferăstrău mecanic fabricat de Husqvarna, model 550 XP. În momentul realizării acestui experiment pe teren, ferăstrăul mecanic avea circa 86 de ore de funcționare. Caracteristicile tehnice de bază ale ferăstrăului mecanic luat în studiu sunt redată în teza în extenso. În cazul testului de teren din **LS2** s-a monitorizat activitatea unui funicular Wyssen echipat cu un grup motor W30 și cu un cărucior HY 4 acționat prin control radio. Principalele caracteristici ale grupului motor și ale căruciorului sunt descrise în teza în extenso. În ceea ce privește colectarea de date din **LS3**, pentru operațiile de doborâre și fasonare a arborilor în arboretele de plop hibrid, s-a utilizat un ferăstrău mecanic fabricat de STIHL MS 362. Caracteristicile tehnice de bază ale ferăstrăului sunt descrise în teza în extenso. Pentru **LS4** s-a luat în studiu un ferăstrău circular dezvoltat pentru operații de retezat. Acesta a fost construit de angajații fabricii de prelucrare a lemnului în care s-au colectat datele de teren. Caracteristicile de bază ale ferăstrăului circular sunt descrise în teza în extenso. În ceea ce privește testul de teren realizat în **LS5**, debitarea buștenilor s-a realizat cu un ferăstrău panglică orizontal, cu acționare manuală. Avansul și poziționarea organului activ al ferăstrăului panglică sunt manuale. Bușteanul care urmează să fie debitat se fixează la mijlocul șinei pe care se deplasează ferăstrăul. Fixarea se realizează cu cleme manuale, la distanțe de 2 metri. Lungimea șinei este 10 m, rezultând o lungime maximă de tăiere 8,5 m, iar diametrul maxim de tăiere este de 74 cm. Principalele caracteristici ale ferăstrăului panglică sunt descrise în teza în extenso. Pentru colectarea datelor de teren s-au utilizat un accelrometru triaxial, un colector de date cu privire la nivelul de presiune acustică, un receptor GPS, un dispozitiv de măsurare a ritmului cardiac și diverse modele de camere video. Caracteristicile tehnice ale acestor instrumente sunt redată în teza în extenso.

3.3. Organizarea muncii și experiența muncitorilor

În **LS1**, testarea potențialului utilizării dispozitivelor externe echipate cu senzori de a colecta automat date cu privire la consumul de timp a fost realizată printr-un experiment condus în condiții controlate (simulate) asupra unui ferăstrău mecanic. Ferăstrăul mecanic a fost operat de un

fasonator mecanic cu o experiență îndelungată în operațiile de doborâre și fasonare a arborilor. Acesta a fost informat cu privire la modul în care trebuie să opereze ferăstrăul mecanic și la modul în care trebuie simulate tăieturile de doborâre și de fasonare. În primă fază, ferăstrăul mecanic a funcționat în ralanti în diferite poziții, pentru un anumit interval de timp; ulterior, ferăstrăul mecanic s-a folosit pentru a executa un număr de 6 tape și, respectiv, 5 tăieturi de secționare (**Figura 2**).



(a)

(b)

Figura 2. Realizarea testelor de teren pentru SC1 și SC2

Legendă: (a) - simulări pentru realizarea tapelor, (b) - simulări pentru realizarea tăieturilor de secționare

În practică, tehnicile cele mai simple de doborâre a arborilor constau în realizarea unor tăieturi la baza arborelui, într-o anumită ordine și într-un anumit raport al unora față de celelalte, acestea declanșând pierderea echilibrului natural al arborelui și angajarea acestuia în cădere (Oprea 2008). Buștenii pe care au fost realizate tapele au fost poziționați vertical, iar cei pe care au fost realizate tăieturile de secționare au fost poziționați orizontal. Buștenii poziționați pe verticală au avut un diametru mediu de 30 cm și o lungime medie de 1,5 m. Cei poziționați pe orizontală au avut diametrul mediu de 44 cm și lungimea medie de 4,5 m. Buștenii utilizați au fost procurați din apropierea locului studiului.

În cazul **LS2**, pentru realizarea operațiilor de colectare a lemnului cu instalații cu cabluri, s-a utilizat o echipă de 4 muncitori, dintre care unul a operat grupul motor, doi și-au desfășurat activitatea în șantierul de exploatare pentru realizarea operațiilor de doborâre și pentru formarea sarcinii prin utilizarea ciochinarelor, iar ultimul și-a desfășurat activitatea la locul de dezlegare a sarcinii, în platforma primară. Toți muncitorii au avut experiență mare în astfel de operații, fiind angajați pe bază de contract de muncă în cadrul companiei respective.

În **LS3**, operațiile de colectare a lemnului au fost efectuate de o echipă formată din doi muncitori, dintre care unul a operat un tractor agricol, echipat pentru operații forestiere (Deutz DX 6.30), iar cel de-al doilea a efectuat doborârea și fasonarea arborilor.

În cazul **LS4**, unde s-a monitorizat ferăstrăul circular, s-a urmărit modul de realizare al operațiilor de tăiere, care au fost efectuate de către doi muncitori ce au deservit echipamentul de tăiere și care și-au desfășurat munca de o manieră obișnuită. Ghidarea echipamentului se realizează manual în timpul tăierii, iar retragerea se realizează mecanic. Instalația de prelucrare a lemnului este specializată în prelucrarea lemnului de molid și brad, care este procurat sub formă de cherestea și

dulapi. Din produsele de lemn intrate în punctul de lucru al societății comerciale luate în studiu, se produc lăzi pentru depozitare, ce se confecționează din cherestea și dulapi.

În testele efectuate în **LS5**, ferăstrăul panglică a fost acționat și reglat manual, a necesitat un muncitor pentru a-l opera și a fost alimentat electric. Astfel de utilaje asigură transformarea buștenilor în produse de lemn prelucrat și sunt utilizate pentru a opera prin tăieri succesive printr-o mișcare înainte-înapoi a cadrului de tăiere.

3.4. Colectarea datelor din teren pentru studiile de caz

3.4.1. Colectarea datelor din teren pentru studiile de caz SC1 și SC2

Colectarea datelor din teren s-a realizat prin intermediul a trei instrumente. Primul a fost o cameră video, prin intermediul căreia s-a realizat o monitorizare continuă a tuturor operațiilor simulate de operatorul ferăstrăului mecanic. Totodată, au fost amplasați, în puncte cheie, doi colectori de date echipați cu senzori, aceștia fiind amplasați în așa fel încât să nu deranjeze modul obișnuit de realizare a operațiilor. S-a utilizat un colector de date echipat cu un senzor de vibrație (mișcare) produs de Extech®, model VB300, a cărui amplasare pe ferăstrăul mecanic s-a realizat prin intermediul unor șuruburi, pentru a realiza un contact perfect cu acesta (**Figura 3**). Un alt instrument utilizat a constat dintr-un colector de date echipat cu un senzor de măsurare a nivelului de presiune acustică Extech® 407760, acesta fiind montat pe frâna de siguranță a ferăstrăului mecanic prin utilizarea unor coliere de plastic (**Figura 3**). Pentru captarea datelor video s-a utilizat un telefon mobil inteligent, model Samsung G900W8.




Figura 3. Amplasarea colectorilor de date pe ferăstrăul mecanic

Legendă: 1 - instrument de măsurare a nivelului presiunii acustice, 2 - instrument de măsurare a vibrației

Configurarea celor două instrumente s-a realizat prin intermediul programului software specializat fiecărui dintre ele. O primă setare a constat în stabilirea ratei de eșantionare la o secundă. Apoi, au mai fost stabilite următoarele setări: pentru instrumentul de măsurare a vibrației (acelerației) s-a stabilit modul de înregistrare a detectării mișcării, utilizarea scării *g* pentru înregistrarea datelor și pornirea manuală, iar pentru instrumentul de măsurare a nivelului de presiune acustică s-a setat modul de înregistrare rapidă, utilizarea scării dB(A), pentru înregistrarea nivelului presiunii acustice și pornirea manuală. O funcționalitate importantă a acestor programe constă din posibilitatea de a exporta datele colectate sub formă de foi de calcul Microsoft Excel; în urma exportului, datele privind mărimile măsurate sunt etichetate prin scrierea datei și orei de colectare a fiecărei observații dintr-un șir. Ambii colectori de date sunt echipați cu ceasuri interne care se sincronizează cu cel al

computerului utilizat pentru configurare, acest lucru făcând ușoară împerecherea datelor furnizate în foi de calcul Microsoft Excel. După ce au fost realizate setările prin intermediul unui computer, colecții de date au fost pornite simultan, acest pas fiind făcut după pornirea camerei video.

3.4.2. Colectarea datelor din teren pentru studiul de caz SC3

Colectarea datelor în mod automat și implementarea studiilor de timp și mișcare în cazul instalațiilor cu cabluri s-a realizat prin folosirea unui receptor GPS Garmin® 62 stc, care a fost amplasat pe cărucior, într-o poziție cât mai bună pentru recepționarea semnalului GPS. Receptorul a fost setat pentru a colecta date la o rată de eșantionare de 5 secunde. În același timp, două instrumente de măsurare a nivelului de presiune acustică (Extech®, model 407760), au fost amplasate pe cadrul grupului motor și pe cadrul căruciorului, pentru a colecta date în mod continuu. Pentru acestea au fost realizate următoarele setări: rata de eșantionare a fost stabilită la o secundă, modul de înregistrare rapidă, utilizarea scării dB(A) pentru înregistrarea nivelului presiunii acustice și pornirea manuală. Toate cele trei dispozitive au fost pornite în același timp. Această abordare s-a utilizat pentru a se obține date comparative, care să fie utilizate în evaluarea consumului de timp.

3.4.3. Colectarea datelor din teren pentru studiile de caz SC4, SC5 și SC6

Colectarea datelor din teren s-a realizat prin implementarea unui studiu de timp detaliat, fiind descrise sarcinile specifice, iar evaluarea consumului de timp la nivel de element de muncă s-a bazat pe conceptele generale și recomandările descrise în Acuna et al. (2012) și Björheden et al. (1995). Acest studiu nu a fost conceput pentru a modela variația consumului de timp în funcție de anumite variabile operaționale, ci doar pentru măsurarea unui set minim de valori, necesare în evaluarea muncii din punct de vedere productiv și ergonomic prin utilizarea de senzori. Timpul total de studiu (T_T , s) a fost divizat, conceptual, în două categorii principale: timpul productiv (t_P , s) și cel neproductiv (t_{NP} , s). În prima categorie au fost grupate toate elementele de muncă ce presupun implementarea efectivă a operațiilor și care sunt, de obicei, luate în considerare și la evaluarea condițiilor ergonomice ale unui loc de muncă dat (Poje et al. 2015, Spinelli et al. 2018, Spinelli et al. 2016). Totodată, această categorie de timp a fost utilizată pentru estimarea productivității și eficienței nete, în conformitate cu definițiile acestor parametri, descrise de studiile de evaluare a productivității în operații forestiere. În a doua categorie au fost grupate toate elementele de muncă ce au presupus apariția unor evenimente și sarcini neproductive, cum ar fi întârzierile, timpul necesar pregătirii muncii, pauzele de odihnă și întârzierile cauzate de studiu, fiind utilizată pentru determinarea productivității și eficienței brute, ce caracterizează condițiile date de teren. Timpul total de studiu (T_T , s) a fost împărțit în elemente de muncă, iar datele referitoare la consumul de timp au fost colectate pe foi de hârtie, folosind metoda cronometrării continue (Björheden et al. 1995). În teren, s-a măsurat diametrul de bază ($D_{1,3}$, cm) și diametrul la înălțimea cioatei ($D_{0,3}$, cm), utilizându-se o clupă forestieră. Volumul producției realizate (P , m³) în operațiile de doborâre și fasonare a arborilor a fost estimat pe baza volumelor extrase din actul de punere în valoare și a numărului de arbori doborâți. Consumul de combustibil (FM , l) și consumul de ulei pentru sistemul de ungere a ferăstrăului mecanic (LO , l) au fost măsurate pe teren, utilizând metodele generale recomandate în Acuna et al. (2012) și descrise într-un studiu similar (Igneu et al., 2017), cu diferența că alimentarea cu combustibil s-a realizat la momente alese de operator, prin urmare datele colectate nu se aplică fiecărui arbore, ci grupurilor de arbori doborâți și fasonați. Consumurile unitare de combustibil (UFM , l × m⁻³) și ulei (ULO , l × m⁻³) au fost calculate la birou pe baza datelor înregistrate în teren și a producției realizate (P , m³). Pentru a se putea descrie expunerea la zgomot pe sarcini specifice, conceptul de împărțire a timpului de studiu pe elementele de muncă a luat în considerare și starea de funcționare a ferăstrăului mecanic (pornit/oprit). Această abordare este o alternativă bună în studiile realizate asupra unor moto-unelte, în care trebuie să se țină seama de astfel de separări, fie pentru a determina rata de utilizare a motorului (Borz et al. 2018), fie pentru a evalua condițiile ergonomice. De exemplu, deplasările cu ferăstrăul mecanic pornit și oprit, au fost considerate elemente de muncă distincte și au fost documentate separat. În plus, această separare a

fost utilă și în alte evaluări ergonomice legate de efortul fizic și evaluarea (analiza) posturală. Expunerea la zgomot a fost monitorizată utilizându-se o procedură aliniată la legislația europeană și la standardele relevante în domeniu (Directiva 2003/10/CE). Acest lucru a fost realizat prin amplasarea unui instrument capabil să înregistreze nivelul de presiune acustică (Extech® 407760) pe cască de protecție a operatorului la o distanță de 10 cm față de ureche. Astfel de dispozitive sunt proiectate să îndeplinească standardele ANSI și IEC 61672 clasa 2 (EXTECH® 407760), fiind capabile să colecteze date, pe scara dB(A) sau dB(C) și să le exporte, prin intermediul programelor software specifice sub formă de fișiere **CSV**. În plus, acestea au capacitatea de a eticheta datele colectate, folosind ora și data fiecărei observații, o caracteristică care, împreună cu mărimea și masa redusă, le face potrivite pentru monitorizarea operațiilor specifice muncii parțial mecanizate (Borz et al. 2018). Totodată, instrumentul folosit a fost configurat pentru a colecta date la rata de eșantionare de o secundă, modul de înregistrare rapid, utilizarea scării dB(A) pentru înregistrarea nivelului presiunii acustice și pornirea manuală. Efortul fizic al operatorului a fost estimat pe baza ritmului cardio-vascular, studiindu-se ritmul cardiac (**HR**, bpm). În acest scop, a fost utilizat un dispozitiv Polar V800 (www.polar.fi), care a fost configurat, pentru a colecta date la o rată de eșantionare de o secundă. Dispozitivul constă dintr-o curea pericardică, echipată cu un senzor capabil să înregistreze ritmul cardiac (**HR**) și să îl transmită unui ceas inteligent purtat de un subiect dat prin tehnologia Bluetooth®. Acesta include, de asemenea, o unitate **GPS** și un ceas intern, care poate documenta mișcarea, timpul, temperatura corpului și ritmul cardio-vascular, iar datele înregistrate, pot fi descărcate prin intermediul aplicației **Polar FlowSync** (www.polar.fi) constând într-o bază de date web, care a fost dezvoltată, pentru a monitoriza activitatea unui subiect pe termen lung. Această aplicație web include capacități și funcționalități ale exportului de date în formate accesibile cum ar fi **.GPX** și **.CSV**. Datele din fiecare zi au fost transferate din baza de date web, prin sincronizarea ceasului cu un computer, la sfârșitul fiecărei zile de lucru. La începutul fiecărei zile de studiu, operatorul a fost rugat să stea într-o poziție confortabilă timp de 15 minute, purtând dispozitivul pornit, pentru a putea culege date despre ritmul cardio-vascular în repaus. În teren s-a folosit o cameră video digitală pentru a înregistra operațiile la intervale aleatorii de prelevare. Fișierele video colectate în acest mod au fost salvate în memoria internă, utilizând o procedură de denumire care să permită identificarea eșantioanelor video dintr-o anumită zi de studiu. Aceste fișiere au fost utilizate pentru a evalua în faza de birou a studiului, prin analiza posturală, riscurile de îmbolnăvire profesională.

3.4.4. Colectarea datelor din teren pentru studiul de caz SC7

Monitorizarea dinamicii operaționale a echipamentului s-a realizat prin intermediul a două dispozitive. Primul dispozitiv a încorporat un senzor de măsurare a nivelului de presiune acustică, de construcție Extech® 407760. Acesta facilitează colectarea de date la o rată fină de eșantionare și exportul datelor înregistrate într-un format uzual, precum Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010). Configurarea dispozitivului se realizează utilizând programul software dedicat care permite alegerea parametrilor de eșantionare specifici. Pentru monitorizare, în acest studiu de caz s-au configurat și utilizat parametri de eșantionare, cum ar fi rata de eșantionare de 500 de milisecunde, modul de înregistrare lent și scara dB(A). Toate aceste setări au fost realizate în faza de birou, urmând ca dispozitivul să se pornească manual, după amplasarea pe echipamentul studiat. Ulterior, colectorul de date s-a plasat pe echipament, astfel încât să se evite orice interferență cu modul obișnuit de lucru, lângă motorul electric și lama de tăiere. Un alt dispozitiv folosit a fost camera video a unui telefon mobil care a fost poziționat astfel încât să permită înregistrarea unor fișiere video în timp real. Dispozitivul de înregistrare video a fost amplasat la aproximativ 2 metri distanță de ferăstrăul circular. După amplasarea celor două dispozitive, acestea au fost pornite pentru a monitoriza operațiile realizate.

3.4.5. Colectarea datelor pentru studiul de caz SC8

În cazul **SC8**, pentru colectarea datelor au fost utilizate trei dispozitive. Colectarea semnalelor de intrare s-a realizat cu un dispozitiv capabil de a colecta nivelul de presiune acustică Extech® 407760 și cu un accelerometru triaxial Extech® VB 300 (Extech Instruments, FLIR Commercial Systems Inc., Nashua, USA), acestea fiind abreviate mai departe ca **S** - nivelul de presiune acustică, în dB(A), și **A** - accelerația, în g. Ambele dispozitive au fost setate pentru a înregistra observații la o rată de eșantionare de 1Hz. Accelerometrul a fost montat pe cadrul ferăstrăului, în timp ce dispozitivul de măsurare a nivelului de presiune acustică a fost montat pe casca operatorului pentru a permite și colectarea de date privind expunerea la zgomot. Cu toate acestea, gradul de expunere la zgomot nu a fost abordat în această lucrare. Procedurile complete utilizate pentru setare, transferul de date și împerecherea de date, precum și capacitățile și caracteristicile dimensionale ale dispozitivelor utilizate sunt descrise în Cheța et al. (2018) și, respectiv, Borz et al. (2019), Borz et al. (2018) și Marogel-Popa et al. (2019). Acestea au fost descrise pentru studiile de caz anterioare, motiv pentru care nu se mai redau, în detaliu, aici. O cameră video Schwartz B1080 de dimensiuni mici a fost amplasată pe un perete al fabricii în care s-a monitorizat ferăstrăul panglică pentru a acoperi în câmpul vizual operațiile realizate. Camera video a fost configurată să monitorizeze operațiile colectând continuu fișiere video la lungime maximă permisă de aceasta (20 de minute pe sesiune de înregistrare-salvare, reluată apoi pentru o nouă sesiune de 20 minute), iar operațiile au fost observate pe o durată de trei zile de muncă, prin înregistrarea și salvarea datelor în memoria internă, urmată de transferul și organizarea acestora într-un calculator personal, la finalul fiecărei zile de observație.

3.5. Procesarea datelor pentru studiile de caz

3.5.1. Procesarea datelor privind studiul de caz SC1

Datele înregistrate de către toate dispozitivele folosite au fost descărcate în memoria unui computer. Datele video au fost transferate din memoria internă a telefonului, utilizând procedurile obișnuite de descărcare și au fost stocate într-un dosar. Datele stocate în memoria internă a instrumentelor au fost descărcate prin programul software dedicat. Acestea au fost salvate ca foi de lucru Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010) și au fost împerecheate utilizând etichetele conținând data și timpul curent de observație, conținute în ambele fișiere colectate, rezultând un singur fișier Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010) cu date asociate.

Tabelul 1. Codificarea evenimentelor conform analizei datelor video

Cod (șir de text)	Elementul de muncă (funcție)
PL	Pregătirea de lucru
PFM	Pornirea ferăstrăului mecanic
AFS	Așezarea ferăstrăului pe sol
OCSGVP	Funcționarea ferăstrăului mecanic pe sol, în poziție verticală
OCSGHP	Funcționarea ferăstrăului mecanic pe sol, în poziție orizontală
OCSHVP	Funcționarea ferăstrăului mecanic în mână, în poziție verticală
OCSHHP	Funcționarea ferăstrăului mecanic în mână, în poziție orizontală
D	Mișcări între elementele de muncă
TO	Tăiere orizontală
TI	Tăiere înclinată
TV	Tăiere verticală

Ulterior, datele video au fost analizate prin redare video la viteză de rulare mică, iar consumul de timp specific fiecărui element de muncă (funcție) a fost extras pe foi de hârtie. Fiecare dintre elementele de muncă analizate au fost codificate prin folosirea unei abrevieri de tip text, așa cum se

arată în **Tabelul 1**. Secvenţele de evenimente identificate prin analiza video au fost folosite pentru a codifica datele colectate de către senzori, în funcţie de durata calculată pentru fiecare element de muncă extras în ordinea firească, de pe fişierele video. Pentru realizarea acestei etape, s-a folosit o coloană suplimentară în foaia de calcul Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010), în care s-au introdus codurile, așa cum au fost extrase din succesiunea reală a evenimentelor. Baza de date realizată în acest fel a fost utilizată pentru a analiza posibilitatea extragerii datelor privind consumul de timp pe elemente de muncă. În acest scop, s-au implementat mai multe proceduri de analiză, după cum urmează: datele colectate de senzori și cele colectate video au fost reprezentate pe scara temporală reală pentru a observa dinamica în semnalul de ieşire colectat de senzori; au fost analizate și stabilite pragurile pentru separarea evenimentelor în dinamica semnalelor, în funcţie de elementele (evenimentele) observate; precizia recunoaşterii prin aplicarea pragurilor liniare a fost analizată pentru mai multe tipuri de evenimente, pentru a se concluziona ce elemente pot fi separate din datele colectate de senzori și cu ce precizie.

3.5.2. Procesarea datelor pentru studiul de caz SC2. Configurarea reţelei neuronale artificiale. Analiza datelor privind studiul de caz SC2

3.5.2.1. Procesarea datelor

Datele înregistrate de camera video și de senzorul de acceleraţie au fost descărcate, prelucrate și sistematizate în baza de date după procedurile prezentate pentru **SC1**. Fiecare eveniment a fost codificat prin utilizarea unui șir de tip text (**Tabelul 2**), iar codurile respective au fost utilizate pentru a documenta semnalul de ieşire al accelerometrului, obținându-se astfel un set (în continuare **E**, care a conţinut un număr de **e** = 5 evenimente).

Tabelul 2. Coduri utilizate pentru documentarea datelor și descrierea acestora

Elementul de muncă	Cod Numeric	Descriere
Oprit	0	Pregătirea muncii și pornirea ferăstrăului mecanic
Ralanti_M	1	Funcționarea ferăstrăului mecanic în ralanti în mână
Ralanti_S	2	Funcționarea ferăstrăului mecanic în ralanti în pe sol
Turat	3	Funcționarea ferăstrăului mecanic în regim turat
Tăiere	4	Funcționarea ferăstrăului mecanic în regim turat pentru a realiza tăierea efectivă

Datele măsurate de accelerometru și utilizate pentru construirea bazei de date inițiale au fost prelucrate în prealabil, prin desfășurarea altor două etape. Într-o primă etapă, mărimea vectorului de acceleraţie a fost utilizată ca sursă de date primară din setul de date generat de accelerometru, deoarece normalizează datele colectate pe cele trei axe și, prin urmare, furnizează o măsură a mărimii care este independentă de orientarea senzorului în spațiul tridimensional. În consecință, s-a presupus că amplitudinea semnalului pe scară temporală va oferi o variație suficientă pentru a permite separarea evenimentelor, aspect pus în evidență de unele studii (e.g. Borz et al., 2018). Cu toate acestea, având în vedere succesiunea evenimentelor la intervale scurte de timp, precum și tranzițiile în amplitudinea datelor (**Figura 4**), a fost necesară filtrarea datelor inițiale pentru a le pregăti pentru o mai bună separare.




Figura 4. Exemplu de distribuție pe scară temporală a semnalului accelerației în conformitate cu Relația 5

Filtrarea datelor inițiale s-a realizat prin utilizarea unui filtru care a presupus calcularea valorilor mediane (**MF**) pe serii de date (kernel-uri) de 3 secunde ($MF_k = 3$). Alegerea acestui tip de filtru a fost legată de capacitatea sa de a păstra marginile reale ale semnalului (fără trunchiere sau teșire pe scara amplitudinii) la tranziții în domeniul amplitudinii (Leeb și Shaw, 1997), deci de a păstra durata reală a evenimentelor observate. Utilizarea acestui tip de filtru a fost, de asemenea, un compromis între păstrarea pattern-ului semnalului de accelerație pe scară temporală și îmbunătățirea raportului semnal-zgomot, primul încercând să păstreze vârfulurile care caracterizează evenimentul real (a se vedea, de exemplu, mărimea accelerației la eticheta temporală 660, **Figura 4**).

3.5.2.2. Configurarea rețelei neuronale artificiale

Configurarea rețelei neuronale artificiale (**ANN**) a fost realizată folosind programul software gratuit Orange Visual Programming (Demsar et al. 2013) și a presupus utilizarea funcției de activare *ReLU* (eng. *REctified Linear Unit*) deoarece aceasta poate rezolva probleme neliniare la performanțe înalte (Maas et al. 2013, Nair și Hinton 2010). S-a ales, de asemenea, algoritmul de optimizare *Adam* (denumirea este derivată din eng. *ADaptive Moment estimation*), descris de Kingma și Ba (2015) și care reprezintă o extensie a algoritmului *Stochastic Gradient Descent*. Algoritmul *Adam* este recunoscut datorită faptului că utilizează resurse computaționale mai mici pentru etapa de învățare (Kingma și Ba, 2015); termenul de regularizare utilizat a fost *L2*, a cărui valoare s-a stabilit la 0,0001. Apoi, tot setul de date a fost utilizat în scopul învățării urmând un protocol (denumit în continuare $P_f \times i \times n$) conceput pentru a varia numărul de segmente utilizate pentru validarea încrucișată ($f = 5, 10$ și, respectiv, 20), numărul de iterații ($i = 10, 100$ și, respectiv, 1000) și numărul de neuroni din stratul ascuns ($n = 5, 10, 15, 20, 25, 30, 50, 75$ și, respectiv, 100). Utilizând aceste setări, etapa de învățare a fost implementată pentru un număr de 81 ($3 \times 3 \times 9$) combinații, atât prin luarea în considerare a setului agregat de date conținut în **E (Total)**, cât și a fiecărui eveniment (clasă conținută) în **E** ($e = \text{Oprit, Ralanti_M, Ralanti_S, Turat}$ și, respectiv, **Tăiere**). Pentru fiecare $P_{f \times i \times n}$ și **E** s-a efectuat un set ($R_{AUC \times PREC \times REC}$) de 10 repetiții pentru etapa de învățare a **ANN** cu scopul de a stabili rezultatele obținute pentru indicatorii performanței de clasificare. Fiecare dintre repetițiile din **R** a luat în considerare calcularea indicatorilor **AUC**, **PREC** și **REC**. Pentru a obține datele necesare pentru comparare, mai departe s-au estimat valorile medii și abaterile standard pentru datele conținute în **R**. Merită precizat faptul că alegerea numărului de neuroni și de straturi ascunse reprezintă încă o

problemă dezbătută, deşi literatura de specialitate a furnizat unele metode în acest sens (e.g. Karsoliya, 2012, Panchal şi Panchal, 2014). De asemenea, semnificaţia, în sensul interpretării, pentru indicatorii performanţei clasificării precum **AUC**, **PREC** şi **REC** este redată, în detaliu, în Fawcett (2006) şi în alte surse bibliografice (e.g. Nasir et al. 2019).

3.5.2.3. Analiza datelor

Analiza şi compararea datelor s-a realizat prin utilizarea unor proceduri simple de raportare grafică a valorilor estimate pentru indicatorii performanţei de clasificare. O astfel de abordare este folosită în mod obişnuit pentru a evalua performanţa **ANN**-urilor şi multe studii au optat pentru această tehnică, atunci când au comparat performanţa algoritmilor şi metodelor de clasificare specifice inteligenţei artificiale (e.g. Keefe et al., 2019) sau cea legată de alte probleme relaţionate cu utilizarea **ANN** (e.g. Partel et al., 2019). Ca atare, valorile indicatorilor performanţei clasificării au fost calculate de **R** ori pentru fiecare **E**, rezultând un număr de 1.458 valori medii ce au caracterizat toate combinaţiile posibile din **P**. Utilizând aceste rezultate, s-a mers mai departe prin a presupune că valorile indicatorilor performanţei de clasificare (**AUC**, **PREC** şi **REC**) pot fi cumulate pentru fiecare P_{fixn} , caz în care valori apropiate de 5, ca urmare a cumulului valorilor pentru clasele (evenimentele) **Oprit**, **Ralanti_M**, **Ralanti_S**, **Turat** şi **Tăiere**, ar fi caracterizat cele mai bune rezultate. Datele agregate au fost tratate şi raportate separat, iar restul datelor care au caracterizat evenimentele menţionate au fost reprezentate grafic pentru fiecare P_{fixn} . Reprezentările grafice descrise au fost folosite pentru a pune în evidenţă efectul numărului de neuroni - **n** - asupra mărimii indicatorilor performanţei de clasificare specifici fiecărui subset $P_{f \times l}$.

3.5.3. Procesarea datelor şi dezvoltarea algoritmului privind studiul de caz SC3

Datele colectate cu dispozitivul **GPS** au fost descărcate într-un computer în format **.GPX**, apoi fişierul a fost încărcat în programul software BaseCamp®, o aplicaţie software gratuită, dezvoltată de Garmin®. Aceasta permite vizualizarea şi editarea datelor, precum şi extragerea parametrilor necesari în diferite tipuri de analize ce utilizează programe software externe. Locaţiile colectate prin procedee **GPS** pot fi preluate împreună cu parametrii de dinamică ai mişcării pentru a fi utilizate în programe software externe, cum ar fi Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010), ultimul permiţând programarea în Visual Basic for Applications®. Variabilele, cum ar fi numărul de puncte (variabilă de tip întreg) - **LI**, altitudinea (text) - **LE**, distanţa (text) - **LD**, viteza (text) - **LS**, poziţia - **LC** şi timpul - **LT** au fost copiate într-o foaie de calcul Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010) şi au servit drept bază de date iniţială. Apoi, s-au folosit funcţii simple scrise în Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010), pentru a extrage şi a converti datele de tip text în date de tip numeric, care au fost copiate într-o altă foaie. Nivelurile de presiune acustică (dB (A)) înregistrate de senzorii amplasaţi pe cărucior (**CSPL**) şi pe grupul motor (**ESPL**) au fost convertite în serii de date noi, prin extragerea a fiecărei a cincea valoare înregistrată din şirurile de date originale. Înainte de această etapă s-a utilizat programul software dedicat 407760®, pentru descărcarea datelor şi conversia acestora în fişiere Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010). Aceste noi şiruri de date au fost sincronizate cu datele **GPS** într-o foaie de calcul Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010). În aceeaşi foaie, s-a implementat o procedură de recalculare pentru variabilele **LD** şi **LS**, care a permis obţinerea unor date mai precise (precizie de o sutime), precum şi o procedură de calcul care a permis extragerea **LT** (5 secunde) şi a timpului cumulat (**CT**). Baza de date organizată în acest mod a servit drept intrare pentru procedurile de programare. Pentru a extrage informaţia necesară din datele colectate prin procedee **GPS** a fost implementat un set de proceduri de programare care au avut scopul de a delimita funcţiile tehnice legate de starea cinematică a căruciorului. În acest scop, s-a recurs la delimitarea a trei stări: mişcarea înspre amonte (**MU**), oprit (**S**) şi mişcarea înspre aval (**MD**). Sub raportul elementelor sau a fazelor dintr-un ciclu de muncă, pentru instalaţia cu cabluri studiată şi din

punct de vedere teoretic, mişcarea înspre amonte se poate suprapune cu cursa în gol, în timp ce se mişcarea înspre aval se poate suprapune cu cursa în plin. În practică însă, nu toate aceste mişcări corespund funcţiilor specifice operaţiilor de colectare a lemnului. De asemenea, starea oprit (**S**) poate să se extindă şi să se suprapună cu alte elemente privind consumul de timp cum ar fi întârzierile, adunatul lateral, inclusiv legarea, ridicarea, coborârea şi dezlegarea sarcinii. Chiar şi în aceste condiţii, comportamentul cinematic al căruciorului poate oferi informaţii utile privind consumul de timp şi productivitatea muncii (Gallo et al. 2013). Pe de altă parte, variabilele precum schimbările regimului de viteză, a poziţiei în plan orizontal şi a altitudinii, ca rezultat al deplasării sarcinilor, pot fi semnificativ influenţate de erorile **GPS**. Ca atare, este important să se dezvolte algoritmi de programare care să permită utilizarea unor praguri de delimitare şi a unor toleranţe, cel puţin pentru parametrii de poziţie.

În faza de programare s-a presupus că starea cinematică a căruciorului poate fi descrisă prin trei parametri: poziţia în plan orizontal (**LC**), viteza (**LS**) şi altitudinea (**LE**). O primă condiţie de programare a fost stabilită în ceea ce priveşte starea căruciorului raportată la altitudine. Algoritmul dezvoltat a presupus trei stări: creşterea, scăderea sau nicio modificare de stare a altitudinii corespunzătoare unei observaţii ($i + 1$), raportat la observaţia anterioară (i); în cazul în care algoritmul a identificat ultima stare, aceasta a fost utilizată pentru a ieşi din algoritm şi pentru a scrie datele cu privire la timpul curent şi la distanţă, în spaţiul alocat, pentru starea oprit (**S**). În cazul în care algoritmul a identificat o schimbare cu privire la altitudine, pasul următor a constat în evaluarea vitezei de mişcare, pe baza unui prag definit de utilizator (**ST**). Dacă această viteză depăşeşte pragul stabilit, atunci algoritmul se îndreaptă către următoarea etapă de evaluare, care ia în considerare poziţia pentru mişcarea în amonte (**LCu**) şi pentru mişcarea în aval (**LCd**), pe care le evaluează prin utilizarea unei toleranţe definite de utilizator (**DC**). Poziţiile definite de utilizator pot fi extrase fără dificultăţi din programul BaseCamp®. Din punctul de vedere al programării, această abordare ar putea fi potrivită şi atunci când se utilizează mai multe seturi de date (preluate din locaţii geografice diferite, care pot fi caracterizate prin poziţii generale diferite).

Pentru nivelurile de presiune acustică, s-a utilizat un prag stabilit la o singură valoare pentru a se face diferenţa între cele două stări cinematice: cărucior în mişcare şi, respectiv, cărucior oprit. În acest scop, s-au folosit doar datele extrase şi prelucrate de la senzorul plasat pe cărucior. Diferite echipamente forestiere sunt caracterizate de diferite niveluri de presiune acustică atunci când se află în stare de operare (Fonseca et al. 2015). Din păcate, la data efectuării acestui studiu nu s-a putut găsi nicio lucrare ştiinţifică care să descrie nivelul presiunii acustice emise de cărucioare aflate în mişcare. Cu toate acestea, comparând datele preluate de acest senzor cu datele preluate prin procedee **GPS** (altitudine şi viteză), s-a presupus ca situaţie probabilă, că un nivel al presiunii acustice mai mare de 85 dB(A) a corespuns mişcării efective a căruciorului.

După implementarea algoritmului descris anterior, informaţia extrasă din datele **GPS** a fost prezentată sugestiv, prin procedee grafice, pentru a descrie starea cinematică a căruciorului. Pentru comparare, aceeaşi abordare a fost utilizată pentru a diferenţia starea căruciorului prin includerea datelor cu privire la nivelul presiunii acustice.

3.5.4. Procesarea datelor privind studiul de caz **SC4**

Datele colectate prin studiul de timp au fost transferate din carnetul de teren într-o foaie de calcul Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010), împreună cu codurile atribuite pentru fiecare dintre sarcinile observate; apoi, a fost calculat consumul de timp pentru fiecare element de muncă şi observaţie în parte, prin efectuarea diferenţelor dintre valorile finale şi cele iniţiale preluate din teren, prin cronometrare continuă (Björheden et al., 1995). Datele descărcate din colectorul de date care a înregistrat nivelul presiunii acustice (dB (A)) şi cele descărcate din colectorul de date care a înregistrat ritmul cardiac (**HR**, bpm) au fost asociate (împerecheate) într-o foaie de calcul Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010), folosindu-se pentru

acest scop etichetele care au indicat timpul curent de înregistrare a fiecărei observații. După realizarea acestor pași, a fost atribuit câte un cod textual fiecărei observații, care să descrie sarcinile efectuate în anumite perioade de timp. Statisticile descriptive cu privire la variabilele operaționale, consumul de carburanți și de lubrifianți, precum și cele cu privire la consumul de timp, au fost calculate luând ca exemplu abordările specifice descrise în Acuna et al. (2012), precum și în alte studii similare (Borz și Ciobanu 2013, Jourgholami et al. 2013). Luând ca referință producția realizată (P , m^3) și consumul de timp productiv și neproductiv, s-au estimat mai departe atât eficiența (E_{NETA} , E_{BRUTA} , $h \times m^{-3}$), cât și productivitatea (P_{NETA} , P_{BRUTA} , $m^3 \times h^{-1}$) netă și cea brută, în conformitate cu procedurile de calcul și conceptele descrise de Acuna et al. (2012) și, respectiv, nomenclatorul privind estimarea productivității în operații forestiere (Björheden et al. 1995).

3.5.5. Procesarea datelor. Configurarea rețelei neuronale artificiale pentru studiul de caz SC5

3.5.5.1. Procesarea datelor

Procedurile utilizate pentru transferul, prelucrarea inițială și codificarea datelor în cazul SC5 au fost, în linii mari, similare celor expuse la subcapitolul 3.5.4. Diferențele specifice acestui studiu de caz au fost cele legate de elementele sau regimurile de funcționare delimitate și luate în studiu. Ca atare, durata totală luată în studiu a fost împărțită, sub raport conceptual, în două sub-seturi: durata în care s-a realizat tăierea efectivă prin folosirea ferăstrăului mecanic (**Tăiere**) și durata în care s-au realizat alte activități (**Altele**) urmărindu-se prin aceasta delimitarea timpului efectiv de tăiere. Pentru aceasta, datele cu privire la nivelul de presiune acustică au fost organizate și codificate de o manieră similară celor expuse la subcapitolul 3.6.4.

Tabelul 3. Descrierea semnalelor de intrare

Semnal	Abreviere	Număr de observații	Scop / Utilizare
Filtrat, inițial	<i>S_{INITIAL}</i>	67.050	Îndepărtarea impulsurilor, învățare preliminară
Filtrat, set pentru învățare	<i>S_{TRAIN}</i>	26.820	Îndepărtarea impulsurilor, set pentru învățare
Filtrat, set pentru testare	<i>S_{TEST}</i>	40.230	Îndepărtarea impulsurilor, set pentru testare

În conformitate cu datele folosite pentru documentare, precum și cu codurile textuale atribuite, clasa care a inclus evenimentul de **Tăiere** și datele specifice acestuia a inclus acele observații în care ferăstrăul a fost angajat efectiv în execuția tăieturilor în diverse scopuri. Clasa care a inclus evenimente precum **Altele** a acoperit acele observații în care s-au realizat alte activități precum deplasarea, pauza de masă, pauza de odihnă etc. Setul de date inițial a fost supus unor proceduri de filtrare similare celor descrise în subcapitolul 3.5.2.1.

3.5.5.2. Configurarea rețelei neuronale artificiale

Configurarea rețelei neuronale artificiale, atât pentru etapa de învățare, cât și pentru etapa de testare s-a realizat, în linii mari, după cele prezentate în subcapitolul 3.5.2.2. Diferențele principale dintre abordarea utilizată și cele prezentate în subcapitolul 3.5.2.2. au fost după cum urmează. Setul de date *S_{INITIAL}* a fost utilizat într-o etapă preliminară de învățare urmând un protocol (în continuare $P_{s \times i}$) conceput pentru a varia numărul de straturi ascunse de neuroni ($s = 1, 2$ și 3), și numărul de iterații ($i = 1000, 10000, 100000$ și, respectiv, 1000000), păstrând, în același timp, constant numărul de neuroni dintr-un strat ascuns dat ($n = 100$). A rezultat, în acest mod, un număr de 12 combinații utilizate în etapa de învățare (3×4), abordare care s-a implementat pentru a se estima parametrii apropiați de cei optimi, pentru implementarea în etapa de testare. Performanța învățării s-a apreciat prin indicatorul **REC** care, alături de ceilalți indicatori, a fost estimat pentru fiecare dintre cele 12 combinații. În urma evaluării s-a ales pentru etapele ulterioare $P_{2 \times 100000}$ (**REC** = 0,980). Pentru acest

mod de setare a parametrilor de configurare a **ANN** ($P_2 \times 100000$) s-a trecut, mai departe, la testarea influenţei mărimii setului de învăţare asupra performanţei învăţării. Pentru aceasta, setul de date a fost divizat în subseturi care au cuprins între 10 și 90% dintre datele inițiale, adoptându-se un pas de 10% pentru efectuarea acestor organizări de date. De exemplu, pentru un subset de date utilizat în etapa de învăţare, reprezentând 10% din setul inițial, restul de 90% au fost reținute pentru testare. Pentru 20%, 80% s-au folosit în testare și așa mai departe. În etapa de învăţare s-au estimat valorile indicatorilor performanţei clasificării și modelul cel mai bun, care a luat în considerare și mărimea subsetului de date utilizat la învăţare, acesta a fost salvat pentru utilizarea ulterioară, în faza de testare care a fost aplicată restului de date din setul inițial. Subsetul de date trecut prin etapa de testare a fost utilizat, în continuare, pentru a se identifica gradul în care anumite observații au fost clasificate greșit. Această etapă procedurală a presupus transferul de date din mediul Orange Visual Programming în programul Microsoft Excel®. În ultimul, s-a realizat o analiză detaliată, efectuată la nivel de clasă și la nivelul rezultatelor clasificării.

3.5.6. Procesarea datelor pentru studiul de caz SC6

În cazul operațiilor forestiere cum sunt cele de colectare și tocare a lemnului, nivelul de expunere la zgomot este influențat, printre alți factori, de regimul de funcționare a motorului, așa cum s-a dovedit prin numeroase studii (Poje et al. 2018, Poje et al. 2016, Poje et al. 2015). Procedurile utilizate pentru prelucrarea datelor și analiza expunerii la zgomot au fost cele descrise de legislația europeană (Directiva 2003/10/CE) și de standardele internaționale de evaluare a expunerii la zgomot. Acestea s-au folosit pentru a estima expunerea efectivă la zgomot în sarcinile date și la nivelul întregului studiu, precum și pentru a estima expunerea la zgomot pentru o zi nominală de 8 ore. Media ponderată cu durata nivelului de expunere la zgomot pentru o sarcină de muncă sau pentru o zi lucrătoare (**LAeq**, dB (A)), precum și media ponderată cu durata nivelului de expunere la zgomot într-o zi lucrătoare nominală de 8 ore (**L_{EX,8h}**, dB (A)), au fost calculate pentru sarcinile realizate cu ferăstrăul mecanic, în urma descărcării datelor și sistematizării acestora, pe elemente de muncă, zile lucrătoare și pe întreaga perioadă a studiului. Aceasta a necesitat utilizarea unor funcții logice simple, implementate în Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010), care au sincronizat valorile înregistrate și calculate pe sarcini, folosind în acest scop codurile atribuite.

Efortul fizic al operatorului în timpul operațiilor de doborâre și fasonare a arborilor cu ferăstrăul mecanic a fost evaluat prin luarea în considerare a sarcinilor de muncă constatate în studiu și prin estimarea unor indicatori furnizați de literatura științifică precum rata creșterii ritmului cardio-vascular (**%HRI**) și rezerva de ritm cardio-vascular (**%HRR**) (e.g. Silayo et al. 2010, Rodahl 1989). Ritmul cardio-vascular este un indicator uzual, folosit în descrierea dificultății activității desfășurate, în special în acele medii de lucru în care utilizarea instrumentelor ergonomice mai precise și mai sofisticate este dificilă. Prin urmare, a fost utilizat în numeroase studii legate de exploatarea lemnului (Kirk și Sullman 2001, Magagnotti și Spinelli 2012, Ottaviani et al. 2010, Silayo et al. 2010, Spinelli et al. 2014, Stampfer et al. 2010, Toupin et al. 2007) și reprezintă un bun estimator al indicatorului **VO₂** (volumului de oxigen consumat) în operațiile forestiere (Dubé et al. 2016), care este utilizat în mod obișnuit, pentru a estima intensitatea muncii în studiile ergonomice generale.

Metoda **OWAS** (sistemul de analiză a posturilor de lucru Ovako) poate fi folosită pentru evaluarea riscului de dezvoltare a unor afecțiuni ale sistemelor muscular și osos (Corella-Justavino et al. 2015). Inițial, **OWAS** a fost dezvoltată pentru a fi utilizată în industria oțelului și se bazează pe prelevarea de observații la intervale de timp variabile sau constante; prin această abordare se poate descrie frecvența posturilor adoptate într-o perioadă de timp (Karhu et al. 1977). Metoda a fost concepută pentru a evalua posturile segmentelor principale ale corpului prin atribuirea unui cod fiecăreia dintre acestea (pentru spate, brațe, picioare și, suplimentar, nivelul de exercitare a forței); această abordare conduce la un cod format din patru cifre care, ulterior, clasifică postura generală a corpului și ajută, în continuare, la evaluarea disconfortului muncii observate, precum și la implementarea unor măsuri corective, descrise de patru categorii de acțiune (**AC**). Având în vedere o variabilitate

potențială ridicată a posturilor înregistrate în diferite **AC**, evaluarea generală a unui loc de muncă dat se bazează pe un indice de risc postural (**PRI**), care este calculat ca o frecvență ponderată a **AC**, în care factorii de ponderare (f_i) sunt frecvențele scorurilor atribuite unui **AC** (Calvo 2009, Spinelli et al. 2018, Spinelli et al. 2016, Zanuttini et al. 2005). În timp ce **OWAS** nu poate măsura unii parametri precum frecvența și durata mișcării, recuperarea fiziologică (David 2005) și nici nu face distincție între munca statică și cea dinamică (Corella Justavino et al. 2015, David 2005), prezintă, totuși, mai multe avantaje, cum ar fi simplitatea în utilizare (Karhu et al. 1977), acoperirea prin evaluare a întregului corp, fiabilitatea și comparabilitatea rezultatelor (Spinelli et al. 2016). Din punct de vedere metodologic, fișierele video înregistrate au fost divizate în cadre componente, care au fost extrase ca imagini statice la o rată de eșantionare de o secundă, obținându-se în acest fel un număr de 8059 de cadre. Apoi, fiecare cadru a fost analizat pentru a fi clasificat într-o anumită **AC**. Numai acele cadre în care toate segmentele corpului au fost vizibile și, prin urmare, analizabile, au fost păstrate ca valide, aspect care a condus la un număr de 6329 de cadre analizate. Pentru fiecare cadru, sarcinile realizate de muncitorul cu ferăstrăul mecanic, au fost codificate prin șiruri scurte și descriptive de text. De asemenea, fiecare cadru a fost utilizat pentru a codifica postura spatelui, brațelor, picioarelor și pentru a se evalua nivelul de exercitare a forței. Datele analizate s-au inclus într-o foaie Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010), unde s-au folosit proceduri simple de programare în Visual Basic for Applications® pentru calculul automat al codului postural general și pentru încadrarea pe categorii de acțiune (**AC**). Apoi, categoriile de acțiune au fost sortate pe sarcini de muncă, iar frecvențele scorurilor pentru fiecare categorie de acțiune au fost calculate, urmând ca indicele de risc postural să fie calculat pentru fiecare sarcină de muncă și pentru întregul studiu.

3.5.7. Procesarea datelor pentru studiul de caz **SC7**

Datele înregistrate de camera video și cele preluate de senzorul pentru nivelul de presiune acustică au fost descărcate într-un computer. Datele video au fost descărcate din memoria internă a camerei video prin metode obișnuite și au fost stocate într-un folder ce a conținut fișierele colectate în succesiunea lor obișnuită. Datele stocate în memoria internă a collectorului de date au fost descărcate prin intermediul programului software dedicat. La o primă vedere, un astfel de program software poate ajuta cercetătorii să facă distincția între anumite tipare și să observe dinamica funcțională a echipamentului studiat în funcție de nivelul presiunii acustice; cu toate acestea, abordarea nu permite niciun fel de segmentare pe categorii a datelor cuprinse în baza de date. Pentru separarea regimurilor de funcționare specifice, datele au fost exportate în fișiere Microsoft Excel®, cu ajutorul programului software dedicat al collectorului de date. Pentru asocierea datelor video cu datele colectate de senzorul de măsurare a nivelului de presiune acustică s-a utilizat un program software de editare video disponibil gratuit pentru a se dezmembra fișierele video în cadre extrase la un interval de 0,5 secunde. Ulterior, a fost creată o bază de date în Microsoft Excel® (Microsoft Corporation, Redmond, SUA, 2010), care a fost concepută să stocheze informațiile colectate prin cele două abordări. Cadrele extrase în acest fel au fost ulterior sincronizate și analizate cu atenție pentru a se observa regimul de funcționare al echipamentului. Această metodă a fost utilă pentru a se delimita și extrage consumul de timp pentru tăierea efectivă (**S**) și consumul de timp pentru retragerea ferăstrăului din tăietură (**R**), acestea fiind grupate sub forma timpului de funcționare (**O**). Totodată, au fost observate pe imagini timpul de funcționare fără tăiere efectivă (**RUN**) și timpul în care ferăstrăul a fost oprit (**STOP**). Datele furnizate de senzor au fost codificate în urma analizei imaginilor. În continuare, baza de date obținută a fost utilizată pentru analiză, ultima presupunând calcule și separarea timpului, bazate pe praguri liniare predefinite. După o analiză atentă a datelor, a fost luată în considerare o valoare, prag pentru separarea regimurilor de funcționare și a timpului în care ferăstrăul a fost oprit. Valoarea pragului a fost setată la 86,5 dB (A). Acest lucru a fost specific designului experimental utilizat în acest studiu, știind că nivelul presiunii acustice este atenuat în funcție de distanța față de sursa de emisie a sunetului. De asemenea, nu este recomandabil să se amplaseze astfel de senzori la distanțe mari de sursa de emisie, deoarece

sunetul/zgomotul emis de alte echipamente sau activități pot interfera cu cel al echipamentului studiat. Regimurile de tăiere și de retragere a ferăstrăului din tăieturi au fost destul de dificil de separat. Acest lucru poate fi legat de dimensiunea pieselor de lemn tăiate, deoarece timpul consumat în astfel de evenimente și zgomotul emis depind de astfel de caracteristici. Prin urmare, a fost normal ca pentru piesele cu dimensiuni mari să se obțină valori ridicate ale nivelului presiunii acustice, iar pentru piesele cu dimensiuni mici acestea să scadă. Cunoscând aceste aspecte, prin studiu s-a presupus o capacitate mai scăzută de identificare a anumitor evenimente și s-a utilizat un prag liniar capabil de a recunoaște evenimentele de tăiere specifice pieselor cu dimensiuni mai mari. Pentru separare, pragul a fost configurat la 110 dB (A), permițând detectarea unei singure valori pentru fiecare dintre piesele tăiate. Pentru demonstrație, s-a luat un interval de timp de 10 minute în care s-a constatat cea mai mare variabilitate a parametrilor studiați și s-a efectuat analiza, folosind pragurile menționate pe acea porțiune din setul de date.

3.5.8. Procesarea datelor pentru studiul de caz SC8. Configurarea rețelei neuronale artificiale

3.5.8.1. Procesarea datelor

Datele colectate de accelerometre și de senzorii de nivel de presiune acustică au fost organizate într-o foaie de calcul Microsoft Excel®, iar fișierele video au fost folosite pentru a le documenta, luând în considerare trei tipuri de evenimente specifice care au fost denumite în raport cu regimul de funcționare-operare: tăiere, mișcare și pauză. Pentru aceasta, șirurile de date au fost analizate împreună cu fișierele video redade la viteză mică și fiecare observație a primit un cod (**C** - tăiere, **M** - mișcare sau **P** - pauză) în funcție de evenimentul la care a fost identificat că aparține, pe baza analizei video. Ca atare, tăierea a acoperit acele observații în care motorul utilajului a fost identificat ca pornit și pânda a fost angajată în tăiere activă, mișcările au corespuns tuturor evenimentelor care au presupus deplasarea sau mișcarea cadrului de tăiere ce încorporează volanții (mișcare înspre înainte, înspre înapoi și ajustarea sus-jos pe verticală), fără a avea motorul pornit, în timp ce pauzele au constat în acele evenimente în care nu s-a observat intenția de a acționa mașina, dar totuși, muncitorul supus observației s-a aflat în apropierea acesteia. Din moment ce setul de date a conținut și alte tipuri de evenimente, care nu au făcut scopul delimitării necesare, unele părți ale setului inițial de date au fost eliminate pentru a acoperi doar acele evenimente relaționate cu monitorizarea modului de utilizare a ferăstrăului panglică. **Tabelul 4** prezintă semnalele utilizate precum și scopul și utilitatea lor în cadrul acestui studiu. Pentru semnalul colectat de senzorul de accelerație, abordarea metodologică a presupus o normalizare a semnalului prin utilizarea sumei vectorilor de accelerație care a avut ca scop creșterea independenței semnalului față de orientarea accelerometrului în spațiul tridimensional.

Tabelul 4. Descrierea seturilor de date și a scopului/modului de utilizare a acestora

Semnale	Abreviere	Număr de observații	Scop / Utilizare
Inițial A	A_{INI}	90.405	Baza de date inițială a studiului
Inițial S	S_{INI}	90.405	Baza de date inițială a studiului
Inițial A&S	AS_{INI}	90.405	Baza de date inițială a studiului
Final A	A_{REF}	78.189	Evenimente strict legate de ferăstrăul panglică
Final S	S_{REF}	78.189	Evenimente strict legate de ferăstrăul panglică
Final A&S	AS_{REF}	78.189	Evenimente strict legate de ferăstrăul panglică
Filtrat, pentru învățare A	AM_{TRAIN}	20.050	Îndepărtarea impulsurilor, set pentru învățare
Filtrat, pentru învățare S	SM_{TRAIN}	20.050	Îndepărtarea impulsurilor, set pentru învățare
Filtrat, pentru învățare A&S	ASM_{TRAIN}	20.050	Îndepărtarea impulsurilor, set pentru învățare
Filtrat, pentru testare A	AM_{TEST}	58.139	Îndepărtarea impulsurilor, set pentru testare
Filtrat, pentru testare S	SM_{TEST}	58.139	Îndepărtarea impulsurilor, set pentru testare
Filtrat, pentru testare A&S	ASM_{TEST}	58.139	Îndepărtarea impulsurilor, set pentru testare

Ca atare, s-au utilizat mărimile vectoriale (măsurate în g) ca semnale de intrare în locul semnalelor preluate pe axe, o procedură care este ușoară, deoarece accelerometrul produce și acest tip de semnal derivat. În cazul datelor privind nivelul de presiune acustică (dB (A)), pentru a se facilita comparația grafică, s-a ales divizarea semnalului preluat cu un factor de 10 pentru a-l aduce într-un domeniu de variație apropiat celui specific semnalului de accelerație. Se precizează aici faptul că această transformare aleasă arbitrar nu a modificat pattern-ul semnalului inițial al nivelului de presiune acustică. Prin urmare, s-a presupus că această transformare nu a modificat nici rezultatele algoritmilor utilizați pentru fazele de învățare și de testare. După înlăturarea acelor observații care au fost legate de alte evenimente decât cele luate în studiu, în total și indiferent de semnal, s-a păstrat un număr de 78.189 observații, dintre care 20.050 au fost utilizate pentru etapa de învățare și 58.139 au fost utilizate pentru etapa de testare a rețelei neuronale artificiale (**ANN**). Înainte de a face acest lucru, însă, au fost aplicate proceduri de filtrare similare celor expuse la subcapitolul 3.5.2.1., pentru a elimina zgomotul generat de impulsuri în semnal, precum și zgomotul generat de unele erori de colectare a datelor. Alegerea și aplicarea unui filtru prin calcularea valorilor mediane pe domenii succesive a câte trei observații, s-a datorat capacității sale de a păstra netrunchiate marginile semnalului pe scară temporală (e.g. Leeb și Shaw 1997, Neal și Gary 1981).

3.5.8.2. Configurarea rețelei neuronale artificiale

Seturile de date caracterizând semnalele **AMTRAIN**, **SMTRAIN** și **ASMTRAIN** au fost folosite pentru a instrui modelul **ANN** și pentru a estima indicatorii de performanță necesari pentru a aprecia care dintre semnale este cel mai bun pentru acest demers. Indicatorii de performanță utilizați pentru a evalua capacitatea semnalelor de a instrui **ANN**, precum și pentru a evalua performanța modelului dezvoltat de **ANN** pe semnalele de testare, sunt cei descriși, în mod obișnuit, în studii similare (Fawcett 2006, Kamilaris și Prenafeta-Boldu 2018), din care aria de sub curbă (**AUC**), acuratețea clasificării (**CA**), precizia clasificării (**PREC**) și rechemarea (**REC**) au fost luați în considerare și utilizați în acest studiu ca referință. Înainte de etapele de instruire și de testare, **ANN** a fost configurată pentru a încorpora trei straturi ascunse a câte 100 de neuroni fiecare și pentru a rula 1.000.000 de iterații pentru fiecare set de date, caracterizând un semnal dat. Având în vedere mențiunile cu privire la numărul de straturi ascunse, precum și cu privire la numărul de neuroni ce se utilizează în configurarea **ANN**, abordarea descrisă cu privire la configurare a fost, mai degrabă, o presupunere acoperitoare care a încercat să maximizeze performanța **ANN** în etapa de învățare, în detrimentul resurselor de calcul necesare, motiv pentru care, în această fază, timpul necesar pentru instruirea **ANN** a fost contorizat pentru fiecare semnal în parte. Ca atare, și după cum s-a mai menționat, alegerea numărului de straturi ascunse și a numărului de neuroni este privită, mai degrabă, ca o artă decât o știință. Chiar dacă există câteva metode descrise în literatura de specialitate disponibilă, care propun criterii pentru alegerea numărului de neuroni și de straturi ascunse (Karsoliya 2012, Panchal și Panchal 2014), după cunoștințele proprii, problema nu este încă rezolvată pentru a oferi cele mai bune practici pentru cazuri date, inclusiv cele descrise în această lucrare. Etapa de învățare s-a făcut prin validare încrucișată, care a presupus o abordare stratificată și un număr de segmente de date stabilit la 20. Pe baza rezultatelor cu privire la datele rezultate din etapa de testare, analiza s-a desfășurat mai detaliat, pentru a vedea care dintre evenimente și în ce măsură au fost clasificate corect, precum și pentru a vedea care dintre ele au fost clasificate greșit, ca alte evenimente. Această etapă a presupus transferarea rezultatelor etapei de testare în Microsoft Excel®, urmată de o analiză detaliată. Deoarece semnalele finale au fost utilizate atât la învățare, cât și la testare, în scopul identificării gradului de echilibrare a datelor pe tipuri de semnale utilizate, a fost realizată o analiză pentru a se pune în evidență proporția claselor în seturile analizate, atât pentru etapa de învățare, cât și pentru cea de testare. Toate analizele suplimentare descrise mai sus, indicatorii statistici de bază ai semnalelor utilizate în învățare și testare, precum și prelucrările grafice prezentate, în acest sens, în capitolul de rezultate, au fost realizate sau elaborate în programul software Microsoft Excel®.

CAPITOLUL 4. REZULTATE ŞI DISCUŢII

4.1. Rezultate privind studiul de caz SC1

4.1.1. Aspecte generale

În **Figura 5** se redă un exemplu concret cu privire la semnalele extrase din colectori de date cu privire la acceleraţie şi la nivelul de presiune acustică, alături de o reprezentare a evenimentelor specifice urmărite, identificate pe scară temporală şi separate prin utilizarea unor praguri liniare.




Figura 5. Exemplu de separare a regimurilor operaționale folosind praguri

Legendă: negru - detectarea evenimentelor; roșu - nivelul presiunii acustice (dB (A)); verde - accelerația (g).

După cum se indică în **Figura 5**, se poate diferenția consumul de timp specific mersului în gol, precum și cel specific funcționării în diferite regimuri de turație, prin utilizarea ambelor tipuri de senzori. Totodată, **Figura 5** indică și o concordanță evidentă între cele două semnale, dacă se iau în considerare variațiile în domeniul amplitudinii. Atât pentru știință cât și pentru practică, acest fenomen are implicații importante, deoarece se pot realiza diferențieri între două regimuri specifice: funcționarea motorului în gol și, respectiv, realizarea tăieturilor specifice diferitelor operații ce utilizează ferăstraie mecanice. Se poate rezolva, astfel, atât problema legată de detectarea și separarea duratelor în care ferăstraiele au motorul pornit precum și problema legată de utilizarea efectivă a acestora în realizarea de tăieturi. Mai mult, sistemul descris are un potențial mare de a fi cuplat cu alte sisteme sau colectori de date, cum ar fi sistemul **GPS**, fapt care, în cazul unei precizii mai mari a ultimului, ar putea permite diferențierea între operațiile de doborâre și cele de fasonare a arborilor. De asemenea, este important de menționat faptul că precizia de colectare a datelor se poate îmbunătăți substanțial prin utilizarea unor astfel de senzori în locul abordărilor tradiționale. Ca atare, în colectarea datelor pentru acest studiu de caz s-a utilizat o rată de eșantionare de 0 secundă; pentru creșterea preciziei colectării datelor rata de eșantionare poate fi modificată, prin setările specifice, la mai puțin de o secundă (Cheța et al. 2017).

4.1.2. Setarea pragurilor de separare și performanța clasificării

Colectarea și clasificarea automată a datelor cu privire la consumul de timp este importantă în încercarea de a monitoriza dinamica operațională a ferăstriailor mecanice utilizate în operațiile de doborâre și de fasonare (curățire de crăci, secționare) a arborilor. Cu toate acestea, abordarea

utilizată în acest studiu de caz, care a constat din stabilirea unor praguri liniare artificiale, nu a fost capabilă să identifice și să delimiteze cu o precizie acceptabilă numărul de evenimente observate. Se precizează faptul că pentru realizarea separării stărilor de funcționare în ralanti, semi-turat și turat, care corespund atât perioadelor și funcțiilor de tăiere, cât și celor care nu au presupus tăierea, s-au utilizat praguri stabilite arbitrar la 102 dB (A) pentru semnalul colectat de senzorul de nivel al presiunii acustice și la 11 g pentru semnalul colectat de senzorul de accelerație. Utilizarea acestor praguri a permis o recunoaștere de aproape 100%, pentru cele două evenimente (regimuri de funcționare) luate în studiu, așa cum se arată în **Tabelul 5**. Diferențele în ceea ce privește precizia la care au fost identificate și separate regimul de funcționare de cel de nefuncționare a motorului sunt, probabil, efectele comutării între aceste două stări, și pentru care nu s-a putut detecta consumul de timp pe baza pragurilor descrise. S-a constatat, de asemenea, că utilizarea acestor praguri nu a generat rezultate precise în identificarea unor evenimente urmărite precum realizarea de tăieturi orizontale, tăieturi înclinate și de tăieturi verticale (**Tabelul 5**).

Tabelul 5. Identificarea și separarea evenimentelor și a consumului de timp în anumite regimuri de funcționare pe baza semnalelor colectate și a pragurilor utilizate

Parametru [variabilă]	Situația reală redată de înregistrarea video	Clasificarea pe baza semnalelor și a algoritmului de separare	Diferențe procentuale între seturile de date (%)
Numărul de elemente executate	12	6	-50
Timpul de tăiere (s)	327	341	+4,28
Timpul de mers în gol (s)	665	646	-2,86

Pe de altă parte, precizia mai scăzută, legată de identificarea și separarea unor evenimente, poate fi și rezultatul unui design mai slab al experimentului, deoarece în acest studiu de caz, tăieturile au fost realizate una după alta, la intervale foarte scurte de timp. Cu toate acestea, în operațiile reale, astfel de situații sunt mai puțin probabile, fiindcă există întotdeauna un interval de timp suficient de mare între ele, indiferent de operațiile efectuate. Pentru obținerea unor performanțe mai ridicate cu privire la identificarea și clasificarea evenimentelor urmărite, datele colectate pentru acest studiu de caz au fost utilizate în **SC2** pentru evaluarea performanței de clasificare prin tehnici specifice rețelelor neuronale artificiale (**ANN**).

4.2. Rezultate privind studiul de caz SC2

4.2.1. Indicatori de performanță

4.2.1.1. Aria de sub curbă

Ca indicator al performanței clasificării unui algoritm, aria sub curbă (**AUC**) deține o proprietate statistică importantă: mărimea lui este echivalentă cu probabilitatea ca un algoritm de clasificare - **ANN** în acest studiu de caz - să clasifice o instanță pozitivă aleasă la întâmplare mai bine decât o instanță negativă aleasă aleatoriu (Fawcett, 2006). În general, cu cât indicatorul **AUC** este mai mare, cu atât performanțele unui algoritm de clasificare sunt mai bune. **Figura 6** prezintă rezultatele cu privire la indicatorul **AUC** cumulat pentru fiecare $P_{f \times i \times n}$ luat în studiu. Se menționează faptul că valorile apropiate de 5 au fost considerate a fi cele care caracterizează cea mai bună performanță a **ANN**. Din analiza **Figurii 6**, se desprind două aspecte. Primul se referă la faptul că numărul de iterații (i) a avut o influență ridicată asupra mărimii indicatorului **AUC**. Ca atare, acele $P_{f \times i \times n}$ care au fost construite folosind un număr de $i = 1000$ de iterații au produs, în general, cele mai bune rezultate pentru acest indicator al performanței de clasificare. Cu toate acestea, unele cazuri care au folosit un număr de iterații $i = 1000$ nu au reușit să ofere performanțe bune (**Figura 6**), fapt care este posibil să fi fost asociat cu numărul de segmente utilizate pentru validarea încrucișată (f). Este de menționat faptul că setul de date din care a fost instruită rețeaua neuronală artificială a acoperit o lungime de

993 de secunde, prin urmare, se pare că unele evenimente au fost prea scurte pentru a îmbunătăți instruirea **ANN** sau au fost distribuite într-un mod prea particularizat în segmentele folosite pentru validarea încrucișată, conducând în acest fel la performanțe mai reduse. S-a constatat această proprietate pentru situațiile în care $f = 10$ și $f = 20$, precum și faptul că pe măsură ce numărul neuronilor din stratul ascuns (n) a crescut, doar situațiile în care $f = 20$ au mai păstrat această performanță scăzută. Așadar, se poate presupune că pentru o mai bună performanță a clasificării, numărul de segmente de date folosite pentru validarea încrucișată ar trebui să fie gestionat în funcție de cantitatea și calitatea datelor de intrare, precum și faptul că o creștere a numărului de neuroni poate echilibra într-o oarecare măsură pierderile în performanța clasificării generate de numărul de segmente utilizate. Pentru $i = 1000$ și $f < 20$, se pare că numărul minim de neuroni necesari pentru a produce rezultate bune a fost, în general, $n \geq 15$. Pentru un număr mai mic de neuroni utilizat pentru a configura **ANN**, evenimentul **Oprit** a fost caracterizat de valori foarte mici sau chiar nule pentru **AUC**. Pentru astfel de situații, s-a constatat că indicatorul **AUC** al setului general de date a avut valoarea minimă de 0,625 ($P_{5 \times 10 \times 5}$), în timp ce valoarea sa maximă a fost de 0,998.




Figura 6. AUC cumulat pentru protocolul utilizat pentru instruirea **ANN**.

Legendă: roșu - **Oprit**, portocaliu - **Ralanti_M**, galben - **Ralanti_S**, verde deschis - **Turat**, verde închis - **Tăiere**

Figurile 7 - 15 indică influenţa numărului de neuroni (n) asupra valorii indicatorului AUC pentru $i = 10, 100, 1000$, având în vedere, de asemenea, numărul de segmente de date utilizate pentru validarea încrucişată.




Figura 7. Variaţia mărimii indicatorului AUC pentru $P_{5 \times 10 \times n}$

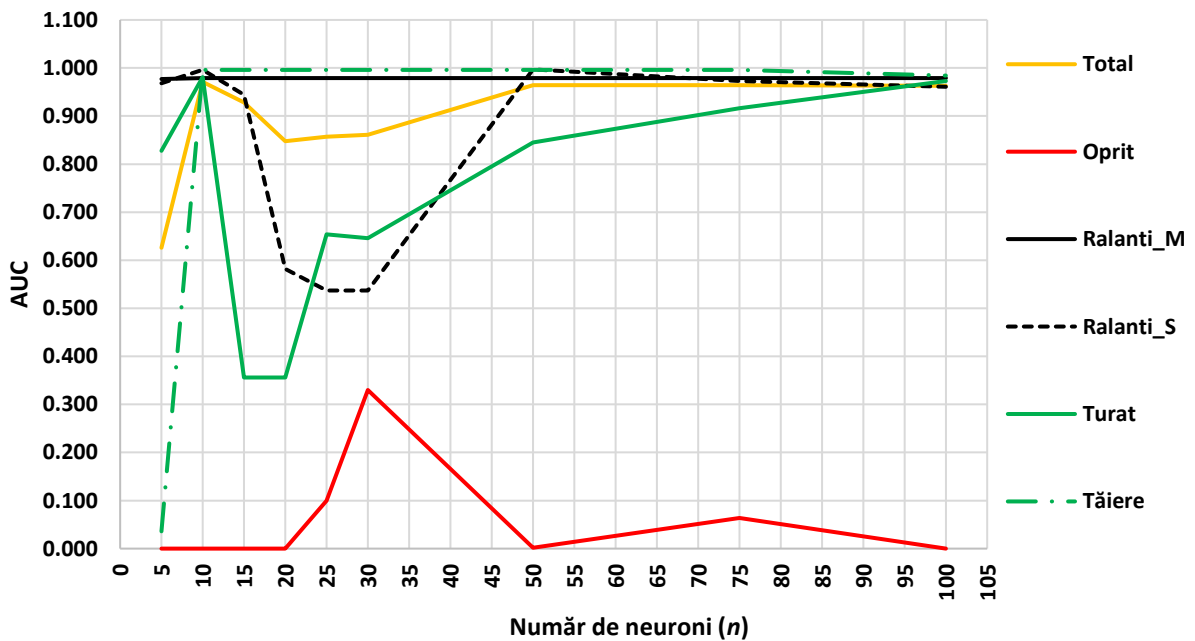


Figura 8. Variaţia mărimii indicatorului AUC pentru $P_{10 \times 10 \times n}$




Figura 9. Variația mărimii indicatorului AUC pentru $P_{20 \times 10 \times n}$

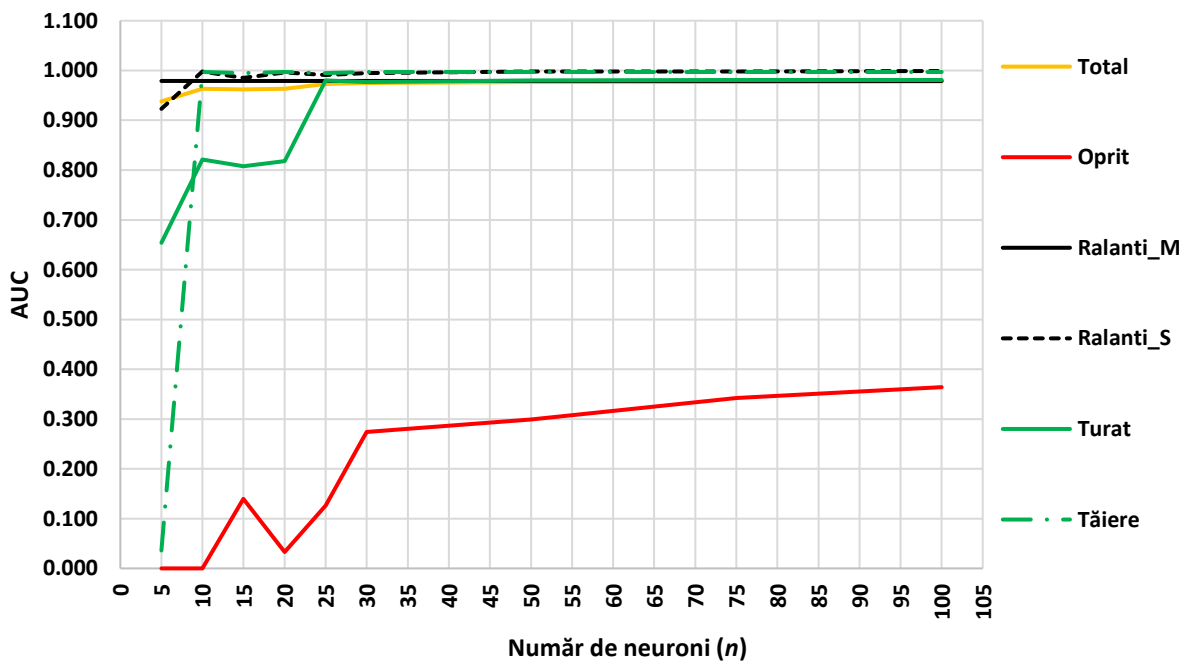


Figura 10. Variația mărimii indicatorului AUC pentru $P_{5 \times 100 \times n}$




Figura 11. Variația mărimii indicatorului AUC pentru $P_{10 \times 100 \times n}$




Figura 12. Variația mărimii indicatorului AUC pentru $P_{20 \times 100 \times n}$




Figura 13. Variația mărimii indicatorului AUC pentru $P_{5 \times 1000 \times n}$




Figura 14. Variația mărimii indicatorului AUC pentru $P_{10 \times 1000 \times n}$




Figura 15. Variația mărimii indicatorului AUC pentru $P_{20 \times 100 \times n}$

După cum se prezintă în **Figurile 7-15**, prin creșterea numărului de neuroni și prin scăderea numărului de segmente de date, utilizate pentru validarea încrucișată, se poate contribui la îmbunătățirea indicatorului AUC . De fapt, unele dintre cele mai bune rezultate au fost asociate cu $f = 5$ și cu un număr de neuroni $n > 30$, valoare de la care, indicatorul AUC specific evenimentului **Turat** a început să se stabilizeze (**Figura 23**). În cazul acestuia, performanțele bune ale indicatorului AUC se pot obține și prin utilizarea unui număr mai mic de neuroni dar, totuși, dacă $f = 10$, rezultatele sugerează că pentru $n \geq 10$, performanța indicatorului AUC a fost mai stabilă pentru toate evenimentele luate în studiu (**Figura 14**). În comparație, pentru $f = 20$, AUC pentru evenimentul **Oprit** a fost evaluat la 0 (**Figura 15**).

4.2.1.2. Precizia clasificării

Ca indicator al performanței clasificării, precizia (**PREC**) reprezintă raportul dintre numărul instanțelor identificate de un algoritm de clasificare ca fiind adevărate pozitive și numărul total de instanțe clasificate ca pozitive (Fawcett, 2006). În cazul unor aplicații cu mai multe clase, cum este și cea din acest studiu de caz, precizia este calculată ca medie pe clase (Kamilaris și Prenafeta-Boldu, 2018; Nasir et al., 2019). Luând în considerare acest indicator al performanței clasificării, **Figura 16** prezintă rezultatele la nivelul $P_{f \times i \times n}$ pentru aceleași evenimente care au fost descrise și în cazul indicatorului AUC . După cum se observă, numărul de iterații a avut influența cea mai mare asupra mărimii indicatorului **PREC**. În cazurile în care $i < 1000$, rezultatele au fost mai slabe din acest punct de vedere, iar pentru unele clase precizia clasificării a fost nulă. De asemenea, se poate observa (**Figura 16**, partea dreaptă) că, atunci când numărul de iterații (i) a fost setat la 1000, precizia clasificării a fost influențată, deși într-o măsură mai mică, și de către numărul de segmente folosite pentru validarea încrucișată. În general, în măsura în care numărul de neuroni folosiți pentru etapa de învățare a **ANN** a crescut, numărul de segmente stabilit la 5 ($f = 5$) a condus la valorile cele mai ridicate ale preciziei clasificării. Pentru un număr mai mic de iterații ($i = 100$) evenimentele **Turat** și **Oprit** au indicat valori nule ale **PREC**, indiferent de numărul de neuroni, iar valorile cele mai mici ale acestui indicator s-au înregistrat în cazurile în care numărul de neuroni a fost mai mic de 10. S-a constatat, de asemenea, că valori ale lui n mai mici de 10 au condus la valori mai mici ale **PREC** chiar

și în cazul în care numărul de iterații a fost de 1000. Ca atare, pentru setul de date utilizat, valori ridicate ale preciziei clasificării se pot obține pentru un număr de neuroni mai mare de 10, adoptarea unui număr mic de segmente pentru validarea încrucișată și prin adoptarea unui număr de cel puțin 1000 de iterații. În ceea ce privește numărul de iterații, studii de specialitate au indicat că acesta ar trebui să fie cât mai mare, cu condiția ca resursele computaționale necesare să fie disponibile; unele studii au folosit un număr de iterații setat la 1.000.000 (e.g. Proto et al., 2020) pentru etapa de învățare a **ANN**. Se menționează însă, că în măsura în care numărul de iterații crește, resursele necesare pentru calcul vor fi mai mari, aspect care s-a constatat și în simulările care s-au realizat în acest studiu de caz.




Figura 16. *PREC cumulat pentru protocolul utilizat pentru etapa de învățare a ANN*
Legendă: roșu - Oprit, portocaliu - Ralanti_M, galben - Ralanti_S, verde deschis - Turat, verde închis - Tăiere

În **Figurile 17 - 25** se prezintă influenţa numărului de neuroni n asupra indicatorului $PREC$ pentru un număr de iteraţii $i = 10, 100, 1000$. De asemenea, reprezentările grafice prezentate au avut în vedere numărul de segmente de date utilizate pentru validarea încrucişată.




Figura 17. Variaţia mărimii indicatorului $PREC$ pentru $P_{5 \times 10 \times n}$




Figura 18. Variaţia mărimii indicatorului $PREC$ pentru $P_{10 \times 10 \times n}$




Figura 19. Variația mărimii indicatorului $PREC$ pentru $P_{20 \times 10 \times n}$




Figura 20. Variația mărimii indicatorului $PREC$ pentru $P_{5 \times 100 \times n}$




Figura 21. Variația mărimii indicatorului $PREC$ pentru $P_{10 \times 100 \times n}$




Figura 22. Variația mărimii indicatorului $PREC$ pentru $P_{20 \times 100 \times n}$




Figura 23. Variația mărimii indicatorului $PREC$ pentru $P_{5 \times 1000 \times n}$

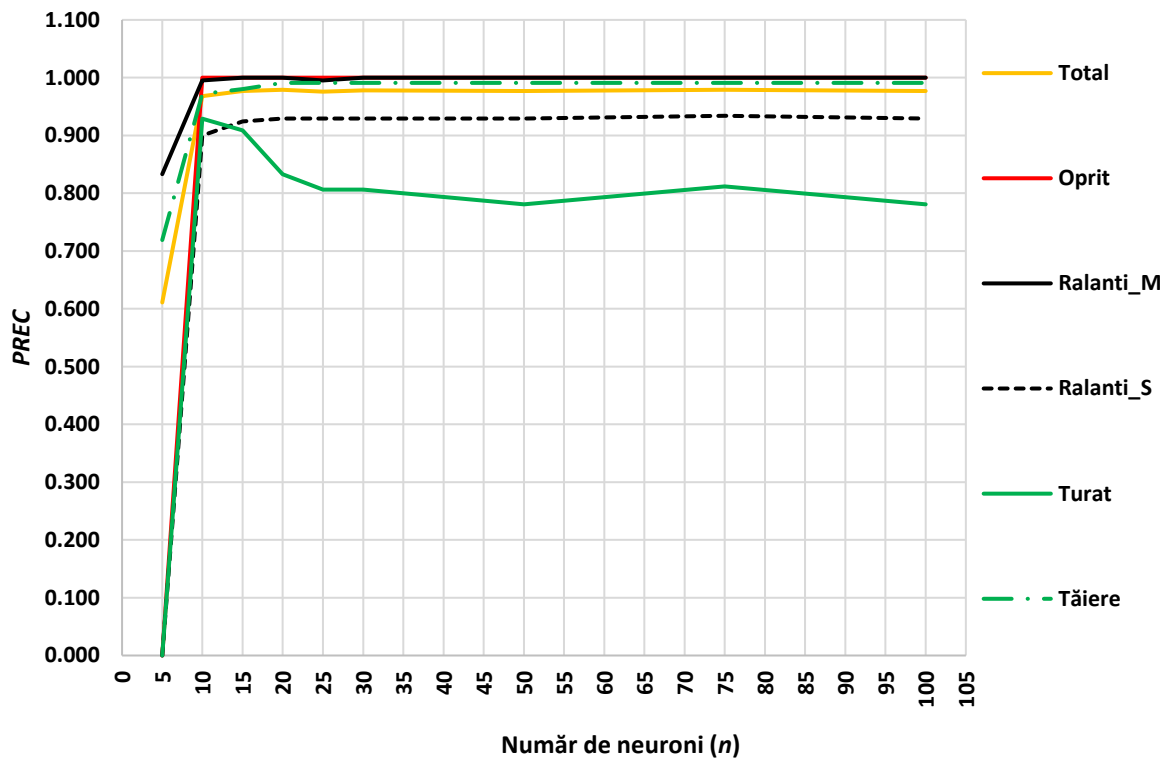


Figura 24. Variația mărimii indicatorului $PREC$ pentru $P_{10 \times 1000 \times n}$

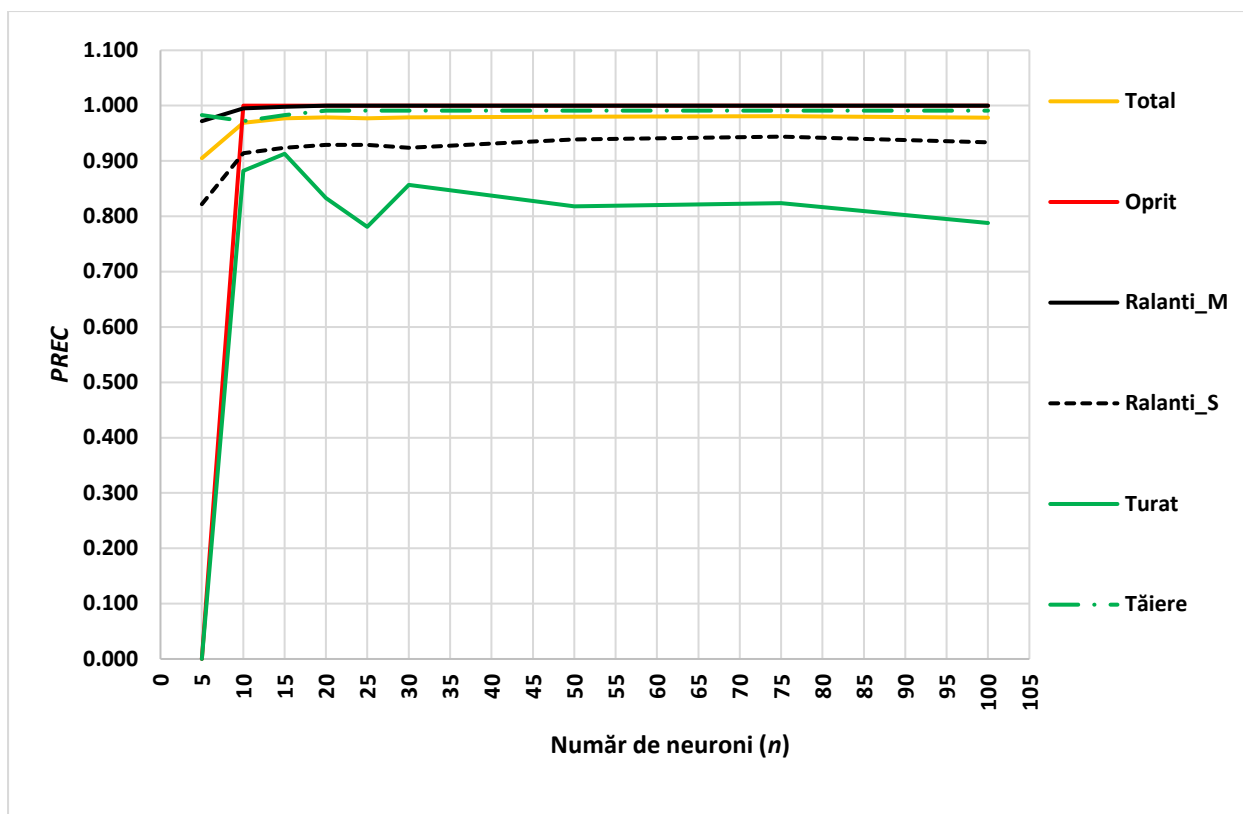


Figura 25. Variația mărimii indicatorului **PREC** pentru $P_{20 \times 100 \times n}$

După cum se observă în **Figurile 23 - 25**, cele mai mici valori ale indicatorului **PREC** au fost cele specifice evenimentelor încadrate în clasa **Turat**, aceste valori înregistrând o dinamică similară celor prezentate pentru indicatorul **AUC**. În ceea ce privește numărul de neuroni folosiți pentru etapa de învățare a **ANN**, rezultatele prezentate indică faptul că valorile cele mai mari ale indicatorului **PREC** au fost înregistrate în cazurile în care $n \geq 30$. Ca atare, situația a fost similară cu cea prezentată pentru indicatorul **AUC**, inclusiv în ceea ce privește stabilizarea valorilor atunci când f a fost stabilit la 5.

4.2.1.3. Indicatorul **REC**

În condițiile în care se înregistrează valori mari pentru indicatorul **AUC**, și presupunând că acestea nu sunt rezultatul întâmplării, se poate afirma faptul că indicatorul cel mai important al performanței clasificării, pentru aplicații precum cea descrisă prin acest studiu de caz, este indicatorul **REC**. Datorită faptului că în literatura de specialitate românească nu s-au identificat denumiri pentru acest indicator, în continuare s-a folosit formularea simplă de „indicatorul **REC**”. Importanța sa în evaluarea performanței clasificării specifice unui algoritm de clasificare se datorează faptului că el redă raportul dintre instanțele clasificate ca fiind adevărat-pozitive (acele instanțe care sunt pozitive și au fost clasificate, ca atare, drept pozitive) și numărul total de instanțe pozitive (Fawcett, 2006), prin urmare exclude instanțele pozitive care au fost clasificate greșit ca negative (Kamilaris și Prenafeta-Boldu, 2018). Din acest punct de vedere, **Figura 26** prezintă situația cumulată luând în considerare protocolul luat în studiu. Similar cu cele precizate pentru **AUC** și **PREC**, acele P care au fost caracterizate, în general, de $i = 1000$ și $n \geq 30$ au furnizat cele mai bune rezultate (cele mai mari valori ale **REC**). Pentru $n \geq 25$ și $i = 100$, evenimentele din clasele **Oprit** și **Turat** au înregistrat valorile nule ale **REC** iar pentru $n = 5$ rezultatele obținute din acest punct de vedere au fost cele mai slabe.

Valoarea cumulată cea mai mare a indicatorului *REC* a fost cea specifică $P_{20 \times 1000 \times 75}$, în timp ce situația cea mai defavorabilă a fost, în general, cea specifică $P_{f \times 10 \times 5}$.

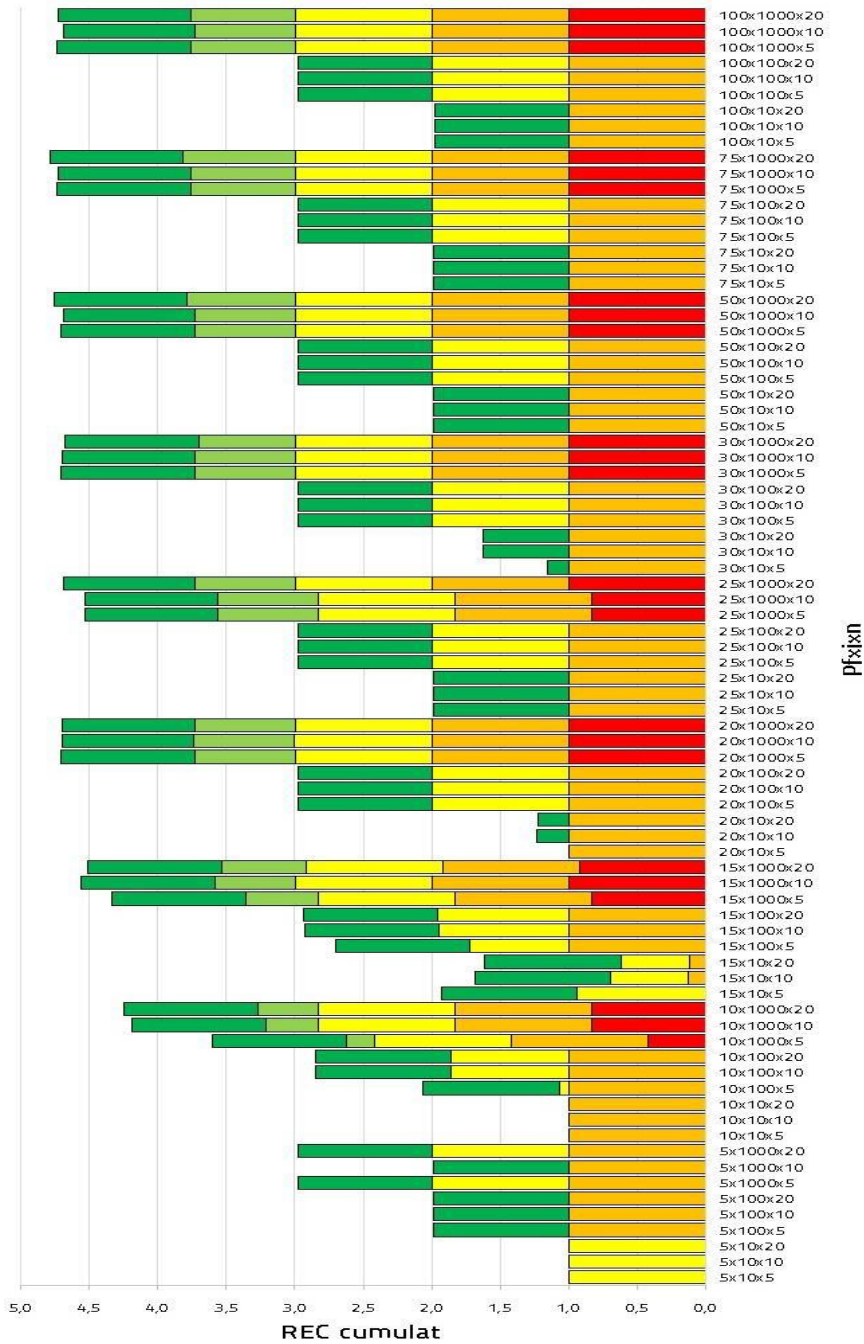


Figura 26. Indicatorul *REC* cumulat pentru protocolul utilizat pentru etapa de învățare a ANN
 Legendă: roșu - *Oprit*, portocaliu - *Ralanti_M*, galben - *Ralanti_S*, verde deschis - *Turat*, verde închis - *Tăiere*

În **Figurile 27 - 35** se prezintă influența numărului de neuroni (n) asupra indicatorului *REC* pentru $i = 10, 100, 1000$, prin luarea în considerare și a numărului de segmente de date utilizate pentru validarea încrucișată.




Figura 27. Variația mărimii indicatorului REC pentru $P_{5 \times 10 \times n}$




Figura 28. Variația mărimii indicatorului REC pentru $P_{10 \times 10 \times n}$

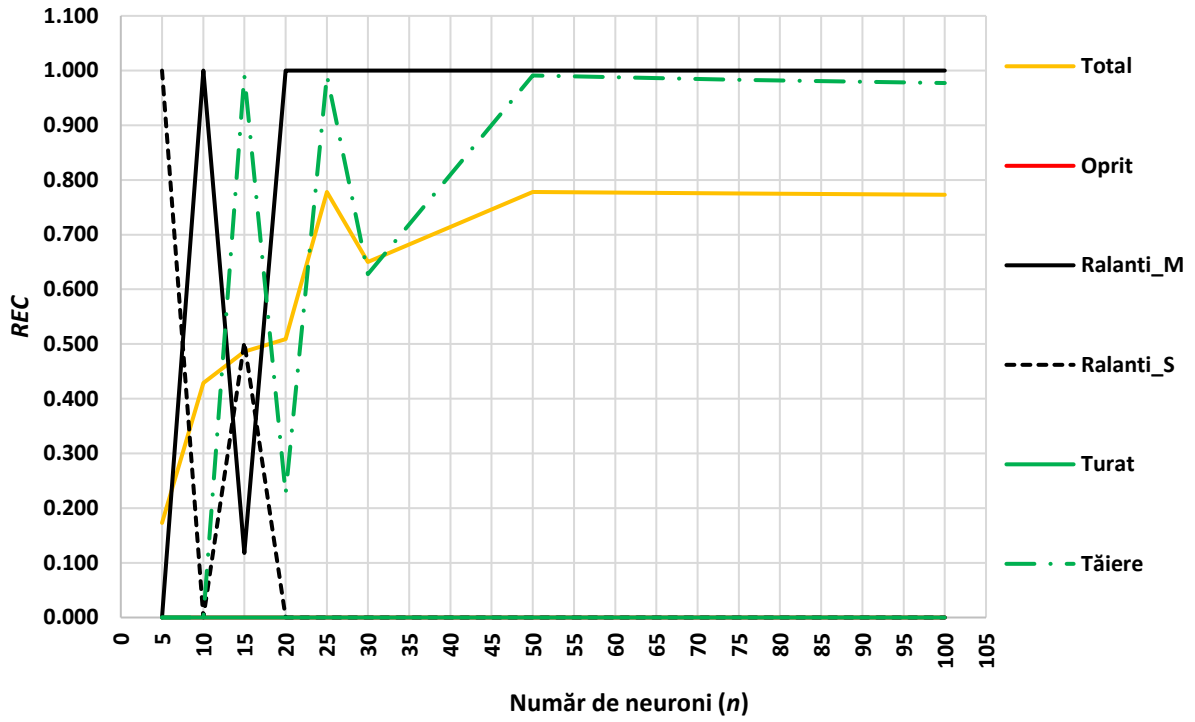


Figura 29. Variația mărimii indicatorului REC pentru $P_{20 \times 10 \times n}$

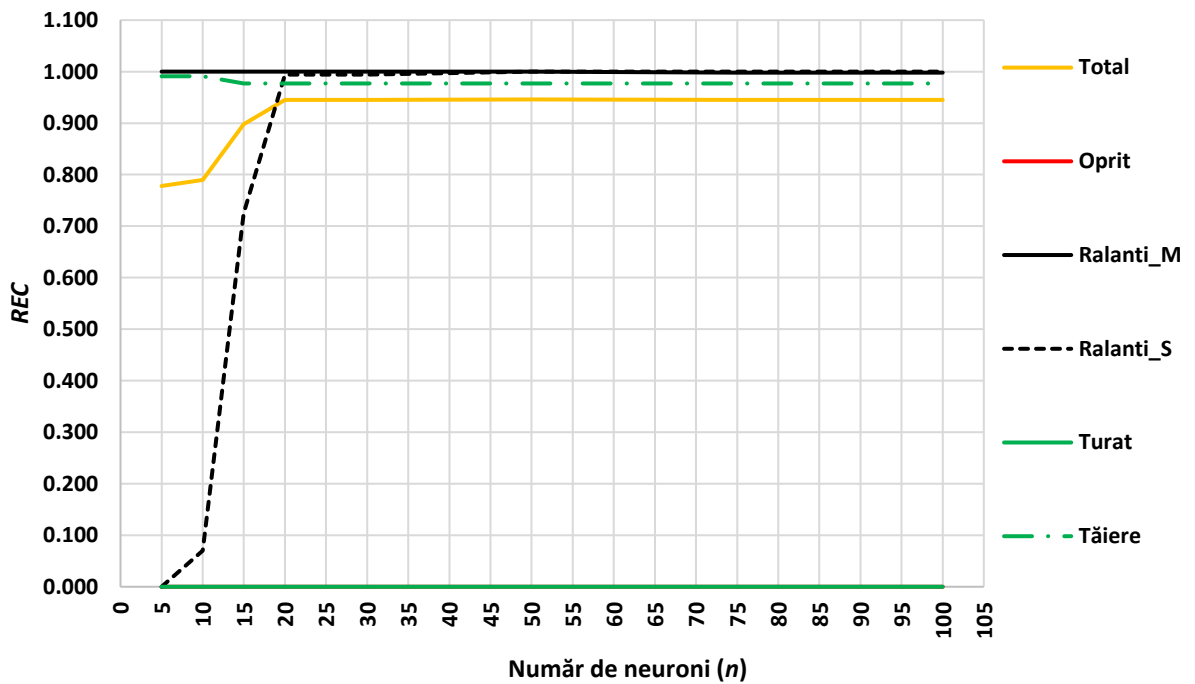


Figura 30. Variația mărimii indicatorului REC pentru $P_{5 \times 100 \times n}$

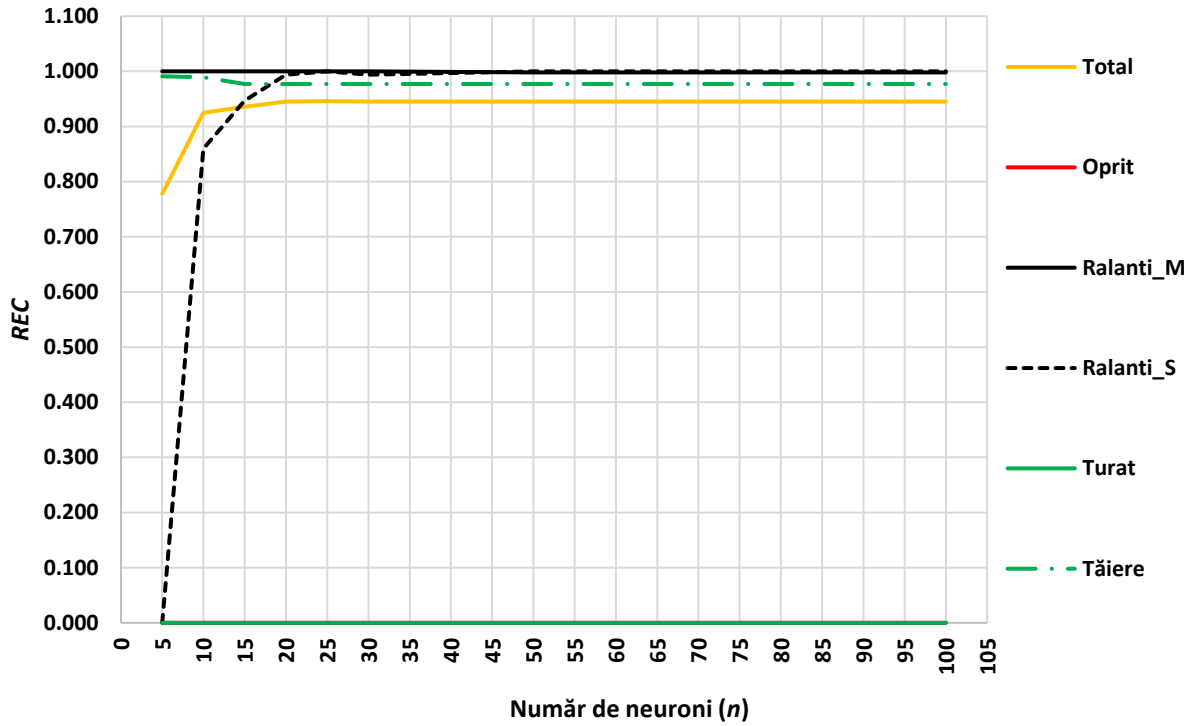


Figura 31. Variația mărimii indicatorului REC pentru $P_{10 \times 100 \times n}$




Figura 32. Variația mărimii indicatorului REC pentru $P_{20 \times 100 \times n}$

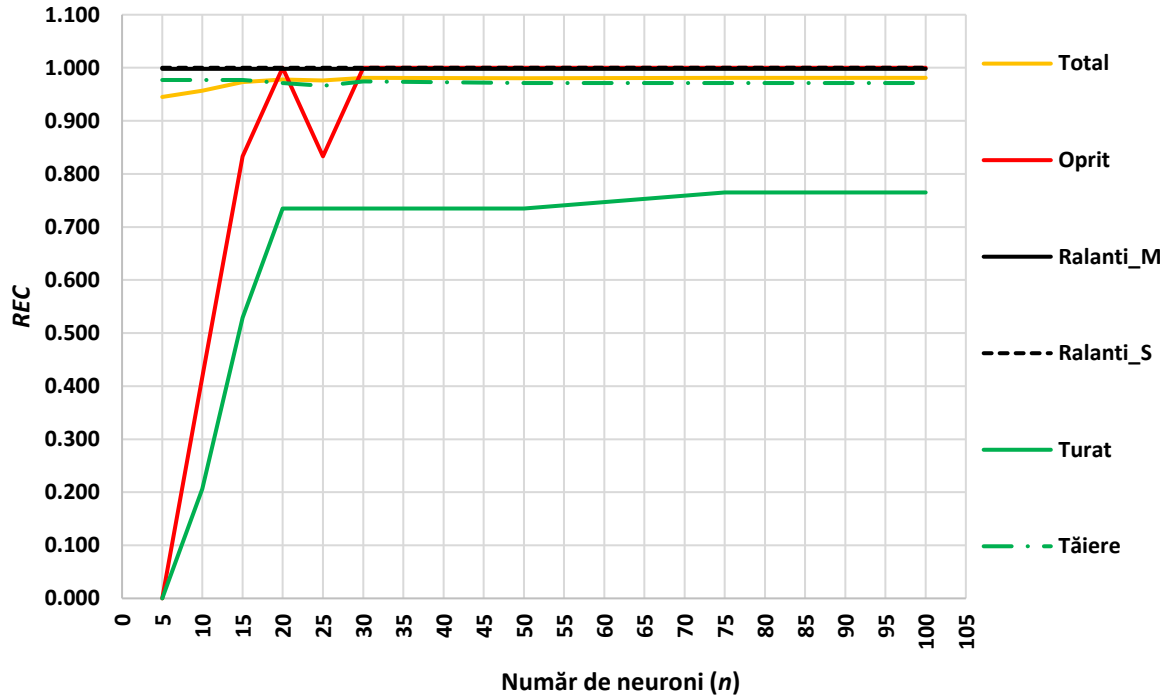


Figura 33. Variația mărimii indicatorului REC pentru $P_{5 \times 1000 \times n}$




Figura 34. Variația mărimii indicatorului REC pentru $P_{10 \times 1000 \times n}$




Figura 35. Variația mărimii indicatorului REC pentru $P_{20 \times 100 \times n}$

Similar celor expuse pentru indicatorii AUC și $PREC$, utilizarea unui număr de peste 30 de neuroni a furnizat cele mai bune rezultate cu privire la mărimea indicatorului REC , pentru fiecare clasă de evenimente luată în studiu, după cum se arată în **Figurile 33-35**. Cu toate acestea, clasa de evenimente **Turat** a oferit cele mai slabe rezultate cu privire la indicatorul performanței de clasificare REC , aspect care a fost similar celor arătate pentru indicatorul $PREC$; de asemenea, rezultatele cu privire la mărimea acestui indicator au fost caracterizate de stabilitate pentru toate clasele de evenimente, cu excepția clasei **Turat** (care a fost caracterizată de stabilitate în intervalul de aproximativ 30 până la 100 de neuroni). Prin urmare, luând în considerare importanța acestui indicator din perspectiva monitorizării operaționale, precum și din perspectiva furnizării de date exacte, pentru a înlătura inconveniențele legate de studiile tradiționale de timp și pentru a automatiza într-o măsură mai mare astfel de demersuri, ar trebui să se ia în considerare cel puțin 30 de neuroni, precum și pe cel puțin 1000 de iterații pentru etapa de învățare a **ANN**. Pentru situația descrisă și având în vedere stabilitatea mai bună a clasei de evenimente **Turat** în cazul $f = 5$, recomandarea care se poate face cu privire la numărul de segmente de date utilizate pentru validarea încrucișată este aceea ca acestea să fie într-un număr cât mai mic. Se precizează, de asemenea, că numărul de segmente de date folosite pentru validarea încrucișată, poate să depindă și de cantitatea de date utilizată pentru etapa de învățare **ANN**, precum și de pattern-ul pe care un set de date îl afișează pe scară temporală.

4.2.2. Performanța generală și implicații pentru monitorizarea operațiilor realizate cu ferăstrăul mecanic

Deși toți indicatorii performanței clasificării utilizați în acest studiu de caz sunt importanți pentru evaluarea performanțelor clasificării, aceștia reprezintă doar o mică parte din setul de indicatori existent (e.g. Kamilaris și Prenafeta-Boldu 2018). Pentru aplicații cum ar fi monitorizarea și obținerea datelor cu privire la consumul de timp în munca realizată cu ferăstraie mecanice, este importantă

utilizarea acelor indicatori care au potențialul de a caracteriza cel mai bine datele care se culeg și se analizează. Ca atare, specific acestor studii este faptul că cercetătorul încearcă să delimiteze, descrie și cuantifice cât mai exact consumul de timp ce caracterizează anumite elemente de muncă (Borz 2014a), aspect care permite, ulterior, utilizarea unor abordări de analiză statistică a datelor, cum ar fi modelarea prin tehnicile regresiei sau compararea datelor (Acuna et al. 2012). Din acest punct de vedere, este importantă obținerea unui semnal bun pentru a fi utilizat ca intrare în analiză, precum și utilizarea unui algoritm de clasificare care să plaseze corect datele în clasele potrivite. În cazul de față, astfel de considerente se referă la indicatorul **REC** al semnalului filtrat ($MFk = 3$) și, ca atare, se vor discuta în continuare. Valorile cumulate cele mai mari ale indicatorului **REC** au fost generate de cazul $P_{20 \times 1000 \times 75}$, care a corespuns valorilor maxime înregistrate pentru indicatorul **REC** specific claselor de evenimente **Total**, **Oprit** și **Turat**, dar nu și pentru restul claselor din **E**, chiar dacă au fost identificate toate clasele ca având valori destul de mari. Cu toate acestea, cele mai importante evenimente pentru practică sunt cele ce corespund realizării de tăieturi, deoarece acestea asigură transformarea formei arborelui, prin urmare, au fost luate în considerare de numeroase studii. Poate fi menționat și faptul că în structura consumului de timp specifică muncii cu ferăstrăul mecanic pot interveni și alte elemente de muncă al căror consum de timp specific poate să fie mai mare decât cel ce caracterizează tăierea efectivă. Chiar și în aceste condiții, diferitele regimuri de funcționare ale motorului caracterizează acele evenimente care influențează consumul de combustibil (e.g. Ignea et al. 2017), prin urmare, ele fac scopul unei monitorizări precise. Din acest punct de vedere, se menționează că pentru clasa de evenimente **Tăiere** s-a înregistrat valoarea cea mai mare a indicatorului **REC** în cazurile $P_{10 \times 10 \times 25}$ și, respectiv, $P_{20 \times 10 \times 25}$, chiar dacă în aceste situații valoarea indicatorului a fost nulă pentru alte clase de evenimente. Pentru protocolul (**P**) luat în analiză, mărirea generală a indicatorului **REC** a variat între 0,173 și 0,981, ceea ce înseamnă că algoritmul de clasificare **ANN** a avut capacitatea de a clasifica corect între 17,3 și 98,1% dintre datele de intrare. Aceste valori au depins, în mare măsură, de numărul neuronilor folosiți în stratul ascuns și de numărul de iterații utilizate pentru etapa de învățare a **ANN**, în timp ce numărul de segmente de date utilizate în procesul de validare încrucișată a avut un rol important. Prin urmare, rezultatele clasificării generale au fost foarte bune pentru $n > 30$ și $i = 1000$, existând posibilitatea ca prin mărirea numărului de iterații ($i > 1000$) acestea să se îmbunătățească. Deoarece cea mai bună valoare a indicatorului **REC** a fost de 98,1%, merită menționat faptul că performanța clasificării caracterizată de valori similare este apreciată ca fiind ridicată (Kamilaris și Prenafeta-Boldu, 2018); pentru 80%, aceasta este apreciată ca fiind acceptabilă (Keefe et al. 2019) în cazul preciziei clasificării (**CA**). Totuși, indicatorul **CA** diferă de indicatorul **REC** (Kamilaris și Prenafeta-Boldu, 2018). Chiar dacă nu au fost prezentate și descrise în mod explicit, valorile maxime ale indicatorului **CA** au fost de 0,981, 1.000, 0,999, 0,989, 0,988 și 0,988 pentru clasele **Total**, **Oprit**, **Ralanti_M**, **Ralanti_S**, **Turat** și, respectiv, **Tăiere**. Pe de altă parte, luând în considerare performanța algoritmului de clasificare prin intermediul indicatorului **REC**, care a indicat o valoare de 98,1%, se poate presupune că, în general, pentru o oră de studiu, se vor clasifica greșit datele provenite din aproximativ un minut de observație. Relevanța acestui inconvenient, precum și semnificația acestuia nu pot fi apreciate până nu se vor realiza studii comparative de amploare mai mare, care să identifice în ce măsură abordările tradiționale pot să producă rezultate caracterizate de precizii similare. Chiar dacă punctul de vedere redat în continuare poate să fie subiectiv, este puțin probabil ca un cercetător să realizeze studii la o precizie atât de ridicată, încât să nu piardă din contorizarea proprie circa 8 minute de observație pe ziua de studiu, în condițiile în care acesta își desfășoară studiul respectiv pe termen lung, iar rezultatele sale pot fi influențate și de oboseală (e.g. Spinelli et al. 2013).

4.3. Rezultate privind studiul de caz SC3

Pentru studiul de caz **SC3**, **Figura 36** redă o parte din rezultatele extrase pe baza algoritmului utilizat. Pentru testarea și demonstrarea capacității algoritmului de a identifica și separa elemente de muncă, regimuri de funcționare ale căruciorului și direcții de deplasare, s-a utilizat o valoare prag

pentru viteza **GPS** de $0,25 \text{ m} \times \text{s}^{-1}$, precum și o toleranță de $\pm 15^\circ$ pentru evaluarea pozițiilor **GPS** în vederea caracterizării acelor evenimente care au presupus mișcarea căruciorului. După cum se poate observa, a existat o bună concordanță între interpretarea datelor de către algoritmul utilizat și variația poziției și vitezei corespunzătoare datelor extrase din fișierul **GPS**. Totuși, există situații în care unele rezultate pot fi interpretate greșit, deoarece anumiți parametri și valori pot corespunde valorilor prag ca rezultat al întâmplării. De asemenea, datele prezentate au caracterul unei simulări realizate pe baza informației colectate prin proceduri **GPS** și de către colecții de date echipați cu senzori, deoarece nu s-au efectuat studii comparative, prin proceduri externe și complementare, pentru caracterizarea dinamicii cinematice a căruciorului în vederea comparării cu rezultatele generate de algoritm. Prin urmare, rezultatele prezentate se bazează pe modificări semnificative ale altitudinii și vitezei, identificate de către algoritmul utilizat, ca set de date de referință. Ca atare, pentru validarea datelor, ar trebui să se urmeze abordarea tradițională, prin conducerea de studii comparative. Totuși, scopul general al acestui studiu de caz nu a fost acela de a compara rezultatele obținute prin aplicarea algoritmului cu cele furnizate de abordările tradiționale, ci de a dezvolta, sub raport metodologic, procedurile necesare pentru automatizarea extragerii, clasificării de date și a efectuării de evaluări. Din punctul de vedere al dinamicii mișcării cărucioarelor instalațiilor cu cabluri, este destul de obișnuită deplasarea acestora cu viteze destul de mari în timpul curselor efectuate înspre amonte și înspre aval (Gallo et al. 2013, Nitami et al. 2011). Atunci când au loc schimbări între aceste două stări, vitezele de deplasare devin mai mici și vor fi captate de către colecătorul de date **GPS**, în funcție de rata de eșantionare a datelor stabilită. În mod obișnuit, reducerea vitezei de deplasare a căruciorului poate să apară la trecerea peste saboți, înainte de oprire în zona de formare a sarcinii și în momentul apropierii de platforma primară pentru detașarea sarcinilor. Pentru a se surprinde în mod adecvat astfel de evenimente și pentru a se delimita în mod corespunzător diferitele stări ale căruciorului, este recomandabilă setarea unei rate de eșantionare cât mai apropiată de cea mai fină pe care o poate asigura un astfel de colecător de date.




Figura 36. Exemplu cu privire la dinamica mișcării căruciorului, interpretată de algoritmul utilizat, în funcție de variația altitudinii și a vitezei măsurate de receptorul GPS.

*Legendă: roșu - oprit, verde - mișcare înspre amonte, albastru - mișcare înspre aval, roșu punctat - viteza **GPS**, negru punctat - altitudinea **GPS** raportată prin utilizarea unui factor de 1/200.*

Modificarea altitudinii caracterizează setul de date colectate și prelucrate în cadrul acestui studiu de caz, în care colectarea lemnului s-a realizat dinspre amonte înspre aval. Se menționează aici că instalațiile cu cabluri pot fi utilizate atât pentru colectarea lemnului în teren înclinat, cât și pentru

colectarea lemnului în teren plan (Oprea 2008). Prin urmare, variația datelor pe scară altitudinală ar putea să devină nerelevantă în anumite cazuri. Chiar și așa, presupunând o precizie ridicată a dispozitivelor utilizate pentru colectarea datelor (în principal cea a dispozitivului **GPS**), algoritmul dezvoltat ar putea fi foarte util în demersul de analiză automată a datelor cu privire la consumul de timp. De exemplu, în cazul unor terenuri plane, condiția cu privire la interpretarea variației altitudinii de către algoritm ar trebui exclusă. În aceste condiții, algoritmul s-ar baza în demersul de delimitare a evenimentelor numai pe utilizarea pragurilor și toleranțelor stabilite pentru viteza de mișcare și poziția în plan orizontal a locațiilor **GPS** colectate, ceea ce include orientarea vectorului de direcție a mișcării raportată la toleranța stabilită de utilizator. **Figura 37** prezintă o parte din datele cu privire la dinamica mișcării căruciorului (oprit vs. mișcare), care au fost interpretate pe baza semnalului colectat de senzorii de măsurare a nivelului presiunii acustice. Ca atare, din **Figura 37** se poate observa că mișcarea căruciorului a fost caracterizată de niveluri de presiune acustică mai mari de 85 dB(A), această valoare utilizându-se ca prag pentru a diferenția cele două stări luate în considerare: mișcare și oprit. De asemenea, rezultatele prezentate în **Figura 37** indică numai dacă s-a identificat sau nu mișcarea căruciorului și nu și direcția sau sensul înspre care a fost realizată această mișcare. În cazul sistemelor care operează gravitațional, cursa în plin poate fi realizată la o viteză diferită de cea a cursei în gol și, în unele cazuri, prima poate să fie caracterizată de viteze mai mari (Gallo et al. 2013). Acest tip de diferențieri încă necesită observații realizate în teren, pentru a caracteriza regimul cinematic al căruciorului și utilizarea doar a semnalului cu privire la nivelul de presiune acustică reprezintă o limitare din acest punct de vedere. Ce se poate afirma este faptul că, o deplasare a căruciorului cu o viteză mai mare va genera un nivel de presiune acustică mai mare, iar prin setarea unor praguri adecvate în acest sens, s-ar putea diferenția între două tipuri de evenimente, dar fără a ști cu exactitate ce reprezintă fiecare dintre ele.



Figura 37. Exemplu cu privire la dinamica mișcării căruciorului, interpretată de algoritmul utilizat pentru diferențierea nivelului presiunii acustice.

Legendă: roșu - dinamica mișcării căruciorului: valoare ridicată - mișcare, valoare scăzută - oprit; albastru punctat - nivelul presiunii acustice (dB (A)) în timpul funcționării pentru motorul grupului de acționare, verde punctat - nivelul presiunii acustice (dB (A)) în timpul funcționării pentru cărucior.

Datele care s-au utilizat în acest studiu de caz au acoperit circa 11 ore de observație (39.090 secunde). Deși nu se redau aici, în mod explicit, date comparative, s-au comparat datele extrase din

setul **GPS** prin algoritmul utilizat cu cele identificate de către senzorul de presiune acustică, pentru cele două regimuri cinematice de funcționare: mișcare și oprit. În urma comparării datelor, s-au identificat diferențe între cele două seturi de date care s-au încadrat în limita a $\pm 2\%$.

4.4. Rezultate privind studiul de caz SC4

Timpul total observat în studiul implementat în condiții operaționale reale (T_T) a totalizat aproape 19 ore. Pentru indicatorii **HR** și **SL** baza de date dezvoltată pe baza observațiilor și măsurătorilor realizate în teren a cuprins un număr de 67.052 observații. În urma analizei datelor, timpul productiv (t_P) a reprezentat mai puțin de 34% din timpul total luat în studiu, după cum se arată în **Tabelul 6**.

Tabelul 6. Statistici descriptive de bază cu privire la consumul de timp, combustibil și lubrifianți și indicatori de bază ai performanței productive

Parametru [variabilă]	Statistici descriptive				
	Valoarea minimă	Valoarea maximă	Media \pm Abaterea Standard	Suma	Pondere (%)
Variabile operaționale					
$D_{1,3}$ (cm)	54	88	67,45 \pm 8,14	-	-
$D_{0,3}$ (cm)	60	100	77,23 \pm 11,17	-	-
P (m ³)	-	-	4,83	149,73	-
Consum de timp					
t_{PL} (s)	-	-	-	4.784	7,14
t_{M_OPRIT} (s)	-	-	-	7.393	11,03
t_{M_PORNIC} (s)	-	-	-	105	0,16
t_{CLM} (s)	-	-	-	1.300	1,94
t_{TP} (s)	-	-	-	2.439	3,64
t_{TO} (s)	-	-	-	1.436	2,14
t_{RC} (s)	-	-	-	879	1,31
t_{CC} (s)	-	-	-	5.561	8,29
t_S (s)	-	-	-	3.414	5,09
t_{BL} (s)	-	-	-	112	0,17
t_{PO} (s)	-	-	-	14.739	21,98
t_{PT} (s)	-	-	-	118	0,18
t_{PM} (s)	-	-	-	14.759	22,00
t_{PS} (s)	-	-	-	4.378	6,53
t_{FM} (s)	-	-	-	5.635	8,40
t_P (s)	-	-	-	22.639	33,76
t_{NP} (s)	-	-	-	44.413	66,24
T_T (s)	-	-	-	67.052	100,0
Consumul de combustibil și lubrifianți					
FM (l)	-	-	-	4,350	-
LO (l)	-	-	-	1,480	-
UFM (l \times m ⁻³)	-	-	0,029	-	-
ULO (l \times m ⁻³)	-	-	0,010	-	-
Indicatori ai performanței productive					
P_{NETA} (m ³ \times h ⁻¹)	-	-	23,81	-	-
P_{BRUTA} (m ³ \times h ⁻¹)	-	-	8,04	-	-
E_{NETA} (h \times m ⁻³)	-	-	0,04	-	-
E_{BRUTA} (h \times m ⁻³)	-	-	0,12	-	-

Timpul consumat în elemente de muncă productive a fost delimitat după analiza consumului de timp sub forma unor întârzieri, precum cele relaționate cu pauzele de odihnă (21,98%), pentru masă

(22,00%), precum și a timpului pentru deplasarea de la locul de cazare la parchet și înapoi (15,54%). Întârzierile cauzate de studiu și cele datorate altor motive tehnice au contribuit cu doar 6,7% în consumul de timp total luat în studiu, majoritatea acestor întârzieri fiind destinate alimentării ferăstrăului mecanic. În structura timpului productiv (t_p), proporția cea mai mare a fost cea care a caracterizat consumul de timp pentru deplasare (33,29%), urmată de cea care a caracterizat curățirea de crăci (24,69%), realizarea tăieturilor de secționare (17,20%) și realizarea tăieturilor de doborâre (15,16%). Proporții mai mici au fost cele care au caracterizat alte sarcini de muncă, cum ar fi curățirea locului de muncă (5,77%) și retezarea crestei trunchiului (3,9%). În ceea ce privește variabilele operaționale, media diametrului la înălțimea pieptului ($D_{1,3}$) a fost estimată la circa 67 cm, fiind apropiată ca valoare de cea înscrisă în actul de punere în valoare. De asemenea, diametrul mediu la cioată ($D_{0,3}$) a fost estimat a fi mai mare cu circa 10 cm. Producția (P , m^3) a fost estimată la aproape $150 m^3$, plecându-se de la numărul de arbori recoltați pe durata efectuării observațiilor de teren (31) și a volumului arborelui mediu, preluat din actul de punere în valoare. Pentru doborârea și fasonarea celor 31 de arbori s-a măsurat un consum de amestec de carburant de $4,350 l (0,029 l \times m^{-3})$ și un consum de lubrifiant de $1,480 l (0,010 l \times m^{-3})$, indicând o cantitate unitară mică de combustibili consumați. În condițiile observate, productivitatea netă și productivitatea brută (P_{NETA} , P_{BRUTA}) au fost evaluate la 23,81 și, respectiv, la $8,04 m^3 \times h^{-1}$. În ipoteza în care s-au exclus din calcul diferitele tipuri de întârzieri, doborârea și fasonarea unui metru cub de lemn a durat 0,04 ore (E_{NETA}), iar prin includerea acestora în calcul, pentru caracterizarea condițiilor de teren reale, eficiența brută (E_{BRUTA}) a fost de $0,12 h \times m^{-3}$.

4.5. Rezultate privind studiul de caz SC5

4.5.1. Statistici descriptive ale semnalului folosit și ale evenimentelor identificate

Figura 38 prezintă un segment din setul de date inițial care a fost supus procedurilor de filtrare descrise în subcapitolul 3.5.2.1. La o primă vedere, observațiile care au caracterizat folosirea ferăstrăului pentru tăiere pot fi identificate destul de ușor, prin mijloace vizuale, în semnalul inițial redat pe scară temporală. Se precizează, de asemenea, că o astfel de distribuție a datelor a fost specifică întregului set de date luat în analiză, care a totalizat un număr de peste 67.000 de observații.




Figura 38. Exemplu de distribuție pe scară temporală a semnalului colectat și filtrat și evenimentele identificate

Legendă: prag arbitrar stabilit la 60 dB(A) - alte elemente de muncă, 90 dB(A) - tăiere propriu-zisă

Statisticile descriptive de bază ale setului de date au relevat câteva informații importante care ar putea fi utilizate pentru a evalua separabilitatea datelor. Chiar dacă nu sunt prezentate sub forma unui tabel în această secțiune (rezultatele complete sunt redată în anexele lucrării), în cele ce urmează se prezintă valorile minime, maxime, medii și abaterile standard. De exemplu, în cazul $S_{INITIAL}$, evenimentele din clasa **Tăiere** au fost caracterizate printr-o gamă de valori cuprinse între 51,5 și 112,3 dB(A), cu o medie $98,7 \pm 7,6$ dB(A); aceleași statistici au fost de 37,6 și 105,9 dB(A), respectiv $59,9 \pm 11,2$ dB (A) pentru evenimentele din clasa **Altele**. **Tabelul 7** prezintă ponderea claselor de evenimente în semnalele utilizate, precum și mărimea seturilor de date folosite în anumite scopuri specifice.

Tabelul 7. Ponderea evenimentelor delimitate în segmentele de semnal utilizate

Semnalul utilizat, scopul și abrevierea	Număr de observații	Ponderea evenimentelor (%) în numărul de observații	
		Tăiere	Altele
Filtrat, set inițial $S_{INITIAL}$	67.050	22,76	77,24
Filtrat, set pentru învățare S_{TRAIN}	26.820	22,89	77,11
Filtrat, set pentru testare S_{TEST}	40.230	22,67	77,33

După cum se prezintă în **Tabelul 7**, proporțiile claselor reale de evenimente, codificate în seturile de date ale semnalelor utilizate, au fost similare, oferind, din acest punct de vedere, un echilibru bun al datelor utilizate în diferite etape ale implementării **ANN**. Acestea reflectă, de asemenea, proporțiile consumului de timp în grupele de operații care caracterizează eficiența producției. Astfel, aproape 77% din timp a fost utilizat pentru alte evenimente (**Altele**) și numai circa 23% pentru tăierea efectivă (**Tăiere**).

4.5.2. Rezultatele etapei de învățare și selectarea modelului **ANN**

Rezultatele etapei de învățare a **ANN**, care a utilizat semnalul filtrat, sunt prezentate în **Tabelul 8**. În urma testelor realizate în conformitate cu cele prezentate în subcapitolul 3.5.5.2, s-a ales pentru etapa de testare modelul caracterizat de un număr de două straturi de neuroni, 100.000 de iterații și un număr de 20 de segmente de date folosite în validarea încrucișată.

Tabelul 8. Rezultate cu privire la indicatorii performanței clasificării în etapa de învățare a **ANN**

Semnalul de intrare	Timpul de învățare (s)	Clasa de evenimente	Indicatorii performanței clasificării				
			AUC	CA	F1	PREC	REC
S_{TRAIN}	117	Tăiere	0,996	0,977	0,951	0,925	0,978
		Altele	0,996	0,977	0,985	0,993	0,977
		Total	0,996	0,977	0,977	0,978	0,977

Ca indicatori ai performanței clasificării, **AUC**, **CA**, **PREC** și **REC** au aceeași semnificație după cum s-a prezentat în subcapitolul 4.2.1. În **Tabelul 8** se observă că, pentru modelul selectat a fi cel mai bun după etapa de învățare, indicatorul **AUC** a avut valori apropiate de 0,97. Acuratețea clasificării (**CA**) a fost caracterizată de valori de circa 98%, iar precizia clasificării (**PREC**) a avut valori de circa 0,93 și 0,99 pentru clasele **Tăiere** și, respectiv **Altele**, înregistrând o valoare globală de circa 0,98. Indicatorul **REC**, care are semnificația cea mai importantă în studii ce adresează consumul de timp a înregistrat, în etapa de învățare a **ANN**, valori de circa 98%. Acestea valori indică o performanță ridicată a clasificării prin utilizarea semnalului filtrat cu privire la nivelul de presiune acustică.

4.5.3. Statistici descriptive privind performanţa clasificării în etapa de testare a modelului

Deoarece S_{TRAIN} , caracterizat de parametrii descrişi în **Tabelul 8** a generat cele mai bune rezultate cu privire la indicatorii performanţei clasificării, inclusiv cu privire la timpul consumat în etapa de învăţare, etapa de testare a **ANN** a fost implementată pe setul de date de testare (S_{TEST}), care a reprezentat restul datelor delimitate din setul iniţial filtrat ($S_{INITIAL}$), folosindu-se modelul generat pe setul S_{TRAIN} care a avut specificaţiile descrise în subcapitolul 4.2.1. În urma etapei de testare, la nivel global, s-au înregistrat valori chiar mai bune ale indicatorilor performanţei clasificării în comparaţie cu cele specifice modelului generat în urma etapei de învăţare. Astfel, performanţa generală a etapei de testare a fost caracterizată de valori ale **AUC** similare cu cele din etapa de învăţare (0,996) şi de valori ale celorlalţi indicatori ai performanţei de clasificare sensibil mai mari: **CA** de 0,980 (0,977 în etapa de învăţare), **PREC** de 0,980 (0,978 în etapa de învăţare) şi **REC** de 0,980 (0,977 în etapa de învăţare) (**Tabelul 9**). În numărul total de observaţii clasificate corect, proporţiile claselor de evenimente **Tăiere** şi **Altele** au fost de circa 22,91 şi, respectiv, 77,09%. Pe de altă parte, un număr de 822 de observaţii din semnalul S_{TEST} au fost incorect clasificate (**Tabelul 29**), reprezentând o pondere de circa 2% din setul de date folosit în etapa de testare. După cum se observă, în acest sub-eşantion, cea mai mare problemă legată de inexactitatea clasificării a fost cea specifică clasificării greşite a unor evenimente din clasa **Altele** ca evenimente din clasa **Tăiere** (aproximativ 89%); într-o măsură mai mică au fost clasificate greşit evenimente din clasa **Tăiere** ca evenimente din clasa **Altele** (11%).

Tabelul 9. Numărul şi ponderea clasificărilor corecte în setul de date de testare şi indicatori globali ai performanţei clasificării

Caracteristici	Număr de observaţii	Ponderea celor clasificate corect	Indicatori ai performanţei clasificării				
			AUC	CA	F1	PREC	REC
Total clasificate corect	39.408	100,00					
Tăiere	9.029	22,91					
Altele	30.379	77,09					
Performanţa generală	-	-	0,996	0,980	0,981	0,980	0,980

Tabelul 10. Numărul şi ponderea clasificărilor greşite din setul de date de testare

Clase interpretate greşit	Numărul de observaţii	Ponderea clasificării în categorii greşite (%)
Total observaţii clasificate greşit	822	100,00
Tăiere clasificată greşit ca Altele	92	11,19
Altele clasificat greşit ca Tăiere	730	88,81

Analizând atât rezultatele cu privire la clasificarea corectă, cât şi rezultatele cu privire la clasificarea greşită a unor evenimente (observaţii) în clasele specifice, se poate afirma că abordarea folosită a furnizat, în general, rezultate foarte bune cu privire la performanţa clasificării. Clasificarea greşită a unui număr mai mare de observaţii ca **Tăiere** se poate datora inclusiv faptului că în clasa **Altele** s-au inclus şi acele observaţii care au caracterizat utilizarea ferăstrăului mecanic cu motorul pornit dar nu angajat în tăierea efectivă. Este posibil ca aceste observaţii să fi generat valori mai ridicate ale

semnalului folosit atât pentru etapa de învățare, cât și pentru etapa de testare a modelului **ANN** și, ca urmare, acestea să fi fost recunoscute de către algoritmul utilizat ca evenimente de **Tăiere**.

4.6. Rezultate privind studiul de caz SC6

4.6.1. Efortul fizic

În **Tabelul 11** sunt prezentate statisticile descriptive și indicatorii ce caracterizează efortul fizic al muncitorului în utilizarea ferăstrăului mecanic. Literatura de specialitate indică, de multe ori, că valori ale rezervei ritmului cardiac mai mari de 40% caracterizează o activitate grea (Potočnik și Poje 2017); dacă se iau în considerare rezultatele obținute prin studiul de caz de față, atunci toate sarcinile ce au caracterizat timpul productiv de muncă pot fi considerate dificile. De asemenea, mișcările pentru eliberarea lamei ferăstrăului mecanic din tăieturi, raportate în acest studiu sub forma unor întârzieri de natură tehnică (**PT**), au fost cele care s-au identificat a genera cel mai mare efort fizic al muncitorului (**%HRR = 57,49**). Retezarea crestei a presupus, de asemenea, un efort fizic susținut, indicând o valoare a rezervei ritmului cardiac de 52,44%. Cu excepția secționării (**S**), toate sarcinile care au fost efectuate în parchetul de exploatare și care au utilizat ferăstrăul mecanic au fost caracterizate printr-o rezervă a ritmului cardiac mai mare de 45%. Chiar și în cazul acelor sarcini de muncă care au presupus mișcarea (**M_OPRIT, M_PORNIT**) a fost depășit pragul ce delimitează un nivel ridicat de dificultate a muncii, de 40%, indicând faptul că toate sarcinile efectuate în timpul desfășurării operațiilor au fost dificile. Dificultatea sarcinilor ce au presupus mișcarea muncitorului luat în studiu ar putea fi atribuită, mai degrabă, prezenței vegetației arbustive și nu înclinării terenului, deoarece parchetul a fost localizat în terenul așezat. O rezervă a ritmului cardiac mai mică de 30% a fost caracteristică doar unor evenimente cum ar fi deplasarea înspre locul de cazare și înapoi la șantierul de exploatare, precum și pauzelor de masă, care au asigurat recuperarea cardiovasculară într-o măsură mai mică. Se menționează, de asemenea, că în timpul pauzelor de odihnă, activitatea cardiovasculară a muncitorului a depășit valoarea rezervei de ritm cardiac de 30%.

Tabelul 11. Activitatea cardiovasculară și dificultatea elementelor de muncă

Elementul de muncă	Statistici descriptive					
	Consum de timp (s)	Pondere (%)	Media HR (bpm)	Abaterea Standard HR (bpm)	%HRI	%HRR
PL	4.784	7,14	93,5	±7,9	34	21,76
M_OPRIT	7.393	11,03	118,0	±12,8	69	44,45
M_PORNIT	105	0,16	116,9	±7,9	67	43,46
CLM	1.300	1,94	120,4	±14,3	72	46,66
TP	2.439	3,64	121,5	±12,5	74	47,71
TO	1.436	2,14	120,6	±13,3	72	46,90
RC	879	1,31	126,6	±12,5	81	52,44
CC	5.561	8,29	123,0	±14,4	76	49,12
S	3.414	5,09	114,2	±15,0	63	40,91
BL	112	0,17	123,1	±9,3	76	49,14
PO	14.739	21,98	105,6	±14,9	51	33,10
PT	118	0,18	132,1	±9,0	89	57,49
PM	14.759	22,00	99,6	±9,4	42	27,39
PS	4.378	6,53	102,8	±11,9	47	30,35
FM	5.635	8,40	94,3	±12,4	35	22,53
TOTAL	67.052	100,0	107,1	±16,0	53	34,38

În conformitate cu Grandjean (1980) la care fac referire și Silayo et al. (2010), efortul fizic care indică munca grea se caracterizează printr-o creștere a frecvenței cardiace (**%HRI**) în intervalul cuprins între 78 și 114. Din acest punct de vedere, doar un interval de timp scurt din studiul de caz de față (circa 1,5%) ar fi fost caracterizat de un efort fizic amplu. Totuși, există studii ce arată faptul că, în cazul în care ritmul cardiac variază de la 110 la 150 bpm (Kilbom 1995), munca este considerată grea pentru operator, iar valori ale ritmului cardiac cuprinse în intervalul de 110-130 bpm constituie limita superioară acceptabilă, din punctul de vedere al efortului fizic, pentru munca continuă (Åstrand 1986). Rezerva ritmului cardiac pentru întreaga perioadă luată în studiul de caz a fost estimată la 34,38%. Aceasta nu ia în considerare doar tipul consumat în sarcini productive, ci este estimată prin utilizarea tuturor observațiilor cu privire la activitatea cardio-vasculară, inclusiv a celor înregistrate în timpul pauzelor, întârzierilor, timpului consumat pentru luarea mesei și a celui pentru pregătirea și finalizarea lucrărilor. În ceea ce privește mărimea acestui indicator numai pentru sarcinile de muncă productive, un calcul simplu, realizat prin ponderarea valorilor **%HRR** cu timpul înregistrat în astfel de activități, ar conduce la o valoare a **%HRR** de aproximativ 46%. Deși rezultatele prezentate pentru acest studiu de caz sunt comparabile cu cele raportate de alții, trebuie menționat faptul că ceea ce se aduce nou prin abordarea studiului de caz este chiar metodologia folosită, care a integrat mai multe tipuri de colectori de date, pentru a facilita colectarea simultană atât a unor parametri cu privire la ergonomia muncii (a se vedea și subcapitolul următor), cât și a unor parametri necesari în studiul timpului. Astfel, prin abordări de acest fel, s-ar putea acoperi variabilitatea antropometrică și operațională în viitor, prin studii de durată mai mare și prin metode care să permită automatizarea pe scară largă a activității de colectare, procesare, analiză și interpretare a datelor.

4.6.2. Expunerea la zgomot

Pe baza datelor analizate prin acest studiu de caz, muncitorul care a efectuat operațiile a fost identificat în proporție de circa 23% din timpul total luat în studiu în sarcini ce au presupus utilizarea ferăstrăului mecanic cu motorul pornit. În **Tabelul 12** se prezintă rezultatele cu privire la nivelul de expunere la zgomot în diferite sarcini de muncă, precum și la nivelul timpului total de studiu.

Tabelul 12. Durata cumulată a elementelor de muncă și nivelurile de expunere la zgomot pe elemente de muncă și la nivel general, al studiului

Elementul de muncă	Consum de timp (s)	Pondere [%]	L_{Aeq} (dB(A))	$L_{Aeq, Te}$ (dB(A))	$L_{EX, 8h}$ (dB(A))
<i>PL</i>	4.784	7,14	76,33		
<i>M_OPRIT</i>	7.393	11,03	79,43		
<i>M_PORNIT</i>	105	0,16	97,65		
<i>CLM</i>	1.300	1,94	100,36		
<i>TP</i>	2.439	3,64	106,14		
<i>TO</i>	1.436	2,14	105,35		
<i>RC</i>	879	1,31	102,40		
<i>CC</i>	5.561	8,29	101,53		
<i>S</i>	3.414	5,09	103,89		
<i>BL</i>	112	0,17	101,61		
<i>PO</i>	14.739	21,98	80,17		
<i>PT</i>	118	0,18	92,58		
<i>PM</i>	14.759	22,00	75,65		
<i>PS</i>	4.378	6,53	80,02		
<i>FM</i>	5.635	8,40	78,05		
TOTAL	67.052	100,0	97,15	97,28	96,18

Făcând referire la timpul productiv, nivelul expunerii la zgomot a variat în funcție de tipul de sarcină realizată. Operatorul a fost expus la cel mai mare nivel al zgomotului în timpul realizării sarcinilor de executare a tapei (**TP**, $LA_{eq} = 106,14$ dB (A)) și în timpul executării tăieturilor din partea opusă a tapei (**TO**, $LA_{eq} = 105,35$ dB (A)), acestea fiind și sarcinile de lucru ce presupun o distanță mai mică între sursa de zgomot și ureche. De asemenea, pentru realizarea acestor sarcini de muncă, motorul este utilizat aproape de capacitatea maximă, producând astfel mai mult zgomot, în comparație cu alte sarcini, când motorul este utilizat mai mult timp în stare de ralanti. Secționarea (**S**) a presupus atât utilizarea ferăstrăului mecanic, cât și efectuarea mișcărilor de-a lungul arborelui cu ferăstrăul neturat, rezultând o expunere medie la zgomot de 103,89 dB(A). Curățirea locului de muncă (**CLM**), retezarea crestei (**RC**) și curățirea de crăci (**CC**) au reprezentat expuneri similare la zgomot, variind de la 100,36 la 102,40 dB(A). Evident, aceste niveluri de expunere au fost corelate cu timpul de funcționare a ferăstrăului mecanic, care a fost scăzut, cu excepția sarcinilor de curățire de crăci (8,29%). Utilizarea ferăstrăului mecanic la capacitate aproape de cea maximă, în timpul curățirii de crăci, a fost mai mică, comparativ, de exemplu, cu executarea tăieturii din partea opusă tapei. De asemenea, multe dintre sarcinile realizate cu ferăstrăul mecanic la capacitatea apropiată de cea maximă de funcționare a motorului nu au presupus existența unor condiții similare de distanță între sursa de emiterie a zgomotului și ureche. Totodată, expunerea la zgomot în operațiile de doborâre și fasonare a arborilor cu ferăstrăul, este dependentă și de postura adoptată de muncitor în timpul realizării acestor sarcini, fiind condiționată, și de alți factori, cum ar fi diametrul arborelui, diametrele mai mari implicând un consum mai mare de timp în astfel de sarcini de muncă. Expunerea zilnică totală la zgomot, calculată pentru întregul studiu de caz a fost de 97,15 dB (A), iar media expunerii zilnice totale pentru studiul de caz a fost de 97,28 dB (A). Zilele de lucru în care s-au efectuat observații nu au inclus, fiecare dintre ele, câte 8 ore de observare a muncii. Ca atare, timpul de observare a muncii prin acest studiu de caz a fost de 8,26 ore în prima zi, 7,16 ore în a doua zi și de 3,21 ore în ultima zi; de aceea, timpul de muncă a fost, în medie, de 6,21 ore pe zi. Se poate menționa, de asemenea, că o proporție de 15,54% din timpul luat în studiu a fost constituită din deplasările pentru a ajunge la locul de muncă și din cele dintre locul de muncă și locul de cazare. Prin urmare, expunerea zilnică calculată pentru o zi nominală de 8 ore ($L_{Ex,8h} = 96,18$ dB (A)), care include și sarcinile de deplasare pentru a ajunge la locul de muncă și înapoi la locul de cazare, a fost cu 1 dB(A) mai mică decât expunerea zilnică reală ($LA_{eq} = 97,15$ dB (A)).

În comparație cu legislația europeană și cu standardele de evaluare a expunerii la zgomot (Directiva 2003/10/CE), rezultatele indică faptul că, în majoritatea sarcinilor observate, expunerea la zgomot a depășit nivelul minim de acțiune, care este de 80 dB(A). Doar deplasarea spre locul de muncă și înapoi la locul de cazare (transportul cu tractorul folosit în timpul operațiilor de colectare), mișcările cu motorul oprit și pauzele de masă au generat expuneri la zgomot mai mici decât acest prag. Astfel de evenimente au reprezentat aproape 50% din timpul observat. Pe de altă parte, 22,92% din timpul observat a fost caracterizat prin expunerea la zgomot care a depășit valoarea limită de expunere stabilită la 87 dB (A).

4.6.3. Analiza posturală

În **Tabelul 13** se prezintă rezultatele cu privire la evaluarea posturală, rezultate care au fost influențate de sarcinile observate în operațiile de doborâre și fasonare a arborilor cu ferăstrăul mecanic. Indicele de risc postural (**PRI**) al sarcinilor observate a variat între 128,1 și 373,2, și, în general, a fost mai mare pentru sarcinile care au implicat folosirea ferăstrăului mecanic cu motorul pornit. În special, realizarea tapei (**TP**) a generat cel mai mare **PRI** (373,2) dintre toate sarcinile luate în studiu (**Tabelul 13**), plasând acest tip de sarcini, din punct de vedere postural, aproape de **AC4**. Această situație a fost rezultatul posturii generale a corpului la realizarea acestei sarcini, ca efect a condițiilor locale de muncă, caracterizate prin diametre mari ale arborilor; pentru aceasta, a fost necesară flexia picioarelor precum și aplecarea și răsucirea concomitentă a spatelui, cu scopul de a urmări mai îndeaproape modul de realizare a tăieturilor.

La realizarea tăieturii din partea opusă a tapei, s-a constatat, în urma analizei, că s-a depăşit valoarea **PRI** de 300, iar valori apropiate de acest prag au fost înregistrate şi în cazul întâzierilor tehnice, care au presupus acţiunile necesare pentru eliberarea lamei ferăstrăului mecanic (**PT**). Cu excepţia acelor sarcini care au implicat deplasarea, retezarea crestei atât de pe cioată, cât şi de pe trunchi, toate valorile estimate pentru **PRI** au situat sarcinile respective în apropierea pragului de 300, aspect care indică necesitatea unor acţiuni corective (Karhu et al. 1977). Se poate menţiona şi faptul că, în realizarea acestor sarcini de muncă, muncitorii sunt nevoiţi să adopte posturi inconfortabile care, în multe cazuri, nu depind de strategia adoptată de muncitor, ci de condiţiile de lucru locale. **PRI** global, care a fost calculat pentru operaţiile de doborâre şi fasonare a arborilor cu ferăstrăul mecanic pe baza datelor furnizate de acest studiu de caz, a avut o valoare de 274,9, valoare ce indică apropierea de categoria de acţiune 3 - **AC3**, conform căreia şi în conformitate cu metoda **OWAS**, sunt necesare acţiuni corective din punct de vedere postural cât mai curând posibil (Karhu et al. 1977).

Tabelul 13. Evaluarea indicelui de risc postural în operaţiile de doborâre şi fasonare a arborilor cu ferăstrăul mecanic

Elementul de muncă	Consum de timp în setul total de date (s)	Pondere în setul total de date (%)	Frecvenţa în eşantionul pentru evaluarea posturală	Pondere în eşantionul pentru evaluarea posturală (%)	PRI
M_OPRIT	7.393	32,65	524	8,28	128,1
M_PORNIT	105	0,46	8	0,13	137,5
CLM	1.300	5,74	611	9,65	264,5
TP	2.439	10,77	1.404	22,18	373,2
TO	1.436	6,34	885	13,98	334,2
RC	879	3,88	461	7,28	232,5
CC	5.561	24,56	1.711	27,03	215,3
S	3.414	15,08	622	9,83	296,9
PT	118	0,52	103	1,63	289,3
TOTAL	22.645	100,00	6.329	100,0	274,9

Frecvenţa sarcinilor observate în setul de date privind evaluarea posturală a fost diferită în comparaţie cu setul de date privind studiul de timp (**Tabelul 13**). De exemplu, realizarea tapei a reprezentat mai mult de 22% în studiul de evaluare posturală, în timp ce în studiul de timp a avut o proporţie de numai 11% din setul de date. Presupunând că **PRI** specific fiecărei sarcini ar fi acelaşi, indiferent de timpul petrecut în fiecare sarcină, ar însemna că la final s-ar obţine un **PRI** mult mai scăzut (227,2) la nivelul studiului, în timp ce această valoare ar fi şi mai mică atunci când sunt evaluate şi sarcinile care nu au fost considerate ca făcând parte din timpul productiv. Cu toate acestea, în evaluarea ergonomică a posturilor de lucru, timpul productiv este cel care face obiectul analizei.

4.7. Rezultate privind studiul de caz **SC7**

Pentru studiul de caz **SC7**, s-a ales ca abordare de separare şi clasificare a datelor folosirea unor praguri liniare stabilite arbitrar, pe baza pattern-ului semnalului colectat de către senzorul de nivel de presiune acustică. Rezultatele acestui studiu de caz indică faptul că există un potenţial mare în monitorizarea dinamicii operaţionale a ferăstraielelor circulare, care sunt, până la urmă, unelte indispensabile ce se folosesc în micile fabrici de prelucrare a lemnului. Principalul aspect vizat prin acest studiu de caz a fost cel legat de separarea timpului de funcţionare de cel de nefuncţionare, deoarece, dacă nu se efectuează operaţii de tăiere, atunci menţinerea motorului în funcţiune este contraproductivă din punctul de vedere al economiei de energie. Pragul stabilit pentru nivelul de

presiune acustică corespunzător celor două stări ale ferăstrăului circular a reuşit să separe timpul petrecut în cele două regimuri cu o precizie de aproape 100%. În urma comparării duratei de funcţionare din datele colectate de către senzor cu cele furnizate de înregistrarea video, s-a constatat o precizie de identificare a acestui eveniment foarte bună (aproximativ 99,8%), diferenţa între cele două fiind negativă, de - 0,24% (**Tabelul 14**), indicând faptul că pragul linear adoptat şi aplicat asupra datelor provenite din senzor a subestimat realitatea. Pentru regimul de nefuncţionare, precizia a fost, de asemenea, foarte bună (aproximativ 99,5%), diferenţa dintre cele două fiind de această dată pozitivă, de +0,54%, ceea ce a indicat o supraestimare generată de pragul aplicat datelor colectate de senzor. Aceste mici erori de recunoaştere şi clasificare a evenimentelor urmărite pot fi şi efectul tranziţiei rapide a nivelului de presiune acustică, pe scara amplitudinii, la trecerea între cele două stări (**Figura 39**), tranziţii ce nu s-au putut reda la o rezoluţie mai mare, utilizându-se rata de eşantionare folosită.

Tabelul 14. Statistici descriptive şi rata identificării unor evenimente după aplicarea pragurilor de separare asupra semnalului colectat de senzor

Parametru (variabilă)	Extras din fişiere video	Identificate prin aplicarea pragurilor liniare asupra semnalului	Diferenţe procentuale între seturile de date (%)
Număr de piese tăiate	30	20	- 33,33
Timpe de funcţionare - RUN (s)	414,50	413,50	- 00,24
Timpe de nefuncţionare - STOP (s)	186,00	187,00	+ 00,54




Figura 39. Exemplu de separare a regimurilor operaționale folosind praguri

Legendă: linie neagră punctată - nivelul de presiune acustică dB(A); linie verde continuă - regim de funcționare; linie roșie continuă - regim oprit, linie albastră continuă - tăieturi recunoscute.

În **Figura 39** se redau, în mod convențional, cele două regimuri (stări) de funcționare ale ferăstrăului luat în studiu. Regimul de funcționare a fost reprezentat, convențional, ca având valoarea nivelului de presiune acustică de 85 dB(A), iar pentru regimul de nefuncționare s-a adoptat, tot convențional, valoarea nivelului de presiune acustică de 80 dB(A). În ceea ce privește gradul de recunoaștere automată a numărului de piese de lemn tăiate, rezultatele nu au fost la fel de satisfăcătoare. În acest

caz, pragul prestabilit pentru a recunoaşte și clasifica ca atare aceste evenimente nu a reușit să interpreteze rezultatele de o manieră exactă. Au fost evidențiate doar 20 din cele 30 de evenimente de acest fel, generând o precizie de identificare mai scăzută (aproximativ 66.7%) și o diferență negativă, de -33,33%, raportat la realitatea operațională înregistrată prin abordarea video (**Tabelul 14**). Se precizează, de asemenea, faptul că monitorizarea operațională prin folosirea senzorilor de presiune acustică poate fi realizată prin conectarea directă a colectorului de date la un computer printr-un cablu extern, aspect care permite eșantionarea de date la o rată mult mai mare în timp real, precum și stocarea acestora pe un computer.

4.8. Rezultate privind studiul de caz SC8

4.8.1. Statisticile descriptive ale semnalelor

Figura 40 prezintă o porțiune comună din cele două seturi de date (nivel de presiune acustică și accelerație) ale semnalelor filtrate după excluderea acelor părți care au fost considerate a nu fi reprezentative, inclusiv o reprezentare grafică a celor trei clase luate în considerare pentru analiză, toate acestea fiind redată pe scară temporală. La o primă vedere, evenimentele din clasa **Tăiere** pot fi identificate destul de ușor în semnalul S_{REF} prin mijloace vizuale, fapt care a fost, în general, adevărat pentru tot setul de date luat în analiză. Pe de altă parte, prin luarea în considerare a unei abordări de delimitare liniară, precum în studiul de caz **SC7**, semnalul A_{REF} a oferit o mai mică separabilitate în pattern-ul său. Aceste două fenomene pot fi explicate prin luarea în considerare a fenomenelor fizico-mecanice care stau la baza proceselor observate. În cazul semnalului nivelului de presiune acustică, separabilitatea evenimentelor din clasa **Tăiere** a fost îmbunătățită de un nivel de zgomot mai ridicat, produs de o manieră mai constantă de interacțiunea lamei cu lemnul. Ca atare, semnalul de ieșire în acest caz a fost mai puțin variabil pe scara de amplitudinii. În cazul semnalului accelerației, se pare însă că mișcarea cadrului de tăiere în evenimente precum cele din clasa **Tăiere** și **Mișcare** a interferat, oferind o separabilitate mai slabă. Deoarece accelerometrul a fost amplasat pe cadrul de tăiere, este posibil ca alte evenimente, externe celor urmărite, să fi putut afecta semnalul accelerației, fapt care a fost valabil și pentru dispozitivul nivelului de presiune acustică, dar într-o măsură mai mică. Din acest punct de vedere și prin luarea în considerare a modalității de amplasare a celor doi colectori de date, informația purtată de sunet poate genera rezultate mai bune în comparație cu cea purtată de accelerație. Statisticile descriptive de bază ale celor două seturi de date (semnale) au relevat câteva informații importante care ar putea fi utilizate pentru a evalua separabilitatea datelor și pentru a justifica necesitatea filtrării acestora. Chiar dacă nu sunt prezentate sub forma unui tabel în această secțiune (rezultatele complete sunt redată în anexele lucrării), în cele ce urmează se prezintă valorile minime, maxime, medii și abaterile standard. De exemplu, în cazul A_{REF} , evenimentele din clasa **Tăiere** au fost caracterizate printr-o gamă de valori cuprinse între 1,01 și 3,78 g, cu o medie $1,16 \pm 0,12$ g; aceleași statistici au fost de 1,01 la 3,51 și $1,17 \pm 0,11$ pentru evenimentele din clasa **Mișcare** și de 1,01 până la 4,98 și $1,14 \pm 0,11$ g pentru evenimentele din clasa **Pauză**. În cazul S_{REF} , acestea au fost de 5,09 până la 10,19 și $8,48 \pm 0,48$ dB(A)/10 pentru evenimentele din clasa **Tăiere**, 2,82 până la 10,02 și $6,26 \pm 0,73$ dB(A)/10 pentru evenimentele din clasa **Mișcare** și de 0,01 până la 10,57 și, respectiv, $4,83 \pm 1,42$ dB(A)/10 pentru evenimentele din clasa **Pauză**. Ca atare, este evident că seturile de date caracterizând semnalele folosite au prezentat posibilități mai limitate pentru o separare liniară; se menționează faptul că frecvența observațiilor pe clase și categorii de magnitudine nu a fost documentată în acest studiu de caz. O parte dintre aceste efecte, reflectate în principalii descriptori statistici (de exemplu, valoarea minimă de 0,01 pentru S_{REF} în cazul clasei **Mișcare**), s-au datorat și unor impulsuri în semnal, precum și erorilor de măsurare și înregistrare, așa cum se arată în **Figura 40**, în partea stângă în cazul S_{REF} și pe partea centrală în cazul A_{REF} .




Figura 40. Exemplu de set de date comun a celor două semnale filtrate cu indicarea evenimentelor din cele trei clase delimitate.

Legendă: roșu - S_{REF} (dB(A)/10), verde - A_{REF} (g), negru - evenimente (0 - pauză, 1 - mișcare, 2 - tăiere)

Tabelul 15 prezintă ponderea claselor de evenimente în semnalele utilizate, precum și mărimea seturilor de date folosite în anumite scopuri specifice. Deși se obișnuiește în multe metode de învățare supervizată să se utilizeze o proporție mai mare a setului de date inițial pentru etapa de învățare a unui model, în acest studiu de caz au fost utilizate doar 25% din datele inițiale pentru etapa de învățare a **ANN**. Această abordare a avut la bază presupunerea că efortul și resursele de calcul ar trebui să fie menținute la minimum.

Tabelul 15. Semnalele utilizate și ponderea claselor în acestea

Tip de semnal și scopul în care a fost utilizat	Număr de observații	Ponderea evenimentelor (%) în numărul de observații		
		Tăiere	Mișcare	Pauză
Filtrat, după îndepărtarea porțiunilor nerelevante (A, S, A&S)	78.189	20,29	13,40	66,31
Filtrat, pentru învățare (A, S, A&S)	20.050	18,47	13,00	68,53
Filtrat, pentru testare (A, S, A&S)	58.139	20,20	13,11	66,68

După cum se prezintă în **Tabelul 15**, proporțiile claselor reale de evenimente, codificate în seturile de date ale semnalelor utilizate, au fost similare, oferind, din acest punct de vedere, un echilibru bun al datelor utilizate în diferite etape ale implementării **ANN**. Acestea reflectă, de asemenea, proporțiile consumului de timp în grupele de operații care caracterizează eficiența producției. După cum se prezintă, aproape 70% din timp a fost utilizat pentru diferite pauze și numai circa 30% pentru operare. Totodată, numai circa 20% din timp a fost utilizat pentru tăiere efectivă. În aceste condiții, este destul de obișnuit ca astfel de utilaje să proceseze mai puțin de 10 m³ pe zi și, cel mai probabil, până la 5 m³ pe zi.

4.8.2. Rezultatele învățării și selectarea modelului

Rezultatele etapei de învățare a **ANN**, care a utilizat cele trei semnale de intrare filtrate, sunt prezentate în **Tabelul 16**. La folosirea ambelor semnale filtrate (**AS_{MTRAIN}**) în procesul de învățare, au fost necesare de circa de 2,8 ori mai multe resurse de timp în comparație cu utilizarea numai a semnalului accelerației (**A_{MTRAIN}**) și de circa de 2 ori mai multe resurse de timp în comparație cu utilizarea doar a semnalului de nivel de presiune acustică (**S_{MTRAIN}**). Semnificația și modul de calcul a indicatorilor performanței clasificării sunt cele prezentate în subcapitolul 4.2.1. În ceea ce privește indicatorul **AUC**, judecând la nivelul seturilor de date utilizate pentru învățare, semnalul **AS_{MTRAIN}** a oferit cele mai bune rezultate, în timp ce **A_{MTRAIN}** le-a oferit pe cele mai slabe. Având în vedere aceeași scară, **S_{MTRAIN}** a generat o valoare a **AUC** similară cu cea generată de **AS_{MTRAIN}**, diferența fiind de 0,005. La nivel de clasă de evenimente, se pare însă că, pentru clasa **Mișcare**, valorile **AUC** au fost cele mai slabe. Situația privind indicatorul **CA** a fost similară cu cea a indicatorului **AUC**, ceea ce indică o performanță a clasificării mai bună pentru **AS_{MTRAIN}**, și care a fost comparabilă cu cea specifică **S_{MTRAIN}**. Cu toate acestea, la nivel de clasă de evenimente, cele mai slabe rezultate au fost cele asociate cu clasa **Pauză**. În ceea ce privește precizia (**PREC**) sau valorile pozitive, la nivelul seturilor de date ale semnalelor de instruire, situația a fost similară valorilor înregistrate pentru indicatorii **AUC** și **CA**; pentru semnalul **AS_{MTRAIN}**, s-a constatat valoarea cea mai mare, iar pentru semnalul **A_{MTRAIN}**, **PREC** a prezentat o valoare foarte scăzută.

Tabelul 16. Rezultatele cu privire la indicatorii performanței clasificării în urma instruirii **ANN**

Semnal de intrare	Timpul de învățare (s)	Clasă de evenimente	Indicator al performanței clasificării				
			<i>AUC</i>	<i>CA</i>	<i>F1</i>	<i>PREC</i>	<i>REC</i>
AS_{MTRAIN}	350	Pauză	0,938	0,871	0,910	0,873	0,951
		Mișcare	0,888	0,884	0,400	0,608	0,299
		Tăiere	0,997	0,977	0,939	0,927	0,951
		Total	0,944	0,866	0,849	0,848	0,866
A_{MTRAIN}	125	Pauză	0,635	0,685	0,813	0,685	1,000
		Mișcare	0,588	0,870	0,000	0,000	0,000
		Tăiere	0,629	0,815	0,001	1,000	0,000
		Total	0,617	0,685	0,558	0,654	0,685
S_{MTRAIN}	175	Pauză	0,932	0,860	0,903	0,862	0,947
		Mișcare	0,880	0,878	0,362	0,570	0,265
		Tăiere	0,996	0,975	0,934	0,929	0,939
		Total	0,939	0,857	0,838	0,837	0,857

Așa cum se arată în **Tabelul 16**, situația cu privire la indicatorul **REC** a menținut **AS_{MTRAIN}** ca fiind cel mai bun semnal în etapa de învățare; în clasamentul valorilor pentru acest indicator, el a fost urmat îndeaproape de **S_{MTRAIN}**. La nivel general, indicatorul **REC** pentru **AS_{MTRAIN}** a atins valoarea de 0,87 (87%) și a prezentat valori de circa 95% pentru clasele **Pauză** și **Tăiere**. A prezentat, în schimb, valori mici pentru clasa **Mișcare** (cca 30%). În cazul **A_{MTRAIN}**, valorile obținute cu privire la indicatorul **REC** au fost cele mai slabe, indicând incapacitatea semnalului de a furniza informația necesară pentru o diferențiere între clasele de evenimente. Ca atare, algoritmul a generat o valoare de 1,0 pentru clasa **Pauză** și valori nule pentru celelalte clase de evenimente. Rezultatele cu privire la indicatorul **REC** pentru **S_{MTRAIN}**, pe de altă parte, au indicat valori similare cu cele de la **AS_{MTRAIN}**. Indicatorul **F1** reprezintă media armonică a **PREC** și **REC**.

4.8.3. Statistici descriptive și performanța clasificării în etapa de testare

Deoarece setul de date specific semnalului AS_{MTRAIN} a furnizat cele mai bune rezultate cu privire la indicatorii performanței clasificării în etapa de învățare, pasul următor, constând din etapa de testare a ANN , a fost implementat pe setul de date al semnalului de testare corespunzător (AS_{MTEST}). Performanța generală a clasificării pe setul de date al semnalului de testare a fost caracterizată de valori ale indicatorilor performanței clasificării după cum urmează: AUC de 0,939, CA de 0,849, $PREC$ de 0,832 și REC de 0,849 (Tabelul 17). În numărul total de observații clasificate corect, proporțiile claselor de evenimente **Tăiere**, **Mișcare** și **Pauză** au fost de circa 23, 5 și 72% (Tabelul 17).

Tabelul 17. Numărul și ponderea clasificărilor corecte în setul de date de testare și indicatori globali ai performanței clasificării

Caracteristici	Număr de observații	Ponderea celor clasificate corect	Indicatori ai performanței clasificării				
			AUC	CA	$F1$	$PREC$	REC
Total clasificate corect	49.366	100					
Tăiere	11.330	22,95					
Mișcare	2.577	5,22					
Pauză	35.459	71,83					
Performanța totală	-	-	0,939	0,849	0,838	0,832	0,849

Chiar dacă rezultatele cu privire la acești indicatori au indicat o bună performanță a clasificării, un număr de 8.773 de observații din semnalul AS_{MTEST} au fost incorect clasificate (Tabelul 18), reprezentând o pondere de circa 15%. În acest sub-eșantion, cea mai mare problemă legată de inexactitatea clasificării pare a fi cea a clasificării greșite a evenimentelor din clasa **Mișcare** ca evenimente din clasa **Pauză** (aproximativ 54%). Această situație a fost urmată de clasificarea greșită a evenimentelor din clasa **Pauză** ca evenimente din clasa **Mișcare** (aproximativ 26%) și a evenimentelor din clasa **Pauză** ca evenimente din clasa **Tăiere** (aproximativ 12%). Doar 416 observații specifice evenimentelor din clasa **Tăiere** au fost clasificate greșit ca evenimente din clasa **Pauză** (aproximativ 4%) sau din clasa **Mișcare** (aproximativ 1%).

Tabelul 18. Numărul și ponderea clasificărilor greșite din setul de date pentru testare

Clase interpretate greșit	Număr de observații	Ponderea clasificării în categorii greșite (%)
Total observații clasificate greșit	8.773	100,00
Tăiere clasificat greșit ca Pauză	341	3,89
Tăiere clasificat greșit ca Mișcare	75	0,85
Mișcare clasificat greșit ca Tăiere	303	3,45
Mișcare clasificat greșit ca Pauză	4.745	54,09
Pauză clasificat greșit ca Tăiere	1.016	11,58
Pauză clasificat greșit ca Mișcare	2.293	26,14

Luând în considerare datele prezentate în **Tabelele 17 și 18**, indicatorul REC pentru evenimentele din clasa **Tăiere** a prezentat o valoare de aproximativ 96%, pentru clasa **Mișcare** de aproximativ 39% și pentru clasa **Pauză** de aproximativ 91,5%, rezultate care au fost similare cu cele prezentate în **Tabelul 16** pentru REC calculat pentru AS_{MTRAIN} . Ca atare, se poate concluziona faptul că modelul utilizat în etapa de testare a generat rezultate foarte bune din punctul de vedere al performanței clasificării. Acest lucru poate fi observat pentru evenimentele din clasele **Tăiere** și **Pauză** în cazul indicatorului REC , care a fost caracterizat de valori foarte bune, în timp ce ponderea acestor clase de evenimente în seturile de date folosite pentru instruire și testare a fost cea mai mare (Tabelul 15).

4.9. Discuții

În cazul **SC1** rezultatele arată că se poate realiza o diferențiere între cele două regimuri operaționale mai importante, care sunt legate și de consumul de energie. Acest lucru ar putea contribui la încercarea de a îmbunătăți designul experimental specific studiilor cu privire la intrările de energie în operațiile de doborâre și fasonare a arborilor cu ferăstrăul mecanic, deoarece astfel de studii pot ajuta la caracterizarea performanței de mediu ca efect al condițiilor operaționale luate în studiu (Balimunsi et al. 2012, Ignea et al. 2017). De asemenea, este posibil să se obțină rezultate mai precise prin adoptarea unei rate de eșantionare mai ridicate, o opțiune care ar trebui explorată în continuare. Ca atare, abordarea utilizată în acest studiu de caz poate face față cerințelor de colectare a datelor pe termen lung, pentru a obține rezultate mai precise necesare în îmbunătățirea sau dezvoltarea modelelor predictive cu privire la consumul de timp și pentru a stabili indicatori de cost și de productivitate mai preciși. Cu toate acestea, abordarea folosită în acest studiu de caz nu permite încă o automatizare completă a colectării și analizei datelor, deoarece este încă necesară intervenția omului, pentru stabilirea pragurilor de separare a regimurilor de funcționare. O îmbunătățire din acest punct de vedere poate fi adusă prin folosirea tehnicilor inteligenței artificiale care au fost abordate în studiul de caz **SC2**.

Astfel, în conformitate cu rezultatele generate în **SC2**, utilizarea rețelelor neuronale artificiale pentru prelucrarea datelor colectate automat cu ajutorul unor senzori indică faptul că, din punctul de vedere al performanței clasificării, se pot obține rezultate foarte bune, depinzând de parametrii care se utilizează pentru etapa de învățare a **ANN**. Principala problemă legată de separarea evenimentelor pe clase și performanța clasificării a fost cea legată de clasa de evenimente **Turat**. Constatarea poate să nu fie rezultatul unui fenomen aleator, deoarece, în acest caz, motorul ferăstrăului a fost operat la o viteză mai mare și variabilă, dar ferăstrăul nu a fost angajat în tăiere și, ca atare, senzorul de accelerație a produs un semnal variabil pe scara amplitudinii și timpului. Deși abordarea utilizată a încercat să asigure un echilibru între precizia sau finețea de colectare a datelor și capacitatea stocării datelor furnizată de colectorul de date, ar fi fost interesantă abordarea conform căreia rata de eșantionare ar fi fost stabilită la mai mult de 1Hz. În ce măsură ar fi fost îmbunătățite rezultatele cu privire la performanța clasificării printr-o abordare de filtrare a semnalelor folosindu-se serii mai mari de date (în studiul de caz filtrul a folosit seturi de date consecutive de câte trei valori pentru a calcula valorile mediane) este o întrebare la care va trebui răspuns prin alte studii de viitor. Din acest punct de vedere, în măsura în care seriile de valori consecutive folosite pentru filtrare devin mai ample, disponibilitatea observațiilor filtrate devine mai limitată, aspect care a limitat această abordare în studiul de caz de față. Studiul de caz de față a fost de tipul „trial-and-error” ceea ce presupus realizarea unor încercări până la obținerea celor mai bune rezultate. Prin urmare, rezultatele obținute se limitează ca aplicabilitate la setul din care provin și, prin studii de viitor, ar trebui verificat dacă o creștere a numărului de iterații sau a numărului de neuroni față de cele utilizate în acest studiu de caz va îmbunătăți performanța clasificării; ce se poate specula pe marginea acestui demers, este faptul că o creștere a valorilor atribuite acestor parametri va conduce și la necesitatea unor resurse mai mari de calcul.

În general, în cazul instalațiilor cu cabluri care funcționează gravitațional, viteza de deplasare a căruciorului la cursa înspre aval este mai mare (Gallo et al. 2013) aspect care poate să permită diferențierea unor regimuri de funcționare. Această situație s-a identificat și prin abordarea studiului de caz specific (**SC3**) cu privire la utilizarea colectoarelor **GPS** și a senzorilor de nivel de presiune acustică. Mișcarea căruciorului cu viteze mari conduce și la creșterea nivelului de presiune acustică, aspect ce poate contribui la diferențierea regimurilor de funcționare. Pe baza datelor utilizate în acest studiu, care au acoperit aproximativ 11 ore de observație, și prin compararea regimurilor de funcționare delimitate de algoritm cu datele colectate de senzorii de nivel de presiune acustică, s-a constatat că algoritmul utilizat furnizează date precise, în limita a $\pm 2\%$ pentru două regimuri: mișcare și oprit.

În cazul **SC4**, se arată că timpul productiv (t_p) a reprezentat mai puțin de 34% din totalul timpului consumat și luat în analiză, iar producția realizată (P , m^3) a fost estimată la aproape $150 m^3$ pe baza numărului de arbori recoltați în timpul studiului (31 de exemplare) și a volumului arborelui mediu. În urma doborârii și fasonării arborilor a rezultat un consum de amestec de carburant de $4,350 l$ ($0,029 l \times m^{-3}$) și un consum de lubrifiant de $1,480 l$ ($0,010 l \times m^{-3}$), indicând o cantitate mică de combustibili consumați. În ceea ce privește productivitatea netă și cea brută (P_{NETA} , P_{BRUTA}), acestea au fost evaluate la $23,81$, respectiv $8,04 m^3 \times h^{-1}$. Doborârea și fasonarea unui metru cub (E_{NETA}) a necesitat $0,04$ ore, în ipoteza excluderii diferitelor tipuri de întâzieri. Cu toate acestea, în condițiile reale ale studiului, eficiența (E_{BRUTA}) a fost caracterizată de o valoare de $0,12 h \times m^{-3}$.

În ceea ce privește **SC5**, acesta a testat capabilitățile de colectare și analiză-interpretare automată a datelor, prin integrarea colectării automate a datelor de teren (prin utilizarea senzorilor de măsurare a nivelului de presiune acustică), cu folosirea tehnicilor inteligenței artificiale (prin dezvoltarea și testarea unei rețele neuronale artificiale). Scopul final a fost acela de a separa datele cu privire la consumul de timp pe categorii, printr-un experiment condus în condiții reale asupra unui ferăstrău mecanic. Pentru etapa de învățare, rezultatele generate de acest studiu de caz indică faptul că abordarea utilizată a generat rezultate foarte bune din punctul de vedere al performanței clasificării, precizia acesteia fiind, în general, de $97,8\%$. Indicatorul **REC**, care poate fi cel mai important pentru aplicațiile ce vizează clasificarea consumului de timp, a înregistrat în etapa de învățare a **ANN** o valoare de aproximativ $97,7\%$. În urma etapei de testare, la nivel global, s-au înregistrat valori chiar mai bune ale indicatorilor performanței clasificării în comparație cu cele specifice modelului generat în urma etapei de învățare. Astfel, performanța generală a etapei de testare a fost caracterizată de valori ale **PREC** de 98% și **REC** de 98% . Aceste valori indică o performanță ridicată a clasificării prin utilizarea semnalului filtrat cu privire la nivelul de presiune acustică.

Un studiu de caz dintre cele tratate (**SC6**) a luat în considerare colectarea și evaluarea integrată a unor parametri ergonomici în operațiile de recoltare cu ferăstraie mecanice. Acești parametri s-au referit la estimarea efortului fizic și a nivelului de dificultate a muncii, precum și la expunerea la zgomot și la riscurile asociate cu posturile de muncă. În principiu, senzorii s-au utilizat pentru a colecta date cu privire la efortul fizic și la expunerea la zgomot. În astfel de studii, o descriere sumară a condițiilor operaționale și a performanței productive ajută la o înțelegere mai bună a sarcinilor de muncă, precum și a acelor factori care pot să genereze riscuri de muncă. Există numeroase studii în literatura internațională care au evaluat consumul de timp și productivitatea operațiilor de doborâre și fasonare a arborilor cu ferăstrăul mecanic, precum și studii care au modelat consumul de timp în funcție de variația condițiilor operaționale (Borz 2014b). În ceea ce privește productivitatea operațiilor de doborâre și fasonare a arborilor, rezultatele din acest studiu de caz sunt comparabile cu cele raportate de alte studii pentru cazul unor arbori voluminoși (e.g. Jourgholami et al. 2013), urmând astfel legitatea piesă-volum (e.g. Heinimann 2007), dar nu se insistă aici asupra lor. Ritmul cardiac (efortul cardio-vascular) este considerat a fi un bun predictor al efortului fizic și al dificultății muncii numai în intervalul de $100-140$ bpm (Helander 2006), aspect ce a fost valabil și pentru rezultatele obținute prin acest studiu de caz. Ceea ce s-a constatat prin studiul de caz a fost faptul că dificultatea muncii, probabil resimțită și de muncitor, apreciată prin indicatorii descriși de literatura de specialitate cu privire la ritmul cardiovascular, a depășit majoritatea pragurilor ce delimitează munca obișnuită de cea grea și foarte grea (e.g. Potočnik și Poje 2017). Rezultatele cu privire la dinamica observată a ritmului cardio-vascular se datorează mai multor factori, inclusiv celor relaționați cu părțile din corp care sunt angajate în muncă. De exemplu, în timpul operațiilor de doborâre și fasonare a arborilor cu ferăstrăul mecanic, o mare parte a operațiilor se realizează prin folosirea într-o proporție mare a brațelor și a picioarelor, aspect indicat și prin acest studiu de caz care a pus în evidență faptul că cea mai mare parte a timpului productiv a constat din elemente de muncă ce au implicat folosirea brațelor. De asemenea, există studii care indică faptul că și cele mai mici modificări ale posturii adoptate în muncă pot provoca modificări semnificative ale ritmului cardiovascular (e.g. Jones et al. 2003). În conformitate cu rezultatele acestui studiu de caz, posturile care au fost caracterizate de riscurile cele mari de dezvoltare a unor afecțiuni ale sistemelor osos și

muscular au fost, de asemenea, asociate cu valorile cele mai mari ale indicatorului **%HRR**. Deşi nu s-au pus în evidenţă relaţii de dependenţă între cei doi parametri, rezultatele acestui studiu de caz subliniază necesitatea de a realiza studii mai detaliate, care să poată identifica în ce măsură postura de muncă afectează dinamica cardio-vasculară a muncitorului. O altă constatare a fost aceea că pauzele de odihnă şi de masă au fost insuficiente pentru recuperarea şi stabilizarea activităţii cardiovasculare a muncitorului. Din acest punct de vedere, literatura de specialitate indică faptul că, în funcţie de intensitatea exerciţiului, recuperarea cardio-vasculară poate dura până la 30 de minute (Javorka et al. 2002). În ceea ce priveşte expunerea la zgomot şi în comparaţie cu caracteristicile altor locuri de muncă (Poje et al. 2016) operaţiile de doborâre şi fasonare a arborilor cu ferăstrăul mecanic nu se realizează în staţionar, motiv pentru care expunerea la zgomot depinde în mare măsură de sarcina realizată şi de postura adoptată de muncitor, dat fiind faptul că distanţa faţă de sursa de zgomot influenţează nivelulul zgomotului care ajunge la urechea operatorului (Helander 2006). Din cunoştinţele proprii, la data publicării acestor rezultate, acest studiu de caz a fost primul care a utilizat colectori de date miniaturizaţi pentru a urma fidel relaţia dintre sarcinile de muncă şi nivelul de expunere la zgomot. O interpretare a celor prezentate anterior este cea conform căreia, pentru un acelaşi element de muncă şi pentru un acelaşi muncitor, pot să apară variaţii semnificative cu privire la expunerea la zgomot, ca urmare a strategiei proprii pe care muncitorul o adoptă în muncă. Din acest punct de vedere, distanţa dintre sursă şi ureche este influenţată de posturile adoptate în muncă, aspect care trebuie clarificat prin luarea în considerare a unor studii desfăşurate pe un eşantion reprezentativ de muncitori şi care să ofere posibilitatea evaluării integrate a sistemului postură adoptată-efort fizic-expunere la factori nocivi. Chiar dacă nu s-a prezentat explicit în rezultatele obţinute prin acest studiu de caz, pentru acele elemente de muncă care au fost observate pe durata timpului de muncă productivă, a existat o relaţie de dependenţă semnificativă ($R^2 = 0,6$, $\alpha = 0,05$, $p < 0,05$) între nivelul de expunere la zgomot (**LAeq**, dB(A)) şi indicele de risc postural (**PRI**). Un alt aspect care merită menţionat este acela că valorile limită de expunere stabilite de reglementările existente (Directiva 2003/10/CE) au fost depăşite în majoritatea sarcinilor observate, precum şi la nivelul global al studiului. Constatarea a fost reflectată şi de valoarea indicatorului $L_{EX,8h}$, ceea ce indică faptul că astfel de operaţii nu pot fi executate fără echipament de protecţie împotriva zgomotului. Totuşi, s-a constatat faptul că pe durata studiului realizat în teren, muncitorul nu a purtat echipament de protecţie împotriva zgomotului. Se precizează faptul că, utilizarea unor dispozitive specifice de protecţie, cum ar fi dopurile pentru urechi, ar fi oferit o atenuare a zgomotului cuprinsă între 15 dB pentru sunete de joasă frecvenţă şi 35 dB pentru cele de frecvenţe mai înalte (Helander 2006). În acelaşi timp, căştile moderne pot oferi o atenuare a zgomotului de circa 26 dB. Prin urmare, în condiţiile observate în acest studiu, oricare dintre aceste alternative de protecţie ar fi redus expunerea la o doză acceptabilă. În ceea ce priveşte evaluarea posturală, indicele de risc postural (**PRI**) a fost estimat în acest studiu la o valoare de 275 care este comparabilă cu cele raportate pentru situaţii similare (e.g. Calvo 2009). De exemplu, Calvo (2009) a constatat că peste 50% din posturile eşantionate pentru operaţii de doborâre şi fasonare a arborilor cu ferăstrăul mecanic au fost atribuite categoriilor de 3 şi 4. Rezultatele acestui studiu de caz cu privire la evaluarea posturală sunt comparabile cu cele raportate de alţii şi confirmă probleme cunoscute; astfel, principalele probleme posturale sunt cele legate de postura spatelui, care s-a dovedit a fi îndoit şi răsucit în 67% dintre imaginile analizate, precum şi de cea a picioarelor care au fost identificate cu genunchii flexaţi în 54% dintre cazuri. Astfel de posturi pot duce la simptome specifice afecţiunilor sistemelor muscular şi osos, cum ar fi durerile localizate în partea inferioară şi superioară a spatelui şi a genunchilor, simptome care par a fi cele mai frecvente în rândul muncitorilor care lucrează în operaţii forestiere de exploatare a lemnului (Grzywinski et al. 2016). Deşi multe dintre rezultatele raportate prin acest studiu de caz se încadrează în ceea ce se cunoaşte şi confirmă unele aspecte cu privire la dificultatea şi pericolozitatea operaţiilor de doborâre şi fasonare a arborilor cu ferăstraie mecanice, contribuţia importantă a acestui studiu de caz este cea care se referă la integrarea setului de senzori externi pentru a colecta date cu privire la mai mulţi parametri ergonomici, precum şi cu privire la consumul de timp. Pe baza unor semnale colectate, se

poate merge mai departe la identificarea și clasificarea automată a unor elemente de muncă, inclusiv prin tehnicile inteligenței artificiale descrise prin studiile de caz anterioare. Ca atare, marele avantaj legat de metoda testată nu este doar cel legat de faptul că ea permite colectarea datelor pe termen lung, fără intervenția observatorului în acest demers, dar și faptul că semnalele colectate permit automatizarea prelucrării, analizei și interpretării datelor colectate prin astfel de procedee.

În cazul testării capacității senzorilor de măsurare a nivelului de presiune acustică de a colecta date automat cu privire la consumul de timp și a unor praguri liniare artificiale de a separa datele pe categorii, printr-un experiment condus în condiții reale asupra unui ferăstrău circular specific studiului de caz **SC7**, s-a constatat că abordarea utilizată are un potențial ridicat de clasificare a datelor, deoarece aceasta a fost în măsură să separe cu exactitate cele două regimuri operaționale legate de economisirea de energie.

În cazul testării capacității senzorilor de accelerație și de nivel de presiune acustică de a colecta date automat cu privire la consumul de timp și a tehnicilor inteligenței artificiale bazate pe rețele neuronale artificiale de a separa datele pe categorii, printr-un experiment condus în condiții reale asupra unui ferăstrău panglică specific studiului de caz **SC8**, s-au constatat mai multe aspecte. Astfel, rețelele neuronale artificiale (**ANN**), precum și alte tehnici specifice domeniului mai larg al inteligenței artificiale (**AI**) au fost utilizate destul de frecvent pentru rezolvarea unor probleme de clasificare în diverse domenii ale științei și practicii. Rezultatele unor lucrări recente din domeniul forestier indică faptul că aceste tehnici au generat rezultate bune atât în problemele de clasificare (Keefe et al., 2019), cât și în cele de regresie (Proto et al., 2020); astfel de tehnici s-au utilizat și în domenii conexe, precum agricultura (Kamilaris și Prenafeta-Boldu 2018) și, sub raportul rezultatelor, preciziile de clasificare mai mari de 90% au fost descrise ca fiind foarte bune (Kamilaris și Prenafeta-Boldu 2018). Rezultatele acestui studiu indică faptul că abordarea utilizată a generat rezultate foarte bune din punctul de vedere al performanței clasificării, precizia atingând valori apropiate de 90% indiferent de clasa de evenimente; aceasta a fost, de asemenea, apropiată ca valoare de 100% în etapa de învățare pentru evenimentele din clasa **Tăiere**. Ca atare, chiar dacă ponderea evenimentelor **Tăiere** a fost scăzută, recunoașterea cu precizie a acestora este importantă, deoarece astfel de evenimente sunt cele în decursul cărora se folosește energia electrică și care, sub raportul performanței operaționale, indică eficiența tehnică. În ceea ce privește indicatorul **REC**, pentru evenimentele din clasa **Tăiere**, acesta a avut o valoare apropiată de 96%, rezultate ce pot fi interpretate ca fiind foarte bune; totuși, aceste rezultate indică, prin extrapolare, că din fiecare oră de tăiere efectivă, aproape 2,5 minute din această clasă de evenimente vor fi clasificate greșit. S-a constatat că în etapa de învățare, semnalele nivelului de presiune acustică au oferit performanțe de clasificare similare cu cele privind folosirea ambelor semnale (nivel de presiune acustică și accelerație). Probabil că utilizarea mai multor date în etapa de învățare ar fi oferit rezultate mult mai bune, fapt ce trebuie verificat, de asemenea, deoarece studii similare au utilizat, de obicei, raporturi de până la 90-10% între seturile de date folosite pentru învățare și, respectiv, testare (Kamilaris și Prenafeta-Boldu 2018).

CAPITOLUL 5. CONCLUZII. RECOMANDĂRI ŞI DIRECŢII VIITOARE DE CERCETARE. CONTRIBUŢII PERSONALE. DISEMINAREA REZULTATELOR CERCETĂRII

5.1. Concluzii

Având în vedere obiectivele propuse, următoarele afirmații prezintă, pe scurt, concluziile cu privire la rezultatele obținute și la interpretarea lor, într-o abordare sistematizată. Astfel, pot fi prezentate următoarele:

I.) Primul obiectiv al prezentei teze de doctorat a fost acela de a caracteriza conceptele, terminologia și definițiile cu privire la știința muncii și la măsurarea muncii prin studii de timp și producție, cât și cele cu privire la senzori, tipurile de studii implementate, abordările utilizate, echipamentele și instrumentele folosite. Având în vedere acest obiectiv, se concluzionează următoarele:

1. În prezent, chiar dacă au fost implementate noi abordări în studiile privind măsurarea muncii, conceptele originale sunt încă cele ale lui Taylor, bineînțeles, cu adaptările de rigoare impuse de diverse sectoare de activitate, în care se încadrează și sectorul forestier, pentru care s-a dezvoltat o terminologie specifică, încercându-se, în ultimul timp, armonizarea modului de implementare a studiilor la nivel internațional. Deși există un real potențial în automatizarea unei mari părți specifice acestor studii, cercetătorii de profil sugerează faptul că metodele clasice sunt încă indispensabile științei muncii, acestea având un rol important pentru testarea metodelor noi ce se introduc sau se propun;

2. În acest sens, abordările moderne sunt promițătoare sub raportul colectării automate a datelor, dar principala problemă asociată cu acestea rămâne efortul mare în procesarea și urii mari de date rezultate în urma colectării. Cu toate acestea, acest tip de abordare poate fi utilizat pentru realizarea studiilor pe termen lung, nefiind necesară intervenția omului în teren. Chiar dacă nivelul de mecanizare a progresat în ultimele decenii, multe din echipamentele utilizate în sectorul forestier nu au capacități de a colecta automat datele de interes, acest fapt datorându-se, de cele mai multe ori, costurilor de achiziție ridicate pentru integrarea unor astfel de senzori. Din acest punct de vedere, monitorizarea operațiilor printr-un sistem de senzori ar putea produce economii substanțiale.

II.) Al doilea obiectiv al prezentei lucrări a fost acela de a testa posibilitățile de utilizare a senzorilor în aplicații de măsurare a muncii în operații forestiere prin studii de caz. Raportat la acest obiectiv și la studiile de caz implementate, se pot concluziona următoarele:

1. În cazul testării capacității senzorilor externi (colectori de date) de a recunoaște diverse elemente de muncă și funcții tehnice, ca fiind specifice operațiilor de doborâre și fasonare a arborilor cu ferăstrăul mecanic, rezultatele obținute sunt încurajatoare, abordarea utilizată putând separa cu precizie mare cele două regimuri operaționale importante, legate de economisirea energiei și comportamentul operațional: mers în gol versus tăiere;

2. În urma dezvoltării și testării unui algoritm capabil să extragă consumul de timp pe elemente de muncă și funcții tehnice, din datele colectate cu ajutorul dispozitivelor **GPS** și a senzorilor de măsurare a nivelului de presiune acustică, un avantaj care a fost identificat constă în automatizarea procesării datelor, care are potențialul de a îmbunătăți gestionarea timpului în astfel de activități, precum și de a oferi premisele unei prelucrări complete a datelor, prin folosirea unui set de praguri. Cu toate acestea, pentru a putea construi modele pentru consumul de timp, încă mai este necesară dezvoltarea algoritmului pentru o organizare suplimentară a datelor;

3. Senzorii de măsurare a nivelului de presiune acustică pot fi, de asemenea, utilizați pentru a extrage informații importante cu privire la funcțiile tehnice și elementele de muncă specifice funicularilor, iar acestea pot fi combinate cu date **GPS** pentru a facilita o diferențiere a acestora cu o precizie mai mare;

4. Pragurile utilizate pentru a diferenția dinamica cinematică a căruciorului au constat din simulări bazate pe un set de date disponibile, fără validare prin comparare cu realitatea. Cu toate acestea,

interpretarea datelor cu ajutorul algoritmului, pentru cele două seturi de date (**GPS** vs. nivelul de presiune acustică), a prezentat multe similitudini, motiv pentru care se poate recurge, în multe dintre cazuri, doar la utilizarea datelor **GPS**. Ca atare, datele colectate de senzorul de nivel de presiune acustică a validat într-un mod corespunzător datele colectate prin procedee **GPS** și analizate prin utilizarea algoritmului;

5. În ceea ce privește învățarea din datele colectate cu senzori, se poate concluziona că implementarea unei arhitecturi **ANN** asupra unor semnale filtrate are un potențial mare în monitorizarea pe termen lung a operațiilor realizate cu ferăstraie mecanice, iar prin studiul de caz specific, s-au evidențiat parametrii care necesită o reglare fină pentru a obține rezultate de calitate prin tehnica **ANN**;

6. În ceea ce privește studiul de caz realizat în condiții reale, rezultatele indică faptul că dispozitivele de colectare a datelor cu privire la nivelul de presiune acustică și tehnicile **AI** de tipul **ANN** au un potențial promițător pentru colectarea, prelucrarea și analiza datelor privind separarea evenimentelor de tăiere efectivă față de restul activităților realizate în timpul operațiilor de doborâre și fasonare a arborilor cu ferăstraie mecanice.

III.) Al treilea obiectiv al prezentei lucrări a fost acela de a testa posibilitățile de utilizare a senzorilor în aplicații de măsurare a muncii în operații de prelucrare a lemnului prin studii de caz. În conformitate cu acest obiectiv și cu rezultatele obținute, se pot concluziona următoarele:

1. În cazul monitorizării unor unelte relativ simple (ferăstraie circulare), care produc și un nivel de presiune acustică ridicat, abordarea de utilizare a unui senzor de măsurare a nivelului de presiune acustică și a unor praguri liniare arbitrare de separare a regimurilor de funcționare este destul de practică și a produs rezultate încurajatoare, deoarece această abordare poate separa cu exactitate consumul de timp pentru cele două regimuri operaționale care au legătură cu economisirea de energie: funcționare versus oprit. Rezultatele au fost, însă, mai imprecise în cazul identificării numărului de piese secționare cu ferăstrăul circular. O automatizare completă, atât pentru culegerea datelor, cât și pentru analiza acestora, nu este încă realizabilă, deoarece este încă nevoie de intervenția omului, în faza de birou, pentru stabilirea pragurilor și algoritmilor folosiți pentru a putea separa cu exactitate regimurile de funcționare. Este probabil ca o abordare de tipul **ANN** să fi furnizat o clasificare mult mai precisă a datelor;

2. În ceea ce privește integrarea semnalelor culese cu ajutorul unor senzori externi, cu tehnicile specifice inteligenței artificiale, pentru a monitoriza automat performanțele unui ferăstrău panglică acționat manual, concluzia principală este că sistemul testat deține un potențial promițător pentru implementarea în colectarea, prelucrarea și analiza automată a unor seturi de date mari, la costuri reduse și în timp real; totuși, limitele actuale sunt cele legate de necesitatea conectării dispozitivelor colectoare cu un computer, fapt care ar putea fi realizat prin proceduri de programare.

IV.) Al patrulea obiectiv a fost cel de a dezvolta și testa o metodă, bazată pe senzori externi, pentru colectarea integrată a unor parametri ergonomici în operații de doborâre și fasonare a arborilor cu ferăstrăul mecanic. În conformitate cu acest obiectiv, se pot concluziona următoarele:

1. Senzorii integrați în dispozitive miniaturizate, cum ar fi cei ce au capacitatea de a măsura ritmul cardiac și nivelul de presiune acustică pot fi utilizați integrat în colectarea de date pe durată mare cu privire la efortul fizic și la expunerea la zgomot. Abordarea metodei a fost validată în condiții reale de desfășurare a operațiilor, presupune o investiție mică și poate servi la automatizarea prelucrării datelor chiar prin folosirea tehnicilor specifice **AI**. Ea are și potențialul de a furniza informațiile necesare pentru o delimitare a consumului de timp pe elemente de muncă;

2. Din punct de vedere ergonomic, operațiile de doborâre și fasonare a arborilor de plop, cu ferăstraie mecanice în tăieri rase aplicate în teren așezat sunt grele și periculoase, provoacă un efort cardio-vascular mare și pot să expună muncitorii la niveluri inacceptabile de zgomot. Prin posturile adoptate, ele pot să genereze riscuri crescute de îmbolnăvire profesională.

5.2. Recomandări și direcții viitoare de cercetare

I. Privind testarea posibilității de utilizare a senzorilor în aplicații de măsurare a muncii în operații forestiere prin studii de caz:

1. În cazul monitorizării ferăstrirelor mecanice, este posibil să se obțină rezultate mai precise prin ajustarea ratei de eșantionare la un interval de timp mai scurt. În general, utilizarea senzorilor în colectarea de date privind utilizarea ferăstrirelor mecanice ar putea economisi timp și alte resurse importante, ceea ce ar putea permite colectarea de date pe intervale de timp mai mari, care să acopere variabilitatea indusă de condițiile operaționale, structura organizatorică, antropometria muncitorilor, precum și comportamentul lor general și operațional. Prin studii de viitor, aceste aspecte ar trebui să fie documentate mai în detaliu pentru a putea oferi rezultate mai concludente;
2. În cazul monitorizării operaționale a instalațiilor cu cabluri, a existat un acord relativ bun între interpretarea datelor de către algoritmul creat și variațiile altitudinii și vitezei, corespunzătoare datelor extrase din fișierul **GPS**. Totuși, unele părți din date pot fi interpretate greșit, aspect care se datorează faptului că anumite valori extrase pot corespunde în mod întâmplător valorilor stabilite ca prag. Pentru evitarea acestor interpretări greșite, ar trebui efectuate studii comparative care să ofere informația necesară identificării valorilor alese ca praguri;
3. În cazul implementării sistemelor descrise, trebuie găsite cele mai bune locuri de amplasare-montare a senzorilor, locuri care ar trebui să fie menținute pe termen lung și care pot presupune dezvoltarea unor noi modele, mai precise și mai adaptate, de **ANN**-uri.

II. Privind testarea posibilității de utilizare a senzorilor în aplicații de măsurare a muncii în operații de prelucrare a lemnului prin studii de caz:

1. În cazul monitorizării instalațiilor de prelucrare a lemnului, nu este recomandabil să se amplaseze senzori de nivel de presiune acustică la distanțe mari de sursa care emite sunetul, deoarece sunetul/zgomotul emis de alte echipamente sau activități poate interfera cu cel al echipamentului studiat. Totodată, este posibil să se obțină rezultate mai exacte prin ajustarea ratei de eșantionare, o opțiune ce trebuie să fie explorată pe viitor;
2. În ipoteza unor implementări pe termen lung a sistemelor descrise, trebuie găsite cele mai bune locuri de amplasare-montare a senzorilor, locuri care ar trebui să fie menținute pe termen lung și care pot presupune dezvoltarea unor noi modele, mai precise și mai adaptate, de **ANN**-uri.

5.3. Contribuții personale

Principalele contribuții personale, sub raport științific și practic, sunt cele ce se prezintă în continuare. Astfel:

1. Utilizarea senzorilor pentru colectarea de date cu privire la consumul de timp în operații de recoltare realizate cu ferăstraie mecanice este abia la începuturi. Din cunoștințele proprii, la data implementării testelor de teren existau puține studii și soluții pentru acest demers. Informal, un astfel de sistem provine din Elveția iar un patent pe problema respectivă provine din Japonia. Acestea sunt integrabile în ferăstraie mecanice dar presupun costuri adiționale pentru operarea lor. Prin urmare, există mari diferențe între abordările utilizate în această lucrare și ceea ce există în prezent; acestea constau din utilizarea de senzori externi și implementarea atât a unor tehnici simple cât și a unor tehnici mai avansate, specifice inteligenței artificiale bazate pe rețelele neuronale artificiale pentru a colecta, analiza și interpreta date, atât în studii simulate cât și în studii conduse în condiții operaționale reale;
2. În astfel de demersuri, printr-o abordare ce a presupus simularea, au fost evidențiați în premieră, pentru cazul monitorizării ferăstrirelor mecanice, parametrii care necesită o reglare fină pentru a obține rezultate de calitate prin aplicarea rețelelor neuronale artificiale (**ANN**);

3. De asemenea, s-au testat pentru prima dată capacitățile senzorilor externi de măsurare a nivelului de presiune acustică de a colecta date automat cu privire la consumul de timp și a tehnicilor inteligenței artificiale bazate pe rețele neuronale artificiale de a separa datele pe categorii, printr-un experiment condus în condiții reale, asupra unui ferăstrău mecanic. La data implementării experimentelor de teren acest demers a fost printre primele la nivel internațional. De asemenea, s-a identificat doar un studiu care a fost realizat pe o problemă similară și care a folosit senzorii încorporați în telefoane mobile;

4. Pentru cazul specific al operațiilor de recoltare a lemnului cu ferăstraie mecanice, după cunoștințele proprii, s-a dezvoltat și aplicat în premieră o metodă capabilă să colecteze concomitent date cu privire la parametrii ergonomici precum efortul fizic și nivelul de expunere la zgomot. Deși rezultatele obținute prin studiul de caz respectiv sunt indicative și necesită validarea pe populații mai mari, aspectul nou adus de studiul de caz se referă la metoda folosită pentru colectarea și analiza datelor;

5. După cunoștințele proprii, pentru cazul ferăstrierilor panglică caracterizate de un nivel de mecanizare redus s-au implementat primele studii care au vizat automatizarea colectării, analizei și interpretării datelor, aspect care este important pentru colectarea de date pe termen lung și pentru monitorizarea acestor utilaje, mai ales pe fondul inexistenței unor sisteme de monitorizare a producției și a largii răspândiri a acestui tip de utilaje în operațiile de prelucrare a lemnului din România.

5.4. Diseminarea rezultatelor cercetării

5.4.1. Rezultate produse în cadrul tezei de doctorat

A. Lucrări publicate în reviste BDI

1. **Cheța, M.**, Borz, S.A. (2017): *Automating data extraction from GPS files and sound pressure level sensors with application in cable yarding time and motion studies*. **Bulletin of the Transilvania University of Brasov. Forestry, Wood Industry, Agricultural Food Engineering. Series II**, 10(59), 1-10.

2. **Cheța, M.**, Șerban, D., Ignea, G., Derczeni, R.A., Sfeclă, V., Borz, S.A. (2017): *Using sound pressure sensors to monitor the performance of manually operated circular saws: What parameters and to what extent can they be inferred?* **Revista Pădurilor** 132(1), 15-22.

3. **Cheța, M.**, Talagai, N. (2017): *Using motion detection and sound pressure sensors to automate data collection in motor-manual production studies*. **Revista Pădurilor** 132(4), 18-29

4. **Cheța, M.**, Marcu, M.V., Borz, S.A. (2020): *Effect of training parameters on the ability of artificial neural networks to learn: a simulation on accelerometer data for task recognition in motor-manual felling and processing*. **Bulletin of the Transilvania University of Brasov. Forestry, Wood Industry, Agricultural Food Engineering. Series II**, 13 (62), 19-36.

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

1. **Cheța, M.**, Marcu, M.V., Borz, S.A. (2018): *Workload, exposure to noise, and risk of musculoskeletal disorders: A case study of motor-manual tree felling and processing in poplar clear cuts*. **Forests**, 9(6), 300.

2. **Cheța, M.**, Marcu, M.V., Iordache, E., Borz, S.A. (2020): *Testing the capability of low-cost tools and artificial intelligence techniques to automatically detect operations done by a small-sized manually driven bandsaw*. **Forests**, 11(7), 739.

5.4.2. Rezultate produse prin participarea în echipe de cercetare externe sferei de doctorat

A. Lucrări publicate în reviste BDI

1. Talagai, N., **Cheța, M.**, (2017): *Work performance in manual manufacturing of willow bundles for bioengineering applications*. **Revista Pădurilor** 132(3), 42-49.
2. Afrăsinei, I., **Cheța, M.**, Talagai, N., Mușat, E.C., Borz, S.A., (2017): *Testing the capacity of willow short rotation crops to act as sound barriers*. **Revista Pădurilor** 132(4), 3-17.
3. Marogel-Popa, T., Marcu, M.V., Cheța, M., Nuță, S.I., Borz, S.A., (2020), *Dificultatea muncii în operații de plantare a puieților și a sadelor de plop: analiza ritmului cardiac*. **Revista Pădurilor** 135(2), 43-62.

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

1. Borz, S.A., Talagai, N., **Cheța, M.**, Gavilanes Montoya, A.V., Castillo Vizuet, D.D., (2018): *Automating data collection in motor-manual time and motion studies implemented in a willow short rotation coppice*. **Bioresources** 13(2), 3236-3249.
2. Marogel-Popa, T., **Cheța, M.**, Marcu, M.V., Duță, C.I., Ioraș, F., Borz, S.A., (2019): *Manual cultivation operations in poplar stands: A characterization of job difficulty and risks of health impairment*. **International Journal of Environmental Research and Public Health** 16(11), 1911.
3. Borz, S.A., Talagai, N., **Cheța, M.**, Chiriloiu, D., Gavilanes Montoya, A.V., Castillo Vizuet, D.D., Marcu, M.V., (2019): *Physical strain, exposure to noise and postural assessment in motor-manual felling of willow short rotation coppice: Results of a preliminary study*. **Croatian Journal of Forest Engineering** 40(2), 377-388

C. Lucrări prezentate la conferințe și simpozioane internaționale

1. Talagai, N., **Cheța, M.**, Gavilanes, A., Castillo, D.D., Borz, S.A., (2019): *Predicting time consumption of chipping tasks in a willow short rotation coppice from Global Positioning System and acceleration data*. Proceedings of the Biennial International Symposium "Forest and Sustainable Development" 8th Edition, Brasov 25-27 October 2018, 1-12.

Bibliografie

1. Ackerman, P., Belbø, H., Eliasson, L., De Jong, A., Lazdins, A., Lyons, J. (2014): The COST model for calculation of forest operations cost. *International Journal of Forest Engineering* 25: 75–81.
2. Acuna, M., Bigot, M., Guerra, S., Hartsough, B., Kanzian, C., Kärhä, K., Lindroos, O., Magagnotti, N., Roux, S., Spinelli, R., Talbot, B., Tolosana, E., Zormaier, F. (2012): Good practice guidelines for biomass production studies. *Forest Energy*, (<http://www.forestenergy.org/pages/cost-action-fp0902/good-practice-guidelines>), Accesat in 18 Martie 2019.
3. Acuna, M., Skinnel, J., Evanson, T., Mitchell, R. (2011): Bunching with a self-levelling feller-buncher on steep terrain for efficient yarder extraction. *Croatian Journal of Forest Engineering* 32(2): 521-531, DOI: 10.1080/14942119.2014.903711
4. Aggarwal, C.C. (2018): *Neural Networks and Deep Learning*. Springer, Cham, 493pp., ISBN: 978-3-319-94463-0.
5. Alam, M., Acuna, M., Brown, M. (2013): Self-levelling feller-buncher productivity based on Lidar-derived slope. *Croatian Journal of Forest Engineering* 34(2): 273-281.
6. Apăfăian, A.I., Proto, A.R., Borz, S.A. (2017): Performance of a mid-sized harvester-forwarder system in integrated harvesting of sawmill, pulpwood and firewood. *Annals of Forest Research* 60(2): 227-241, DOI: 10.15287/afr.2017.909.
7. Åstrand, P.O.; Rodahl, K. (1989): *Textbook of Work Physiology - Physiological Bases of Exercise*. 3rd ed.; McGraw-Hill, New York, U.S.A., 756p, ISBN 978-007-00241-8-6.
8. Atanasov V., Todorov M., Spasov V. (2018): Research on the quality of processing with a horizontal bandsaw. *Innovation in Woodworking Industry and Engineering Design* 1/2018 (13): 5–11.
9. Balimunsi, H., Grigolato, S., Picchio, R., Nyombi, K., Cavalli, R. (2012): Productivity and energy balance of forest plantation harvesting in Uganda. *Forestry Studies China* 14(4): 276-282, DOI: 10.1007/s11632-012-0404-y.
10. Bariska M., Pásztor Z. (2015): The optimum log feed speed with bandsaw. *European Journal of Wood and Wood Products* 73(2): 245-250.
11. Björheden, R., Apel, K., Shiba, M., Thompson, M. (1995): *IUFRO Forest Work Study Nomenclature*. Swedish University of Agricultural Sciences Department of Operational Efficiency, Uppsala, Sweden. 16p.
12. Behjou, F.K., Majouninan, B., Dvorak J., Namiranian, M., Saeed, A., Fegghi, J. (2009): Productivity and cost of manual felling with a chainsaw in Caspian forests. *Journal of Forest Science* 55(2): 96-100, DOI: 10.17221/69/2008-JFS.
13. **Borz, S.A., Talagai, N., Cheța, M., Chiriloiu, D., Gavilanes Montoya, A.V., Castillo Vizuite, D.D., Marcu, M.V. (2019): Physical strain, exposure to noise and postural assessment in motor-manual felling of willow short rotation coppice: results of a preliminary study. *Croatian Journal of Forest Engineering* 40: 377-388.**
14. **Borz, S.A., Talagai, N., Cheta, M., Gavilanes Montoya, A.V., Castillo Vizuite, D.D. (2018): Automating data collection in motor-manual time and motion studies implemented in a willow short rotation coppice. *Bioresources* 13: 3236–324, DOI:10.15376/biores.13.2.3236-3249.**
15. Borz, S.A. (2016): Turning a winch skidder into a self-data collection machine using external sensors: a methodological concept. *Bulletin of the Transilvania University of Braşov* 9(58): 1-6.
16. Borz S.A., Adam M. (2015): Analiza fişierelor video în studii de timp prin utilizarea de software gratuit sau cu cost redus: factori care influențează cantitativ consumul de timp la procesare și predicția acestuia. *Revista Pădurilor* 130(3/4): 60-71.

17. Borz, S.A., Ignea, G., Popa, B., Sparchez, G., Iordache, E. (2015): Estimating time consumption and productivity of roundwood skidding in group shelterwood system - a case study in a broad leaved mixed stand located in reduced accessibility conditions. *Croatian Journal of Forest Engineering* 36(1): 137–146.
18. Borz, S.A., Ignea, G., Popa, B. (2014a): Modelling and comparing timber winching performance in windthrow and uniform selective cuttings for two Romanian skidders. *Journal of Forest Research* 19(6): 473–482, DOI: 10.1007/s10310-014-0439-0.
19. Borz, S.A., Bîrda, M., Ignea, Gh., Popa, B., Câmpu, V.R., Iordache, E., Derczeni, R.A. (2014b): Efficiency of a Woody 60 processor attached to a Mounty 4100 tower yarder when processing coniferous timber from thinning operations. *Annals of Forest Research* 57(2): 333-345, DOI: 10.15287/afr.2014.258.
20. Borz, S.A., Ignea, G., Vasilescu, M.M. (2014c): Small gains in wood recovery rate when disobeying the recommended motor-manual tree felling procedures: another reason to use the proper technical prescriptions. *Bioresources* 9(4): 6938–6949, DOI: 10.15376/biores.9.4.6938-6949.
21. Borz, S.A. (2014a): Evaluarea eficienței echipamentelor și sistemelor tehnice în operații forestiere. Editura Lux Libris, Braşov, 251 p. ISBN 978-973-131-294-1.
22. Borz, S.A. (2014b): Eficiența în utilizare a ferăstraielor mecanice în operații de recoltare a lemnului - o sinteză a preocupărilor științifice naționale și internaționale. *Revista Pădurilor* 129(3-4), 80–96.
23. Borz, S.A., Ciobanu, V.D. (2013): Efficiency of motor-manual felling and horse logging in small-scale firewood production. *African Journal of Agricultural Research* 8(24): 3126–3135, DOI: 10.5897/AJAR2013.7306.
24. Borz, S.A., Dinulica, F., Bîrda, M., Ignea, G., Ciobanu, V.D., Popa, B. (2013): Time consumption and productivity of skidding Silver fir (*Abies alba* Mill.) round wood in reduced accessibility conditions: a case study in windthrow salvage logging from Romanian Carpathians. *Annals of Forest Research* 56(2): 363–375, DOI: 10.15287/afr.2013.38.
25. Bush, C., Volk, T.A., Eisenbies, M.H. (2015): Planting rates and delays during the establishment of willow biomass crops. *Biomass and Bioenergy* 83: 290-296, DOI: 10.1016/j.biombioe.2015.10.008.
26. Bovenzi, M. A. (2008): A follow up study of vascular disorders in vibration-exposed forestry workers. *International Archives of Occupational and Environmental Health* 81: 401–408, DOI: 10.1007/s00420-007-0225-9.
27. Calvo, A., Manzone, M., Spinelli, R. (2013): Long term repair and maintenance cost of some professional chainsaws. *Croatian Journal of Forest Engineering* 34(2): 265–272.
28. Calvo, A. (2009): Musculoskeletal disorders (MSD) risks in forestry: a case study to propose an analysis method. *Agricultural Engineering International* 11: 1–9.
29. Cavalli R. (2012): Prospects of research on cable logging in forest engineering community. *Croatian Journal of Forest Engineering* 33(2): 339-356.
30. Cepișcă, C., Jula, N. (1998): Traductoare și senzori, Editura ICPE, București.
31. Cheța, M., Borz, S.A. (2017): Automating data extraction from GPS files and sound pressure level sensors with application in cable yarding time and motion studies. *Bulletin of the Transilvania University of Braşov* 10(59): 1-10.
32. Cheța, M., Talagai, N. (2017): Using motion detection and sound pressure sensors to automate data collection in motor-manual production studies. *Revista Pădurilor* 132(4): 18-29.
33. Cheța, M., Șerban, D., Ignea, Gh., Derczeni, R.A., Sfeclă, V., Borz, S.A. (2017): Using sound pressure sensors to monitor the performance of manually operated circular saws: what parameters and to what extent can they be inferred? *Revista Pădurilor* 132(1): 15-22.
34. Cheța M., Marcu M.V., Borz S.A. (2018): Workload, Exposure to Noise, and Risk of Musculoskeletal Disorders: A Case Study of Motor-Manual Tree Felling and Processing in Poplar Clear Cuts. *Forests* 9(6), 300, DOI: <https://doi.org/10.3390/f9060300>

35. Contreras, M., Freitas, R., Ribeiro, L., Stringer, J., Clark, C. (2017): Multi-camera surveillance system for time and motion studies of timber harvesting equipment. *Computers and Electronics in Agriculture* 135: 208-215, DOI: 10.1016/j.compag.2017.02.005
36. Cordero R., Mardones O., Marticorena M. (2006): Evaluation of forestry machinery performance in harvesting operations using GPS technology. *Precision Forestry in Plantations, Semi-Natural and Natural Forests, Proceedings of the International Precision Forestry Symposium, Stellenbosch University, South Africa*, pp 163- 173
37. Corella Justavino, F., Jimenez Ramirez, R., Meza Perez, N., Borz, S.A. (2015): The use of OWAS in forest operations postural assessment: advantages and limitations. *Bulletin of the Transilvania University of Braşov* 8(57): 7–16.
38. Davis, C.T., Kellogg, L.D. (2005): Measuring machine productivity with the MultiDAT datalogger: A demonstration on three forest machines. USDA Forest Service. Gen. Tech. Rep. PSW-GTR-194
39. David, G.C. (2005): Ergonomic methods for assessing exposure to risk of factors for work-related musculoskeletal disorders. *Occupational Medicine* 55(3): 190–199, DOI: <https://doi.org/10.1093/occmed/kqi082>
40. de Hoop, C.F., Dupre, R.H. (2006): Using GPS to document skidder motions – a comparison with manual data collection. In *Proceedings: “Working Globally –Sharing Forest Engineering Challenges and Technologies around the World” of the Council of Forest Engineering (COFE). 29th Annual Meeting. Coeur d’Alene, Idaho, USA*, pp 393-402
41. Demsar, J., Curk, T., Erjavec, A., Gorup, C., Hocevar, T., Milutinovic, M., Mozina, M., Polajnar, M., Toplak, M., Staric, A., Stajdohar, M., Umek, L., Zagar, L., Zbontar, J., Zitnik, M., Zupan, B., (2013): Orange: Data Mining Toolbox in Python. *Journal of Machine Learning Research* 14(Aug): 2349-2353.
42. Directive 2003/10/CE of the European Parliament and European Council. Available online: <http://eur-lex.europa.eu/legal-content/RO/TXT/HTML/?uri=CELEX:02003L0010-20081211&from=EN> (accessed on 1st of April 2018).
43. Dubé, P.A.; Imbeau, D.; Dubeau, D.; Lebel, L.; Kolus, A. (2016): Removing the thermal component from heart rate provides an accurate VO₂ estimation in forest work. *Applied Ergonomics* 54: 148–157, DOI: <http://dx.doi.org/10.1016/j.apergo.2015.12.005>
44. Eisenbies, M.H., Volk, T.A., Posselius, J., Foster, C., Shi, S., Karapetyan, S. (2014): Evaluation of a single-pass cut-and-chip harvest system on commercial-scale, short rotation shrub willow biomass crops. *BioEnergy Research* 7(4): 1506-1518, DOI: 10.1007/s12155-014-9482-0
45. Eliasson, L. (1998): Analysis of single-grip harvester productivity. Doctoral thesis. Swedish University of Agricultural Sciences. Department of Operational Efficiency. Umeå. 24 p.
46. Ertel, W. (2017): Introduction to Artificial Intelligence. 2nd edition: © Springer International Publishing AG, 351pp., ISBN: ISSN 2197-1781
47. European Commission. The new EU forest strategy, 2013. Available online: http://eur-lex.europa.eu/resource.html?uri=cellar:2c1c71af-8384-11e3-9b7d01aa75ed71a1.0003.01/DOC_1&format=PDF (accessed on 30th of April 2018)
48. EXTECH[®], 407760: USB Sound Level Datalogger. Available online: <http://www.extech.com/display/?id=14225> (accessed 30th of April 2018).
49. Fawcett, T., (2006): An introduction to ROC analysis. *Pattern Recognition Letters*, 27: 861-874.
50. Fonseca, A., Aghazadeh, F., de Hoop, C., Ikuma, L., Al-Qaisi, S. (2015): Effect of noise emitted by forestry equipment on workers’ hearing capacity. *International Journal of Industrial Ergonomics* 46: 105–112, DOI: 10.1016/j.ergon.2014.05.001

51. Gallo, R., Grigolato, S., Cavalli, R., Mazzetto, F. (2013): GNSS-based operational monitoring devices for forest logging operation chains. *Journal of Agricultural Engineering* XLIV: 140-144, DOI: 10.4081/jae.2013.s2.e27
52. Gallis, C. (2006): Work-related prevalence of musculoskeletal symptoms among Greek forest workers. *International Journal of Industrial Ergonomics* 36: 731–736, DOI: 10.2016/j.ergon.2006.05.007
53. Gerasimov, Y., Senkin, V., Väätäinen, K. (2012): Productivity of single-grip harvesters in clear-cutting operations in the northern European part of Russia. *European Journal of Forest Research* 131(3): 647–654, DOI: 10.1007/s10342-011-0538-9
54. Gerasimov, Y., Seliverstov, A. (2010): Industrial round-wood losses associated with wood harvesting systems in Russia. *Croatian Journal of Forest Engineering* 31(2): 111-126.
55. Ghaffariyan, M.R., Naghdi, R., Ghajar, I., Nikooy, M. (2013): Time prediction models and cost evaluation of cut-to-length harvesting method in a mountainous forest. *Small-Scale Forestry* 12(2): 181-192, DOI: 10.1007/s11842-012-9204-4
56. Gligoraş, D., Borz, S. A. (2015): Factors affecting the effective time consumption, wood recovery and feeding speed when manufacturing lumber using a FBO-02 CUT mobile bandsaw. *Wood research* 60(2):329-338
57. Grandjean, E. (1980): *Fitting the task to the man: an ergonomic approach*. Taylor and Francis: London, UK, pp. 210–211, ISBN 978-973-85874-4-1.
58. Groover, M.P. (2007): *Fundamentals of modern manufacturing, Materials Processes and Systems*. 3rd ed., John Wiley & Sons, Inc., 1022 p, ISBN 978-0-471-74485-6
59. Grzywinski, W., Wandycz, A., Tomczak, A., Jelonek, T. (2016): The prevalence of self-reported musculoskeletal symptoms among loggers in Poland. *International Journal of Industrial Ergonomics* 52: 12–17, DOI: 10.1016/j.ergon.2015.07.003
60. Haykin, S.S. (2006): *Neural networks and learning machines*. Vol. 3, Upper Saddle River: Pearson, 26p
61. Heinimann H.R. (2007): Forest operations engineering and management – the ways behind and ahead of a scientific discipline. *Croatian Journal of Forest Engineering* 28(1): 107-121.
62. Heinimann H.R., Stampfer K., Loschek J., Caminada, J. (2001): Perspectives of Central European cable yarding systems. *International Mountain Logging and 11th Pacific Northwest Skyline Symposium*, December 10-12, 2001, Seattle, Washington, USA., 268-279
63. Hejazian, M., Hosseini, S., Lotfalian, M., Ahmadikoolaei, P. (2013): Possibility of global positioning system (GPS) application for time studies in forest machinery. *European Journal of Experimental Biology* 3(4): 93–98, (www.pelagiaresearchlibrary.com) Accesat in 18 Martie 2019.
64. Helander, M. (2006): *A guide to human factors and ergonomics*. 2nd ed., CRC Press Taylor & Francis Group: Boca Raton London New York, USA, pp. 224–255, ISBN 0-203-68775-2.
65. Hiesl, P., Benjamin, J.G. (2013): Applicability of international harvesting equipment productivity studies in Maine, USA: a literature review. *Forests* 4(4): 898-921, DOI: 10.3390/f4040898
66. Ignea, G., Ghaffaryian, M.R., Borz, S.A. (2017): Impact of operational factors on fossil energy inputs in motor-manual tree felling and processing: results of two case studies. *Annals of Forest Research* 60(1): 161–172, DOI: 0.15287/afr.2016.705
67. Ištvančić, J., Ružica, B-L., Matija J., Karan R. (2009): Analysis of factors affecting log band saw capacity. *Croatian Journal of Forest Engineering* 30 (1): 27-35.
68. Javorka, M., Žila, I., Balhárek, T., Javorka, K. (2002): Heart rate recovery after exercise: relations to heart rate variability and complexity. *Brazilian Journal of Medical and Biological Research*, 35: 991–1000, DOI: 101590/S0100-879X2002000800018

69. Jirousek, R., Klvac, R., Skoupy, A. (2007): Productivity and costs of the mechanised cut-to-length wood harvesting system in clear-felling operations. *Journal of Forest Science* 53(10): 476–48.
70. Johnson, C, D. (1982): *Process control instrumentation technology*. John Wiley & Sons Inc; International 2 Revised Ed edition, 512p, ISBN 978-0471097211
71. Jones, A.Y.M., Kam, C., Lai, K.W., Lee, H.Y., Chow, H.T., Lau, S.F., Wong, L.M., He, J. (2003): Changes in heart rate and R-wave amplitude with posture. *Chinese Journal of Physiology*, 46(2), 63–69,
72. Jourgholami, M., Majnounian, B., Zargham, N. (2013): Performance, capability and costs of motor-manual tree felling in Hyrcanian hardwood forest. *Croatian Journal of Forest Engineering* 34(2): 283-293.
73. Karhu, O., Kansi, P., Kuorinka, I. (1977): Correcting working postures in industry: a practical method for analysis. *Applied Ergonomics* 8(4): 199–201, DOI: 10.1016/0003-6870(77)90164-8
74. Kärhä, K., Rönkkö, E., Gumse S.I. (2004): Productivity and cutting costs of thinning harvesters. *International Journal of Forest Engineering* 15(2): 43–56.
75. Kamilaris, A., Prenafeta-Boldu, F.X., (2018): Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147:70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
76. Karsoliya, S., (2012): Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture. *International Journal of Engineering and Technology*, 3(6): 714-717.
77. Keefe, R.F., Zimbelman, E.G., Wempe A.M., (2019): Use of smartphone sensors to quantify the productive cycle elements of hand fallers on industrial cable logging operations, *International Journal of Forest Engineering* 30(2): 132-143. DOI: 10.1080/14942119.2019.1572489
78. Kellog, L.D., Bettinger, P. (1994): Thinning productivity and cost for a mechanized cut-to-length system in the Northwest Pacific Coast Region of the USA. *Journal of Forest Engineering* 5(2): 43–52, DOI: 10.1080/08435243.1994.10702659
79. Kilbom, A. (1995): Measurement and assessment of dynamic work. *Evaluation of Human Work - A Practical Ergonomics Methodology*, Wilson J.R. and Corlett E.N (eds.) 2nd ed. London, UK, Taylor and Francis, 1134 p., ISBN 0748400842.
80. Kingma, D.P., Ba, J.L., (2015): ADAM: A method for stochastic optimization. *Proceedings of ICLR 2015 - International Conference of Learning Representations 2015*.
81. Kirk, P.M., Sullman, M.J.M. (2001): Heart rate strain in cable hauler choker setters in New Zealand logging operations. *Applied Ergonomics* 32: 389–398, DOI: 10.1016/S0003-6870(01)00003-5
82. Košir, B., Magagnotti, N., Spinelli, R. (2015): The role of work studies in forest engineering: status and perspectives. *International Journal of Forest Engineering* 26(3): 160-170.
83. Laschi, A., Marchi, E., Foderi, C., Neri, F. (2016): Identifying causes, dynamics and consequences of work accidents in forest operations in an alpine context. *Safety Science*, 89: 28–35, DOI: 10.1016/j.ssci.2016.05.017
84. Leeb, S.B., Shaw, S.R., (1997): Applications of real-time median filtering with fast digital and analog sorters. *IEEE/ASME Transactions of Mechatronics* 2(2): 136-143.
85. Lindroos, O. (2010): Scrutinizing the theory of comparative time studies with operator as a block effect. *International Journal of Forest Engineering* 21: 20–30, DOI: <https://doi.org/10.1080/14942119.2010.10702587>
86. Lindroos, O., Burstrom, L. (2010): Accident rates and types among self-employed private forest owners. *Accident; analysis and prevention* 42(6): 1729–1735, DOI: 10.1016/j.aap.2010.04.013
87. Maas, A.L., Hannun, A.Y., Ng, A.Y., (2103): Rectifier nonlinearities improve neural network acoustic models. *Proceedings of the 30th International Conference on Machine Learning, Atlanta, Georgia, USA, 2013*. JMLR: W&CP volume 28.

88. Magagnotti, N., Kanzian, C., Schulmeyer, F., Spinelli, R. (2013): A new guide for work studies in forestry. *International Journal of Forest Engineering* 24:249–253, DOI: 10.1080/14942119.2013.856613
89. Magagnotti, N., Spinelli, R. (2012): Replacing steel cable with synthetic rope to reduce operator workload during log winching operations. *Small-Scale Forestry* 11: 223–236, DOI: 10.1007/s11842-011-9180-0
90. Marogel-Popa, T., Cheța, M., Marcu, M.V., Duță, C.I., Ioraș, F., Borz S.A. (2019): Manual cultivation operations in poplar stands: A characterization of job difficulty and risks of health impairment. *International Journal of Environmental Research and Public Health* 16, 1911
91. McDonald, T., Fulton, J. (2005): Automated time study of skidders using global positioning system data. *Computers and Electronics in Agriculture* 48(1): 19-37, DOI: 10.1016/j.compag.2005.01.004.
92. Melemez, K. (2015): Risk factor analysis of fatal forest harvesting accidents: a case study in Turkey. *Safety Science* 79: 369–378, DOI: 10.1016/j.ssci.2015.07.004
93. Montorselli, B.N., Lombardini, C., Magagnotti, C., Marchi, E., Neri, F., Picchi, G., Spinelli, R. (2010): Relating safety, productivity and company type for motor-manual logging operations in the Italian Alps. *Accident Analysis and Prevention* 42: 2013-2017, DOI: 10.1016/j.aap.2010.06.011
94. Mousavi, R., Nikouy, M., Uusitalo, J. (2011): Time consumption, productivity, and cost analysis of the motor manual felling and processing in the Hyrcanian forest in Iran. *Journal of Forestry Research* 22(4): 665-669, DOI: 10.1007/s11676-011-0208-2
95. Mukhopadhyay, S.C. (2013): *Intelligent Sensing, Instrumentation and Measurements*, Springer Heidelberg New York Dordrecht London, 175 p., ISBN 978-3-642-37026-7.
96. Mușat, E.C., Apăfăian, A. I., Ignea, Gh., Ciobanu, V.D., Iordache, E., Derczeni, R.Al., Spârchez, Gh., Vasilescu, M.M., Borz, S.Al. (2016): Time expenditure in computer aided time studies implemented for highly mechanized forest equipment. *Annals of Forest Research* 59(1): _-_-
97. Nair, V., Hinton, G.E., (2010): Rectified linear units improve restricted Boltzmann machines. *Proceedings of the 27th International Conference on Machine Learning*, Haifa, Israel, 2010.
98. Nakagawa, M., Hamatsu, J., Saitou, T., Ishida, H. (2007): Effect of Tree Size on Productivity and Time Required for Work Phases in Selective Thinning by a Harvester. *International Journal of Forest Engineering* 18(2): 24–2, DOI: <https://doi.org/10.1080/14942119.2007.10702547>
99. Nasir, V., Nourian, S., Avramidis, S., Cool, J., (2019): Classification of thermally treated wood using machine learning techniques: *Wood Science and Technology*, 53: 275-288. <https://doi.org/10.1007/s00226-018-1073-3>
100. Neal, C.G. jr.; Gary, L.W. (1981): A theoretical analysis of the properties of median filters. *IEEE T Acoust Speech* 29, 1136 – 1141.
101. Neitzel, R., Yost, M. (2002): Task-based assessment of occupational vibration and noise exposure in forestry workers. *AIHA Journal*, 63: 617–627, DOI: 10.1080/1542811028984748
102. Nikooy, M., Naghdi, R., Ershadifar, M. (2013): Survey of directional felling and analysis of effective factors on felling error (Case study; Iranian Caspian forests). *Caspian Journal of Environmental Science* 11(2): 177-184.
103. Nitami, T., Soil, S., Kataoka, A., Mitsuyama, T. (2011): Tower Yarder operation in Japan and the performance analysis by GPS-based system. *Pushing the boundaries with research and innovation in forest engineering, FORMEC 2011, Proceedings of the 44th International Symposium on Forestry Mechanization*, 9-13 October 2011, Graz, Austria.
104. Nurminen, T., Korpunen, H., Uusitalo, J. (2006): Time consumption analysis of the mechanized cut-to-length harvesting system. *Silva Fennica* 40(2): 335–36, DOI: 10.14214/sf.346.

105. Nuutinen, Y., Väättäin, K., Heinonen, J., Asikainen, A., Röser, D. (2008): The accuracy of manually recorded time study data for harvester operation shown via simulator screen. *Silva Fennica* 42(1): 63–72, DOI: 10.14214/sf.264.
106. Nyland C. (1996): Taylorism, John R. Commons, and the Hoxie report. *Journal of Economic Issues* 30(4): 985-1016, DOI: 10.1080/00213624.1996.11505862.
107. Odhiambo, N.M. (2010): Energy consumption, prices and economic growth in three ssa countries: A comparative study. *Energy Policy* 38(5): 2463-2469, DOI: 10.1016/j.enpol.2009.12.040
108. Olivera, A., Visser, R. (2016): Using the harvester on-board computer capability to move towards precision forestry. *New Zealand Journal of Forestry* 60(4): 3-7,
109. Oprea, I. (2008): *Tehnologia Exploatării Lemnului*. Transilvania University Press, Braşov, Romania, pp. 9–93, ISBN 978-973-598-301-7.
110. Ottaviani, G., Talbot, B., Nitteberg, M., Stampfer, K. (2010): Workload benefits of using synthetic rope strawline in cable yarder rigging in Norway. *Croatian Journal of Forest Engineering* 32(2): 561–569.
111. Ovaskainen, H. (2009): Timber harvester operators' working technique in first thinning and the importance of cognitive abilities on work productivity. Doctoral thesis. University of Eastern Finland. *Dissertationes Forestales* 79, 62p
112. Palander, T., Ovaskainen, H., Tikkanen, L. (2012): An adaptive work study method for identifying the human factors that influence the performance of a human–machine system. *Forest Science* 58(4): 377–389, DOI: <https://doi.org/10.5849/forsci.11-013>
113. Panchal, F.S., Panchal, M., (2014): Review on methods of selecting number of hidden nodes in Artificial Neural Network. *International Journal of Computer Science and Mobile Computing*, 3(11): 455-464.
114. Parker, R., Vitalis, A., Moore, D., Ashby, L., Baillie, B., Amishev, D. (2010): Wearable video to record tree felling work methods, In: Paper Presented at the 43th International Symposium on Forestry Mechanisation: “Forest Engineering: Meeting the Needs of the Society and the Environment”, Padova, Italia
115. Partel, V., Kakarla, S.C., Ampatzidis, Y., (2019): Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence. *Computers and Electronics in Agriculture*, 157: 339-350. <https://doi.org/10.1016/j.compag.2018.12.048>
116. Poje, A., Spinelli, R., Magagnotti, N., Mihelic, M. (2018): The effect of feedstock, knife wear and work station on the exposure to noise and vibrations in wood chipping operations. *Silva Fennica* 52(1): 14p., DOI: <https://doi.org/10.14214/sf.7003>
117. Poje, A., Spinelli, R., Magagnotti, N., Mihelic, M. (2015): Exposure to noise in wood chipping operations under the conditions of agro-forestry. *International Journal of Industrial Ergonomics* 50: 151–157, DOI: 10.1016/j.ergon.2015.08.006
118. Poje, A., Potočnik, I., Danilovic, M., AntoniĆ, S. (2016): A case study of the impact of skidding distance on tractor operator exposure to noise. *Baltic Forestry* 22(2): 357–364.
119. Ponsse (2005): The cut-to-length harvesting system, citat în Adebayo, A.B., Han, H.-S., Johnson, L., 2007: Productivity and cost of cut-to-length and whole-tree harvesting in a mixed-conifer stand. *Forest Products Journal* 57(6): 59-69.
120. Potočnik, I., Poje, A. (2017): Forestry ergonomics and occupational safety in high ranking scientific journals from 2005-2016. *Croatian Journal of Forest Engineering* 38(2): 291–310.
121. Proto, A.R., Sperandio, G., Costa, C., Maesano, M., Antonucci, F., Macri, G., Scarascia Mugnozza, G., Zimbalatti, G., (2020): A three-step neural network artificial intelligence modeling approach for time, productivity and costs prediction: A case study in Italian forestry. *Croatian Journal of Forest Engineering* 41(1): 15pp. DOI: <https://doi.org/10.5552/crojfe.2020.611>

122. Purfürst, F.T., Lindroos, O. (2011): The long-term productivity's correlation with subjective and objective ratings of harvester operators. *Croatian Journal of Forest Engineering* 32:509–519
123. Purfürst, F.T. (2010): Learning curves of harvester operators. *Croatian Journal of Forest Engineering* 31(2): 89–97.
124. Puttock, D., Spinelli, R., Hartsough, B.R. (2005): Operational trials of cut-to-length harvesting of poplar in a mixed wood stand. *Journal of Forest Engineering* 16(1): 39–4
125. Rauch, P., Wolfsmayra, U.J., Borz, S.A., Triplat, M., Krajnc, N., Kolck, M., Oberwimmer, R., Ketikidis, C., Vasiljevic, A., Stauder, M., Mühlberg, C., Derczeni, R., Oravec, M., Krissakova, I., Handlos, M. (2015): SWOT analysis and strategy development for forest fuel supply chains in South East Europe. *Forest Policy and Economics* 61: 87-94.
126. Rodahl, K. (1989): *The physiology of work*. 1st ed., Taylor and Francis: London, UK, pp. 335–336, ISBN 0-85066-478-0.
127. Rottensteiner, C., Stampfer, K. (2013): Evaluation of operator vibration exposure to chainsaw equipped with a Kesper safety bar. *Scandinavian Journal of Forest Research* 28(2): 193–200, DOI: 10.1080/02827581.2012.706636
128. Rottensteiner, C., Tsioras, P., Stampfer, K. (2012): Wood density impact on hand-arm vibration. *Croatian Journal of Forest Engineering* 33(2): 303-312.
129. Sbera, I. (2007): Wood resources and market potential [in Romania]. *Meridiane Forestiere* 2: 3-7.
130. Sheela, K.G., Deepa, S. N. (2013): Review on methods to fix number of hidden neurons in neural networks. *Mathematical Problems in Engineering* Volum 2013, Article ID 425740, 11p., <http://dx.doi.org/10.1155/2013/425740>
131. Silayo, Dos S.A., Kiparu, S.S., Mauya, E.W., Shemwetta, D.T.K. (2010): Working conditions and productivity under private and public logging companies in Tanzania. *Croatian Journal of Forest Engineering* 31(1): 65–74.
132. Skogforsk (2012): StanForD. <http://www.skogforsk.se/en/About-skogforsk/Collaboration-groups/StanForD/>
133. Spinelli, R., Aminti, G., Magagnotti, N., de Francesco, F. (2018): Postural risk assessment of small-scale debarkers for wooden post production. *Forests* 9(3): 111, DOI: 10.3390/f9030111
134. Spinelli, R., Aminti, G., de Francesco, F. (2016): Postural risk assessment of firewood processing. *Ergonomics* 60(3): 1-9, DOI: 10/1080/00140139.2016.1172738
135. Spinelli, R., Ottaviani Aalmo, G., Magagnotti, N. (2014): The effect of a slack-pulling device in reducing operator physiological workload during log winching operations. *Ergonomics* 58(5): 781–790, DOI: 10.1080/00140139.2014.983184
136. Spinelli, R., Laina-Relaño, R., Magagnotti, N., Tolosana, E. (2013): Determining observer and method effect on the accuracy of elemental time studies in forest operations. *Baltic Forestry* 19(2): 301-306
137. Spinelli, R., Schweier, J., de Francesco, F. (2012): Harvesting techniques for non-industrial biomass-plantations. *Biosystems Engineering* 113 (4): 319-324.
138. Spinelli, R., Visser, R. (2008): Analyzing and estimating delays in harvester operations. *International Journal of Forest Engineering* 19(1): 36–41, DOI: <https://doi.org/10.1080/14942119.2008.10702558>
139. Spinelli, R., Owende, P.M.O., Ward, S. (2002): Productivity and cost of CTL harvesting of *E. globulus* stands using excavator-based harvesters. *Forest Products Journal* 52(1): 67-77
140. Stampfer, K., Leitner, T., Visser, R. (2010): Efficiency and ergonomic benefits of using radio controlled chokers in cable yarding. *Croatian Journal of Forest Engineering* 31(1): 1–9.
141. Strandgard, M., Mitchell, R. (2015): Automated time study of forwarders using GPS and a vibration sensor. *Croatian Journal of Forest Engineering* 36(2): 175-184

142. Strandgard, M., Walsh, D., Acuna, M. (2013): Estimating harvester productivity in *Pinus radiata* plantations using StanForD stem files. *Scandinavian Journal of Forest Research* 28(1): 73–80, DOI: 10.1080/02827581.2012.706633
143. Talagai, N., Borz, S.A., Ignea, G. (2017): Performance of brush cutters in felling operations of willow short rotation coppice. *Bioresources* 12(2): 3560-3569, DOI: 10.15376/biores.12.2.3560-3569
144. Talagai, N., Borz, S.A. (2016): Concepte de automatizare a activităţii de colectare a datelor cu aplicabilitate în monitorizarea performanţei productive în operaţii de gestionare a culturilor de salcie de rotaţie scurtă. *Revista Pădurilor* 131(3/4): 74-90.
145. **Talagai, N., Cheţa, M. (2017): Work performance in manual manufacturing of willow bundle for bioengineering applications. *Revista Pădurilor* 132(3): 42-49.**
146. Taylor F.W. (1895): A piece-rate system being a step toward partial solution of the labor problem. *Trans Am Soc Mec Eng.* 16: 865–903.
147. Taylor, S. E., McDonald, T. P., Veal, M. V. & Grift, T. E. (2001): Using GPS to evaluate the productivity and performance of forest machine systems. In: D. Briggs (Char), *Proceedings of the first international precision forestry co-operative symposium*, Seattle, University of Washington, pp. 151-156.
148. Toupin, D., LeBel, L., Dubeau, D., Imbeau, D., Bouthillier, L. (2007): Measuring the productivity and physical workload of brushcutters within the context of a production-based pay system. *Forest Policy and Economics* 9: 1046–1055, DOI: 10.1016/j.forpol.2006.10.001
149. Tsioras, P.A., Rottensteiner, C., Stampfer, K. (2014): Wood harvesting accidents in the Austrian State Forest Enterprise 2000-2009. *Safety Science* 62: 400–408, DOI: 10.1016/j.ssci.2013.09.016
150. Tunay, M., Melemez, K. (2008): Noise induced hearing loss of forest workers in Turkey. *Pakistan Journal of Biological Sciences* 1(17): 2144–2148, DOI: 10.3923/pjbs.2008.2144.2148
151. Veal, M.W., Taylor, S.E., McDonald, T.P., McLemore, D.K., Dunn, M.R. (2001): Accuracy of tracking forest machines with GPS. *Transactions of the ASAE* 44(6): 1903–1911, DOI: 10.13031/2013.6978
152. Visser, R., Spinelli, R. (2012): Determining the shape of the productivity function for mechanized felling and felling-processing. *Journal of Forest Research* 17(5): 397-402, DOI: 10.1007/s10310-011-0313-2
153. Wang, J., Long, C., McNeel, J., Baumgras, J. (2004): Productivity and cost of manual felling and cable skidding in central Appalachian hardwood forests. *Forest Products Journal* 54(12): 45-51.
154. Wang, J., LeDoux, C.B. (2003): Estimating and validating ground-based timber harvesting production through computer simulation. *Forest Science* 49(1): 64-76
155. Wang, P., Liu, Q. (2011): *Advanced topics in science and technology in China*. Zhejiang University Press, Hangzhou, China, 293 pp., ISBN 978-7-308-08269-3
156. Wasson, C.S. (2015): *System engineering analysis, design, and development: Concepts, principles, and practices*. John Wiley & Sons, Inc, 821 p. ISBN-13 978-0-471-39333-7
157. Yongang, W., Baojun, J. (1998): Effects of low temperature on operation efficiency of tree-felling by chainsaws in north China. *Journal of Forestry Research* 9(1): 57–58, DOI: 10.1007/BF02856458
158. Zanuttini, R., Cielo, P., Poncino, D. (2005): The OWAS method. Preliminary results for the evaluation of the risk of work-related musculo-skeletal disorders (WMSD) in the forestry sector in Italy. *Forest@ - Rivista Di Selvicoltura Ed Ecologia Forestale* 2: 242–255, DOI: 10.3832/efor0294-0020242
159. Zinkevičius, R., Steponavičius, D., Vitunskas, D., Činga, G. (2012): Comparison of harvester and motor-manual logging in intermediate cuttings of deciduous stands. *Turkish Journal of Agriculture and Forestry* 36: 591-600, DOI: 10.3906/tar-1103-46

ANEXE

Anexa 3. Rezumat /Abstract

Rezumat

Identificarea unor modalități de automatizare a activităților de colectare, analiză și interpretare a datelor, reprezintă o provocare actuală în majoritatea domeniilor de activitate cu beneficii evidente, în special în ceea ce privește gestionarea timpului. În cadrul acestei teze, s-au evaluat utilitatea și limitările folosirii senzorilor și a tehnicilor inteligenței artificiale (AI) bazate pe rețele neuronale artificiale (ANN) în colectarea, analiza și interpretarea automată a datelor specifice studiilor de timp aplicate în operațiile forestiere și în cele ale industriei de prelucrare a lemnului. În cazul operațiilor forestiere, au fost monitorizate echipamente cu grad variat de mecanizare, precum ferăstrăul mecanic și funicularul. Abordările utilizate în ceea ce privește ferăstrăul mecanic au indicat faptul că ele au un potențial promițător. Astfel, utilizarea unor praguri artificiale pentru separarea timpului în diferite regimuri de funcționare este realizabilă și suficient de precisă. Prin utilizarea unor algoritmi de clasificare ANN, a rezultat o mărime generală a indicatorului REC între 0,173 și 0,981, ceea ce înseamnă că algoritmul a avut capacitatea de a clasifica corect între 17,3 și 98,1% dintre datele de intrare cu privire la accelerație. În cazul utilizării algoritmilor pe datele provenite de la un senzor de nivel de presiune acustică, s-au constatat rezultate bune atât pentru etapa de învățare cât și pentru etapa de testare. În etapa de învățare, indicatorul REC a avut o valoare de 97,7%, iar în etapa de testare de 98%. Printr-o abordare metodologică integrată de monitorizare a operațiilor de doborâre și fasonare a arborilor s-au obținut rezultate relevante cu privire la consumul de timp, productivitate, expunere la zgomot, efort și posturi de muncă, o astfel de metodă putând să fie generalizată pentru conducerea de studii pe termen lung. Utilizarea combinată a unor receptoare GPS cu senzori de nivel de presiune acustică pentru monitorizarea funicularelor, a condus la diferențe mici ($\pm 2\%$) între cele două, sub raportul clasificării evenimentelor. În cazul operațiilor de prelucrare a lemnului, s-a monitorizat activitatea unui ferăstrău circular și a unui ferăstrău panglică, ambele caracterizate de un grad redus de mecanizare. Precizia de identificare a timpului de funcționare și nefuncționare în cazul ferăstrăului circular a fost ridicată (99,8 și, respectiv, 99,5%). Utilizarea tehnicilor ANN în etapa de învățare și testare a datelor cu privire la ferăstrăul panglică a condus la rezultate foarte bune cu privire la precizia clasificării. Abordările metodologice prezentate în această lucrare pot fi deosebit de utile în conducerea de studii pe termen lung, iar rezultatele obținute pot să ofere un punct de plecare pentru demersuri similare.

Abstract

Finding ways to automate the activities related to data collection, analysis and interpretation is a current challenge in most areas of activity, with obvious benefits, especially in terms of time saving. This thesis aimed to evaluate the usefulness and limitations of the use of sensors and techniques of artificial intelligence (AI) based on artificial neural networks (ANN) in the automatic collection, analysis and interpretation of data specific to time studies applied in forest and wood processing operations. In the case of forest operations, monitoring was implemented on equipment characterized by various degrees of mechanization, such as the chainsaws and cable yarders. The tests done by case studies on the motor-manual work have shown a promising potential. Using artificial thresholds for various chainsaw work regimes has led to an accurate separation of such regimes. By using some ANN classification algorithms on data provided by an accelerometer, it was found that the recall metric had values as high as 0.981, which means that by using this kind of techniques one could correctly classify as much as 98.1% of the data. When using this kind of techniques on data collected by sound pressure level sensors, excellent results were found both, for training and testing phases. In the learning phase, the value of recall indicator was of 97.7% while in the testing phase it reached to 98%. By the use of an integrated methodological approach to monitor the motor-manual tree felling and processing operations, relevant results were obtained in regards to the time consumption, productivity, exposure to noise, physical effort and postural condition; such an integrated method could be generalized to conduct long-term multidisciplinary studies. A combined use of GPS receivers and sound pressure level sensors in the case of monitoring cable yarding operations has led to small differences ($\pm 2\%$) in terms of event classification. For wood processing operations, two case studies were implemented to observe a circular and a bandsaw, respectively. Identification of the working and non-working time of the circular saw was characterized by a high precision (99,8 and 99,5%, respectively). The use of ANN techniques in the learning and testing phases for the data collected in the case of the bandsaw has led to excellent results in terms of classification precision. The methodological approaches used in this work could be very useful in the attempt to collect long-term data, while the obtained results could be used as a basis for similar attempts.