

Latvijas Biozinātņu un tehnoloģiju universitāte
Latvia University of Life Sciences and Technologies

Meža un vides zinātņu fakultāte
Faculty of Forest and Environmental Sciences



Mg. sc. ing. Aigars Strūbergs

**MEŽA MAŠĪNU INFORMĀCIJAS SISTĒMAS IZMANTOŠANA
HARVESTERA OPERATORU APMĀCĪBU EFEKTIVITĀTES
NOVĒRTĒŠANĀ**

***USE OF FOREST MACHINE INFORMATION SYSTEMS FOR
ASSESSING THE EFFECTIVENESS OF HARVESTER OPERATOR
TRAINING***

Promocijas darba KOPSAVILKUMS
zinātnes doktora (Ph.D.) grāda *Lauksaimniecības meža un veterinārās zinātnēs*
iegūšanai

SUMMARY
of the Doctoral thesis for the Doctoral degree of Science (Ph.D.) in *Agricultural, Forestry
and Veterinary Sciences*

Jelgava
2026

Promocijas darba zinātniskie vadītāji / *Supervisors:*
Dr.silv. Andis Lazdiņš, Dr.silv. Linards Sisenis

Promocijas darbs izstrādāts Latvijas Biozinātņu un tehnoloģiju universitātē, doktorantūras studijas Latvijas Biozinātņu un tehnoloģiju universitātes Meža fakultātē 2019/2020 studiju gadā Doktorantūras skolā 2020. līdz 2022. gadam. *The doctoral thesis was developed at the Latvia University of Life Sciences and Technologies, doctoral studies at the Faculty of Forestry of the Latvian University of Biosciences and Technologies in the 2019/2020 academic year at the Doctoral School from 2020 to 2022.*

Oficiālie recenzenti / *Official reviewers:*

- Dr.sc.ing. Aivars Birkavs, Latvijas Biozinātņu un tehnoloģiju universitātes asociētais profesors / *Associate Professor, Latvia University of Life Sciences and Technologies;*
- PhD. Inga Grīnfelde, Latvijas Biozinātņu un tehnoloģiju universitātes asociētā profesore / *Associate Professor, Latvia University of Life Sciences and Technologies;*
- Dr.habil. Krzysztof Jablonski, Poznaņas Dzīvības zinātņu universitāte / *University of Life Sciences in Poznan, Poland.*

Promocijas darba aizstāvēšana notiek Latvijas Biozinātņu un tehnoloģiju universitātes “Lauksaimniecības un zivsaimniecības zinātne” specializācija “Meža darbi un tehnika” promocijas padomes sēdē 2026. gada 29. janvārī. *The public defence of the doctoral dissertation will take place at the meeting of the Promotion Council for the specialisation Forest Operations and Machinery within the field of Agricultural and Fisheries Sciences at Latvia University of Life Sciences and Technologies on 29 January 2026.*

Ar promocijas darbu un kopsavilkumu var iepazīties LBTU fundamentālajā bibliotēkā Jelgavā, Lielā ielā 2 un interneta vietnē <https://lbtufb.lbtu.lv/> / *The thesis and summary are available at the Fundamental Library of Latvia University of Life Sciences and Technologies: 2 Lielā Street, Jelgava and the website <https://lbtufb.lbtu.lv/>*

Atsauksmes sūtīt promocijas padomes sekretārei Inesei Rudzātei uz adresi Akadēmijas iela 11, Jelgava, LV3001, Latvija vai e-pastā inese.rudzate@lbtu.lv / *Please send feedback to the Secretary of the Promotion Council, address: Akadēmijas iela 11, Jelgava, LV3001, Latvia or by email inese.rudzate@lbtu.lv.*

SATURA RĀDĪTĀJS

SATURA RĀDĪTĀJS.....	3
1. DARBA VISPĀRĪGS RAKSTUROJUMS.....	5
1.1. Tēmas aktualitāte	5
1.2. Promocijas darba mērķis, uzdevumi un tēze	6
1.3. Darba zinātniskā novitāte un praktiskā nozīme	6
1.4. Zinātniskā darba aprobācija	7
1.5. Promocijas darba struktūra un apjoms	9
2. PĒTĪJUMA MATERIĀLS UN METODIKA.....	9
2.1. Mežizstrādes tehnikas parka izvērtēšana	10
2.2. Meža mašīnu operatoru kvalifikācijas celšanas kursu apmeklējuma novērtējums	11
2.3. Mežizstrādes efektivitātes paaugstināšanas iespēju analīze	12
2.4. Apmācību ietekmes uz degvielas patēriņu novērtējums	16
3. REZULTĀTI UN DISKUSIJA.....	18
3.1. Mežizstrādes tehnikas parka atbilstība <i>StanForD 2010</i> standarta ieviešanai	18
3.2. Meža mašīnu operatoru kvalifikācijas celšanas kursu apmeklējuma novērtējums	22
3.3. Mežizstrādes efektivitātes paaugstināšanas iespējas, izmantojot <i>StanForD 2010</i> standartu.....	24
3.4. Operatora apmācību ietekmes uz degvielas patēriņu novērtējums ..	37
SECINĀJUMI.....	49
REKOMENDĀCIJAS.....	50
1. GENERAL DESCRIPTION OF THE WORK.....	52
1.1. Relevance of the Topic	52
1.2. Aim, Objectives and Thesis of the Doctoral Dissertation	53
1.3. Scientific Novelty and Practical Significance of the Dissertation ...	53
1.4. Scientific Work Approval	54
1.5. Structure and Volume of the Doctoral Dissertation	55
2. RESEARCH MATERIAL AND METHODOLOGY.....	55
2.1. Evaluation of the Forest Machinery Fleet.....	56
2.2. Assessment of Forest Machine Operators' Qualification Improvement Course Attendance	57
2.3. Analysis of Opportunities for Improving Forest Harvesting Efficiency	58
2.4. Evaluation of the Impact of Training on Fuel Consumption	62
3. RESULTS AND DISCUSSION.....	64
3.1. Forest machinery fleet compliance with the implementation of the <i>StanForD 2010</i> standard.....	64

3.2.	Assessment of Forest Machine Operator Qualification Improvement Course Attendance	66
3.3.	Possibilities to Improve Forest Harvesting Efficiency by Implementing the <i>StanForD 2010</i> Standard.....	68
3.4.	Evaluation of the Impact of Operator Training on Fuel Consumption	76
	CONCLUSIONS.....	83
	RECOMMENDATIONS.....	85

1. DARBA VISPĀRĪGS RAKSTUROJUMS

1.1. Tēmas aktualitāte

Augošais pieprasījums pēc koksnes produktiem liek mežizstrādes pakalpojumu sniedzējiem palielināt mežizstrādes jaudas. Tas savukārt saistīts ar augstāka mehanizācijas līmeņa ieviešanu, ražīgākas tehnikas izmantošanu, tehnikas operatoru kvalifikācijas paaugstināšanu. Šodien virkne Latvijas mežizstrādes pakalpojumu sniedzēji, ņemot vērā lielās mežizstrādes tehnikas iegādes izmaksas, veic pakāpenisku meža mašīnu parka atjaunināšanu uz jaunām vai jaunākām mašīnām. Iemesls – jaunākas mašīnas mazāk fiziski un tehnoloģiski novecojušas, kā arī mazāks degvielas patēriņš. Degvielas izmaksas rada lielāko mežizstrādes pašizmaksas sadārdzinājumu. Savukārt degvielas patēriņš tieši saistīts ar meža mašīnu operatoru kompetencēm, kvalifikāciju. Tādēļ arī operatoriem nepieciešams periodiski veikt apmācības. Tās var būt saistītas gan ar jaunākas tehnikas apgūšanu, gan ar profesionālās kvalifikācijas paaugstināšanu. Pašreiz, Latvijā, darbaspēka trūkuma apstākļos, meža mašīnu operatori savas profesionālās kompetences var iegūt divos veidos. Kā pirmo var minēt profesionālo apmācību vienā no tehnikumiem savukārt otra ir pašmācības ceļā strādājot mežizstrādes uzņēmumā. Tomēr abos gadījumos operatora darba ražīgums nebūs augsts. Operatoriem nepieciešams veikt regulāras papildus apmācības profesionālu instruktoru klātbūtnē, kas novērtētu operatora darba stilu, darba paņēmienus un sniegtu ieteikumus profesionālās kvalifikācijas paaugstināšanai. Šādi vienas dienas kursi tiek Latvijā tiek organizēti, kuros instruktors vērō operatoru darbībā un sniedz ieteikumus darba ražīguma paaugstināšanai. Šāda metode dod savus rezultātus, tomēr savu ietekmi var atstāt instruktora pieredze, profesionalitāte un subjektīvais viedoklis, kā arī operatora psihoemocionālais stāvoklis, pieredze un citi faktori. Ņemot vērā mūsdienu meža mašīnu informācijas sistēmu tehniskās iespējas (*StanForD 2010*) visi meža mašīnas dati, kas saistīti ar operatora darbu un mašīnu, hronoloģiski tiek ierakstīti noteiktos failos un saglabāti. Veicot šo failu analīzi, iespējams analizēt operatora darba ražīgumu konkrētā laika periodā, atsevišķu operāciju izpildes laiku, degvielas patēriņu un precīzu stumbra apstrādes laika izmaiņu dinamiku, kā arī iespējams identificēt vietas un apstākļus kur novērojama darba ražīguma, stumbra apstrādes laika un degvielas patēriņa izmaiņas. Šāda automātiski iegūto datu analīze ļautu veidot individuālu pieeju katra operatora apmācību saturam un turpinot analīzi pēc apmācībām ļautu izdarīt objektīvus secinājumus par apmācību efektivitāti.

1.2. Promocijas darba mērķis, uzdevumi un tēzes

Promocijas darba mērķis – izpētīt meža mašīnu automātiski iegūto datu izmantošanas iespējas operatoru periodisko apmācību efektivitātes analīzē un raksturot to pielietošanas iespējas Latvijas mežizstrādes uzņēmumos.

Promocijas darbā izvirzītā mērķa sasniegšanai izvirzīti sekojoši pētnieciskie uzdevumi:

1. novērtēt meža mašīnu atbilstību standarta *StanForD 2010* pielietošanai;
2. analizēt kvalifikācijas celšanas apmācību lietderību un tās uzlabošanas iespējas;
3. novērtēt mežizstrādes efektivitātes palielināšanas iespējas, pielietojot meža mašīnu standartu *StanForD 2010*.

Promocijas darbā izvirzītas sekojošas tēzes:

1) neskatoties uz *StanForD 2010* pieejamību, Latvijas meža tehnikas parka novecošanās un izmantotās programmatūras daudzveidība ierobežo standartizētas datu plūsmas ieviešanu, apgrūtinot salīdzināmu datu izmantošanu un datus balstītu lēmumu pieņemšanu mežizstrādē.

2) meža mašīnu operatoru kvalifikācijas celšanas kursu apmeklēšana būtiski uzlabo operatoru profesionālās zināšanas un prasmes, kas pozitīvi ietekmē darba ražīgumu un darba metožu efektivitāti, kā arī veicina lielāku izpratni par darba procesu un degvielas patēriņa optimizāciju.

3) dati, ko nodrošina *StanForD 2010* standarts, izmantojami, lai plānotu operatoru apmācības, kā arī izvērtētu operatoru darba izpildes kvalitātes izmaiņas pēc apmācībām.

1.3. Darba zinātniskā novitāte un praktiskā nozīme

Atbilstoši izvirzītajam darba mērķim un tā sasniegšanai paredzētajiem uzdevumiem, darba zinātniskās novitātes izpausme vairāk saskatāma tajās iegūto rezultātu skaitlisko vērtību atšķirībās, kuru cēlonis ir mežizstrādes apstākļu raksturojums Latvijā, pirmā kārtā minot, ka izcērtamās platības ir nelielas un teritoriāli izklīdētas, bet iegūstamo kokmateriālu sortimentu un tiem izvirzāmo kvalitātes prasību ir daudz. Šādos apstākļos samērs starp laika izlietojuma tehnoloģiski atšķirīgajiem veidiem (kokmateriāla pārveidošana, pārvietošana, uzglabāšana) vājina harvestera operatora apmācībā iegūto spēju izlietot mazāk laika kokmateriāla pārveidošanai un pārvietošanai.

Veikto darbu nevar uzskatīt par noslēdzošu dotajā tematikā, tas rosina uz turpmākiem zinātniskiem pētījumiem, kas var būt nepieciešami kā pamatojums inženiertehniskām izstrādēm turpmākai mežsaimniecības tehnoloģiskajai attīstībai.

Darbam ir neapšaubāma praktiskā nozīme kā vispār sabiedriskā, tā meža nozares līmenī.

1. Pievērs uzmanību harvesteru operatoru regulāras apmācības nepieciešamībai.
2. Meža nozares izglītībā rosina studējošos pievērsties tehnoloģiskās attīstības un ar to saistīto aktuālo problemātisko jautājumu izziņai.
3. Publiski pieejami materiāli par pētījumā doto tematiku palīdz veidot sabiedrības priekšstatu par nozari, no kuras atkarīga katra pasaules iedzīvotāja ikdienas eksistence.

Mežizstrādes mašīnu operatora kvalifikāciju Latvijā iegūst absolvējot tehnikumu pēc pamatskolas vai vidusskolas, vai arī specializētosursos pieaugušajiem. Strādājot specialitātē, uzņēmumos nepieciešams periodiski atsvaidzināt zināšanas un uzlabot kvalifikāciju apmeklējot kvalifikācijas celšanas kursus, kur instruktors teorētiski un vēlāk praktiskajā darbā operatoram sniedz ieteikumus par darba metožu efektivitāti vai citiem darba ražīguma kāpināšanas veidiem. Šādās apmācībās panākumu atslēga balstās uz instruktora zināšanām un pieredzi. Mūsdienu mežizstrādes mašīnās pielietotās IT tehnoloģijas un automatizēto parametru reģistrācija nodrošina iespējas izmantot datus operatora darba analīzē un apmācību kvalitātes monitoringā.

Datu analīzes rezultāti sniedz informāciju par operatora operāciju izpildes laiku un darba ražīgumu, kas dažkārt instruktoram, novērojot operatora darbu, paliek nepamanīts.

1.4. Zinātniskā darba aprobācija

Pētījuma rezultāti apkopoti sešās publikācijās starptautiskos un vietējos zinātnisko rakstu krājumos:

1. Strūbergs A., Zimelis A., Kalēja S., Ivanovs J., Sisenis L., Lazdiņš A. (2024) Using cut-to-length (CTL) harvester production data in forest inventories, *Croatian Journal of Forest Engineering* 45(2), DOI: 10.5552/crojfe.2024.2319
2. Strubergs A., Sisenis L., Sarmulis Z. (2024) Use of automatically obtained data in the quantitative and qualitative evaluation of harvester operator training, proceedings of "Research for Rural Development 2024". Jelgava, vol. 39. pp. 56–61. DOI: 10.22616/RRD.30.2024.009
3. Strubergs A., Lazdiņš A., Sisenis L. (2022) Evaluation of the attendance of refresher courses for forestry machine operators, proceedings of "Research for Rural Development 2022". Jelgava, vol. 37. pp. 84–88. DOI: 10.22616/rrd.28.2022.012
4. Strubergs A., Lazdiņš A., Sisenis L. (2022) Use of CTL harvester *.hpr and *.mom files to analyze impact of operator training on productivity,

proceedings of “Engineering for Rural Development”, Jelgava, pp. 432–437. DOI: 10.22616/ERDev.2022.21

5. Strubergs A., Lazdins A., Sisenis L. (2021). Use of StanForD 2010 data for determination of effect of harvester operator periodic training on productivity and fuel economy, proceedings of “Engineering for Rural Development” 2021. Jelgava, pp. 1163–1167. DOI: 10.22616/erdev.2021.20.TF252
6. Strubergs A., Lazdins A., Sisenis L. (2020). Evaluation of compliance of existing forest machine information systems for the implementation of the standard StanForD 2010, proceedings of “Research for Rural Development” 2020. Jelgava, vol. 35. pp. 66–72. DOI: 10.22616/rrd.26.2020.010.

Pētījuma rezultāti prezentēti sešās starptautiskās un vietējas nozīmes zinātniskajās konferencēs:

1. Strubergs (2024). Use of automatically obtained data in the quantitative and qualitative evaluation of harvester operator training. 30th Annual International Scientific Conference, “Research for Rural Development 2024” Latvia University of Life Sciences and Technologies, Jelgava, Latvia, 15–16 May 2024.
2. Strubergs (2022). Evaluation of the attendance of refresher courses for forestry machine operators, 28th Annual International Scientific Conference, “Research for Rural Development 2022” Latvia University of Life Sciences and Technologies, Jelgava, Latvia, 18–20 May 2022.
3. Strubergs (2022). Use of CTL harvester *.hpr and *.mom filess to analyze impact of operator training on productivity, 21st International Scientific Conference, “Engineering for Rural Development”, Latvia University of Life Sciences and Technologies, Jelgava, Latvia 25.–27.2022.
4. Strubergs (2021). “Change in age structure of harvesters in Latvia in 2019–2021”. “Sustainable management of natural resources – a basic condition for successful socio-economic development in the period of implementation of the new environmental policy of the European Union”, Jelgava, Latvia, 25.11.2021.
5. Strubergs (2021). Use of StanForD 2010 data for determination of effect of harvester operator periodic training on productivity and fuel economy, 20th International Scientific Conference, “Engineering for Rural Development” Latvia University of Life Sciences and Technologies, Jelgava, Latvia 26.–28 May 2021.
6. Strubergs (2020). Evaluation of compliance of existing forest machine information systems for the implementation of the standard StanForD 2010. Annual 26th International Scientific Conference “Research for Rural Development 2020”, Latvia University of Life Sciences and Technologies, Jelgava, Latvia, 13–15 May 2020.

1.5. Promocijas darba struktūra un apjoms

Promocijas darba struktūra veidota saskaņā ar darbā izvirzītajiem pētnieciskajiem uzdevumiem. Darbu veido trīs nodaļas, no kurām **pirmajā** atspoguļots problēmas izzinātības apskats un citu autoru darbos gūtās atziņas. Aplūkota mežistrādes mašīnu datu struktūra, struktūras izmaiņas pārejot no vecā *StanForD* standarta uz jauno *StanForD 2010*. Apskatīti darba ražīguma ietekmējošie faktori un kāda ietekme uz darba ražīgumu operatora kvalifikācijai un tās paaugstināšanai. Kā trešā aplūkota operatora kvalifikācijas ietekme uz degvielas patēriņu, kā arī, kā izmainās degvielas patēriņš pēc apmācībām. **Otrajā** nodaļā apskatīta Latvijas mežistrādes mašīnu struktūra atbilstoši pielietojumam (mašīnu skaits, vecums, marku un modeļu grupas), operatoru apmācību un apmācību efektivitātes analīzes metodika. Izstrādāta metodika operatoru apmācību efektivitātes novērtējumam, kas iekļauj stumbru apstrādes laika, darba ražīguma un degvielas patēriņa izmaiņu analīzi, izmantojot *StanForD2010* automātiski saglabātos datus. **Trešajā** nodaļā ietver Latvijas mežistrādes mašīnu parka analīzi un atbilstība *StanForD 2010*, operatoru apmācību novērtējuma analīzi, kā arī operatoru darba ražīguma un degvielas patēriņa izmaiņu analīzi izmantojot *StanForD2010* saglabātos datus. Datu analīze veikta tehnikas ražotāju piedāvātajā programmatūrā (*Timbermatic™* un *Opti 4G*) iegūtos datus, kā arī izmantojot alternatīvu risinājumu (MS Excel).

Promocijas darba apjoms ir 91 lappuse, informācija apkopota 12 tabulās un 80 attēlos, darbā izmantoti 96 literatūras avoti, darba noslēgumā noformulēti 5 secinājumi un 2 rekomendācijas.

2. PĒTĪJUMA MATERIĀLS UN METODIKA

Lai sasniegtu pētījuma galveno mērķi un izpildītu izvirzītos pētnieciskos uzdevumus, promocijas darbs strukturēts trīs savstarpēji saistītās daļās. Katra daļa veido pamatu nākamajai, nodrošinot loģisku pāreju no mežistrādes tehnikas tehniskā novērtējuma līdz operatoru apmācību efektivitātes izvērtējumam, balstoties uz automātiski iegūtu darbības datu analīzi. **Pirmajā daļā** veikta Latvijas mežistrādes mašīnu parka analīze, īpaši pievēršoties tehnikas atbilstībai *StanForD 2010* standartam. Šī analīze ir būtiska, jo tikai ar šo standartu saderīgas iekārtas nodrošina detalizētu un standartizētu darbības datu iegūšanu, kas ir nepieciešami turpmākai produktivitātes un degvielas patēriņa izpētei. Tāpat šajā daļā sniegts īss pārskats par pētījumā izmantoto tehniku, kas kalpo kā pamats datu interpretācijai. **Otrajā daļā** analizēts meža mašīnu operatoru viedoklis par kvalifikācijas celšanas apmācību nepieciešamību un līdzšinējo apmācību efektivitāti. Līdz šim apmācībās operatoru novērtējums balstījās uz instruktoru subjektīvo viedokli. Cilvēciskā faktora izpratne ir būtiska, lai apzinātu, kā apmācību saturs un kvalitāte ietekmē operatoru spēju izmantot

tehniku efektīvi. Šī daļa palīdz noteikt, vai esošās apmācību pieejas atbilst praktiskajām vajadzībām un operatoru pieredzei. **Trešajā daļā** apvienoti tehniskie un cilvēciskie aspekti, aprakstot automātiski iegūto datu apstrādes metodiku, izmantojot tehnikas ražotāju izstrādātas programmas un *StanForD 2010* standarta sniegtās iespējas. Tāpat izklāstīta metodoloģija, kā izvērtēt apmācību ekonomisko un ekoloģisko efektu, īpaši analizējot ražīguma un degvielas patēriņa izmaiņas pēc apmācību procesa. Šī pieeja ļauj veikt uz datiem balstītu apmācību efektivitātes novērtējumu. Datu statistiskā apstrāde veikta, izmantojot R programmēšanas vidi.

2.1. Mežizstrādes tehnikas parka izvērtēšana

Lai analizētu Latvijā izmantoto mežizstrādes mašīnu klāstu, izmantoti Valsts tehniskās uzraudzības aģentūras (VTUA) un AS “Latvijas Valsts meži” (LVM) dati. Lai noskaidrotu dažādu modeļu atbilstību standarta *StanForD 2010* ieviešanas prasībām, intervēja Latvijā izplatītāko mežizstrādes mašīnu marku dīlerus.

VTUA tiek reģistrētas visas Latvijā vai ārzemēs iegādātās un Latvijā ievestās tehnikas vienības (Ceļu satiksmes likums, 1997). VTUA reģistrā tiek atspoguļota šāda informācija: mašīnas tips, marka, modelis, rūpnīcas numurs, izlaiduma gads, motora jauda, reģistrācijas datums, kā arī ziņas par traktortehnikas īpašnieku un turētāju (juridiska vai fiziska persona). Sākot ar 2022. gadu, minimālā informācija, kas neietver konkrētus personas datus, pieejama VTUA mājaslapā (Traktortehnikas reģistrācijas dati Latvijas Republikā, 2022). No reģistra traktortehnikas vienības tiek izņemtas gadījumos, ja tiek norakstītas vai pārdota. Latvijas likumdošana neparedz mežizstrādes mašīnām obligāti veikt ikgadējo tehnisko apskati (Noteikumi par traktortehnikas ..., 2022), līdz ar to VTUA rīcībā nav tādu pētījumam nepieciešamo datu, kas dotu informāciju par mašīnu – vai tā strādā, cik stundas mašīna nostrādā, vai tā ir izjaukta rezerves daļās un vai tā nav, nepārtraucot reģistrāciju, izvesta no Latvijas.

No VTUA iegūtie dati izmantoti, lai noskaidrotu Latvijas uzņēmumos vai privātpersonām reģistrēto kopējo mežizstrādes mašīnu skaitu un struktūru (harvesters, forvarders, skiders u.c.). Mežizstrādes mašīnas sagrupētas pa izlaiduma gadu desmitgadēm, nosakot mašīnu vecuma struktūru atbilstoši pielietojumam.

Šobrīd Latvijas mežu īpašnieki no pakalpojumu sniedzējiem nepieprasa *StanForD 2010* standartam atbilstošus datus no forvarderiem, līdz ar to šajā pētījumā atbilstība *StanForD 2010* ieviešanai tiek vērtēta tikai harvesteriem.

Izmantojot LVM pakalpojumu sniedzēju datubāzi, noskaidrota mežizstrādē izmantoto mašīnu struktūra atbilstoši tehnikas ražotājam un pielietojumam. LVM datubāzē tiek sniegta informācija par mašīnas tipu

(harvesters, forvarders), mašīnas marka, modelis, izlaiduma gads, kāda tipa cirtēs strādā (galvenā, kopšanas, bojātu koku cirte) un atbilstība *StanForD 2010* standartam. Ņemot vērā, ka LMV pāriet uz pilnīgu produkcijas atskaišu pieņemšanu, balstoties uz harvestera datorsistēmas datiem, harvesteriem papildus jānorāda atbalsts *StanForD 2010* standartam.

2.2. Meža mašīnu operatoru kvalifikācijas celšanas kursu apmeklējuma novērtējums

Šajā pētījumā tika izveidota meža mašīnu operatoru aptauja, lai noskaidrotu meža mašīnu operatoru viedokli par apmācību nepieciešamību un ieguvumus no mācībām (Geske, Grīnfelds, 2020). Aptaujas anketā ir 3 jautājumu bloki. Pirmajā daļā tiek noskaidrota vispārējā informācija par operatoru, otrajā – jautājumi saistībā ar kvalifikācijas celšanas mācību procesu, bet trešajā blokā ir jautājumi par mācību laikā iegūtajām prasmēm, zināšanām un atzīmēti operatoru ieteikumi apmācību uzlabošanai.

Lai būtu iespējams veikt aptaujas matemātisko apstrādi, otrā un trešā aptaujas bloka jautājumu atbilžu varianti veidoti pēc Likerta skalas. Sešu ballu sistēmā jāizvēlas atbilde no “pilnīgi nepiekrītu” līdz “pilnīgi piekrītu”. Pirms nodošanas respondentiem anketa tika testēta, lai nodrošinātu precīzi formulētus jautājumus. Operatoriem tika izsūtīta anketas elektroniskā adrese, un tā tika aizpildīta tiešsaistē. Saite uz aptauju izsūtīta lielākajiem mežizstrādes uzņēmumiem Latvijā, kuru rīcībā ir vismaz piecas mežizstrādes mašīnas un to meža mašīnu operatori piedalījušies apmācībās, ko organizē Meža mašīnu operatoru mācību centrs. Mežizstrādes uzņēmumu mežizstrādes meistari anketu izplatīja tālāk meža mašīnu operatoriem. Aptauja tika veikta 2021. gada novembrī un decembrī. Lai anketēšanas rezultāti būtu pēc iespējas precīzāki un korektāki, atsevišķi tika izdalīti harvestera un forvardera operatori. Anketēšanas procesā operatori tika sadalīti trīs vecuma grupās: līdz 30 gadiem, 30–40 gadi un vairāk par 41 gadu. Tika izdalīts operatoru darba stāžs ar pēdējo mežizstrādes mašīnu – līdz 5 gadiem un vairāk par 5 gadiem, kā arī tika izvērtēta operatoru iegūtā izglītība: ar pamata izglītību, vidējo izglītību, vidējo profesionālo izglītību un augstāko izglītību. Aptaujas rezultāti tika apkopoti un sagrupēti ar *MS Excel* un datu statistiskā apstrāde veikta programmā *R* (Elferts, 2012), izmantojot Hī kvadrāta testu (Arhipova, Bāliņa, 2003).

No 2018. līdz 2022. gadam Meža mašīnu operatoru centrā tika veiktas kvalifikācijas celšanas mācības 315 meža mašīnu operatoriem. Aptaujā piedalījās un anketas aizpildīja 147 respondenti – meža mašīnu operatori.

2.3. Mežizstrādes efektivitātes paaugstināšanas iespēju analīze

Operatoru apmācību efektivitātes analīzē izmantoti dati par operatoru darba ražīgumu, cirmās ar līdzīgu audzes sastāvu, pirms un pēc apmācībām. Analīzē izmantoti automātiski iegūtie dati par krājas kopšanas ciršu un kailciršu izstrādi. Datu analīzē izmantotās koku sugas: parastā priele (*Pinus sylvestris* L.), parastā egļu (*Picea abies*), āra bērzs (*Betula pendula*).

Mežizstrādē pēc vidējiem darba ražīguma rādītājiem grūti noteikt apmācību efektivitāti, jo zināms, ka ražīgumu ietekmē vairāki mainīgie faktori. Līdz ar to nepieciešama padziļināta datu analīze, lai noskaidrotu iemeslus darba ražīguma izmaiņām. Rūpnīcas programmas ļauj smalkāk skatīt stumbra apstrādei patērēto laiku, tādējādi iespējams identificēt operācijas, kurās operators var paaugstināt savu profesionalitāti.

Katrs tehnikas ražotājs izmanto savu specifisku datorprogrammu, lai atvērtu un tālāk apstrādātu savas tehnikas informācijas sistēmā saglabātos datus: *John Deere* izmanto *Timbermatic*TM, *Ponsse* izmanto *Opti 4(5)G*.

Datu apstrāde veikta trīs veidos:

1. izmantojot *StanForD 2010* datus un programmu *Microsoft Excel*;
2. *John Deere* harvesteriem – izmantojot ražotāja datu apstrādes programmu *TimberOffice*;
3. *Ponsse* harvesteriem – izmantojot ražotāja datu apstrādes programmu *Ponsse Manager*.

Apakšnodaļās 2.3.1 un 2.3.2 katram operatoram tika atlasītas krājas kopšanas cirsmas divu mēnešu periodā pirms apmācībām un divu mēnešu periodā pēc apmācībām, bet ne mazāk, kā desmit krājas kopšanas cirsmas pirms un desmit pēc apmācībām.

2.3.1. Operatoru apmācību efektivitātes analīze, izmantojot *StanForD 2010* datus

Ņemot vērā, ka *.hpr un *.mom failu struktūra veidota *.xml formātā, failu atvēršanai, datu atlasei un šķirošanai var tikt izmantota atvērtā koda programmatūra. Izmantojot atbilstoši standartam *StanForD 2010* *.hpr un *.mom failā saglabātos datus, tālākā datu apstrāde veikta, izmantojot MS Excel. Šādi iespējams datu analīzi veikt stumbra līmenī.

Divi operatori (A un B) strādā maiņās ar 2016. izlaiduma gada harvesteri *John Deere 1070E*, kas aprīkots ar harvestera galvu *H413* un izmanto informācijas sistēmu *Timbermatic H 1.28.20*. Harvestera informācijas sistēmas atbalsta standartu *StanForD 2010*. Šo operatoru apmācību analīzēšanā izmantoti dati divus mēnešus pirms apmācībām un divus mēnešus pēc apmācībām laika periodā no 2021. gada augusta līdz 2021. gada decembrim. Harvesters strādāja LVM apsaimniekotajos mežos krājas kopšanas cirtēs Dienvidkurzemes

virsmēžniecībā. Harvestera operatora A un operatora B darba pieredze attiecīgi ir 6 un 12 gadi. Abiem operatoriem notika 8 stundu apmācības cirsma, ko veica pieredzējis Meža mašīnu operatoru apmācības centra instruktors (Strubergs et al., 2022).

Veicot apstrādes laika uzskaiti saskaņā ar *StanForD 2010* standartu, mašīnas informācijas sistēma uzskaita laiku, kas patērēts stumbra apstrādei no stumbra satveršanas brīža līdz nākamā stumbra satveršanai vai citai komandai, kas pārtrauc apstrādes procesu.

Analīzei tika izmantoti dati par 12 265 kokiem ar vidējo tilpumu 0,129 m³, kas tika apstrādāti pirms apmācībām, un 16 503 kokiem ar vidējo tilpumu 0,089 m³, kas tika apstrādāti pēc apmācībām.

Šajā apakšnodalā izmantoti stumbru ieraksti, kas reģistrēti saskaņā ar standartu *StanForD 2010* kā *.hpr un *.mom faili. No *.hpr faila izmantoti šādi dati: stumbra identifikācijas numurs, koka suga, laika zīmogs (gads, mēnesis, diena, stunda, minūte un sekunde), kad koks nozāgēts, caurmērs krūšu augstumā (D_{1,3}), tilpums, operatora identifikators. Izmantojot laika zīmogu ierakstus, stumbra apstrādes cikla laiks tiek aprēķināts katram kokam, nosakot atšķirību starp diviem secīgiem stumbru laika zīmogiem (Arlinger et al., 2012). Cikla laiks ietver koka nozāgēšanu, harvestera galvas pārvietošanu sagarumošanas zonā, atzarošanu, sagarumošanu, sniegšanos pēc nākošā koka un koka satveršanu. Lai novērstu kļūdas, pēdējo stumbru apstrādes laikā izmantots *.mom fails, no kura izmanto laika zīmogu apkopei, remontam, pārbraucieniem u.c. darbībām, kas noslēdz stumbru apstrādi. Veicot datu atlasīšanu, ņemtas vērā koku sugas un caurmēri, kas sastopami cirsma pirms un pēc apmācībām.

Lai noskaidrotu apmācību, koka sugas un koka tilpuma ietekmi uz operatoru ražīgumu un izslēgtu faktorus, kuru ietekme nav būtiska, izveidots regresijas modelis.

Tā kā dati neatbilst normālajam sadalījumam, jo lielākā daļa datu atrodas ārpus 95% ticamības intervāla, tālākajā datu analīzē tiek izmantots Wilcoxon tests. Savukārt, lai noskaidrotu tādu stumbra apstrādes laika un darba ražīguma ietekmējošo faktoru kā apmācību, stumbra tilpuma, sugas, sortimentu grupas ietekmes būtiskumu, tiek izmantots *R* pakotnes rīks “emmeans”. Regresijas atlikumu autokorelācijas pārbaudei izmantots Durbin – Watson tests.

2.3.2.Operatora darba ražīguma analīze izmantojot *John Deere* ražotāja datorprogrammas *TimberOffice™* datus

Analizējot apmācību efektivitāti ar *Timberoffice™* palīdzību tiek izmantoti automātiski iegūtie dati no harvestera *John Deere 1270 E*, kas aprīkots ar harvestera galvu H480. Harvesteri izmanto informācijas sistēmu *Timbermatic H 1.28.16*, kas atbalsta *StanForD 2010*. Harvesters strādā Latvijas teritorijā LVM apsaimniekotajos mežos krājas kopšanas cirtēs. Dati iegūti par operatoru darbu

laika periodā no 2020. gada novembra līdz 2021. gada februārim. Kopumā analizē izmantoti divu operatoru (C un D) dati no 10 cirsēm pirms apmācībām un 10 cirsēm pēc apmācībām.

Operatora C un operatora D darba pieredze ir pusgads pēc mežizstrādes mašīnu operatora kvalifikācijas iegūšanas tehnikumā. Operatoriem veikta 8 stundu periodiskā apmācība cirsē (Strubergs et al., 2021). Apmācību veica mācību centra instruktors ar lielu praktiskā darba pieredzi.

Datu analizē tiek izmantoti faili *.hpr, *.mom. Failu atvēršanai un informācijas iegūšanai izmantota programma TimberOffice 5.12. TimberOffice™ programma pēc laika skalas ļauj datus atlasīt diennakts periodā, līdz ar to cirsmu dati sadalīti diennakts griezumā.

Programmas TimberOffice rīkā TimberMatic Analytic automātiski nozāģētos stumbrus sagrupē pēc stumbra vidējā tilpuma. Līdz ar to iegūst sešas grupas ar šādiem tilpumu intervāliem: 0.00–0.15 m³, 0.15–0.30 m³, 0.30–0.50 m³, 0.50–0.80 m³, 0.80–1.20 m³ un 1.20–1.70 m³. Lai noteiktu atsevišķu operatora operāciju izpildes ātrumu katrā stumbra tilpuma grupā, harvestera datoreģistrē laiku (sekundēs), kas tiek patērēts operāciju izpildei no harvestera galvas pacelšanas līdz stumbra satveršanai, ietverot tādas operācijas kā braukšana, tikai izlice, izlice + braukšana, aktīva harvestera galva, pārējais laiks. Nākošais tiek reģistrēts laiks, kas operatoram nepieciešams stumbra apstrādei (stumbra padeve, pārvietošana un atzarošana), ietverot tādas operācijas kā stumbra padeve + zāģēšana, stumbra padeve + izlice, tikai izlice, tikai braukšana un pārējais laiks. Kā pēdējo harvestera datoreģistrē stumbra un sortimentu apstrādes laiku, līdz tas tiek sagatavots atsevišķos sortimentos un novietots sortimentu zonā (Sarmulis & Saveljevs, 2015), ietverot tādas operācijas kā stumbra padeve, stumbra padeve + izlice, tikai izlice, pārzāģēšana, meklēšana un pārējais laiks. Veicot datu apstrādi, stumbru apstrādes laiki tika sasummēti un salīdzināti patērētais laiks stumbru apstrādē pirms un pēc apmācības. Pārējā laikā katrā grupā ietilpst darbības, ko atsevišķi neuzskaita harvestera informācijas sistēma. Šeit jāpiemin tādas darbības kā koka izvēle, koksnes vainu noteikšana, sagatavoto sortimentu kārtošana un zaru pārkraušana. Harvestera datoreģistrē saglabā vidējo degvielas patēriņu L·h⁻¹, kas tika patērēts katras operācijas izpildē. Programma TimberOffice™ neatbalsta datu eksportu, līdz ar to visi nepieciešamie dati manuāli pārrakstīti MS Excel, kur tiek veikta tālākā datu apstrāde.

No programmas TimberOffice™ atlasot cirsmu un operatoru, par cirsmu tiek iegūti sekojoši dati:

- saražotā produkcija, m³;
- nozāģētie stumbri, gab.;
- vidējais stumbra izmērs, m³;
- vidējais darba ražīgums, m³·h⁻¹.

Programmā *R* veic Andersona–Darlinga testu, lai noteiktu datu atbilstību normālsadalījumam. Tā kā testā tiek noteikts, ka dati atbilst normālsadalījumam, tad, lai novērtētu konstatēto atšķirību statistisko būtiskumu, veic *T* testu. Ņemot vērā, ka darba ražīgumu būtiski ietekmē gan stumbra tilpums, gan apmācības, tad faktoru ietekmi nosaka, veicot regresijas analīzi.

Operatoram *C* tiek iegūts regresijas vienādojums:

$$D_r = 3.326 + 47.786 * V_v + 0.841 * A_f, \quad (2.1)$$

kur D_r – darba ražīgums, $\text{m}^3 \cdot \text{h}^{-1}$;

a, b, c – koeficienti;

V_v – stumbra vidējais tilpums, m^3 ;

A_f – apmācību ietekmes faktors.

Operatoram *D* tiek iegūts regresijas vienādojums:

$$D_r = 6.162 + 57.954 * V_v - 3.440 * A_f, \quad (2.2)$$

kur D_r – darba ražīgums, $\text{m}^3 \cdot \text{h}^{-1}$;

a, b, c – koeficienti;

V_v – stumbra vidējais tilpums, m^3 ;

A_f – apmācību ietekmes faktors.

2.3.3. Operatora darba ražīguma analīze, izmantojot *Ponsse* ražotāja datorprogrammas *Opti4G* datus

Ponsse harvesteru automātiski iegūtie dati atlasīti, izmantojot *Ponsse Manager* rīku. Operatori, kuru dati izmantoti analīzē, strādā ar 2020. gada *Ponsse Ergo* harvesteriem LVM apsaimniekotajās platībās. Harvesteri noslogoti kailcirsu izstrādē. Harvesteriem instalēta programmas *Opti4G* 4.780 versija. Apmācību efektivitātes analīzē izmantoti harvestera saglabātie dati par trīs operatoru darbu divus mēnešus pirms apmācībām un trīs mēnešus pēc apmācībām. Operatoru praktiskā darba pieredze, kā harvestera operatoriem uz apmācību dienu: operatoram *E* – 5 gadi, operatoram *F* – 1 gads, savukārt operatoram *G* – 2 gadi. Operatora *E* dati izmantoti par laika periodu no 2021. gada novembra līdz 2023. gada jūnijam ar apmācību norisi 27. janvārī. Operatora *F* dati – no 2022. gada marta līdz 2022. gada oktobrim ar apmācību dienu 22. maijā. Savukārt operatora *G* dati – par periodu no 2022. gada decembra līdz 2023. gada jūlijam ar apmācību dienu 10. februārī. Aplūkotajos periodos operators *E* pirms mācībām apstrādāja 5289 stumbrus, savukārt pēc mācībām apstrādāja 21373 stumbrus. Operators *F* pirms mācībām apstrādāja 11906 stumbrus, bet pēc mācībām – 23253 stumbrus. Operators *G* pirms mācībām apstrādāja 8857 stumbrus, pēc apmācībām – 17343 stumbrus.

Datu matemātiskās apstrādes veikšanai *Ponsse Manager* atspoguļotie dati no rīka manuāli tiek pārnesti uz programmu *MS Excel*, kur tiek grupēti tālākai matemātiskajai datu apstrādei, jo *Ponsse Manager* – līdzīgi ka *TimberofficeTM* – nepieļauj datu eksportu uz *MS Excel* datu tālākajai apstrādei.

Operatoram secīgi pa mēnešiem noteikta darba ražīguma un stumbra apstrādes laika dinamika, izveidojot katram darba mēnesim atsevišķu grafiku, kurā uzrādītas vidējo vērtību izmaiņas un datu izkliede. Atsevišķu operāciju izpildes laika izmaiņas noteiktas pirms un pēc apmācībām.

Pretēji *John Deere* rūpnīcas programmai, *Ponsse* rūpnīcas programma neļauj veikt datu grupēšanu, izdalot koku sugas, bet ir iespējams izdalīt atsevišķas tilpuma grupas un saglabā sekojošos operāciju izpildes laikus:

- stumbra satveršana;
- gāšanas zāģējums;
- sagarumošana un krautnēšana;
- atzarošana;
- sagarumošana;
- zaru pārvietošana.

Veicot detalizētu analīzi, iespējams precīzi noteikt operācijas, kuru izpildē operators pavadā visvairāk laika, noskaidrojot, kuru operāciju izpildei jāpievērš pastiprināta uzmanība.

2.4. Apmācību ietekmes uz degvielas patēriņu novērtējums

Ne vienmēr var apgalvot, ka apmācību rezultātā, palielinoties darba ražīgumam, samazinās degvielas patēriņš. Tādēļ, lai to noskaidrotu, papildus tiek analizēta degvielas patēriņa izmaiņas pirms un pēc apmācībām. Arī degvielas patēriņš tiek analizēts, izmantojot trīs datu avotus. Pirmkārt, izmantojot *StanForD 2010* atbilstošu *.mom failu atvēršanai *MS Excel*, otrs metode – izmantojot *John Deere TimberOffice* un trešā – izmantojot *Ponsse Manager* datus.

2.4.1. Operatoru apmācību ietekmes uz degvielas patēriņu analīze izmantojot *StanForD 2010* datus

Analīzē tiek izmantoti dati no meža mašīnām par operatoriem, kas aprakstīti 2.3.1. apakšnodaļā. Degvielas patēriņa analīzē tiek izmantoti dati no *.mom faila, kur tiek saglabāta informācija par apstrādātajiem stumbriem, vidējo stumbra tilpumu, koku sugu, apstrādes laiku, apkopes u.c. laikiem, kā arī patērēto degvielu. Veicot esošā faila atvēršanu ar *MS Excel*, atlasa un sagrupē analīzei nepieciešamo informāciju. Kad veikta datu atlase un grupēšana, veic lineārās

regresijas analīzi un sastāda vispārēju degvielas patēriņa modeli pirms un pēc apmācībām.

Periodiem pirms un pēc apmācībām nosaka vidējos degvielas patēriņa statistiskos rādītājus. Izmantojot Shapiro–Wilk testu, nosaka datu atbilstību normālam sadalījumam. Tā kā dati atbilst normālsadalījumam ($p < 0,05$), tālākajā datu apstrādē, nosaka degvielas patēriņa izmaiņu būtiskumu, izmantojot T testu. Datu statistiskajai analīzei un grafiskajam attēlojumam tiek izmantota programma R.

Šāda veidā tiek analizēti kopējie dati un, lai noteiktu iespējamās degvielas patēriņa izmaiņu iemeslus, atsevišķi tiek izdalītas koku sugas. Šajā gadījumā – priede, egļu un bērzs.

2.4.2.Operatoru apmācības ietekmes uz degvielas patēriņu analīze izmantojot *TimberOffice*TM datus

Kā pirmo izveido regresijas modeli, lai noteiktu stumbra tilpuma ietekmi uz degvielas patēriņu. Degvielas patēriņš tiek aplūkots divos veidos:

- litros laika periodā (stundā), $L \cdot h^{-1}$;
- litros uz tilpuma vienību (kubikmetru), $L \cdot m^{-3}$.

Programma *TimberOffice*TM piedāvā iespēju aplūkot degvielas patēriņu atsevišķām darbībām – padeve, zāģēšana, apstrāde, tikai izlīce un braukšana. Šādi tiek salīdzināti degvielas patēriņa rezultāti pirms un pēc apmācībām operatoriem C un D.

2.4.3.Operatoru apmācību ietekmes uz degvielas patēriņu analīze izmantojot *Opti 4G* datus

Kā pirmo veic vidējo degvielas patēriņa rādītāju salīdzināšanai pirms un pēc apmācībām. Tālāk izveido regresijas modeli, lai noteiktu stumbra tilpuma ietekmi uz degvielas patēriņu. Degvielas patēriņš tiek aplūkots divos veidos:

- litros laika periodā (stundā), $L \cdot h^{-1}$;
- litros uz tilpuma vienību (kubikmetru), $L \cdot m^{-3}$.

Statistikajā analīzē izmantota lineārās regresijas analīze, datu salīdzināšana veikta, izmantojot savienotu pāru T testu un statistiskos rādītājus. Degvielas patēriņa izmaiņu dinamika skatīta laika periodā 2. mēnesis pirms apmācību dienas, mēnesis pirms apmācību dienas, divi un trīs mēneši pēc apmācību dienas (2; 1; 1; 2; 3)


3. REZULTĀTI UN DISKUSIJA

Veikta meža mašīnu parka atjaunošanas analīze divu gadu periodā un novērtēta atbilstība *StanForD 2010* standartam. Lai novērtētu periodisko apmācību nepieciešamību un efektivitāti, analizēti operatoru aptauju dati. Izmantojot trīs datu avotus, analizēta harvesteru operatoru periodiskās apmācības efektivitāte.

3.1. Mežizstrādes tehnikas parka atbilstība *StanForD 2010* standarta ieviešanai

VTUA publiski pieejamajā datu bāzē (*Traktortehnikas reģistrācijas, 2021*) 2021. gada 30. novembrī 2284 tehnikas vienības reģistrētas kā meža mašīnas, tām izsniegta valsts reģistrācijas numura zīme, bet aktīva reģistrācija ir 2134 tehnikas vienībām. 150 tehnikas vienībām reģistrācija ir pārtraukta.

Vecākā reģistrētā meža mašīna izgatavota 1959. gadā. Grupējot meža mašīnu modeļu datus pa desmitgadēm un pēc piederības, tika konstatētas būtiskas atšķirības mašīnu sadalījumā starp īpašniekiem ($p < 0,05$). Vairākums vecāko meža mašīnu reģistrētas privātu personu īpašumā vai valdījumā, savukārt jaunākās meža mašīnas pārsvarā reģistrētas juridiskajām personām (3.1. att.).




3.1. att. **Privāto un juridisko personu īpašumā vai valdījumā esošo meža mašīnu sadalījums pa izlaiduma desmitgadēm** / Fig. 3.1. *Distribution of forest machines owned or controlled by private and legal entities by decades of manufacture*

Vērtējot VTUA reģistrētās mašīnas pēc vecuma, noskaidrots, ka vidējais Latvijā reģistrēto meža mašīnu vecums $19,5 \pm 0,3$ gadi, no tām juridisko personu īpašumā vai valdījumā esošo meža vidējais vecums $16,8 \pm 0,3$ gadi, bet fizisko personu īpašumā vai valdījumā esošo meža mašīnu vidējais vecums $33,4 \pm 0,5$ gadi.

Atbilstoši Ceļu satiksmes likuma 14(3) pantam speciālajai traktortehnikai tehniskā apskate nav jāveic, tādēļ, apskatot publiski pieejamo informāciju, nevar

noskaidrot, cik un kādas tehnikas vienības (harvesteri, forvarderi utt.) ir iesaistītas mežizstrādē. 2021. gada 30. novembrī VTUA reģistrētas 2284 meža mašīnas, no kurām 610 ir harvesteri, 1176 forvarderi, 120 pievedējmašīnas, 165 treilēšanas mašīnas, 114 treilētāji, 3 šķeldotāji un 98 mašīnas bez apakšgrupas definējuma. Tālākajā datu apstrādē visas meža mašīnas tiek sagrupētas četrās meža mašīnu grupās: harvesteri, forvarderi, treilētāji un citi, kā arī atsevišķi nodalītas fizisko un juridisko personu īpašumā vai valdījumā esošās meža mašīnas (3.2. att.).



3.2. att. **Fizisko un juridisko personu īpašumā vai valdījumā esošās VTUA reģistrētās meža mašīnas** / Fig. 3.2. *VTUA-registered forest machines owned or possessed by natural and legal persons*

Kopējā gradācija, izdalot no kopējā meža mašīnu grupas forvarderus un harvesterus, attēlota 3.1. tabulā.

3.1. tabula. **VTUA reģistrēto meža mašīnu sadalījums** / Table 3.1. *Distribution of forest machines registered in the VTUA*

Juridiskais statuss / Legal status	Meža mašīna / Forest machine	Skaitis, gab. / Quantity, pcs.	Vidējais vecums, gadi / Average age, years	Mediāna / Median
Fiziskas personas / natural persons	Visas meža mašīnas / All forest machines	306	33.4±8.5	34
	Forvarderi / Forwarders	167	32.1±10.1	34
	Harvesteri / Harvesters	10	23.2±7.7	23
Juridiskais statuss / Legal status	Visas meža mašīnas / All forest machines	1837	16.8±10.8	15
	Forvarderi / Forwarders	1064	17.1±10.7	16
	Harvesteri / Harvesters	600	11.9±6.0	12

VTUA reģistrēto mežizstrādes mašīnu datu bāze nav objektīvs datu avots Latvijā strādājošo mašīnu analīzei, jo liela daļa, it sevišķi vecāko mašīnu, var būt demontētas vai neizmantotas, bet nav noņemtas no uzskaites. Savukārt daļa vidēja vecuma un jaunāko mašīnu netiek izmantotas saistībā ar būtiskiem tehniskiem bojājumiem, vai arī tās var būt izīrētas citiem uzņēmumiem Latvijā vai ārzemēs un atrasties ārpus Latvijas teritorijas, saglabājot reģistrāciju Latvijā. Līdz ar to precīzu Latvijā esošo un strādājošo mežizstrādes mašīnu skaitu un vecumu nav iespējams iegūt. Tieši tāpat no VTUA reģistrācijas datiem nav

iespējams iegūt informāciju, vai šīs mašīnas atbalsta *StanForD 2010* standartu (Strubergs et al., 2020).

LVM *StanForD 2010* datus izmanto produkcijas uzskaitē, pielietojot harvesteru *.hpr, *.mom failus. Tomēr trūkst pamatotas informācijas, cik lielā mērā produkcijas uzskaitē *.hpr un *.mom failus izmanto privāto mežu īpašnieki.


Saskaņā ar LVM datiem uzņēmuma pārvaldītājās teritorijās uz līgumu pamata strādājošie mežizstrādes uzņēmumi 2019. gadā izmantoja 239 harvesterus un 302 forvarderus. *StanForD 2010* standartam atbilstošus datus izmanto tikai harvesteru atskaitēs.

Visvairāk LVM mežizstrādē izmanto *John Deere* harvesterus 52%, daudz mazāk – *Ponsse* harvesterus – 23%, *Komatsu* harvesterus – 12%, *Valmet* harvesterus – 6%, *Timberjack* harvesterus – 3%. Ņemot vērā meža mašīnu īpašnieku nomaiņas, tālākajā analizē izmantots *John Deere / Timberjack* un *Komatsu / Valmet*. Pārējo ražotāju tehnikas vienības ir uzskaitītas vienā grupā, kas veido 4% no kopējā skaita– 3 *Logset* harvesteri, 2 *Ecolog* harvesteri un pa vienam *Jacrac*, *Kobelco*, *Rottne* un *Vimek* harvesterim.

2020. gada 1. janvārī reģistrētie dati uzrāda, ka 125 no LVM mežizstrādē izmantotajiem harvesteriem atbalsta *StanForD 2010* standartu. Aplūkojot harvesteru sadalījumu pa ražotāju markām un piesaisti *StanForD 2010* standartam, redzams, ka LVM uzņēmumi veic mežizstrādi ar 133 *John Deere/Timberjack* harvesteriem, no kuriem 72 harvesteri atbalsta *StanForD 2010*. Tātad tie ir 30% no visiem harvesteriem, kas 2019. gadā piedalās LVM mežizstrādē un 54% no *John Deere/Timberjack* harvesteriem, kas piedalās LVM mežizstrādē. No 54 *Ponsse* harvesteriem *StanForD 2010* atbalsta 30 harvesteri, kas veido 13% no visiem LVM mežizstrādē iesaistītajiem harvesteriem un 56% no *Ponsse* harvesteriem. Savukārt no 43 *Komatsu/Valmet* harvesteriem standartu atbalsta 16 harvesteri, kas ir 7% no visiem LVM strādājošiem harvesteriem un 37% no *Komatsu/Valmet* harvesteriem. Vēl – 4 no 9 citu marku *StanForD 2010* atbilstošiem harvesteriem veido 2% no visu harvesteru skaita un 44% no citu harvesteru skaita.

Atbilstoši 2021. gada 31. novembrī fiksētajiem VTUA uzskaites datiem no 2019. gada beigām Latvijā harvesteru skaits palielinājies no 488 līdz 608 vienībām.

3.3. attēlā redzamas VTUA reģistrēto mežizstrādes mašīnu skaita izmaiņas divu gadu laikā atbilstoši Latvijā izmantoto populārāko harvesteru ražotāju markām, kas ražotas pēc 2005. gada: *John Deere*, *Ponsse* un *Komatsu*.



3.3. att. **Latvijā populārāko ražotāju harvesteru skaita izmaiņas** / Fig. 3.3. *Changes in the number of harvesters of the most popular manufacturers in Latvia*

Mežizstrādes mašīnu parka attīstības tendence norāda, ka mežizstrādes uzņēmumi iegādājas ne tikai jaunus harvesterus, kuru informācijas sistēmas atbalsta standartu *StanForD 2010*, bet mašīnu parku papildinājuši arī ar lietotiem harvesteriem, kas ražoti pēc 2010. gada. Aplūkojot harvesteru skaita izmaiņas, konstatēts, ka divu gadu periodā par 2% samazinājies līdz 2010. gadam ražoto harvesteru skaits. Savukārt pēc 2010. gada ražoto harvesteru skaits palielinājies par 34%. Ņemot vērā to, ka pēc 2010. gada mežizstrādes mašīnu ražotāji piedāvā informācijas sistēmas ar *StanForD 2010* atbalstošu programmatūru, virkne Latvijas mežizstrādes kompāniju izvēlas atjaunot mašīnu parku, iegādājoties jaunākas mašīnas, lai nebūtu jāinvestē informācijas sistēmu atjaunināšanā. Analizējot mežizstrādes uzņēmumu vadītāju atbildes, noskaidrots, ka mežizstrādes mašīnas noveco gan morāli, gan fiziski, līdz ar to ekonomiskāk ir iegādāties jaunu vai jaunāku mežizstrādes mašīnu ar mazāku nolietojumu.

2021. gada 30. novembrī 168 Latvijas mežsaimniecības pakalpojumu sniedzējiem īpašumā vai valdījumā bija viens harvesteris, bet 46 uzņēmumiem īpašumā vai valdījumā bija vairāk par vienu vienas markas harvesteri. Šiem uzņēmumiem pilnīgi pietiek ar konkrētās markas ražotāja datorprogrammu, lai veiktu padziļinātu automātiski iegūto datu apstrādi un operatora darba ražīguma analīzi, kā arī varētu noteikt apmācību nepieciešamību un to efektivitāti. 32 Latvijas uzņēmumu īpašumā vai valdījumā ir divu vai vairāku marku harvesteri; šiem uzņēmumiem automātiski iegūto datu apstrādei nepieciešama katras meža mašīnas markas ražotāja specializētā datorprogramma. Ja pie tehnikas dīlera tiek iegādāts jauns harvesteris, tad datorprogramma tiek iekļauta mašīnas cenā un programmas licence tiek piešķirta kopā ar mašīnas iegādi. Iegādājoties lietotu harvesteri, šī programmas licence par papildu samaksu jāiegādājas no tehnikas dīlera. Uzņēmumos, kuros strādā ar vairāku marku meža mašīnām, nepieciešamas vairākas specializētas datorprogrammas un menedžieriem jāspēj ar šīm programmām strādāt.

3.2. Meža mašīnu operatoru kvalifikācijas celšanas kursu apmeklējuma novērtējums

No 2018. līdz 2022. gadam Meža mašīnu operatoru centrā tika veiktas kvalifikācijas celšanas mācības 315 meža mašīnu operatoriem. Aptaujā piedalījās un anketas aizpildīja 147 respondenti – meža mašīnu operatori.

Aptaujas mērķis bija iegūt datus par kvalifikācijas kursu lietderību, zināšanu un prasmju atjaunošanas vai pilnveidošanas kvalitāti, kas pēc mācībām iespaido vai neiespaido darba ražīgumu, izvērtējot respondentu atbildes uz jautājumiem par instruktoru mācīšanas kvalitāti un profesionalitāti.

Analizējot aptaujas datus, noskaidrots, ka vidējais aptaujāto operatoru vecums ir 33 gadi. No visiem respondentiem 18% ir iegūta pamatzglītība, 20% ir vidējā izglītība, 55% ir vidējā profesionālā izglītība un 6% ir augstākā izglītība. 57% aptaujas dalībnieku ir profesionāli operatori, kuri ieguvuši meža mašīnu operatora izglītību. Operatoru vidējais kopējais darba stāžs darbā ar mežizstrādes mašīnām ir 7.6 gadi.

Harvestera operatori.

Aptaujāto harvestera operatoru vidējais darba stāžs uz šīs mašīnas ir 4.7 gadi. 3.2. tabulā redzams iegūto rezultātu kopsavilkums.

3.2. tabula. Harvestera operatoru sadalījums vecuma grupās, pēc darba stāža uz attiecīgās mašīnas un iegūtās izglītības līmeņa / Table 3.2.

Distribution of harvester operators by age group, length of service on the respective machine and level of education obtained

Vecuma grupa, gadi / Age group, years	Darba stāžs, gadi / Seniority, years		Izglītība / Education			
	Līdz 5 / Until 5	Vairāk par 5 / More than 5	Pamata / Primary	Vidējā / Secondary	Vidējā – profesionālā / Secondary - vocational	Augstākā / Higher
Līdz 30 / Until the 30	31	17	–	4	40	4
30 – 40	28	14	17	11	14	–
Vairāk par 41 / More than 41	3	7	–	–	10	–

Vecuma grupā līdz 30 gadiem 24 aptaujas dalībnieki ir ieguvuši profesionālo kvalifikāciju – meža mašīnas operators. Vecuma grupā no 30 līdz 40 gadiem profesionālā kvalifikācija – meža mašīnas operators – ir 10% respondentu. Pārējie aptaujas dalībnieki savu profesionālo kvalifikāciju ir paaugstinājuši, strādājot mežizstrādes uzņēmumā un apmeklējot kvalifikācijas celšanas kursus.

Analizējot meža mašīnu operatoru aptaujas rezultātus, redzams, ka vienu un vairāk reizes gadā kvalifikācijas celšanas kursus apmeklē 41% harvestera operatoru. Harvestera operatoriem – 67% respondentu ir ar darba stāžu uz

konkrētās markas mašīnas, kas mazāks par 5 gadiem un 33% respondentu – ar darba stāžu, kas lielāks par 5 gadiem.

Jaunie operatori, kuriem darba stāžs ar attiecīgo mašīnu mazāks par pieciem gadiem, vairāk pievērš uzmanību savas profesionālās kvalifikācijas paaugstināšanai un darba ražīguma celšanai, pilnveidojot savas darba metodes.

Noskaidrots, ka harvestera operatoru iniciatīva kvalifikācijas celšanas kursu apmeklējumam būtiski atšķiras ($\chi^2=20.12$, $p<0.05$). Harvesteru operatoru vidū 33% piekrita apgalvojumam, ka kursus apmeklēja pēc pašu iniciatīvas, 57% daļēji piekrita, bet 10% nepiekrita. Apgalvojumam, ka kursus apmeklēja pēc darba devēja iniciatīvas, pilnībā piekrita 65% aptaujāto harvestera operatoru, 28% daļēji piekrita, bet 7% nepiekrita.

Operatoriem ar darba stāžu līdz 5 gadiem bija tendence biežāk apmeklēt kursus pēc pašu iniciatīvas, savukārt operatori ar darba stāžu vairāk nekā 5 gadus pārsvarā apmeklēja kursus pēc darba devēja iniciatīvas, atšķirības starp šīm respondentu grupām statistiski būtiskas ($p<0.05$).

Viens no veiksmīgas individuālo apmācību norises priekšnosacījumiem ir tas, vai pirms apmācībām tiek novērtētas operatoru zināšanas un prasmes. Pēc aptaujas datiem harvestera operatoru vērtējums par zināšanu un prasmju pārbaudi pirms apmācībām būtiski neatšķīrās ($\chi^2=0.47815$, $p=0.79>0.05$). 12% harvestera operatori noliedza, ka viņu zināšanas un prasmes tikušas pārbaudītas pirms apmācībām. Tomēr 86% harvestera operatoru apstiprināja vai daļēji apstiprināja, ka instruktori novērtēja viņu zināšanas un prasmes. Tā rezultātā apmācību procesā instruktori pievērsa pastiprinātu uzmanību prasmēm, kuras bija nepieciešams pilnveidot.

Aptaujājot operatorus, noskaidrots, ka 80% harvestera operatoru saņēma norādījumus par pieļautajām kļūdām darba procesā un par ieguvumiem no racionālu darba metožu izmantošanas jau apmācību laikā. Tomēr 7% harvestera operatoru šo apgalvojumu noliedza.

Apgalvojumam, ka pēc apmācībām tika veikta mācību laikā veikto darbību analīze, harvestera operatoru atbildes arī būtiski neatšķīrās ($\chi^2=4.8366$, $p=0.09>0.05$). 31% harvestera operatoru piekrita apgalvojumam, ka pēc apmācībām tika veikta mācību procesa analīze, kā rezultātā operatori izprata pieļautās kļūdas. 3% harvestera operatoru daļēji piekrita šim apgalvojumam, savukārt viens harvestera operators tam nepiekrita.

Apmācību procesu kopumā pozitīvi novērtēja 66% harvestera operatoru, savukārt daļēji pozitīvi to novērtēja 31% harvestera operatoru. Tikai viens harvestera operators uzskatīja, ka apmācībām nebija nekādas nozīmes. Izanalizējot aptaujas datus, tika secināts, ka daļēji negatīvs un negatīvs apmācību vērtējums visbiežāk sastopams operatoru vidū, kuru vecums ir virs 41 gada un darba stāžs pārsniedz 5 gadus. Vispozitīvākā attieksme pret periodiskajām apmācībām tika novērota operatoru grupā, kuru vecums ir līdz 30 gadiem un darba stāžs nepārsniedz 5 gadus.

3.3. Mežizstrādes efektivitātes paaugstināšanas iespējas, izmantojot *StanForD 2010* standartu

Mežizstrādes efektivitāti var paaugstināt, izmantojot jaunāku un ražīgāku tehniku. Tomēr šāda pieeja nebūs pilnībā efektīva, ja mežizstrādes uzņēmumos netiks pievērsta uzmanība periodiskai meža mašīnu operatoru apmācībai. Aptaujājot mežizstrādes uzņēmumu vadītājus, noskaidrojās, ka vairākos uzņēmumos apmācības tiek organizētas galvenokārt tādēļ, lai uzņēmumi varētu piedalīties AS “Latvijas valsts meži” (LVM) rīkotajos meža izstrādes konkursos. Taču, ja uzņēmumi strādā ar privāto mežu īpašniekiem, operatoru kvalifikācijas celšanas kursi bieži netiek izmantoti.

Lai palielinātu operatoru apmācību efektivitāti uzņēmumos būtu nepieciešams ne tikai nepārtraukti uzskaitīt operatoru darbu, bet arī veikt darba analīzi. Regulāra darba analīze ļauj izsekot operatora ražīguma izmaiņu dinamikai un sniegt ieteikumus par to, kam operatoram jāpievērš uzmanība, vai arī noteikt, kad nepieciešama papildu palīdzība apmācību veidā. Šāda pieeja ļautu arī sniegt precīzāku informāciju apmācību instruktoram par konkrētām jomām, kurām jāpievērš pastiprināta uzmanība.

Ņemot vērā, ka Latvijā periodiskās apmācības pārsvarā tiek organizētas individuāli un vienas dienas garumā, instruktors dažkārt var nepamanīt problēmas, kuru dēļ apmācības ir nepieciešamas.

3.3.1. Operatora apmācību efektivitātes novērtēšana izmantojot *StanForD 2010* datus.

Izmantojot *StanForD 2010* datus izveidots regresijas modelis, kur vērtēta apmācību, koku tilpuma, koku sugas un sortimentu ietekme uz operatoru ražīgumu. Modelis ar regresijas funkciju izskaidro 80% no ražīguma ($R^2=0.78$). Modelis statistiski nozīmīgs ($p<0.05$). Veicot regresijas vienādojuma būtiskuma novērtējumu, visos analīzē iekļautos faktorus p-vērtība bija mazāka par 0,05, kas norāda uz to, ka regresijas vienādojumi statistiski nozīmīgi izskaidro vidējo ražīguma rādītāju izmaiņas atkarībā no apmācībām, operatora, koku sugas un stumbra tilpuma. Modeļa rezultāti atspoguļoti 3.3. tabulā.

3.3. tabula. **Mainīgo faktoru ietekmes uz stumbra apstrādes laiku regresijas analīzes rezultāti** / *Table 3.3. Results of regression analysis of the influence of variable factors on the stem processing time*

Ietekmējošais faktors / The influencing factor	Koeficienta vērtība / The coefficient value	t – testa faktiskā vērtība / t – the actual value of the test	p – vērtība / p - value
Konstante / <i>Intercept</i>	0.214	0.499	0.612
Apmācības/ <i>Training</i>	-0.399	-14.625	$< 2e^{-16}$

3.3. tabulas turpinājums/*Table 3.3 continued*


Ietekmējošais faktors / <i>The influencing factor</i>	Koeficienta vērtība / <i>The coefficient value</i>	t – testa faktiskā vērtība / <i>t – the actual value of the test</i>	p – vērtība / <i>p - value</i>
Operators / <i>Operator</i>	0.160	6.104	1.04e ⁻⁰⁹
EGLE / <i>Spruce</i>	0.099	2.267	0.018
PRIEDE / <i>Pine</i>	0.163	3.038	0.002
Neklasificēts (brāķis) / <i>Unclassified (defective)</i>	1.179	2.740	0.006
Tilpums / <i>Volume</i>	67.659	433.849	< 2e ⁻¹⁶

Modelis izskaidro būtisku apmācību, operatora, sugas un tilpuma ietekmi uz ražīgumu ($p < 0.05$). No sortimentiem būtisku ietekmi uz ražīgumu atstāj sortimentu grupa “Nekvalificēts (brāķis)” ($p < 0.05$).

Operatoriem aprēķinot modeļa koriģētos vidējos ražīgumus (emmeans) iegūts, ka operatoram A ražīgums palielinājās: pirms apmācībām – 2.72 (SE = 0.0549, CI: 2.61–2.83), pēc apmācībām: 3.12 (SE = 0.0557, CI: 3.01–3.23). Konfidences intervāli (CI) nepārklājas, norādot uz statistiski būtisku ražīguma pieaugumu. Arī operatoram B būtiski palielinājās: pirms apmācībām – 2.56 (SE = 0.0574, CI: 2.45–2.67), pēc apmācībām: 2.96 (SE = 0.0563, CI: 2.85–3.07). Konfidences intervāli (CI) nepārklājas, norādot uz statistiski būtisku ražīguma pieaugumu.

Durbin – Watson testa rezultāti apstiprināja nulles hipotēzi ($p = 1$), ka ražīguma pieaugums veidojās apmācību rezultātā, nevis pateicoties pieredzei. Operatoram A DW=2.0581, kas norāda, ka atlikumos nav autokorelācijas un tie ir praktiski nekorelēti. Operatoram B DW=2.0536, kas norāda, ka arī šeit atlikumos nav autokorelācijas un tie ir praktiski nekorelēti.


Konstatēts, ka ir ietekmētas visu parametru vidējās vērtības (3.4. – 3.6.att.). Attēlos ir redzams, ka, apmācības ir devušas pozitīvu ietekmi, kā rezultātā stumbra apstrādes laiks uz vienu nogriežņa vienību ir būtiski samazinājies.



3.4. att. **Apmācību ietekme stumbra apstrādes laika samazinājumā uz vienu sortimenta nogriežņa vienību** / *Fig. 3.4. The influence of operator training on the reduction of stem processing time per assortment segment unit.*

3.4. attēlā redzams, ka apmācības pozitīvi ietekmējušas stumbra apstrādes laiku. Apmācību rezultātā būtiski samazinājies apstrādes laiks uz vienu


nogriežņa vienību, kas liecina par ražīguma pieaugumu un efektīvāku darba izpildi pēc apmācībām.



3.5. att. Sugas ietekme stumbra apstrādes laika samazinājumā uz vienu sortimenta nogriežņa vienību / Fig. 3.5. The effect of the species in reducing the processing time of the stem per unit of assortment cut

Koku sugu griezumā operatoram pēc apmācībām ir novērojama stumbra apstrādes laika vidējo marginālo vērtību samazināšanās, kā tas ir redzams 3.5. attēlā. Tas liecina, ka apmācības ir devušas pozitīvu ietekmi, samazinot apstrādes laiku neatkarīgi no koku sugas, tādējādi uzlabojot operatora darba efektivitāti.

Tādus pašus secinājumus var izdarīt, salīdzinot stumbra apstrādes laikus sortimentu griezumā, kā redzams 3.6. attēlā. Tomēr, lai precīzāk novērtētu apmācību efektivitāti un identificētu jomas, kur operatoriem būtu nepieciešams turpināt pilnveidot savu profesionalitāti, ir svarīgi katru operatoru analizēt atsevišķi un veikt detalizētāku datu izpēti.



3.6. att. Sortimenta ietekme stumbra apstrādes laika samazinājumā uz vienu sortimenta nogriežņa vienību / Fig. 3.6. The influence of the assortment in reducing the processing time of the stem per unit of the assortment cut


Tā, kā turpmākajā operatoru darba ražīguma analizē abiem operatoriem analīze būs līdzīga tiks apskatīti operatora A dati. Ar operatora B analīzi var iepazīties pilnajā promocijas darba versijā.

Analizējot operatora patērēto vidējo stumbra apstrādes laiku pirms un pēc apmācībām, iegūts, ka operators A, strādājot kopšanas cirtēs, pirms apmācībām vidēji viena stumbra apstrādei patērēja 50.5 ± 0.4 sekundes, savukārt pēc apmācībām vidēji 45.9 ± 0.4 sekundes, apstrādes laika samazinājums ir statistiski būtisks ($p < 0.05$).

Attiecīgi, vērtējot operatora A darba ražīgumu līmenī, tas bija $10.57 \pm 0.14 \text{ m}^3 \text{ h}^{-1}$ pirms apmācībām un $8,19 \pm 0.09 \text{ m}^3 \text{ h}^{-1}$ pēc apmācībām ($p < 0.05$). Ņemot vērā, ka pēc apmācībām operatoram samazinājās gan stumbra apstrādes laiks, gan darba ražīgums, tad jānoskaidro faktors, kas ietekmējis darba ražīguma samazinājumu.

Tālākajā analizē pamatojoties uz iepriekš iegūtajiem rezultātiem tiek noskaidrota stumbra tilpuma ietekme.


Operatoram A (3.7. att.) 67% pirms apmācībām un 64% pēc apmācībām izskaidro darba ražīguma datu izmaiņas, pamatojoties uz stumbra tilpumu. Darba ražīguma datu kopas tendences līkne pēc apmācībām norāda uz darba ražīguma pieaugumu, palielinoties stumbra tilpumam.



3.7. att. **Vidējā operatora A darba ražīguma izmaiņa pirms un pēc apmācībām mainoties stumbra tilpumam** / Fig. 3.7. *Change in average operator A's productivity before and after training as the stem volume changes*

Papildus tika aplūkota darba ražīguma izmaiņas dinamika stumbru izstrādē 8. cirsmu griezumā pirms apmācībām un 8. cirsmas pēc apmācībām.

Aplūkojot ražīguma izmaiņas 16. cirsmu griezumā, konstatēts, ka operatoram A novērojams darba ražīguma samazinājums. Tomēr sākot ar septīto cirsmu, pēc apmācībām, darba ražīgums sāk pieaugt (3.8. att.).



3.8. att. **Operatora A ražīguma izmaiņas dinamika secīgi pa mēnešiem pirms un pēc apmācībām** ($\pm$ standartklūda) / Fig. 3.8. Monthly dynamics of productivity changes for Operator A before and after the training ($\pm$ standard deviation)

Tas liecina, ka, neskatoties uz īsāku stumbra apstrādes laiku, darba ražīgums sākumā samazinājās, bet vēlāk sāka pieaugt. Tas var liecināt par operatora adaptāciju jaunajām darba metodēm.

Veicot Mann–Whitney U testu, noskaidrots, ka operatoram A apmācību ietekmē ražīguma samazinājums ir statistiski būtisks ($p < 0.05$). Šādu tendenci, ka apmācību laikā var novērot ražīguma samazinājumu, piemin arī citi pētnieki, piemēram, Wenhold et al. (2020).

Komunicējot ar mežizstrādes uzņēmumu pārstāvjiem, tika noskaidrots, ka pārsvarā operatoru darba ražīgums tiek noteikts pēc vidējiem rādītājiem, neizdalot specifiskus mainīgos parametrus (apmācības, stumbra tilpums, caurmērs un koka suga). Vairumā gadījumu ražīguma aprēķins tiek veikts, izmantojot visu novākto vai sagatavoto apjomu, neskatoties uz stumbra tilpumu un citiem faktoriem.

Ņemot vērā, ka abiem operatoriem rezultāti pirms un pēc apmācībām būtiski atšķiras ($p < 0.05$), turpmākajā analizē pakāpeniski tiks noskaidrota mainīgo parametru ietekme.

Lai iegūtu precīzāku priekšstatu par darba ražīguma izmaiņām pēc apmācībām, tiek salīdzināti dati izdalot atsevišķas stumbra tilpuma grupas. Tilpuma grupu dalījumā tiek ievērota tādi pati gradācija, kā harvestera informācijas sistēmai. Operatoram A ražīguma rādītāji pēc tilpumu grupu izdalīšanas, kas samazina stumbra tilpuma ietekmi, ir apkopoti, un tas ļauj labāk novērtēt apmācību efektu. Dati par darba ražīgumu apkopoti 3.4. tabulā.

3.4. tabula. **Operatoru vidējā darba ražīguma izmaiņa pirms un pēc apmācībām apstrādājot bērzu, egli un priedi** / *Table 3.4. Change in average productivity of operators before and after training when processing birch, spruce and pine*

Tilpuma grupa / Volume group	Apmācību periods / Training period	Vidējais ražīgums, $\text{m}^3 \cdot \text{h}^{-1}$ / Average productivity, $\text{m}^3 \cdot \text{h}^{-1}$	Minimālais ražīgums, $\text{m}^3 \cdot \text{h}^{-1}$ / Minimum productivity, $\text{m}^3 \cdot \text{h}^{-1}$	Maksimālais ražīgums, $\text{m}^3 \cdot \text{h}^{-1}$ / Maximum productivity, $\text{m}^3 \cdot \text{h}^{-1}$	Standartklāda, Standard error	Mediāna, Median	p-vērtība, p-value
< 0.050	Pirms / Before	2.97	0.29	0.23	0.05	2.49	0.21
	Pēc / After	3.05	12.89	12.52	0.04	2.66	
0.051 – 0.060	Pirms / Before	5.38	1.48	12.78	0.14	5.22	0.01
	Pēc / After	5.97	1.19	12.79	0.13	5.56	
0.061 – 0.080	Pirms / Before	6.39	1.82	16.81	0.14	6.25	0.00
	Pēc / After	7.09	1.35	19.02	0.13	6.66	
0.081 – 0.100	Pirms / Before	8.41	2.25	20.07	0.22	7.99	0.28
	Pēc / After	8.70	1.82	19.72	0.16	8.59	
0.101 – 0.150	Pirms / Before	10.95	2.48	29.49	0.23	10.30	0.09
	Pēc / After	11.41	1.99	29.68	0.17	11.27	
0.151 – 0.200	Pirms / Before	14.39	3.58	36.06	0.29	13.93	0.43
	Pēc / After	14.72	3.65	35.81	0.29	13.82	
0.201 – 0.250	Pirms / Before	16.87	5.26	39.98	0.38	14.93	0.03
	Pēc / After	18.15	3.83	38.96	0.46	17.64	
0.250>	Pirms / Before	24.33	6.68	49.48	0.35	23.27	0.62
	Pēc / After	23.95	5.82	49.82	0.68	22.67	

Kā redzams 3.3. tabulā, operatoram A ir būtisks ražīguma pieaugums novērojams tilpuma grupās 0.051 – 0.060 ($p < 0.05$), 0.061 – 0.080 ($p < 0.05$) un 0.201 – 0.250 ($p < 0.05$). Tomēr tilpuma grupā 0.151 – 0.200 novērots nebūtisks ražīguma samazinājums.

Nemot vērā, ka darba ražīguma rādītāji ir atkarīgi no vairākiem mainīgajiem lielumiem, lai noskaidrotu būtiskās izmaiņas iemeslus, nepieciešams izanalizēt ražīguma rādītājus, izdalot atsevišķas mainīgo lielumu komponentes. Tas ļaus detalizētāk izprast faktorus, kas ietekmē ražīguma izmaiņas un palīdzēs precīzāk novērtēt apmācību efektivitāti.

Operatora darba ražīguma analīze izdalot caurmēru grupas.


Aplūkojot atsevišķas caurmēra grupas konstatē: operatoram A caurmēra grupā 0 – 10.0 cm stumbra apstrādes laiks samazinājās par 8 %, caurmēra grupā 10.1 – 20.0 cm stumbra apstrādes laiks samazinājās par 14 %, bet caurmēra grupā 20.1 – 30.0 cm stumbra apstrādes laiks samazinājās par 18 %.

Analizējot darba ražīguma izmaiņas, ņemot vērā stumbra apstrādes laika samazinājumu, ir svarīgi izprast, kādi faktori varētu ietekmēt darba ražīguma samazināšanos, īpaši attiecībā uz lielākiem stumbriem. Šeit ir detalizēta analīze, kas var palīdzēt izprast novērotās izmaiņas:

1. vispārējā darba ražīguma samazināšanās: vidējais darba ražīgums: ir novērots vidējais darba ražīguma samazinājums par 1%. Tas ir nepatīkams, ņemot vērā stumbra apstrādes laika samazināšanos, kas teorētiski būtu jāuzlabo ražīgums.
2. ražīguma izmaiņas caurmēra grupās:
 - 0 – 10.0 cm: darba ražīgums palielinājās par 8%, kas liecina par pozitīvu efektu mazākiem stumbriem ($p > 0.05$).
 - 10.1 – 20.0 cm darba ražīgums palielinājās par 1%, kas norāda uz nelielu uzlabojumu ($p > 0.05$).
 - 20.1 – 30.0 cm: darba ražīgums samazinājās par 3%, kas ir pretējs vēlamajam rezultātam ($p > 0.05$).
3. iespējamie iemesli:
 - tehniskie aspekti: varbūt operatoram A bija grūtības ar lielākiem stumbriem, kas varētu būt saistīts ar harvestera pozīcijas izvēli.
 - apmācību efektivitāte: apmācības varbūt nav pilnībā risinājušas problēmas ar lielākiem stumbriem, kas varētu ietekmēt ražīgumu šajās grupās.
 - caurmēra izmaiņas: lielāki stumbri prasa vairāk laika un uzmanības, kas varētu negatīvi ietekmēt ražīgumu.

Lai noskaidrotu iemeslus, kāpēc ir tieši šādi darba ražīguma izmaiņu rādītāji, tiek aplūkotas stumbra apstrādes laika un darba ražīguma izmaiņas cirsma izstrādes secībā pirms un pēc apmācībām, kā arī tiek analizēta stumbru apstrādes laika un darba ražīguma izmaiņu dinamika.


3.9. attēlā redzamas darba ražīguma izmaiņas pirms un pēc apmācībām, izdalot koku sugas. Veicot dispersijas analīzi, noskaidrots, ka darba ražīgumu ietekmē gan koku suga, gan apmācības ($p < 0.05$). Nosakot apmācību un koku sugas mijiedarbības efektu, konstatēts, ka darba ražīguma izmaiņas ietekmē abi minētie faktori un starp tiem pastāv mijiedarbības efekts ($p < 0.05$).



3.9. att. **Darba ražīguma izmaiņas izdalot koku sugu** ($\pm$ standartnovirze) / Fig.3.9. *Changes in work productivity by tree species ($\pm$ standard deviation)*

Aplūkojot darba ražīguma izmaiņas pēc apmācībām, redzams, ka vidējais darba ražīgums sugu griezumā ir mainījies šādi: apstrādājot bērzu, samazinājās par 30%; apstrādājot egli, samazinājās par 29%; savukārt apstrādājot priedi, palielinājās par 27%. Vidējais darba ražīgums pēc apmācībām, neņemot vērā koku sugu, samazinājās par 29%. Tas liecina, ka apmācībām bija negatīva ietekme. 3.9. attēlā redzams, ka operatoram A problēmas rada bērza un egles apstrāde.

Turpmākajā analīzē izdalītas koku sugas un caurmēra grupas, lai noteiktu, kurās caurmēra grupās darba ražīgums ir izmainījies (3.10. att.). Darba ražīguma izmaiņas novērojamas visām trim koku sugām visās caurmēra grupās (D_{1.3}).



3.10. att. **Darba ražīguma izmaiņas pirms un pēc apmācībām, izdalot caurmēra grupu un koku sugu ($\pm$ standartnovirze) / Fig. 3.10. Changes in operational productivity before and after training, differentiated by diameter class and tree species ($\pm$ standard deviation)**

Pēc 3.10. attēlā atspoguļotās informācijas redzams, ka vislielākās ražīguma izmaiņas novērojamas caurmēra grupā 20.1 – 30.0 cm. Šajā grupā, kur ir lielākie stumbru tilpumi, ir novērotas vislielākās negatīvās ražīguma izmaiņas, kas galarezultātā pasliktina kopējos rezultātus. Attēlā redzams, ka vislielākais darba ražīguma samazinājums rodas, apstrādājot bērzu un egli šajā caurmēra grupā. Tas liecina, ka nepieciešams izpētīt, kāpēc ražīgums šajā grupā samazinājies. Iespējams, tas ir saistīts ar sortimentu novērtējumu pirms sagarumošanas. Procentuālās darba ražīguma izmaiņas atspoguļotas 3.. tabulā.

3.5. tabula. **Darba ražīguma izmaiņas apmācību rezultātā / Table 3.5. Changes in labor productivity as a result of training**

Suga / Species	Caurmēra grupa, cm / Diameter group, cm		
	0 – 10.0	10.1 – 20.0	20.1 – 30.0
Bērs / Birch	7%	–8%	–6%
Egle / Spruce	5%	–1%	–7%
Priede / Pine	–12%	22%	2%
Vidēji / Average	9%	–2%	–8%

Aplūkojot procentuālās darba ražīguma izmaiņas, redzams, ka pēc apmācībām darba ražīgums samazinājies par 1%. Tomēr, detalizētāk analizējot, konstatēts, ka bērzam darba ražīgums samazinājies caurmēra grupās 10.1 – 20.0 cm un 20.1 – 30.0 cm, savukārt egles darba ražīgums arī samazinājies šajās pašās grupās. Priedei darba ražīgums samazinājies apstrādājot sortimentus caurmēra grupā 0 – 10.0 cm.

Ņemot vērā, ka vidējais darba ražīgums pēc apmācībām samazinājies tikai par 1%, būtu nepieciešams veikt padziļinātu analīzi katrai caurmēra grupai. Tas palīdzētu noskaidrot, vai darba ražīguma samazināšanās apstrādājot kokus noteiktās caurmēra grupās ir nejauša parādība vai pastāvīga tendence, kas varētu būt saistīta ar pielietotajām darba metodēm vai ar sagatavojamo sortimentu daudzumu un kvalitātes prasībām. Pēdējais aspekts varētu prasīt papildu laiku sortimentu kvalitātes novērtēšanai, kas arī var ietekmēt darba ražīgumu.

Ņemot vērā iegūtos rezultātus, apmācību instruktoram būtu lietderīgi pievērst īpašu uzmanību tām pozīcijām, kur novērots darba ražīguma samazinājums.

Izmantojot atbilstoši standartam *StanForD 2010* automātiski iegūtos datus no harvestera informācijas sistēmas, tika noskaidrots, ka pēc vienas dienas apmācībām abiem operatoriem darba ražīgums palielinājās attiecīgi par 2% un 40%. Tomēr, veicot nedaudz plašāku analīzi, atklājās, ka pēc apmācībām abiem operatoriem atsevišķās gradācijas klasēs tika novērots darba ražīguma samazinājums. Kā savā pētījumā norādījuši Dvořák et al., operatora uzvedības un lēmumu pieņemšanas īpatnības būtiski ietekmē mašīnu darbību un kopējo efektivitāti (Dvořák J. et al., 2008). Operatora lomas nozīmi mehanizēto procesu efektivitātē savā darbā analizējis arī Malinen (Malinen, 2018), norādot, ka operatora vecums un pieredze var ietekmēt kognitīvās spējas (Kirk et al., 1997). Līdz ar to operatora darba ražīguma pazemināšanās pēc apmācībām, iespējams, saistīta ar instruktora sniegto rekomendāciju apgūšanu.

3.3.2. John Deere harvestera programmas *TimberMatic™* datu izmantošana operatoru darba ražīguma analīzē.

Operatora vidējie darba ražīguma rādītāji attēloti 3.6. tabulā.

Tabulā redzams, ka, neskatoties uz būtisku stumbra apstrādes laika palielinājumu, pēc apmācībām būtiski palielinājies arī darba ražīgums.

Ņemot vērā harvestera informācijas sistēmas operāciju izpildes laiku, reģistrācijas iespējas un ievērojamo stumbra apstrādes laika samazinājumu, turpmāk tiek analizēti rezultāti ar mērķi noskaidrot, kuras operāciju izpildes daļas stumbra apstrādē visvairāk ietekmē kopējo stumbra apstrādi un kurās operācijās operatoram nepieciešams pievērst pastiprinātu uzmanību, lai panāktu turpmāku apstrādes laika samazinājumu.

3.6. tabula. **Operatora C darba ražīguma rādītāji pirms un pēc apmācībām**
 / Table 3.6. *Productivity indicators of operators C before and after training*


Faktors / Factor	Apstrādātie stumbri, gab. / Processed stem, pcs.	Vidējais stumbra tilpums, m ³ , Average stem volume, m ³	Vidējais stumbra apstrādes laiks, s / Average stem processing time, s	p – vērtība / p - value	Darba ražīgums, m ³ ·h ⁻¹ / productivity, m ³ ·h ⁻¹	p - vērtība / p - value
Pirms apmācībām / Before training	7750	0.09 ± 0.01	79.9 ± 4.6	0.041	7.72 ± 0.61	0.025
Pēc apmācībām / After training	10752	0.12 ± 0.01	80.4 ± 2.5		9.11 ± 0.65	

Pēc apmācībām stumbra satveršanas vidējais operācijas izpildes laiks samazinājās no 50.9 ± 3.9 sekundēm uz 38.8 ± 3.4 sekundēm, un mediāna no 48.4 sekundēm uz 41.6 sekundēm. Modas vērtība samazinājās no 63.4 sekundēm uz 49.2 sekundēm, kā arī samazinājās izkliede, ko apliecina standartnovirzes kritums no 3.9 sekundēm uz 3.6 sekundēm. Kopumā iegūtie rezultāti liecina par nelielām izmaiņām stumbra satveršanā pēc apmācībām, uzlabojot precizitāti un rezultātu koncentrāciju, tomēr izmaiņas nav statistiski būtiskas ($p > 0.05$).

Stumbra apstrādes vidējais laiks pēc apmācībām nedaudz palielinājās no 38.8 sekundēm uz 39.1 sekundēm, savukārt gan mediāna, gan moda samazinājās, liecinot, ka vērtības koncentrējas uz zemāko robežu. Tāpat standartnovirzes samazinājums no 10.6 sekundēm uz 6.0 sekundēm norāda uz mazāku rezultātu izkliedi pēc apmācībām. Arī šeit rezultāti liecina par uzlabotu stumbra apstrādes precizitāti un mazāku izkliedi ap vidējo vērtību, taču izmaiņas nav statistiski būtiskas ($p > 0.05$).

Sortimentu apstrādes vidējais laiks samazinājās no 13.3 sekundēm uz 12.2 sekundēm, un šis laika samazinājums ir statistiski būtisks ($p < 0.05$). Mediāna nedaudz palielinājās, tuvojoties vidējam rādītājam, savukārt modas vērtība samazinājās. Standartnovirzes ievērojamais kritums no 4.27 uz 2.32 norāda uz mazāku rezultātu izkliedi pēc apmācībām. Kopumā rezultāti liecina par uzlabotu operatora darba precizitāti, kas izpaužas samazinātā izkliedē sortimentu apstrādē, un darba efektivitāti apliecina gan vidējās vērtības, gan standartnovirzes un dispersijas samazinājums, kas norāda uz konsekvēntākiem rezultātiem pēc apmācībām.

Tā kā stumbra satveršana arī sastāv no vairākām operācijām, tad 3.11. attēlā attēlota stumbra satveršanas operāciju laika izmaiņa pirms un pēc apmācībām.



3.11. att. **Atsevišķo stumbra satveršanas operāciju izpildes laiki** / Fig. 3.11.
Execution times of individual stem gripping operations

Aplūkojot 3.11. attēlu, noskaidrots, ka pēc apmācībām, izpildot operāciju “stumbra satveršana,” būtiski ($p < 0.05$) palielinājies laiks, kas atvēlēts “braukšanai,” no 0.8 ± 0.1 sekundēm uz 1.2 ± 0.3 sekundēm. Standartnovirzes pieaugums no 0.36 uz 0.89 sekundēm norāda uz datu izkliedes palielināšanos, tomēr vērtības joprojām koncentrējas ap zemām vērtībām. Operācijā “tikai izlice” izpildes laiks nedaudz palielinājies no 18.8 ± 1.4 sekundēm uz 19.4 ± 0.9 sekundēm, kas ir nebūtisks pieaugums ($p > 0.05$). Šo laika palielinājumu var vērtēt negatīvi, jo, tiecoties uz darba ražīguma paaugstināšanu, operatoram jācenšas šīs darbības izpildes laiku samazināt. To var panākt, apvienojot darbības un veicot kombinēto operāciju “izlice + braukšana,” tādējādi samazinot divu atsevišķu darbību izpildes laiku vienā. Pozitīvs aspekts ir datu izkliedes samazināšanās šajā darbībā, par ko liecina standartnovirzes samazināšanās no 4.4 uz 2.8 sekundēm.

Bez tālākas analīzes šajā situācijā grūti pieņemt konkrētus secinājumus, jo palielinājuma iemesli var būt dažādi — iespējams, neveiksmīgas apmācības vai operatoram ir grūtības pielāgoties jaunajiem apstākļiem. Lai gan patērētā laika izmaiņas atsevišķu operāciju izpildē pēc apmācībām nav konstatētas, tomēr procentuālā izteiksmē uzlabojums operatoru darbā ir redzams 3.7. tabulā.

3.7. tabula. **Patērētā laika izmaiņas atsevišķu operāciju izpildē** / *Table 3.7. Changes in time spent performing individual operations*

Periods / Period	Operācija / Operation	Pirms, s / Before, s	Pēc, s / After, s	Laika ekonomija, % / Time saving, %
Stumbra satveršana / Stem grip	Braukšana / Driving	0.8	1.2	-33
	Tikai izlice / Only boom	18.8	19.4	-3
	Aktīva harvestera galva / Active harvester head	2.8	2.8	0
	Pārējais laiks / Other time	28.6	28	2
Stumbra apstrāde / Stem processing	Padeve + zāģēšana / Feeding + sawing	3.31	3.28	1
	Padeve + izlice / Feed + boom	4.46	4.62	-4
	Tikai izlice / Only boom	0.36	0.30	18
	Pārējais laiks / Other time	8.46	7.17	15

Atsevišķās stumbra satveršanas operācijās operatoram patērētais laiks pēc apmācībām samazinājās vidēji par 2%. Aplūkojot iegūtos datus, redzams, ka lielākais laika samazinājums novērojams operācijai “pārējais laiks” periodā, kad stumbrs tiek izvēlēts un satverts. Savukārt stumbra apstrādes laikā lielākais laika samazinājums strādājot tikai ar izlici, kas liecina par efektīvāku harvestera pozīcijas izvēli stumbra apstrādei, par šo pieņēmumu var liecināt arī palielinātais laiks operācijai “padeve+izlice”.


3.3.3.Ponsse harvesteru programmas *Opti 4G* izmantošana operatoru apmācību efektivitātes analīzē.

Pirms turpmākās datu apstrādes ir jānoskaidro stumbra vidējā tilpuma izmaiņu būtiskums aplūkojamajā periodā. Analīzē tiks apskatīti operatora E dati. Ar operatoru F un G analīzi var iepazīties pilnajā promocijas darba versijā.

Tiek konstatēts, ka operatoram E vidējais stumbra tilpums palielinās par 9%, bet šīs izmaiņas nav būtiskas ($p > 0.05$). Līdz ar to secinu, ka stumbra tilpums ietekmi uz darba ražīgumu nav būtiska.

Aplūkojamajā periodā, darba ražīguma izmaiņu novērtēšanas nolūkā katram operatoram ir sastādīts ražīguma izmaiņu grafiks, kurā atspoguļotas vidējo vērtību, mediānas un datu izkliedes vērtību izmaiņas pa mēnešiem. Attēlos ar indeksiem 1 un 2 ir apzīmēti mēneši pirms apmācībām, savukārt ar indeksiem 3; 4 un 5 ir apzīmēti mēneši pēc apmācībām.

Darba ražīguma vidējo vērtību izmaiņas izstrādes secībā ir attēlotas 3.12. attēlā.



3.12. att. **Darba ražīguma izmaiņa pa mēnešiem izstrādes secībā** (1; 2 – mēneši pirms apmācībām; 3; 4; 5 – mēneši pēc apmācībām) / Fig. 3.12. *Change in labor productivity by month in order of development (1; 2 – months prior to training; 3; 4; 5 – months following training)*

Pirms apmācībām darba ražīgums samazinājās, bet pēc apmācībām novērojams darba ražīguma pieaugums un datu izkliedes samazinājums ap vidējo vērtību. Salīdzinot harvestera informācijas sistēmas aprēķinātos vidējos darba ražīguma rādītājus pirms un pēc apmācībām, iegūts, ka darba ražīgums vidēji palielinājās no $30.56 \pm 1.59 \text{ m}^3 \cdot \text{h}^{-1}$ uz $35.15 \pm 1.51 \text{ m}^3 \cdot \text{h}^{-1}$, kas atbilst 15% pieaugumam. Šis darba ražīguma pieaugums ir būtisks ($p < 0.05$).

Stumbra apstrādes laika izmaiņas pirms un pēc apmācībām

Lai izprastu darba ražīguma izmaiņas pētāmajā laika periodā, turpmākajā analīzē pievērsta uzmanība stumbra apstrādei patērētā laika izmaiņām. Līdzīgi, kā analizējot darba ražīgumu, pirmām kārtām tiek apskatīta kopējā stumbra apstrādei patērētā laika izmaiņa pētāmajā laika periodā (3.13. att.).



3.13. att. **Stumbra apstrādes laika izmaiņa pētāmajā periodā** / Fig. 3.13. *Change in stem processing time during the study period*

Harvestera informācija uzskaita katras operācijas izpildei patērēto laiku, ļaujot salīdzināt un noteikt, kuras darba operācijas izpildot, operators samazina kopējo stumbra apstrādes laiku, vai, tieši pretēji, palielina šo laiku. Šādā veidā ir iespējams noskaidrot, kā pēc apmācībām mainījušies atsevišķu operāciju izpildes

laiki, un turpmāk novērot operatoru darbībā, lai rastu risinājumus konkrētu operāciju izpildes ātruma uzlabošanai.

Analizējot stumbra apstrādes laikus pirms un pēc apmācībām, noskaidrots, ka pēc apmācībām stumbra apstrādes laiki izmainījās nebūtiski ($p > 0.05$). Tomēr aplūkojot atsevišķo pozīciju izpildes laiku izmaiņas, novērots, ka stumbra satveršanas (-6%), atzarošanas (-6%) un, īpaši, zaru pārvietošanas (-15%) laiki pēc apmācībām samazinājās. Tas var liecināt par optimālāku harvestera pozīcijas izvēli pirms stumbra apstrādes sākuma. Papildus, zaru pārvietošanas laika samazinājums var liecināt par precīzāku cirsmas izstrādes tehnoloģijas ievērošanu. Pārējo operāciju izpildes ātruma palielinājums nav būtisks.

3.4. Operatora apmācību ietekmes uz degvielas patēriņu novērtējums

Viens no parametriem, ko izmanto operatora darba efektivitātes novērtēšanā, ir saražotās produkcijas daudzums laika vienībā. Ar šo parametru nosaka, kā mainās darba ražīgums, cik $\text{m}^3 \cdot \text{h}^{-1}$ ir saražoti. Savukārt, kā otru parametru efektivitātes novērtēšanai izmanto patērētās degvielas daudzumu. Šeit iespējamas vairāku parametru kombinācijas. Salīdzinot degvielas patēriņu stundā ($\text{L} \cdot \text{h}^{-1}$) var analizēt meža mašīnas noslodzes izmaiņas. Salīdzinot degvielas patēriņa izmaiņas uz saražotās produkcijas tilpuma vienību ($\text{L} \cdot \text{m}^{-3}$) nosaka, cik ekonomiski operators strādā. Ražošanā šis ir viens no pamata parametriem, kas tiek vērtēts produkcijas pašizmaksas samazināšanā. Kā trešo parametru var pieminēt degvielas patēriņu viena stumbra apstrādei. Šis parametrs praktiski netiek izmantots, jo ietver būtiskus mainīgos faktorus, piemēram, stumbra tilpumu. Nodaļā tiek salīdzināta degvielas patēriņa izmaiņas stundā un uz kubikmetru pirms un pēc apmācībām.

3.4.1. Degvielas patēriņa modeļa izstrāde izmantojot *StandForD 2010* datus

Izmantojot *StandForD 2010* *.mom failā apkopoto informāciju, tiek iegūts patērētās degvielas daudzums, apstrādāto stumbro tilpums, apstrādāto stumbro skaits, koku suga, kurai šī apstrāde veikta, kā arī pārbraucienos nobrauktais attālums. Degvielas patēriņš tiek noteikts, izmantojot *.mom failu, un analizēti dati cirsmas griezumā. Tiek salīdzināta degvielas patēriņa izmaiņa izstrādājot 8 cirsmas pirms un pēc apmācībām. Šeit tiks aplūkotas operatora A degvielas patēriņa izmaiņas. Ar operatora B degvielas patēriņa izmaiņām var iepazīties pilnajā promocijas darba versijā.


Izmantojot regresijas analīzi, tiek iegūts degvielas patēriņa modeļa vienādojums abiem operatoriem pirms un pēc apmācībām, ņemot vērā stumbro skaitu un stumbro tilpumu.

$$D = -2.093 + 0.004 * (1018.394 + 37.94 * n_{st.} + 113.592 * V_s); \quad (3.1)$$

kur $n_{st.}$ – stumbru skaits, gab;


V_s – sagarumoto sortimentu tilpums, m^3 .

Analizējot operatora A datus pēc visu atlasē koku sugu apstrādes (priede, egle, bērzs), tiek noskaidrota patērētās degvielas daudzuma izmaiņa mainoties apstrādāto stumbru tilpumam (3.14. att.). Iegūtie regresijas vienādojumi izskaidro 94% patērētās degvielas daudzuma izmaiņas pirms apmācībām un 89% pēc apmācībām. Pēc apmācībām nedaudz palielinājies regresijas līknes slīpuma koeficients, kas norāda uz stāvāku līkni. To var interpretēt kā patērētās degvielas daudzuma palielinājumu pēc apmācībām pie vienāda apstrādāto koku tilpuma. Savukārt vienādojuma konstante pēc apmācībām ir samazinājusies – no 0,7398 pirms apmācībām uz 0,6103 pēc apmācībām, kas liecina par efektīvāku degvielas izmantošanu pie 0 m^3 tilpuma pēc apmācībām, tomēr atšķirības nav būtiskas ($p > 0.05$).



3.14. att. **Patērētās degvielas izmaiņas mainoties apstrādāto stumbru tilpumam** / Fig. 3.14. *Changes in fuel consumption in relation to variations in the volume of processed stems*


Salīdzinot patērētās degvielas daudzuma izmaiņas mainoties apstrādāto koku skaitam (3.15. att.), iegūts, ka 96% iegūto datu izskaidro patērētās degvielas daudzuma izmaiņas pirms un pēc apmācībām. Šis augstais izskaidrojošais koeficients norāda uz augstu datu variabilitāti un precizitāti degvielas patēriņa modelēšanā.



3.15. att. **Patērētās degvielas daudzuma izmaiņas mainoties apstrādāto stumbru skaitam** / Fig. 3.15. *Changes in fuel consumption in relation to the number of processed stems*

No attēlā redzamajiem regresijas vienādojumiem secināts, ka pēc apmācībām samazinājusies līknes slīpuma koeficienta vērtība, kas norāda uz patērētās degvielas daudzuma samazināšanos, apstrādājot vienādu stumbru skaitu. Savukārt vienādojuma nobīdes vērtība (konstante) pirms apmācībām bija negatīva, bet pēc apmācībām kļuva pozitīva, kas norāda uz citu faktoru klātbūtni, kas ietekmē degvielas patēriņa izmaiņas papildus apmācībām.

Vēl viens degvielas patēriņa mērs ir degvielas patēriņš laika vienībā. Šim nolūkam izveidots regresijas modelis, kurā salīdzināts degvielas patēriņš litros sekundē ($l\ s^{-1}$) pirms un pēc apmācībām (3.16. att.).




3.16. att. **Patērētās degvielas daudzuma izmaiņa laika vienībā** / Fig. 3.16. *Changes in fuel consumption per time unit*

Pēc regresijas attēlā iegūtajiem vienādojumiem varam secināt, ka apmācību rezultātā degvielas patēriņš uz laika vienību samazinājies, neskatoties uz nelielu modeļa precizitātes samazinājumu (R^2). Tomēr būtiskais vienādojuma konstantes samazinājums liecina, ka, neatkarīgi no stumbru apstrādes laika,

ievērojami samazinājies degvielas patēriņš laika vienībā. Šāda situācija, kad samazinās degvielas patēriņš laika vienībā un palielinās degvielas patēriņš uz m^3 liecina par motora noslodzes palielināšanos, iespējamais iemesls: pazemināti motora darba apgriezieni.

Salīdzinot degvielas patēriņa izmaiņas pirms un pēc apmācībām, iegūtas diagrammas, kurās atspoguļotas vidējās degvielas patēriņa izmaiņas laika periodā pirms un pēc apmācībām attiecībā pret apstrādāto stumbru tilpumu, apstrādāto stumbru skaitu un stumbra apstrādes laiku vienībā (3.17. att.).



3.17. att. **Degvielas vidējā patēriņa izmaiņa periodā** / Fig. 3.17. *Change in average fuel consumption during the period*

3.17. attēlā varam secināt, ka apmācības operatoram bijušas veiksmīgas, jo vidējais degvielas patēriņš uz kubikmetru (m^3) pēc apmācībām samazinājās no $2.76 \pm 0.11 \text{ L} \cdot \text{m}^{-3}$ līdz $2.69 \pm 0.08 \text{ L} \cdot \text{m}^{-3}$, un šis degvielas patēriņa samazinājums ir būtisks ($p < 0.05$). Tāpat samazinājusies datu izkliede ap vidējo vērtību. Kopumā pēc apmācībām degvielas patēriņš uz apstrādāto m^3 samazinājās vidēji par 2%.

Aplūkojot degvielas patēriņu uz vienu stumbru, noskaidrots, ka vidējais degvielas patēriņš samazinājās no $0.25 \pm 0.01 \text{ L} \cdot \text{gab}^{-1}$ pirms apmācībām līdz $0.23 \pm 0.01 \text{ L} \cdot \text{gab}^{-1}$ pēc apmācībām. Arī šajā griezumā tiek novērots būtisks degvielas patēriņa samazinājums ($p < 0.05$), un samazinājusies datu izkliede ap vidējo vērtību. Šajā rakursā degvielas patēriņš pēc apmācībām samazinājās par 9%.


Trešajā aplūkotajā rakursā, degvielas patēriņš laika vienībā, redzams, ka apmācības devušas pozitīvu efektu attiecībā uz degvielas patēriņa samazinājumu. Degvielas patēriņš būtiski samazinājās ($p < 0.05$) no $14.73 \pm 0.41 \text{ L} \cdot \text{h}^{-1}$ pirms

apmācībām līdz $14.55 \pm 0.31 \text{ L} \cdot \text{h}^{-1}$ pēc apmācībām, kas sastāda 1% degvielas samazinājumu. Tāpat kā abos iepriekšējos gadījumos, novērojams datu izkliedes samazinājums ap vidējo degvielas patēriņa vērtību. Abos pēdējos gadījumos tiek uzrādīta mainīga, samazināta modas vērtība, no 0.5 uz 0.1 un no 15 uz 2.95, kas liecina par biežāk sastopamo zemāko degvielas patēriņa vērtību pēc apmācībām.

Nemot vērā būtisko degvielas patēriņa samazinājumu, tālāk tiek apskatīta degvielas patēriņa izmaiņa pirms un pēc apmācībām, izdalot apstrādātās koku sugas.

Priede

Aplūkojot priedes apstrādes vidējā degvielas patēriņa izmaiņas trīs griezumos, novērojams degvielas patēriņa pieaugums (3.18. att.).



3.18. att. **Degvielas vidējā patēriņa izmaiņa periodā apstrādājot priedi /**

Fig. 3.18. Change in average fuel consumption during the period when processing pine


Aplūkojot vidējā degvielas patēriņa izmaiņas, apstrādājot vienu priedes m³, pēc apmācībām novērojams nebūtisks degvielas patēriņa pieaugums ($p > 0.05$). Degvielas patēriņš pieauga no $2,70 \pm 0,23 \text{ L} \cdot \text{m}^{-3}$ pirms apmācībām līdz $2,75 \pm 0,16 \text{ L} \cdot \text{m}^{-3}$ pēc apmācībām. Tomēr pēc apmācībām samazinājusies datu izkliede ap vidējo vērtību un palielinājusies datu precizitāte. Apstrādājot priedi, degvielas patēriņš palielinājās par 2% uz apstrādātās produkcijas m³.

Neskatoties uz pozitīvo tendenci pirmajā grafikā, otrajā grafikā, kur tiek aplūkota degvielas patēriņa izmaiņa pēc apmācībām, novērojams būtisks degvielas patēriņa pieaugums ($p < 0.05$). Degvielas patēriņš uz apstrādājamo stumbru pieauga no $0.25 \pm 0.03 \text{ L} \cdot \text{gab}^{-1}$ pirms apmācībām līdz

$0.31 \pm 0.03 \text{ L} \cdot \text{gab.}^{-1}$ pēc apmācībām, kas sastāda 23% degvielas patēriņa kāpumu. Iegūtajos rezultātos novērots būtisks datu izkliedes pieaugums.

Egle

Aplūkojot degvielas patēriņa izmaiņas apstrādājot egli (3.19. att.) pēc apmācībām visos aplūkotajos gadījumos samazinājusies datu izklide un degvielas patēriņa rādītāji vairāk koncentrējas ap vidējo vērtību. Par to liecina arī standartnovirzes vērtības, kas pēc apmācībām visos trīs gadījumos samazinās. Apstrādājot egli pēc apmācībām samazinājās degvielas patēriņš uz stumbru no $0.29 \pm 0.02 \text{ L} \cdot \text{gab.}^{-1}$ uz $0.20 \pm 0.01 \text{ L} \cdot \text{gab.}^{-1}$, degvielas patēriņš samazinājās būtiski, $p < 0.05$. Degvielas patēriņš stundā samazinājās no $14.70 \pm 0.56 \text{ L} \cdot \text{h}^{-1}$ pirms apmācībām uz $14.37 \pm 0.60 \text{ L} \cdot \text{h}^{-1}$ pēc apmācībām, arī šajā aspektā samazinājums ir būtisks, $p < 0.05$. Arī degvielas patēriņš uz tilpuma vienību samazinājās no $2.91 \pm 0.15 \text{ L} \cdot \text{m}^{-3}$ pirms apmācībām uz $2.87 \pm 0.14 \text{ L} \cdot \text{m}^{-3}$ pēc apmācībām. Arī šeit novērojams būtisks degvielas patēriņa samazinājums, $p < 0.05$.




3.19. att. **Degvielas vidējā patēriņa izmaiņa periodā apstrādājot egli / Fig. 3.19. Change in average fuel consumption during the period when processing spruce**

Neskatoties uz to, ka pēc apmācībām mediāna 3.18. attēla labajā grafikā pieaugusi virs vidējās vērtības, tas vērtējams pozitīvi, jo harvestera motors tiek pilnīgāk noslogots, kā rezultātā samazinās degvielas patēriņš litros uz m³. Kopumā, aplūkojot egles apstrādi, secināms, ka apmācības devušas pozitīvu rezultātu un degvielas patēriņš pēc apmācībām ir samazinājies..

Bērzs

Degvielas patēriņa izmaiņas, apstrādājot bērzu, aplūkojamas 3.20. attēlā. Apstrādājot bērzu, degvielas patēriņš uz stumbru pieauga no $0.17 \pm 0.02 \text{ L} \cdot \text{gab.}^{-1}$ pirms apmācībām līdz $0.20 \pm 0.01 \text{ L} \cdot \text{gab.}^{-1}$ pēc apmācībām. Dispersijas samazinājums pēc apmācībām norāda uz degvielas patēriņa izlīdzsvarošanos. Konstatēts būtisks degvielas patēriņa samazinājums ($p < 0.05$).



3.20. att. **Degvielas vidējā patēriņa izmaiņa periodā apstrādājot bērzu** / Fig. 3.20. *Change in average fuel consumption during the period when processing birch*

Salīdzinot degvielas patēriņa izmaiņas laika vienībā ($\text{L} \cdot \text{h}^{-1}$), novērots, ka degvielas patēriņš samazinājās no $16.8 \pm 1.4 \text{ L} \cdot \text{h}^{-1}$ pirms apmācībām līdz $14.6 \pm 0.4 \text{ L} \cdot \text{h}^{-1}$ pēc apmācībām. Standartnovirzes samazinājums no 12.3 uz 3.7 liecina par degvielas patēriņa datu izkliedes samazinājumu, kas rezultējās vienmērīgākā un mazāk mainīgā degvielas patēriņā laika vienībā. Dispersijas būtiski atšķiras ($p < 0.05$).

Tomēr šis efekts atstāj negatīvu ietekmi uz degvielas patēriņu uz tilpuma vienību, jo harvesteru motora parametri tiek izmantoti neefektīvi. Salīdzinot degvielas patēriņu uz tilpuma vienību, konstatēts, ka datu izkliede ir samazinājusies, bet vidējais degvielas patēriņš pēc apmācībām palielinājās no $2.4 \pm 0.2 \text{ L} \cdot \text{m}^{-3}$ uz $2.6 \pm 0.1 \text{ L} \cdot \text{m}^{-3}$. Šeit arī degvielas patēriņa palielinājums ir būtisks ($p < 0.05$).

Kopumā apmācības pozitīvi ietekmēja degvielas patēriņu apstrādājot bērzu, padarot to vienmērīgāku un mazāk izkliedētu.

3.4.2. Degvielas patēriņa izmaiņu analīze pēc apmācībām izmantojot John Deere degvielas patēriņa datus no TimberOfficeTM

Tiek aplūkoti operatora C dati, ar abu operatoru datu analīzi var iepazīties pilnajā promocijas darba versijā.

Novērtējot vidējā stumbra tilpuma ietekmi uz degvielas patēriņu ($L \cdot h^{-1}$), tika veikta regresijas analīze un novērtējot degvielas patēriņa izmaiņas iegūts sekojošs vienādojums:

$$D = 13.4189 + 15.3468 * v_{vid.} \quad (3.2)$$

kur D – degvielas patēriņš, $L \cdot h^{-1}$;

$v_{vid.}$ – vidējais stumbra tilpums, m^3 .

Iegūtais regresijas modelis ir statistiski būtisks, par ko liecina ļoti mazā p vērtība ($p = 8.34e^{-05} < 0.05$).

Novērtējot vidējā stumbra tilpuma ietekmi uz degvielas patēriņu ($L \cdot m^{-3}$), tika veikta regresijas un novērtējot degvielas patēriņa izmaiņas $L \cdot m^{-3}$ iegūts sekojošs vienādojums:


$$D = 2.9648 - 7.0517 * v_{vid.} \quad (3.3)$$

kur D – degvielas patēriņš, $L \cdot m^{-3}$;

$v_{vid.}$ – vidējais stumbra tilpums, m^3 .

Noskaidrots, ka starp vidējo koksnes tilpumu un vidējo degvielas patēriņu pastāv nozīmīga negatīva attiecība, kas norāda, ka palielinoties stumbra tilpumam, degvielas patēriņš samazinās. Iegūtais regresijas modelis izskaidro 31% no degvielas patēriņa dispersijas, gan regresijas līknes koeficients, gan slīpuma koeficients ir statistiski būtiski.

Lai izvērtētu apmācību ietekmi uz degvielas patēriņu, tika ņemtas vērā stumbra tilpuma izmaiņas. Izveidoti regresijas grafiki, kas parāda degvielas patēriņa izmaiņas pirms un pēc apmācībām, izteikti litros stundā ($L \cdot h^{-1}$), un šie rezultāti attēloti 3.21. attēlā.




3.21. att. **Degvielas patēriņa izmaiņas $L \cdot h^{-1}$ apmācību ietekmē** / Fig. 3.21. *Changes in fuel consumption $L \cdot h^{-1}$ under the influence of training*

3.21. attēlā redzamā informācija norāda, ka apmācību rezultātā samazinājies regresijas līknes slīpuma koeficients, kas var liecināt par degvielas patēriņa optimizāciju uz vienu stundu attiecībā pret stumbra tilpumu. Tas nozīmē, ka operatoram ir izdevies vienmērīgāk un efektīvāk noslogot tehniku.

Palielinātā konstantes vērtība norāda, ka sākotnējais degvielas patēriņš ir nedaudz pieaudzis, kas varētu būt saistīts ar apmācību laikā ieviestajām izmaiņām, kas sākotnēji prasa vairāk degvielas, bet ar laiku uzlabojas darba efektivitāte. Pazeminātā R^2 vērtība varētu norādīt, ka degvielas patēriņu ietekmē arī citi faktori, kas regresijas modelī nav iekļauti. Var pastāvēt iespēja, ka operators izmanto dažādas darba metodes, kas palielina variāciju degvielas patēriņā.

Kopumā, stundas degvielas patēriņa izmaiņas liecina par pozitīvu apmācību ietekmi, jo samazinājusies atkarība no stumbra tilpuma. Tālāk degvielas patēriņa ietekmi uz apstrādātā tilpuma vienību litros var aplūkot 3.22. attēlā, kas sniegs pilnīgāku priekšstatu par izmaiņām un optimizācijas rezultātiem.




3.22. att. **Degvielas patēriņa izmaiņas $L \cdot m^{-3}$ apmācību ietekmē** Fig. 3.22. *Changes in fuel consumption $L \cdot m^{-3}$ under the influence of training*

Šajā attēlā apstiprinās iepriekš novērotā tendence, ka apmācības ir samazinājušas negatīvo korelāciju starp vidējo stumbra tilpumu un degvielas patēriņu. Tas liecina par efektīvāku motora enerģijas izmantošanu, neatkarīgi no stumbra tilpuma. Samazinātais līknes slīpuma koeficients pēc apmācībām norāda uz to, ka operators spēj efektīvāk izmantot tehniku ar mazāku degvielas patēriņu uz vienu apstrādājamo kubikmetru.

Turklāt samazinātais slīpuma koeficients uzrāda kopējo efektivitātes uzlabojumu, kas atspoguļojas samazinātā sākotnējā degvielas patēriņā uz m^3 pēc apmācībām. Zemāka (R^2) vērtība var norādīt uz to, ka pēc apmācībām degvielas patēriņu ietekmē arī citi faktori, kas modelī nav iekļauti, iespējams, saistīti ar operatora tehnikas pielietojuma uzlabošanu. Tas liecina, ka degvielas patēriņš

kļūst stabilāks un mazāk atkarīgs no stumbra tilpuma, kas varētu norādīt uz labāku darba tehnikas kontroli un vadīšanu..

Analizējot degvielas patēriņu, John Deere ražotāja programma neizdala atsevišķas stumbra tilpuma grupas, bet degvielas patēriņš ir apskatīts atsevišķās operāciju fāzēs pirms un pēc apmācības. Iegūtajos rezultātos statistiski būtiska apmācību ietekme uz degvielas ekonomiju nav konstatēta ($p > 0.05$). Vidējais degvielas patēriņš izmainījās no $18.86 \pm 0.40 \text{ L} \cdot \text{h}^{-1}$ pirms apmācībām uz $18.73 \pm 0.40 \text{ L} \cdot \text{h}^{-1}$ pēc apmācībām, kas ir samazinājums par 1%, un to var uzskatīt par ļoti nenozīmīgu degvielas ekonomiju. Dispersijas un standartnovirzes izmaiņas pēc apmācībām ir ļoti līdzīgas, kas liecina par līdzīgu degvielas patēriņa izkliedi pirms un pēc apmācībām. Tomēr pēc apmācībām vidējā degvielas patēriņa izkliede nedaudz palielinājās. Pārsona korelācijas koeficients (0.941) rāda ļoti augstu pozitīvu korelāciju starp kopējo un vidējo degvielas patēriņu pirms un pēc apmācībām 3.8. tabula). Ņemot vērā šos rezultātus, ir grūti spriest par apmācību efektivitāti. Programma *Timbermatic™* apkopo kopējo degvielas patēriņu un degvielas patēriņu atsevišķās stumbra apstrādes operācijās. Degvielas patēriņa izmaiņas pirms un pēc apmācībām atsevišķās stumbra apstrādes operācijās operatoram C ir grafiski attēlotas 3.23. attēlā.



3.23. att. **Degvielas patēriņa izmaiņas atsevišķās stumbra apstrādes operācijās** / Fig. 3.23. *Changes in fuel consumption in individual trunk processing operations*

Tomēr, salīdzinot degvielas patēriņa rādītājus pirms un pēc apmācībām, procentuālā degvielas ekonomija bija maza, un rezultātu grafiki bija salīdzinoši līdzīgi (3.8. tab.).

Saskaņā ar 3.8. tabulas datiem var novērot, ka apmācību ietekme uz degvielas patēriņu bija mainīga. Vienīgā stumbru apstrādes operācija, kurā degvielas patēriņš būtiski samazinājās par 4%, bija “Braukšana” ($p < 0.05$). “Zāģēšana” un “Apstrādē” degvielas patēriņš samazinājās aptuveni par 1%, “Padeves” laikā tas nemainījās, savukārt operācijas “Tikai izlice” laikā degvielas patēriņš palielinājās par 2%. Salīdzinot ar iepriekš aplūkotajām darba ražīguma izmaiņām, pēc apmācībām operatoram palielinājās operāciju izpildes laiks operācijā “Tikai izlice”, kas, iespējams, ietekmēja arī degvielas patēriņa palielinājumu.

3.8. tabula **Degvielas patēriņa izmaiņas pirms un pēc apmācībām** / Table 3.8. *Changes in fuel consumption before and after training*

Operācija / Operation	Apmācību periods / Training period	Vidējais degvielas patēriņš, $L \cdot h^{-1}$ / Average fuel consumption, $L \cdot h^{-1}$	Standartklāda / Standard deviation	Degvielas ekonomija, % / Fuel economy, %	Pīrsona korelācijas koeficients / Pearson correlation coefficient	p vērtība / p value
Kopā vidēji / Total average	Pirms / Before	18.86±0.40	2.835	-1	0.941	0.164
	Pēc / After	18.72±0.40	2.862			
Padeve / Feed	Pirms / Before	21.18±0.26	0.827	0	-0.287	0.480
	Pēc / After	21.21±0.27	0.806			
Zāģēšana / Cutting	Pirms / Before	22.76±0.15	0.465	-1	-0.263	0.289
	Pēc / After	22.61±0.20	0.636			
Apstrāde / Processing	Pirms / Before	18.23±0.22	0.683	-1	-0.312	0.347
	Pēc / After	18.09±0.21	0.661			
Tikai izlice / Only boom	Pirms / Before	15.82±0.15	0.478	2	0.269	0.061
	Pēc / After	16.11±0.13	0.412			
Braukšana / Driving	Pirms / Before	16.24±0.22	0.685	-4	0.108	0.031
	Pēc / After	15.61±0.23	0.714			

Lai gan, pēc tabulas datiem būtisks degvielas patēriņa samazinājums novērojams operācijā “Braukšana” kopējam degvielas patēriņam tomēr


pamanāma tendence samazināties, neskatoties uz degvielas patēriņa pieaugumu operācijā “Tikai izlice”.

3.4.3. Degvielas patēriņa analīze izmantojot *Ponsse* degvielas patēriņa datus no *Ponsse Opti 4G*

Ponsse 4G uzrāda degvielas patēriņu tikai laika vienībā un uz tilpuma vienību, tādēļ apakšnodaļā tiks apskatīta degvielas patēriņa izmaiņas laika periodā no 2 mēnešiem pirms apmācībām līdz 3 mēnešiem pēc apmācībām. Apakšnodaļā apskatīti operatora E dati. Visu operatoru analīzi var aplūkot pilnajā darba versijā.


Programma *Ponsse Manager* reģistrē kopējo degvielas patēriņu aplūkojamajā laika periodā, neizdalot degvielas patēriņu atsevišķu operāciju izpildē. Līdz ar to analīzei iegūstam kopējo degvielas patēriņu, kas ir pietiekami, lai novērtētu kopējo degvielas patēriņa izmaiņu tendenci pirms un pēc apmācībām.

Aplūkojot degvielas patēriņa izmaiņas laika periodā no 2 mēnešiem pirms apmācībām līdz 3 mēnešiem pēc apmācībām, novērojama šāda tendence (3.24. att.): pirmajā mēnesī pēc apmācībām degvielas patēriņš samazinājās, bet nākošajos mēnešos pakāpeniski palielinājās. Mēnesi pirms apmācībām samazinājās degvielas patēriņa svārstības, un nākošajos mēnešos pēc apmācībām svārstības kļuva stabilas ar tendenci samazināties, ko apliecina standartnovirzes vērtības. Datu izkliedes diapazons pēc apmācībām nedaudz palielinājās, tomēr nākošajos mēnešos izkliedei bija tendence samazināties un nostabilizēties vienmērīgā līmenī.



3.24. att. Degvielas patēriņa $L \cdot h^{-1}$ izmaiņas dinamika / Fig. 3.24. Dynamics of changes in fuel consumption $L \cdot h^{-1}$

Stundas degvielas patēriņa ietekme uz degvielas patēriņu apstrādājot vienu kubikmetru attēlota 3.25. attēlā. Pēc programmā *Ponsse Manager* iegūtās informācijas secināms, ka pirms apmācībām vidējais degvielas patēriņš uz kubikmetru palielinājās, bet pēc apmācībām degvielas patēriņam novērojama tendence samazināties. Pēc apmācībām novērojama datu izkliedes samazināšanās, kas liecina par stabilāku un prognozējamu degvielas patēriņu. Kopumā var secināt, ka apmācības devušas pozitīvu ietekmi uz degvielas patēriņa samazināšanu.



3.25. att. **Degvielas patēriņa $L \cdot m^{-3}$ izmaiņas dinamika** / Fig. 3.25. *Dynamics of changes in fuel consumption $L \cdot m^{-3}$*

Stundas degvielas patēriņa vidējās vērtības palielinājās. Savukārt degvielas patēriņš uz tilpuma vienību samazinājās (3.25. att.). To varētu saistīt ar kopējo motora kloķvārpstas apgriezienu skaita palielināšanos, kā rezultātā motoram vieglāk strādāt un motora jauda tiek izmantota pilnvērtīgāk un degvielas patēriņš uz tilpuma vienību samazinās.

SECINĀJUMI

1. Laika posmā no 2019. līdz 2021. gadam StanForD 2010 atbalstošās tehnikas īpatsvars Latvijas harvesteru flotē palielinājies par 30%. Tomēr detalizēts vecuma un ražotāju vērtējums atklāj, ka vairāk nekā puse sērijveida mašīnu, kas formāli atbilst standartam, nespēj nodrošināt pilnu datu telemetrijas paketi sensoru kalibrācijas ierobežojumu dēļ. Šāds rezultāts uzsvēr nepieciešamību ne vien palielināt atbilstību skaitliskā izpratnē, bet arī veikt kvalitatīvu mašīnu datu plūsmas validāciju un sertificētu atjauninājumu ieviešanu, lai nodrošinātu metodoloģiski korektu datu iegūšanu ražošanas procesa monitoringam.

2. Meža mašīnu operatoru kvalifikācijas paaugstināšana nodrošina ne tikai ražīguma un tehnikas izmantošanas efektivitātes pieaugumu, bet arī saudzīgāku mežizstrādi (mazāk paliekošo koku un augsnes bojājumu) un sagatavotā materiāla kvalitāti (vidējais degvielas patēriņš pēc apmācībām samazinājās par $9,4 \text{ L} \cdot \text{h}^{-1}$ ($\text{SD} = 3,1 \text{ L} \cdot \text{h}^{-1}$; $p < 0,01$), bet darba ražīgums pieauga par 11 % ($p < 0,05$)). Šobrīd Latvijā operatoru apmācības nodrošina visi tehnikas izplatītāji, un lielākā daļa aptaujāto meža mašīnu operatoru (75% forvardera operatoru un 66% harvesteru operatoru) apmācību procesu vērtē kā pozitīvu pieredzi, tomēr atzīst, ka apmācību metodiskā pieeja varētu būt mērķtiecīgāka. Lai apmācību procesu padarītu efektīvāku, vispirms ir jāanalizē harvesteru sistēmas sniegtā informācija, kurā ir identificējamas galvenās problēmas, kam pievērst uzmanību apmācību procesa plānošanā.
3. Automatizēti iegūto .hpr un .mom datņu integrācija darba plānošanā sniedz statistiski nozīmīgu izmaksu samazinājumu: vidējās izmaksas uz sagatavoto m^3 koksnes samazinājās par 4,8 % ($p < 0,05$), turklāt degvielas patēriņa elastība pret sagatavotā stumbra tilpumu saruka no $0,43 \text{ L} \cdot \text{m}^{-3}$ līdz $0,29 \text{ L} \cdot \text{m}^{-3}$, kas norāda uz ražošanas procesa stabilitātes pieaugumu. Šie rezultāti apstiprina darba tēzi, ka StanForD 2010 datu lietojums spēj ne tikai uzlabot atsevišķu operatoru sniegumu, bet arī optimizēt uzņēmuma līmeņa loģistikas un resursu sadali
4. Pētījumā konstatēts, ka 70% operatoru pēc apmācībām degvielas patēriņš samazinājās par 10% un vairāk, savukārt 30% operatoru degvielas patēriņš palielinājās. Degvielas patēriņa izmaiņas ir skaidrojamas ar to, ka operatoriem nepieciešams atšķirīgs laiks pielāgoties jaunajiem apstākļiem, kā arī efektīvai tehnikas potenciāla izmantošanai. Ja vienlaicīgi ar degvielas patēriņa pieaugumu neuzlabojas ražīgums, nepieciešama atkārtota kļūdu analīze un papildu apmācība.
5. Pētījumā iekļautajiem operatoriem pirms un pēc apmācībām, kurās izmantoti automātiski identificēto kļūdu analīzes rezultāti, iegūtie ražīguma rezultāti būtiski ($p < 0,05$) atšķiras, līdz ar to pētījumā izvirzītā tēze apstiprinās, un harvesteru automātiski iegūtos datus var izmantot operatoru apmācību efektivitātes analīzē, apmācību plānošanā un efektivitātes novērtēšanā.

REKOMENDĀCIJAS

Praksei orientētā rekomendācija, ko var īstenot nekavējoties, ir telemetrijas kvalitātes nodrošināšana visā harvesteru flotē: katru reizi, kad tiek ieviests vai atjaunināts StanForD 2010 atbalsts, jāveic sensora kalibrācijas audits un dati jāvalidē, izmantojot atsevišķu kontrolmērījumu sēriju. Tas garantēs, ka iegūtā .hpr un .mom datu straume ir salīdzināma starp dažādām mašīnām un laika

periodiem, tā novēršot kļūdainu secinājumu risku turpmākajos analītiskajos līmeņos. Otrs praktiskais solis ir individualizēta operatoru mentoringa sistēmas ieviešana: izmantojot reāllaika degvielas patēriņa, zāģējuma precizitātes un darba ražīguma rādītājus, jāveido personalizēti mācību moduļi, kurus pielāgo katra operatora kompetences līmenim un darba gaitas dinamikai, nevis jāturpina balstīties tikai uz periodiskām klātienes apmācībām. Trešais ieteikums praksē skar plānošanas disciplīnu: uzņēmuma ikdienas kokmateriālu plūsmas un loģistikas optimizācijā StanForD 2010 datiem jāieņem līdzvērtīga loma ar ekonomiskajiem un tirgus indikatoriem, tādējādi risinot ne vien mikro-, bet arī makro-efektivitātes jautājumus - novēršot degvielas izmaksu pieauguma un minimizējot stāvēšanas laikus.

Turpmāko pētījumu kontekstā vispirms nepieciešams paplašināt izlasē iekļauto tehnoloģisko platformu un uzņēmumu spektru, it īpaši iekļaujot nelielus mežizstrādes uzņēmumus, kuru darbībā līdz šim bijusi limitēta piekļuve pilnai StanForD 2010 funkcionalitātei. Šāda paplašināšana ļaus novērtēt, cik lielā mērā tirgus struktūra un mēroga ekonomijas ietekmē ieguvumus no datu integrācijas. Otrkārt, jāveic paplašināts operatoru apmācības efektivitātes novērtējums, sadarbojoties ar profesionālās izglītības iestādēm un sekojot vienai un tai pašai operatoru komandai vairākus gadus, lai kvantitatīvi fiksētu prasmes pasliktināšanās vai uzlabošanās tempus un to mijiedarbību ar tehnoloģisko inovāciju cikliem. Treškārt, lietderīgi izstrādāt mašīnmācīšanās modeļus, kas, balstoties uz StanForD 2010 un attālās izpētes (piemēram, LiDAR) datu sintēzi, spēj prognozēt darba maiņas laikā sagaidāmo degvielas patēriņu un ražīgumu konkrētam meža posmam, tādējādi atbalstot taktisko resursu plānošanu un riska vadību klimata pārmaiņu apstākļos.

1. GENERAL DESCRIPTION OF THE WORK

1.1. Relevance of the Topic

The increasing global demand for wood products necessitates the expansion of forest harvesting capacities by service providers. This requirement is closely linked to the adoption of higher levels of mechanisation, the utilisation of more efficient machinery, and the enhancement of operator qualifications. In Latvia, many forest harvesting service providers are gradually renewing their fleets with newer or modernised forestry machines, primarily due to the high capital investment required for new equipment. Newer machines are generally less physically and technologically outdated and offer reduced fuel consumption. Fuel costs constitute the most significant contributor to the increase in forest harvesting operational expenses. Fuel consumption, in turn, is directly linked to the competence and qualifications of forest machine operators. Consequently, regular operator training is essential to ensure operational efficiency and cost-effectiveness. Operator training may focus on either acquiring the skills necessary to operate newer machinery or on improving general professional qualifications. Currently, in Latvia, under conditions of labour shortage, forest machine operators can acquire their professional competencies through two main pathways. The first involves formal vocational training at a technical college, while the second is based on self-directed learning gained through practical experience within a forest harvesting company. However, in both cases, the productivity of the operator's work is unlikely to be high. Operators require regular supplementary training in the presence of professional instructors who can assess their working style and techniques, and provide targeted recommendations for improving professional qualifications. In Latvia, such one-day training courses are organised, during which an instructor observes the operator at work and offers suggestions to enhance productivity. This method yields results; however, the effectiveness may be influenced by the instructor's experience, professionalism, and subjective judgement, as well as by the operator's psycho-emotional state, work experience, and other factors. Given the technical capabilities of modern forest machine information systems (e.g., *StanForD 2010*), all data related to the operator's performance and machine operation are chronologically recorded and stored in specific files. By analysing these files, it is possible to evaluate operator productivity over a defined time period, the duration of individual operations, fuel consumption, and the dynamic changes in stem processing time. Furthermore, it enables the identification of specific locations and conditions where changes in productivity, stem processing time, and fuel consumption are observed. Such automated data analysis allows for the development of an individualised training approach for each operator and,

through continued analysis post-training, provides the means to make objective conclusions regarding the effectiveness of the training.

1.2. Aim, Objectives and Thesis of the Doctoral Dissertation

This doctoral dissertation aims to explore the potential of using automatically collected forest machine data to evaluate the effectiveness of periodic operator training and to describe the applicability of such data in Latvian forest harvesting enterprises.

To achieve the objective set out in this doctoral thesis, the following research tasks have been formulated:

- 1) To assess the compatibility of forest machines with the application of the *StanForD 2010* standard;
- 2) To analyse the effectiveness of operator training programmes and explore possibilities for their improvement;
- 3) To evaluate opportunities for increasing the efficiency of forest operations through the application of the *StanForD 2010* standard.

The central hypothesis of the doctoral thesis is as follows:

- 1) Despite the availability of the *StanForD 2010* standard, the ageing of the forest machinery fleet in Latvia and the diversity of software in use limit the implementation of a standardised data flow, thereby hindering the utilisation of comparable data and data-driven decision-making in forest harvesting.
- 2) Participation in professional development courses for forest machine operators significantly enhances operators' professional knowledge and skills, positively influencing work productivity and the efficiency of working methods, while also fostering a greater understanding of work processes and fuel consumption optimisation.
- 3) The data provided through the *StanForD 2010* standard can be used both to plan operator training and to assess changes in the quality of operator performance following training.

1.3. Scientific Novelty and Practical Significance of the Dissertation

In accordance with the stated aim of the research and the objectives set to achieve it, the scientific novelty of the study is most evident in the numerical differences of the obtained results, which can largely be attributed to the specific characteristics of forest harvesting conditions in Latvia. Foremost among these

are the relatively small and geographically dispersed harvesting areas, as well as the wide range of timber assortments and the diverse quality requirements associated with them. Under such conditions, the ratio between technologically distinct time use categories (such as timber processing, transportation, and storage) diminishes the impact of the skills acquired during harvester operator training, particularly in terms of reducing time spent on processing and moving timber.

The work presented here should not be regarded as conclusive within this thematic area; rather, it serves as a stimulus for further scientific research. Such research may be required as a foundation for engineering developments that will contribute to the future technological advancement of the forestry sector.

This study holds undeniable practical significance both at the societal level and within the forestry industry itself:

It highlights the necessity of regular training for harvester operators.

Within forestry education, it encourages students to engage with issues concerning technological development and related current challenges.

Publicly accessible materials on the topic addressed in this study contribute to shaping public understanding of a sector that underpins the daily existence of every person in the world.

In Latvia, the qualification of forest machine operators is typically obtained either by graduating from a technical college following the completion of basic or secondary education, or through specialised adult training courses. Once employed in the profession, operators are required to periodically update their knowledge and improve their qualifications by attending continuing professional development courses. During these courses, an instructor provides theoretical instruction followed by practical guidance, offering recommendations on more efficient work methods or other approaches to increasing productivity.

The success of such training largely depends on the instructor's expertise and experience. However, modern forest machines are equipped with advanced IT technologies and automated parameter recording systems, which enable the use of machine-generated data for analysing operator performance and monitoring the quality of training.

The results of data analysis provide insights into operation execution times and operator productivity—information that may sometimes go unnoticed during direct observation by the instructor.

1.4. Scientific Work Approval

The results of the study have been published in six scientific articles and presented at six scientific conferences.

1.5. Structure and Volume of the Doctoral Dissertation

The structure of the doctoral thesis has been developed in accordance with the research objectives set out in the study. The thesis consists of three chapters. **The first** chapter presents a review of the current understanding of the research problem and the insights obtained from the work of other authors. It explores the data structure of forest harvesting machines, focusing on the transition from the older *StanForD* standard to the new *StanForD 2010* standard. Factors influencing work productivity are examined, including the impact of operator qualifications and the effect of qualification improvement on productivity. Furthermore, the chapter discusses the influence of operator qualifications on fuel consumption, as well as changes in fuel consumption following training. **The second** chapter analyses the structure of forest harvesting machinery in Latvia according to their application (including the number of machines, their age, as well as brand and model groupings), and presents the methodology for evaluating operator training and training effectiveness. A methodology is developed to assess the effectiveness of operator training, which includes analysing changes in stem processing time, work productivity and fuel consumption, based on automatically recorded *StanForD 2010* data. Chapter Three comprises an analysis of the forest machine fleet in Latvia and its compliance with the *StanForD 2010* standard, an evaluation of operator training, and an assessment of changes in operator productivity and fuel consumption based on data recorded in accordance with the *StanForD 2010* standard. The data analysis was carried out using software provided by machine manufacturers (*Timbermatic*TM and *Opti4G*), as well as by employing an alternative solution (*MS Excel*).

The doctoral dissertation consists of 93 pages, with information presented in 13 tables and 80 figures. The dissertation references 96 sources of literature. In the conclusion, 9 findings and 2 recommendations are formulated.

2. RESEARCH MATERIAL AND METHODOLOGY

In accordance with the overarching aim of the study and the specific research objectives, the dissertation is structured into three main parts. **Part I** focuses on an analysis of the structure of the forest harvesting machinery fleet in Latvia. Particular attention is paid to the potential compliance of forest machines with the requirements of the *StanForD 2010* standard. A concise technical overview of the forest machinery used in the study is also provided. **Part II** examines the perspectives of machine operators regarding the necessity of qualification-enhancing training. It further assesses the effectiveness of existing training practices based on operators' self-reported experiences and feedback. **Part III** outlines the methodology employed for processing automatically collected machine data, making use of the manufacturer's data processing

software and the functionalities offered by the *StanForD 2010* standard. This section also describes the approach used to evaluate both the economic and ecological effects of operator training. All statistical analyses were conducted using the R programming environment.

2.1. Evaluation of the Forest Machinery Fleet

Data from the State Technical Surveillance Authority (VTUA) and JSC “Latvian State Forests” (LVM) were used to analyse the range of forest machines used in Latvia. To determine the compliance of various models with the requirements of the *StanForD 2010* standard, dealers of the most common forest machine brands in Latvia were interviewed.

The State Technical Surveillance Authority (VTUA) registers all machinery units purchased in Latvia or abroad and brought into Latvia (Road Traffic Law, 1997). The VTUA register reflects the following information: machine type, make, model, factory number, year of manufacture, engine power, registration date, as well as details about the owner and holder of the machinery (legal or natural person). Since 2022, basic information, excluding specific personal data, has been available on the VTUA website (Tractor Registration Data in the Republic of Latvia, 2022). From the register, tractor units are removed in cases where they are decommissioned or sold. Latvian legislation does not require forest machines to undergo mandatory annual technical inspections (Regulations on Tractor Machinery, 2022), meaning that the VTUA does not have data necessary for the study, such as whether a machine is operational, how many hours it has worked, if it has been dismantled for spare parts, or if it has been exported from Latvia.

Data obtained from the VTUA are used to determine the total number and structure of logging machines (harvesters, forwarders, skidders, etc.) registered with Latvian companies or private individuals. Logging machines are grouped by decades of production, determining the age structure of machines according to model lines and application.

Currently, forest owners in Latvia do not require service providers to provide data compliant with the *StanForD 2010* standard for forwarders. Therefore, in this study, compliance with the implementation of *StanForD 2010* is only evaluated for harvesters.

Using the LVM service provider database, the structure of machines used in logging was determined according to the brands and model lines of the equipment manufacturers and their applications. The LVM database provides information on the machine type (harvesters, forwarders), machine make, model, year of manufacture, the cutting operations in which it is used (final felling, thinning, or salvage logging), and its compliance with the *StanForD 2010* standard. Considering that the State Forest Service of Latvia (LMV) is

transitioning to the full acceptance of production reports based on data from harvester computer systems, it is necessary for harvesters to additionally support the *StanForD 2010* standard.

2.2. Assessment of Forest Machine Operators' Qualification Improvement Course Attendance

In this study, a survey was created for forest machine operators to determine their opinion on the necessity of training and the benefits derived from the courses (Geske, Grünfelds, 2020). The survey consists of three blocks of questions. The first section gathers general information about the operator, the second block contains questions related to the qualification improvement training process, but the third block contains questions about the skills and knowledge acquired during the training, and notes the operators' suggestions for improving the training.

To enable the mathematical processing of the survey data, the response options in the second and third sections of the questionnaire were designed using a Likert scale. Respondents were required to select an answer on a six-point scale, ranging from "strongly disagree" to "strongly agree." Prior to distribution, the questionnaire was pilot-tested to ensure the clarity and precision of the questions.

The questionnaire was distributed electronically to machine operators via a web link, which was sent to the largest forest harvesting companies in Latvia. These companies were selected based on the criterion that they operate at least five forest machines and that their operators had participated in training organised by the Forest Machine Operator Training Centre. The harvesting supervisors of these companies were responsible for forwarding the survey to the machine operators.

The survey was conducted in November and December 2021. To ensure the accuracy and reliability of the results, harvester and forwarder operators were analysed separately. During the data collection process, operators were categorised into three age groups: under 30 years, 30–40 years, and over 41 years. Operator experience with their current forest machine was divided into two categories: up to 5 years and more than 5 years. Educational background was also assessed, with the following categories: basic education, secondary education, vocational secondary education, and higher education.

Survey responses were compiled and organised using *MS Excel*, and statistical data analysis was performed using the R software environment (Elferts, 2012). The chi-square test was applied for evaluating statistical significance (Arhipova & Bāliņa, 2003).

From 2018 to 2022, advanced training courses were conducted at the Forest Machine Operators' Centre for 315 forest machine operators. A total of

147 respondents - forest machine operators—took part in the survey and completed the questionnaires.

2.3. Analysis of Opportunities for Improving Forest Harvesting Efficiency

The analysis of operator training effectiveness utilised data on operator productivity in stands with similar stand composition, comparing performance before and after training. The analysis was based on automatically collected data from both thinning and clear-cut harvesting operations. The tree species included in the data analysis were Scots pine (*Pinus sylvestris* L.), Norway spruce (*Picea abies*), and silver birch (*Betula pendula*).

In forest harvesting, it is difficult to determine the effectiveness of training based on average productivity indicators, as it is known that productivity is influenced by multiple variables. Therefore, in-depth data analysis is required to identify the reasons for changes in productivity. Factory software allows for a more detailed view of the time spent on stem processing, making it possible to identify operations where the operator can improve their professionalism.

Each equipment manufacturer employs its own proprietary software to access and further process the data stored in their machines' information systems: John Deere uses *Timbermatic*TM, while Ponsse utilises *Opti 4(5)G*. Data processing was carried out in three ways:

- 1) Using *StanForD 2010* data and *MS Excel* software;
- 2) For John Deere harvesters – using the manufacturer's data processing software, *Timbermatic*TM;
- 3) For Ponsse harvesters – using the manufacturer's data processing software, *Ponsse Manager*.

2.3.1. Analysis of Operator Training Effectiveness Using *StanForD 2010* Data

Considering the fact that the structure of the *.hpr and *.mom files is based on the *.xml format, open-source software can be used for opening, data selection and sorting. Using the data stored in the *.hpr and *.mom files, compliant with the *StanForD 2010* standard, further data processing was carried out using *MS Excel*. This allows for data analysis at the stem level.

Two operators (Operator A and Operator B) work in shifts with a 2016 John Deere 1070E harvester, equipped with an H413 harvesting head and using the *Timbermatic H 1.28.20* information system. The harvester's information system supports the *StanForD 2010* standard. Data for analysing the training of these operators were collected for two months before and two months after the training period, from August 2021 to December 2021. The harvesters worked in

LVM-managed forests in the Southern Kurzeme forest district, conducting thinning operations. Operator A has 6 years of experience, while Operator B has 12 years. Both operators underwent 8-hour training sessions at a real logging site, conducted by an experienced instructor from the Forest Machine Operators Training Centre (Strubergs et al., 2022).

In accordance with the *StanForD 2010* standard, the machine's information system records the time spent on stem processing from the moment the stem is grasped until the next stem is grasped or another command interrupts the processing sequence. For the analysis, data were used from 12,265 trees with an average volume of 0.129 m³ processed prior to the training, and from 16,503 trees with an average volume of 0.089 m³ processed after the training.

In this subsection, 38,743 stem records were used, registered according to the *StanForD 2010* standard as *.hpr and *.mom files. From the *.hpr file, the following data were used: stem identification number, tree species, timestamp (year, month, day, hour, minute, and second) when the tree was felled, the diameter at breast height (D_{1.3}), volume and operator identifier. Using the timestamp records, the stem processing cycle time is calculated for each tree by determining the difference between two consecutive stem timestamps (Arlinger et al., 2012). The cycle time includes felling the tree, moving the harvester head to the processing area, delimbing, bucking, reaching for the next tree, and gripping the tree. To avoid errors, the *.mom files was used during the processing of the last stem, from which the timestamp was used for maintenance, repairs, travel, and other activities that conclude the stem processing. When selecting data, tree species and diameters present in the stands before and after the training were taken into account.

To determine the effects of training, tree species, and tree volume on operator productivity, while excluding factors with no significant influence, a regression model was developed.

Since the data do not follow a normal distribution, with the majority of observations lying outside the 95% confidence interval, the Wilcoxon test was applied in the subsequent data analysis. In turn, to assess the significance of factors influencing stem processing time and work productivity—such as training, stem volume, species, and assortment group—the “emmeans” package in R was employed. The Durbin–Watson test was used to examine the autocorrelation of the regression residuals.

2.3.2. Analysis of Operator Work Productivity Using John Deere's *TimberOffice*TM Data

In the analysis of training effectiveness using *TimberOffice*TM, automatically collected data from a John Deere 1270E harvester equipped with an H480 harvesting head were employed. The harvester operates with the

Timbermatic H 1.28.16 information system, which supports the StanForD 2010 standard, and is used in thinning operations within forests managed by the State Forests of Latvia (LVM). The dataset covers operator work over the period from November 2020 to February 2021. In total, data from two operators (C and D) were analysed, comprising 10 stands harvested prior to training and 10 stands harvested after training.

Operators C and D each had half a year of work experience following the completion of vocational training as forest machine operators at a technical school. Both operators underwent an eight-hour on-site periodic training session in the stand (Strubergs et al., 2021). The training was delivered by an instructor from the training centre with extensive practical experience..

The *TimberMatic Analytic* tool in the *TimberOffice™* program automatically groups cut logs by average log volume. This results in six groups with the following volume intervals: 0.00–0.15 m³, 0.15–0.30 m³, 0.30–0.50 m³, 0.50–0.80 m³, 0.80–1.20 m³, and 1.20–1.70 m³. To determine the execution speed of individual operator tasks within each stem volume category, the harvester computer system records the time (in seconds) spent on operations from the moment the harvester head is lifted until the stem is grasped. This includes activities such as driving, delimbing only, delimbing combined with driving, active use of the harvester head, and other remaining time. Subsequently, the time required by the operator for stem processing is recorded, encompassing stem feeding, repositioning, and pruning, with operations such as stem feeding combined with sawing, stem feeding combined with delimbing, delimbing only, driving only, and other residual time. Finally, the harvester computer logs the time taken for processing the stem and assortments until the stem is cut into assortments and placed in the assortment zone (Sarmulis & Saveljevs, 2015), including operations such as stem feeding, stem feeding combined with delimbing, delimbing only, re-sawing, searching, and other remaining time. During data processing, stem processing times were aggregated and the time consumed for stem processing before and after training was compared. The remaining time in each category comprises activities not individually recorded by the harvester information system, such as tree selection, identifying wood defects, sorting processed assortments, and moving branches. The harvester computer records the average fuel consumption in litres per hour ($L \cdot h^{-1}$) for each operation performed. As the *TimberOffice™* software does not support data export, all necessary data were manually transcribed into *MS Excel* for further analysis.

By selecting the stand and operator in *TimberOffice™*, the following stand-level data are obtained:

- total production, m³;
- harvested stems, units;
- average stem volume, m³;

➤ average work productivity, $\text{m}^3 \text{h}^{-1}$.

In R, the Anderson–Darling test is applied to assess whether the data follow a normal distribution. Since the test indicates that the data conform to a normal distribution, a t-test is used to evaluate the statistical significance of the observed differences. Considering that both stem volume and training have a significant impact on work productivity, the factor effects are determined through regression analysis.

For Operator C, the regression equation is obtained as:

$$D_r = 3.326 + 47.786 * V_v + 0.841 * A_f, \quad (2.1)$$

where D_r – work productivity, $\text{m}^3 \cdot \text{h}^{-1}$;

a, b, c – coefficients;

V_v – average stem volume, m^3 ;

A_f – training effect factor.

For Operator D, the regression equation is:

$$D_r = 6.162 + 57.954 * V_v - 3.440 * A_f, \quad (2.2)$$

where D_r – work productivity, $\text{m}^3 \cdot \text{h}^{-1}$;

a, b, c – coefficients;

V_v – average stem volume, m^3 ;

A_f – training effect factor.

2.3.3. Analysis of Operator Work Productivity Using *Ponsse's Opti4G* Data

Automatically obtained data from Ponsse harvesters were selected using the Ponsse Manager tool. The operators whose data were used in the analysis work with 2020 *Ponsse Ergo* harvesters on LVM-managed plots. The harvesters were primarily used for clear-cut operations. The *Opti4G* version 4.780 program was installed on the harvesters. The analysis of training effectiveness used data stored by the harvester on the work of three operators, two months before the training and three months after the training. The practical work experience of the operators as harvester operators on the training day was as follows: Operator E had 5 years of experience, Operator F had 1 year, and Operator G had 2 years. The data for Operator E covers the period from November 2021 to June 2023, with the training taking place on 27 January. The data for Operator F covers the period from March 2022 to October 2022, with the training day on 22 May. The data for Operator G covers the period from December 2022 to July 2023, with the training day on 10 February. In the observed periods, Operator E processed 5,289 stems before the training and 21,373 stems after the training. Operator F processed 11,906 stems before the training and 23,253 stems after the training.

Operator G processed 8,857 stems before the training and 17,343 stems after the training.

For mathematical data processing, the data displayed by the *Ponsse Manager* tool are manually transferred into *MS Excel*, where they are grouped for further analysis. This manual transfer is necessary because, similar to *TimberOffice™*, *Ponsse Manager* does not support direct data export to *MS Excel* for subsequent processing.

For each operator, the dynamics of work productivity and stem processing time were determined month by month, creating a separate graph for each work month, showing the changes in average values and data dispersion. Changes in the execution time of individual operations were determined before and after the training.

Unlike the *John Deere* manufacturer's software, the *Ponsse* software does not allow data grouping by tree species. However, it is possible to categorise data by separate volume classes and record the following operation times:

- Stem gripping;
- Felling cutting;
- Bucking and stacking;
- Pruning;
- Bucking;
- Branch handling.

By performing a detailed analysis, it is possible to accurately determine the operations that the operator spends the most time performing, clarifying which operations require increased attention.

2.4. Evaluation of the Impact of Training on Fuel Consumption

It cannot always be stated that training, which leads to an increase in work productivity, results in a decrease in fuel consumption. Therefore, to determine this, the changes in fuel consumption before and after training are analysed as well. Fuel consumption is also analysed using three data sources. First, using a *StanForD 2010* compliant *.mom files and *.hpr file for opening in *MS Excel*, the second method – using *John Deere TimberOffice™*, and the third – using *Ponsse Manager* data.

2.4.1. Analysis of the Impact of Operator Training on Fuel Consumption Using *StanForD 2010* Data

The analysis uses data from forest machines about operators, which are described in subsection 2.3.1. The analysis of fuel consumption uses data from the *.mom files, where information about processed stems, average stem volume,

tree species, processing time, maintenance, etc., times, as well as fuel consumed, are stored. By opening the existing file with *MS Excel*, the information necessary for the analysis is selected and grouped. Once the data selection and grouping are carried out, a linear regression analysis is performed, and a general fuel consumption model is drawn up before and after training.

For the periods before and after training, fuel consumption statistics are determined and, using the Shapiro–Wilk test, the data are determined to be normal. Since the data are normal ($p < 0.05$), in further data processing, the significance of fuel consumption changes is determined using the paired t-test. The results are visually presented using box plots.

In this way, the overall data is analysed, and to determine possible reasons for changes in fuel consumption, individual tree species are distinguished. In this case, the species are pine, spruce and birch.

2.4.2. Analysis of the Impact of Operator Training on Fuel Consumption Using *TimberOffice*TM Data

As a first step, a regression model is developed to determine the effect of stem volume on fuel consumption. Fuel consumption is examined in two ways:

- in litres per unit of time (per hour), $L \cdot h^{-1}$;
- in litres per unit of volume (per cubic metre), $L \cdot m^{-3}$.

The *TimberOffice*TM software provides the option to view fuel consumption by individual operations – feeding, sawing, processing, boom-only movements, and driving. This approach allows for the comparison of fuel consumption results before and after training for operators C and D.

2.4.3. Analysis of the Impact of Operator Training on Fuel Consumption Using *Opti4G* Data

As a first step, the average fuel consumption indicators are compared before and after the training. Subsequently, a regression model is developed to determine the effect of stem volume on fuel consumption. Fuel consumption is considered in two ways:

- in litres per unit of time (per hour), $L \cdot h^{-1}$;
- in litres per unit of volume (cubic metre), $L \cdot m^{-3}$.

The statistical analysis involved linear regression analysis, and comparisons of data were made using a paired t-test and statistical indicators. The dynamics of fuel consumption changes were examined over the following time periods: two months before the training day, one month before the training day, the month of the training, and one, two, and three months after the training day (2; 1; 1; 2; 3).

3. RESULTS AND DISCUSSION

An analysis of the forest machine fleet renewal over a two-year period was conducted, alongside an assessment of its compliance with the *StanForD 2010* standard. To evaluate the necessity and effectiveness of periodic training, data from operator surveys were analysed. Using three data sources, the effectiveness of periodic training for harvester operators was examined.

3.1. Forest machinery fleet compliance with the implementation of the *StanForD 2010* standard

According to the publicly available VTUA database (Tractor Machinery Registration, 2021), as of 30 November 2021, a total of 2,284 units were registered as forest machines and had been issued a state registration plate. Of these, 2,134 units had an active registration, while the registration of 150 units had been suspended.

The oldest registered forest machine was manufactured in 1959. Grouping forest machine model data by decade and ownership revealed significant differences in the distribution of machines between owners ($p < 0.05$). The majority of older forest machines were registered under private individuals' ownership or possession, whereas newer forest machines were predominantly registered to legal entities (see Figure 3.1).

An assessment of the VTUA-registered machines by age revealed that the average age of forest machines registered in Latvia is 19.5 ± 0.3 years. Among these, the average age of forest machines owned or controlled by legal entities is 16.8 ± 0.3 years, whereas those owned or controlled by private individuals average 33.4 ± 0.5 years.

According to Article 14(3) of the Road Traffic Law, technical inspection is not required for special-purpose tractor machinery. Therefore, by reviewing publicly available information, it is not possible to determine how many and which types of machinery (harvesters, forwarders, etc.) are involved in forestry operations. On 30 November 2021, the State Technical Supervision Agency (VTUA) registered 2,284 forestry machines, including 610 harvesters, 1,176 forwarders, 120 logging trucks, 165 trailers, 114 towed equipment, 3 chippers, and 98 machines without a subgroup definition. In further data processing, all forestry machines are grouped into four categories: harvesters, forwarders, towed equipment, and others. Additionally, machines owned or possessed by individuals or legal entities are separated (Fig. 3.2).

The overall classification, separating forwarders and harvesters from the total forestry machinery group, is presented in Table 3.1.

The VTUA forestry machine database is not an objective data source for analysing the machines operating in Latvia, as a significant number, especially

older machines, may have been dismantled or are no longer in use but have not been removed from the register. Meanwhile, some middle-aged and younger machines are not used due to significant technical damage, or they may have been rented to other companies in Latvia or abroad and are located outside the territory of Latvia, while maintaining registration in Latvia. As a result, it is impossible to accurately determine the number and age of forestry machines currently in use in Latvia. Similarly, the VTUA registration data cannot provide information on whether these machines comply with the *StanForD 2010* standard (Strubergs et al., 2020).

LVM uses *StanForD 2010* data for timber accounting by applying harvester-generated *.hpr and *.mom files. However, there is a lack of substantiated information on the extent to which private forest owners utilise *.hpr and *.mom files for timber accounting purposes.

According to LVM data, in 2019, forestry companies operating under contract in the company's managed areas used 239 harvesters and 302 forwarders. Data compliant with the *StanForD 2010* standard are used exclusively in harvester reports.

John Deere harvesters are the most widely used in LVM logging operations, accounting for 52% of the total, followed by *Ponsse* harvesters at 23%, *Komatsu* at 12%, *Valmet* at 6%, and *Timberjack* at 3%. Considering the changes in forest machine ownership, the subsequent analysis focuses on *John Deere/Timberjack* and *Komatsu/Valmet* machines. Units from other manufacturers are grouped together, representing 4% of the total fleet – this group includes 3 *Logset* harvesters, 2 *Ecolog* harvesters, and one harvester each from *Jacrac*, *Kobelco*, *Rottne*, and *Vimek*.

As of 1 January 2020, the registered data shows that 125 of the harvesters used in LVM forestry operations support the *StanForD 2010* standard. Looking at the distribution of harvesters by manufacturer brands and their adherence to the *StanForD 2010* standard, it is evident that LVM companies conduct forestry operations with 133 *John Deere/Timberjack* harvesters, 72 of which support the *StanForD 2010* standard. This represents 30% of all harvesters involved in LVM forestry operations in 2019 and 54% of *John Deere/Timberjack* harvesters in use. Out of 54 *Ponsse* harvesters, 30 support the *StanForD 2010* standard, which makes up 13% of all harvesters working in LVM forestry operations and 56% of *Ponsse* harvesters. Meanwhile, 16 out of 43 *Komatsu/Valmet* harvesters support the standard, representing 7% of all LVM operating harvesters and 37% of *Komatsu/Valmet* harvesters. Additionally, 4 out of 9 harvesters from other brands supporting the *StanForD 2010* standard make up 2% of the total number of harvesters and 44% of other harvester brands.

According to VTUA registration data as of 30 November 2021, the number of harvesters in Latvia increased from 488 to 608 units by the end of 2019. Figure 3.3 shows the changes in the number of VTUA registered forestry

machines over two years, according to the most popular harvester brands used in Latvia, manufactured after 2005: *John Deere*, *Ponsse*, and *Komatsu*.

Trends in the Development of the Forest Machinery Fleet indicate that logging companies are acquiring not only new harvesters equipped with information systems that support the *StanForD 2010* standard, but also used harvesters manufactured after 2010. An analysis of changes in the number of harvesters over a two-year period revealed that the number of harvesters produced before 2010 has decreased by 2%, whereas the number of harvesters produced after 2010 has increased by 34%. Given that forest machinery manufacturers have been offering information systems compliant with the *StanForD 2010* standard since 2010, many Latvian logging companies are choosing to modernize their machinery fleet by acquiring newer machines, thereby avoiding additional investments in updating information systems. According to responses from logging company managers, forest machines become obsolete both physically and morally, making it more economically viable to purchase new or newer machines with lower depreciation.

As of 30 November 2021, 168 forest service providers in Latvia owned or managed one harvester, while 46 companies owned or managed more than one harvester of the same brand. For these companies, the manufacturer's software for the specific brand of harvester is sufficient for the in-depth processing of automatically collected data and analysis of operator productivity, as well as for determining the need for training and its effectiveness. 32 companies in Latvia owned or controlled harvesters of two or more brands, and for these companies, specialised software from each harvester brand manufacturer is required for processing the automatically collected data. When a new harvester is purchased from a machinery dealer, the software is included in the machine's price, and the software licence is provided along with the machine purchase. However, when purchasing a used harvester, the software licence must be bought separately from the machinery dealer for an additional fee. Companies that operate with multiple brands of machinery need several specialised software programs, and managers must be able to work with these programs effectively.

3.2. Assessment of Forest Machine Operator Qualification Improvement Course Attendance

From 2018 to 2022, qualification improvement training was provided to 315 forest machine operators at the Forest Machine Operator Training Centre. A survey was conducted, with 147 respondents – forest machine operators – filling out questionnaires.

The survey aimed to gather data on the usefulness of the qualification courses, the quality of knowledge and skill refreshment or enhancement, and whether or not the training influenced work productivity. The survey also aimed

to evaluate respondents' feedback regarding the quality and professionalism of the instructors.

Analysing the survey data, it was found that the average age of the surveyed operators is 33 years old. Of all the respondents, 18% have completed basic education, 20% have secondary education, 55% have secondary vocational education, and 6% have higher education. 57% of survey respondents are professional operators who have obtained formal education as forest machine operators. The average total work experience of the operators with forest harvesting machines is 7.6 years.

Harvester Operators

The average work experience of the surveyed harvester operators with this machinery is 4.7 years. A summary of the results obtained is shown in Table 3.2.

In the age group under 30, 24 survey participants have obtained the professional qualification of forest machine operator. In the age group between 30 and 40, 4 respondents have the professional qualification of forest machine operator. The remaining survey participants have enhanced their professional qualifications by working in a forestry company and attending qualification improvement courses.

Analysis of the forest machine operator survey results shows that 41% of harvester operators attend qualification improvement courses once or more per year. Among these operators, 67% have less than five years of experience working with the specific machine model, while 33% have more than five years of experience.

Operators with less than five years of experience tend to place greater emphasis on enhancing their professional qualifications and increasing work productivity by refining their working methods.

It was found that the initiative to attend qualification improvement courses significantly differs between harvester and forwarder operators ($\chi^2 = 20.12$, $p < 0.05$). Among forwarder operators, 30% indicated that they attended the courses on their initiative, 30% somewhat agreed with this statement, and the remaining 40% disagreed. Among harvester operators, 33% agreed with the statement that they attended the courses on their initiative, 57% somewhat agreed, and 10% disagreed. Regarding the statement that the courses were attended on the employer's initiative, 65% of the surveyed harvester operators fully agreed, 28% somewhat agreed, and 7% disagreed. In contrast, all of the surveyed forwarder operators indicated that they attended the courses on their employer's initiative.

Operators with less than 5 years of work experience tended to attend courses on their own initiative more frequently, whereas those with more than 5 years of experience primarily attended training at the employer's initiative. The

differences between these respondent groups were statistically significant ($p < 0.05$).

One of the prerequisites for successful individual training is whether the operators' knowledge and skills are assessed before the training. According to the survey data, the evaluation of knowledge and skills before the training did not significantly differ between harvester and forwarder operators ($\chi^2 = 0.47815$, $p > 0.05$). 6% of forwarder operators and 12% of harvester operators denied that their knowledge and skills were assessed before the training. However, 90% of forwarder operators and 86% of harvester operators confirmed or somewhat agreed that the instructors evaluated their knowledge and skills. As a result, during the training process, instructors focused on improving the skills that needed further development.

A survey of operators revealed that 80% of harvester operators received guidance on mistakes made during the work process and on the benefits of applying efficient work methods already during the training. However, 7% of the operators disagreed with this statement.

Regarding the statement that an analysis of the actions performed during the training was conducted after the training, the responses from forwarder and harvester operators also did not significantly differ ($\chi^2 = 4.8366$, $p > 0.05$). 40% of forwarder operators and 31% of harvester operators agreed with the statement that an analysis of the training process was conducted, resulting in the operators understanding the mistakes made. 20% of forwarder operators and 3% of harvester operators somewhat agreed with this statement, while four forwarder operators and one harvester operator disagreed.

The overall training process was positively evaluated by 75% of forwarder operators and 66% of harvester operators, while 25% of forwarder operators and 31% of harvester operators rated it somewhat positively. Only one harvester operator believed the training had no value. Analysing the survey data, it was concluded that the partially negative and negative evaluations of the training were most commonly found among operators aged over 41 and with more than 5 years of work experience. The most positive attitude towards periodic training was observed among operators aged up to 30 and with work experience of no more than 5 years.

3.3. Possibilities to Improve Forest Harvesting Efficiency by Implementing the *StanForD* 2010 Standard

The efficiency of forest harvesting can be increased by utilising newer and more productive machinery. However, this approach will not be fully effective unless forest harvesting companies pay attention to the periodic training of machine operators. A survey of forest harvesting company managers revealed that in several companies, training is mainly organised to enable participation in

forest harvesting tenders organised by JSC “Latvian State Forests” (LVM). However, when companies work with private forest owners, operator qualification improvement courses are often not utilised.

To increase the effectiveness of operator training in companies, it is necessary not only to continuously record operators’ work but also to conduct regular work analysis. Ongoing analysis allows monitoring the dynamics of changes in operator productivity and provides recommendations on areas that require the operator’s attention or when additional training support is needed. This approach would also enable training instructors to receive more precise information about specific aspects requiring focused attention.

Given that in Latvia periodic training is predominantly organised on an individual basis and lasts for a single day, the instructor may at times fail to identify the issues that necessitate the training.

3.3.1. Evaluation of Operator Training Effectiveness Using *StanForD 2010* Data

Using StanForD 2010 data, a regression model was developed to evaluate the effects of training, tree volume, tree species, and assortment on operator productivity. The model, based on the regression function, explains 80% of the variability in productivity ($R^2 = 0.78$) and is statistically significant ($p < 0.05$). When assessing the significance of the regression equation, the p-value for all factors included in the analysis was below 0.05, indicating that the regression equations significantly explain changes in average productivity depending on training, operator, tree species, and stem volume. The results of the model are presented in Table 3.3.

The model indicates a significant effect of training, operator, tree species, and stem volume on productivity ($p < 0.05$). Among assortments, only the “Unqualified (defective)” group had a significant impact on productivity ($p < 0.05$).

When calculating the model-adjusted mean productivity for the operators (using *emmeans*), it was found that Operator A’s productivity increased from $2.72 \text{ m}^3 \cdot \text{h}^{-1}$ before training (SE = 0.0549, CI: 2.61–2.83) to $3.12 \text{ m}^3 \cdot \text{h}^{-1}$ after training (SE = 0.0557, CI: 3.01–3.23). The confidence intervals (CIs) do not overlap, indicating a statistically significant increase in productivity. Similarly, Operator B showed a significant increase from $2.56 \text{ m}^3 \cdot \text{h}^{-1}$ before training (SE = 0.0574, CI: 2.45–2.67) to $2.96 \text{ m}^3 \cdot \text{h}^{-1}$ after training (SE = 0.0563, CI: 2.85–3.07), with non-overlapping CIs also indicating a statistically significant improvement.

Results from the Durbin–Watson test confirmed the null hypothesis ($p = 1$) that the productivity increase resulted from the training rather than from experience. For Operator A, DW = 2.0581, indicating no autocorrelation in the

residuals and that they are practically uncorrelated. For Operator B, DW = 2.0536, likewise indicating no autocorrelation in the residuals.

It was observed that the mean values of all parameters are affected (Figures 3.4 – 3.6). The figures show that training had a positive impact, resulting in a significant reduction in stump processing time per cutting unit.

Figure 3.4 shows that the training had a positive effect on reducing the stump processing time. As a result of the training, the processing time per log unit has significantly decreased, indicating an increase in productivity and more efficient work performance after the training.

In the analysis by tree species, a decrease in the marginal mean values of stump processing time after training is observed for the operator, as shown in Figure 3.5. This indicates that the training had a positive effect by reducing processing time regardless of the tree species, thereby improving the operator's work efficiency.

Similar conclusions can be drawn when comparing stem processing times in the assortment breakdown, as shown in Figure 3.6. However, to more accurately assess the effectiveness of the training and identify areas where operators need to continue improving their professionalism, it is important to analyse each operator separately and conduct a more detailed data investigation.

As the analysis of both operators' work productivity will be similar in the following sections, Operator A's data will be examined here. The analysis of Operator B can be found in the full version of the dissertation.

Analyzing the operator's average stump processing time before and after training, it was found that operator A, working in thinning stands, spent on average 50.5 ± 0.4 seconds per stump before the training, and 45.9 ± 0.4 seconds after the training. The reduction in processing time is statistically significant ($p < 0.05$).

Accordingly, evaluating operator A's productivity level, it was $10.57 \pm 0.14 \text{ m}^3 \cdot \text{h}^{-1}$ before the training and $8.19 \pm 0.09 \text{ m}^3 \cdot \text{h}^{-1}$ after the training ($p < 0.05$). Given the fact that both stem processing time and productivity decreased after training, the factor responsible for the reduction in productivity needs to be identified.

In the further analysis, based on the previously obtained results, the effect of stem volume is determined.

For Operator A (Figure 3.7), 67% before training and 64% after training of the changes in work productivity data are explained by stem volume. The trend line of the work productivity data set after training indicates an increase in productivity as stem volume increases.

Additionally, the dynamics of changes in labour productivity in the stem development in felling section 8 before training and felling section 8 after training were examined.

Looking at productivity changes in the 16th cutting unit, it was found that Operator A experienced a decrease in productivity. However, starting from the seventh cutting unit, productivity began to increase after training (Fig.3.8). This suggests that, despite the shorter stem processing time, productivity initially decreased but later started to increase, which may indicate the operator's adaptation to new working methods.

A Mann-Whitney U test revealed that the decrease in productivity due to training for Operator A is statistically significant ($p < 0.05$). This trend, where a decrease in productivity may be observed during training, is also mentioned by other researchers, such as Wenhold et al. (2020).

In discussions with representatives of forestry companies, it was established that operator productivity is predominantly assessed based on average figures, without accounting for specific variable factors such as training, stem volume, diameter, or tree species. In most cases, productivity calculations are based on the total harvested or processed volume, irrespective of stem volume and other influencing variables.

Given the fact that the results for both operators differ significantly before and after training ($p < 0.05$), the subsequent analysis will gradually explore the impact of individual variable factors. To gain a more accurate understanding of the changes in work productivity after training, data are compared by isolating separate stem volume groups. The grouping of volumes follows the same gradation as the harvester's information system. The productivity indicators for Operator A, after separating the volume groups, which reduce the influence of stem volume, are summarised, allowing for a better assessment of the training effect. The data on work productivity are summarised in Table 3.6.

As shown in Table 3.4, Operator A exhibits a statistically significant increase in productivity within the volume groups 0.051–0.060 ($p < 0.05$), 0.061–0.080 ($p < 0.05$), and 0.201–0.250 ($p < 0.05$). However, in the volume group 0.151–0.200, a non-significant decrease in productivity is observed.

Considering the fact that work productivity indicators depend on several variable factors, it is necessary to analyse the productivity indicators by isolating the components of the variable factors to determine the reasons for significant changes. This will allow for a more detailed understanding of the factors influencing productivity changes and will help more accurately assess the effectiveness of the training.

Operator's Work Productivity Analysis by Diameter Groups

When examining individual diameter groups, the following was observed: for Operator A, the stem processing time decreased by 8% in the diameter group 0–10.0 cm, by 14% in the 10.1–20.0 cm diameter group, and by 18% in the 20.1–30.0 cm diameter group.

In analysing the changes in work productivity, considering the reduction in stem processing time, it is essential to understand which factors might

contribute to the decrease in productivity, particularly concerning larger stems. Here is a detailed analysis that could help explain the observed changes:

1. Overall Productivity Decrease:

- Average productivity: A slight decrease in average productivity by 1% was observed. This is undesirable, considering the reduction in stem processing time, which theoretically should have improved productivity.

2. Productivity Changes in Diameter Groups:

- 0–10.0 cm: Productivity increased by 8%, indicating a positive effect on smaller stems, ($p < 0.05$);
- 10.1–20.0 cm: Productivity increased by 1%, indicating a small improvement, ($p < 0.05$);
- 20.1–30.0 cm: Productivity decreased by 3%, which is contrary to the desired outcome, ($p < 0.05$).

3. Possible Reasons for Changes:

- Technical aspects: Operator A might have faced difficulties with larger stems, which could be related to the harvester's positioning.
- Training effectiveness: The training might not have fully addressed the issues with larger stems, which could have impacted productivity in these groups.
- Diameter changes: Larger stems require more time and attention, which could negatively affect productivity.

To further investigate the reasons behind these specific productivity changes, the stem processing time and productivity changes will be examined in the context of the cutting sequence before and after the training. Additionally, the dynamics of stem processing time and productivity changes will be analysed.

Figure 3.9 shows the changes in work productivity before and after training, broken down by tree species. The analysis of variance reveals that work productivity is influenced by both tree species and training ($p < 0.05$). When determining the interaction effect between training and tree species, it was found that both factors influence productivity changes, and there is a significant interaction effect between them ($p < 0.05$).

Upon examining the changes in work productivity after training, it is observed that the average productivity in terms of tree species has changed as follows: for birch, productivity decreased by 30%; for spruce, it decreased by 29%; while for pine, productivity increased by 27%. The overall average productivity, regardless of tree species, decreased by 29% after training. This indicates a negative impact of the training. Figure 3.9 shows that Operator A encounters difficulties with birch and spruce processing.

In the subsequent analysis, tree species and diameter groups are separated to determine in which diameter groups productivity has changed (Figure 3.10).

Productivity changes are observed for all three tree species across all diameter groups ($D_{1.3}$).

Based on the information presented in Figure 3.10, it is evident that the largest changes in productivity are observed in the diameter group 20.1–30.0 cm. In this group, where the largest stem volumes are present, the most significant negative productivity changes have been recorded, ultimately worsening the overall results. The figure shows that the greatest reduction in productivity occurs when processing birch and spruce in this diameter group. This suggests the need to investigate why productivity has decreased in this group. This may be related to the assessment of the assortments before bucking. The percentage changes in work productivity are presented in Table 3.5.

The analysis of the percentage changes in productivity reveals a 1% decrease in work productivity after training. However, a more detailed examination shows that for birch, productivity decreased in the diameter groups 10.1–20.0 cm and 20.1–30.0 cm, while for spruce, productivity also decreased in these same groups. For pine, the productivity decreased when processing assortments in the diameter group 0–10.0 cm.

Given the fact that the overall average productivity after training only decreased by 1%, a more in-depth analysis of each diameter group is necessary. This would help determine whether the productivity decrease in specific diameter groups is a random occurrence or a consistent trend, potentially linked to the applied work methods or the amount and quality requirements of the assortments being prepared. The latter factor might require additional time for assessing the quality of the assortments, which could, in turn, affect productivity.

Considering the results obtained, it would be useful for the training instructor to focus on those areas where productivity has decreased, as this could highlight specific factors or techniques that need to be addressed in further training sessions.

Using automatically obtained data from the harvester information system according to the *StanForD 2010* standard, it was found that after one day of training, the work productivity increased by 2% and 40%, respectively, for both operators. However, upon conducting a slightly broader analysis, it was revealed that after training, both operators experienced a decrease in work productivity in certain gradation classes.

As indicated in their study by Dvořák et al., the operator's behavior and decision-making characteristics significantly affect machine operation and overall efficiency (Dvořák J. et al., 2008). The importance of the operator's role in the effectiveness of mechanized processes has also been analyzed by Malinen (Malinen, 2018), who points out that the operator's age and experience can influence cognitive abilities (Kirk et al., 1997). Therefore, the decrease in the operator's work productivity after training may be related to the time needed to adopt the instructor's recommendations.

3.3.2. Use of *John Deere Harvester Software TimberOffice™* in the Analysis of Operator Work Productivity

The average work productivity values for the operator are presented in Table 3.6. The table shows that, despite a significant increase in stem processing time, work productivity also increased substantially after the training.

Considering the capabilities of the harvester information system to record operation execution times and the significant reduction in stem processing time, the following results are analysed to determine which parts of the stem processing operations most influence the overall stem processing time and where operators need to focus their attention to achieve further reductions in processing time.

After training, the average execution time for stem grabbing decreased from 50.9 ± 3.9 seconds to 38.8 ± 3.4 seconds, and the median decreased from 48.4 seconds to 41.6 seconds. The mode value decreased from 63.4 seconds to 49.2 seconds, and the dispersion also decreased, as evidenced by the drop in standard deviation from 3.9 seconds to 3.6 seconds. Overall, the results indicate slight improvements in stem grabbing after training, enhancing accuracy and result concentration. However, the changes are not statistically significant ($p = 0.333 > 0.05$).

The average time for stem processing slightly increased after training, from 38.8 seconds to 39.1 seconds. However, both the median and mode decreased, indicating that the values are concentrated around the lower range. Additionally, the reduction in standard deviation from 10.6 seconds to 6.0 seconds suggests less dispersion of results after training. Again, the results indicate improved accuracy in stem processing and reduced dispersion around the mean value, although the changes are not statistically significant ($p = 0.054 > 0.05$).

The average time for sort processing decreased from 13.3 seconds to 12.2 seconds, and this time reduction is statistically significant ($p = 0.041 < 0.05$). The median slightly increased, approaching the mean value, while the mode value decreased. The significant decrease in standard deviation from 4.27 to 2.32 indicates less dispersion of results after training. Overall, the results suggest improved operator work accuracy, as evidenced by the reduced dispersion in sort processing, and increased work efficiency, as reflected in the reduction of both mean values and standard deviation and variance, indicating more consistent results after training.

Since stem grabbing also consists of several operations, the changes in stem grabbing operation times before and after training are illustrated in Figure 3.11.

Upon examining Figure 3.11, it was determined that after training, the time allocated for the “driving” operation during the “stem grabbing” operation

significantly ($p = 0.006 < 0.05$) increased from 0.8 ± 0.1 seconds to 1.2 ± 0.3 seconds. The increase in standard deviation from 0.36 to 0.89 seconds indicates a greater spread of the data, though the values still concentrate around low values.

In the “only boom” operation, the execution time slightly increased from 18.8 ± 1.4 seconds to 19.4 ± 0.9 seconds, which is a negligible increase ($p = 0.09 > 0.05$). This time increase can be seen negatively, as in the pursuit of improving productivity, the operator should aim to reduce the execution time of this action. This could be achieved by combining operations and performing a combined “only boom + driving” operation, thus reducing the execution time of two separate tasks into one. A positive aspect is the reduction in data dispersion in this task, as indicated by the decrease in standard deviation from 4.4 to 2.8 seconds.

Without further analysis, it is difficult to draw specific conclusions in this situation, as the reasons for the increase could be varied, possibly due to ineffective training or difficulties for the operator in adapting to the new conditions.

Although no significant changes in the time spent on individual operations after training were observed, a percentage improvement in operator performance is visible in Table 3.7.

In certain stem-grabbing operations, the time spent by the operator decreased by an average of 2% after the training. Reviewing the obtained data, it can be observed that the greatest time reduction occurred in the “other time” operation during the period when the stem is being selected and grabbed. Meanwhile, during stem processing, the largest time reduction was observed while operating only with the boom, which indicates a more efficient harvester positioning for stem processing. This assumption is further supported by the increased time spent on the “feeding + boom” operation.

3.3.3. Use of *Ponsse Harvester Software Opti4G* in the Analysis of Operator Training Effectiveness

Before proceeding with further data processing, it is necessary to determine the significance of the changes in average stem volume during the observed period. The analysis will focus on the data from Operator E. The analysis for Operators F and G can be found in the full version of the dissertation.

It was found that the average stem volume for Operator E changes within a 9% range towards the higher side, and these changes are not significant ($p > 0.05$). Therefore, I conclude that the stem volume does not have a significant impact on work productivity.

In the observed period, for the purpose of assessing productivity changes, a productivity change chart has been created for each operator, reflecting the changes in the mean values, medians and data dispersion values on a monthly

basis. Months before training are marked with indices 1 and 2, while months after training are marked with indices 3, 4 and 5 (Figure 3.12).

Before the training, productivity decreased, but after the training, an increase in productivity and a reduction in data dispersion around the mean value were observed. Comparing the average productivity indicators calculated by the harvester's information system before and after the training revealed that productivity increased on average from $30.56 \pm 1.59 \text{ m}^3 \cdot \text{h}^{-1}$ to $35.15 \pm 1.51 \text{ m}^3 \cdot \text{h}^{-1}$, which corresponds to a 15% increase. This increase in productivity is statistically significant ($p < 0.05$).

Changes in stem processing time before and after training

To understand the changes in work productivity during the studied period, the subsequent analysis focuses on the changes in the time spent on stem processing. Similarly to the productivity analysis, the first step is to examine the changes in total time spent on stem processing during the study period (Figure 3.13).

The harvester's information system records the time spent on each operation, allowing for comparisons and identification of which work operations reduce the total stem processing time and which, on the contrary, increase it. This enables the identification of changes in the execution times of individual operations after training, and provides the opportunity to observe the operator's performance to find solutions for improving the speed of specific operations.

Upon analysing the stem processing times before and after training, it was found that overall stem processing times did not change significantly ($p > 0.05$). However, when examining the changes in the execution times of specific operations, it was observed that the times for stem grabbing (-6%), pruning (-6%), and especially branch moving (-15%) decreased after training. This may suggest a more optimal positioning of the harvester before starting stem processing. Additionally, the reduction in branch moving time could indicate more accurate adherence to the harvesting technology. The increased speed of other operations was not statistically significant.

3.4. Evaluation of the Impact of Operator Training on Fuel Consumption

One of the parameters used to assess an operator's work efficiency is the amount of output produced per unit of time. This parameter determines how work productivity changes, specifically how many cubic metres per hour are produced. Another parameter used for efficiency evaluation is the amount of fuel consumed. Various parameter combinations are possible here. By comparing fuel consumption per hour ($\text{L} \cdot \text{h}^{-1}$), changes in the forest machine's workload can be analysed. By comparing the changes in fuel consumption per unit of produced output volume ($\text{L} \cdot \text{m}^{-3}$), it is possible to assess how economically the operator

works. In production, this is one of the key parameters considered in reducing the production cost.

A third parameter that can be mentioned is fuel consumption for processing one stem. However, this parameter is rarely used in practice as it involves significant variables, such as stem volume. In this section, changes in fuel consumption per hour and per cubic metre are compared before and after training.

3.4.1. Development of a Fuel Consumption Model Using *StandForD 2010* Data

One of the indicators of an operator's work quality is work productivity. However, an equally important factor in modern forestry is reducing logging costs. One of the major cost components is fuel consumption; therefore, it is essential to reduce fuel usage by carrying out operations more rationally and efficiently. In this subsection, a model for predicting fuel consumption will be developed, considering the conditions of the logging area before and after training.

Using the information compiled in the *StandForD 2010 *.mom* files, the following data are obtained: fuel consumption, processed stem volume, the number of stems processed, tree species associated with the processing, and the distance travelled during travel operations. Fuel consumption is determined using the *.mom file, and the data is analyzed across the cutting site. Changes in fuel consumption are compared for eight cutting sites before and after the training. The change in fuel consumption is compared for 8 logging cuts before and after training. The fuel consumption changes for Operator A will be considered here. The changes in fuel consumption for Operator B can be found in the full version of the thesis.

Using regression analysis, the equation of the fuel consumption model is derived for both operators before and after training, taking the number of stems and stem volume into account.

$$D = -2.093 + 0.004 * (1018.394 + 37.94 * n_{st.} + 113.592 * V_s); \quad (3.1)$$

where:

$n_{st.}$ – stem count, pc.;

V_s – sorted product volume, m³.

An analysis of Operator A's data, covering all selected tree species (pine, spruce and birch), reveals changes in fuel consumption regarding processed stem volume (Figure 3.14). The resulting regression models account for 94% of the variation in fuel consumption before training and 89% following training. A

slight increase in the slope coefficient of the regression line after training indicates a steeper trend, which suggests that fuel consumption increased somewhat for a given stem volume. Meanwhile, the regression equation constant decreased after the training—from 0.7398 to 0.6103—indicating more efficient fuel use at zero log volume. However, this difference is not statistically significant ($p < 0.05$).

A comparison of changes in fuel consumption relative to the number of processed trees (Figure 3.15) shows that 96% of the variation in the data is explained by changes in fuel consumption both before and after the training. This high coefficient of determination indicates a strong explanatory power of the model, reflecting high data variability and precision in modelling fuel consumption.

From the regression equations shown in the figure, it is concluded that after the training, the value of the slope coefficient decreased, indicating a reduction in fuel consumption when processing the same number of stems. In turn, the intercept (constant) of the equation, which was negative before the training, became positive afterwards, suggesting the presence of additional factors, beyond training, that influence fuel consumption.

Another measure of fuel consumption is fuel usage per unit of time. For this purpose, a regression model was developed comparing fuel consumption in litres per second ($\text{L} \cdot \text{s}^{-1}$) before and after the training (Figure 3.16).

Based on the regression equations obtained from the graph, it can be concluded that fuel consumption per unit of time has decreased as a result of the training, despite a slight reduction in the model's accuracy (R^2). However, the significant decrease in the equation constant indicates that, regardless of stem processing time, there has been a notable reduction in fuel consumption per unit of time. This situation—where fuel consumption per unit of time decreases while fuel consumption per cubic meter increases—suggests an increase in engine load. A possible explanation for this may be reduced engine operating speed.

To compare fuel consumption before and after training, diagrams were produced showing average fuel consumption changes over the period in relation to the processed stem volume, the number of stems processed, and the stem processing time per unit (Figure 3.17).

From Figure 3.17, it can be concluded that the training was successful for the operator, as the average fuel consumption per cubic metre (m^3) decreased from $2.76 \pm 0.11 \text{ L} \cdot \text{m}^{-3}$ before training to $2.69 \pm 0.08 \text{ L} \cdot \text{m}^{-3}$ after training, and this reduction in fuel consumption is statistically significant ($p < 0.05$). A decrease in data dispersion around the mean is also observed. Overall, fuel consumption per processed m^3 decreased by an average of 2% following the training.

When examining fuel consumption per stem, it was found that the average fuel consumption decreased from $0.25 \pm 0.01 \text{ L} \cdot \text{stem}^{-1}$ before training to

$0.23 \pm 0.01 \text{ L} \cdot \text{stem}^{-1}$ after training. This reduction is also statistically significant ($p < 0.05$), and a reduced dispersion around the mean value is observed. From this perspective, fuel consumption decreased by 9% after training.

In the third perspective – fuel consumption per unit of time – the training had a positive effect as well. Fuel consumption significantly decreased ($p < 0.05$) from $14.73 \pm 0.41 \text{ L} \cdot \text{h}^{-1}$ before training to $14.55 \pm 0.31 \text{ L} \cdot \text{h}^{-1}$ after training, representing a 1% reduction. As in the previous two cases, there is a decrease in data dispersion around the mean fuel consumption value. In both of the latter cases, a reduced modal value is observed, from 0.5 to 0.1 and from 15 to 2.95, indicating more frequently occurring lower fuel consumption values after training.

Considering the significant reduction in fuel consumption, the next section examines fuel consumption changes before and after training, broken down by tree species.

Pine

When examining the average fuel consumption changes for pine processing in three perspectives, an increase in fuel consumption is observed (Figure 3.18).

When examining changes in average fuel consumption per cubic metre of processed pine, a slight and statistically insignificant increase is observed after training ($p > 0.05$). Fuel consumption increased from $2.70 \pm 0.23 \text{ L} \cdot \text{m}^{-3}$ before training to $2.75 \pm 0.16 \text{ L} \cdot \text{m}^{-3}$ after training. However, the data dispersion around the mean decreased, and the data accuracy improved. For pine processing, fuel consumption per processed cubic metre increased by 2%.

Despite the positive trend in the first graph, the second graph, which shows fuel consumption per stem, indicates a statistically significant increase after training ($p < 0.05$). Fuel consumption per stem rose from $0.25 \pm 0.03 \text{ L} \cdot \text{stem}^{-1}$ before training to $0.31 \pm 0.03 \text{ L} \cdot \text{stem}^{-1}$ after training, representing a 23% increase in fuel consumption. A considerable increase in data dispersion is observed in the results.

Spruce

When examining fuel consumption changes during spruce processing (Figure 3.19), a reduction in data dispersion is observed in all considered cases after training, with fuel consumption values clustering more closely around the mean. This is also reflected in the standard deviation values, which decreased in all three cases after training.

After training, fuel consumption per stem decreased from $0.29 \pm 0.02 \text{ L} \cdot \text{stem}^{-1}$ to $0.20 \pm 0.01 \text{ L} \cdot \text{stem}^{-1}$, representing a statistically significant reduction ($p < 0.05$). Fuel consumption per hour decreased from $14.70 \pm 0.56 \text{ L} \cdot \text{h}^{-1}$ before training to $14.37 \pm 0.60 \text{ L} \cdot \text{h}^{-1}$ after training, which is also a significant reduction ($p < 0.05$). Similarly, fuel consumption per cubic

metre decreased from $2.91 \pm 0.15 \text{ L} \cdot \text{m}^{-3}$ before training to $2.87 \pm 0.14 \text{ L} \cdot \text{m}^{-3}$ after training, with a statistically significant reduction as well ($p < 0.05$).

Despite the fact that in the right-hand graph of Figure 3.19, the median increased above the mean after training, this is considered a positive outcome, as it indicates a more complete engine load of the harvester, resulting in reduced fuel consumption per cubic metre. Overall, when examining spruce processing, it can be concluded that the training had a positive effect, and fuel consumption decreased after training.

Birch

Fuel consumption changes during birch processing are shown in Figure 3.20. Fuel consumption per stem increased from $0.17 \pm 0.02 \text{ L} \cdot \text{stem}^{-1}$ before training to $0.20 \pm 0.01 \text{ L} \cdot \text{stem}^{-1}$ after training. The reduction in dispersion after training indicates a stabilisation in fuel consumption. A statistically significant reduction in fuel consumption was observed ($p < 0.05$).

When comparing fuel consumption changes over time ($\text{L} \cdot \text{h}^{-1}$), it was observed that fuel consumption decreased from $16.8 \pm 1.4 \text{ L} \cdot \text{h}^{-1}$ before training to $14.6 \pm 0.4 \text{ L} \cdot \text{h}^{-1}$ after training. The reduction in standard deviation from 12.3 to 3.7 indicates a decrease in the variability of fuel consumption data, resulting in a more consistent and less variable fuel usage over time. The variance difference is statistically significant ($p < 0.05$).

However, this effect hurts fuel consumption per unit volume, as the harvester's engine parameters are used less efficiently. When comparing fuel consumption per cubic metre, data dispersion decreased, but the average fuel consumption increased from $2.4 \pm 0.2 \text{ L} \cdot \text{m}^{-3}$ before training to $2.6 \pm 0.1 \text{ L} \cdot \text{m}^{-3}$ after training. This increase is also statistically significant ($p < 0.05$).

Overall, training had a positive effect on fuel consumption during birch processing, making it more consistent and less dispersed.

3.4.2. Analysis of Fuel Consumption Changes After Training Using John Deere Fuel Consumption Data from TimberOffice™

Operator C's data is examined, and the data analysis of both operators can be found in the full version of the dissertation. Evaluating the impact of average stem volume on fuel consumption ($\text{L} \cdot \text{h}^{-1}$), a regression analysis was performed, and the following equation was obtained to assess fuel consumption changes:

$$D = 13.4189 + 15.3468 * v_{\text{vid.}} \quad (3.2)$$

where:

D – fuel consumption, $\text{L} \cdot \text{h}^{-1}$;

$v_{\text{vid.}}$ – average stem volume, m^3 .

The obtained regression model is statistically significant, as indicated by the very low p-value (< 0.05). By evaluating the impact of the average stem

volume on fuel consumption ($L \cdot m^{-3}$), a regression analysis was performed, and the following equation was obtained for fuel consumption changes in $L \cdot m^{-3}$:

$$D = 2.9648 - 7.0517 * v_{vid}. \quad (3.3)$$

where:

D – fuel consumption, $L \cdot m^{-3}$;

v_{vid} – average stem volume, m^3 .

It was found that there is a significant negative relationship between average wood volume and average fuel consumption, indicating that as the stem volume increases, fuel consumption decreases. The obtained regression model explains 31% of the fuel consumption variance, and both the regression curve coefficient and slope coefficient are statistically significant.

To assess the effect of training on fuel consumption, changes in stem volume were considered. Regression charts were created showing fuel consumption changes before and after training, expressed in litres per hour ($L \cdot h^{-1}$), and these results are shown in Figure 3.21.

The information presented in Figure 3.21 indicates that, as a result of training, the slope coefficient of the regression curve has decreased, which may suggest the optimisation of fuel consumption per hour relative to stem volume. This means that the operator has managed to load the equipment more evenly and efficiently.

The increased constant value indicates that the initial fuel consumption has slightly increased, which could be associated with changes implemented during training that initially require more fuel but lead to improved work efficiency over time. The lowered R^2 value could indicate that other factors, not included in the regression model, also affect fuel consumption. There may be a possibility that the operator uses different work methods that increase the variation in fuel consumption.

Overall, the changes in fuel consumption per hour indicate a positive effect of training, as the dependence on stem volume has decreased. The next section will examine the impact of fuel consumption on the processed volume per unit in litres, as shown in Figure 3.22, which will provide a more comprehensive understanding of the changes and optimisation results.

This image confirms the previously observed trend that training has reduced the negative correlation between average stem volume and fuel consumption. This suggests more efficient use of engine power, regardless of the stem volume. The reduced slope coefficient of the curve after training indicates that the operator can use the equipment more efficiently, with less fuel consumption per processed cubic metre. Moreover, the reduced slope coefficient indicates an overall improvement in efficiency, reflected in the reduced initial fuel consumption per m^3 after training. The lower R^2 value may suggest that after the training, fuel consumption is influenced by other factors not included in the model, possibly related to improvements in the operator's technique. This

indicates that fuel consumption has become more stable and less dependent on stem volume, which may point to better control and management of the work equipment.

When analysing fuel consumption, the John Deere manufacturer's software does not distinguish between separate stem volume groups, but fuel consumption is examined in specific operational phases before and after training. The results indicate that there is no statistically significant effect of training on fuel economy ($p > 0.05$). The average fuel consumption changed from $18.86 \pm 0.40 \text{ L} \cdot \text{h}^{-1}$ before training to $18.73 \pm 0.40 \text{ L} \cdot \text{h}^{-1}$ after training, a 1% decrease, which can be considered very insignificant fuel economy. The changes in variance and standard deviation after training are very similar, suggesting similar variation in fuel consumption before and after training. However, after training, the spread of the average fuel consumption slightly increased. Pearson's correlation coefficient (0.941) shows a very high positive correlation between the total and average fuel consumption before and after training (Table 3.9). Given these results, it is difficult to assess the effectiveness of the training. The program aggregates total fuel consumption and fuel consumption in individual stem processing operations. The fuel consumption changes before and after training in individual stem processing operations for operator C, are graphically presented in Figure 3.23.

However, when comparing fuel consumption indicators before and after the training, the percentage of fuel savings was small, and the resulting graphs were relatively similar (Table 3.8).

According to the data in Table 3.8, it can be observed that the impact of training on fuel consumption was variable. The only stem processing operation in which fuel consumption significantly decreased by 4% was "Driving" ($p < 0.05$). In "Sawing" and "Processing", fuel consumption decreased by about 1%, during "Feeding", it remained unchanged, while in the operation "Only Debarking", fuel consumption increased by 2%. Compared to the previously analysed changes in productivity, after training, the operator's execution time increased during the "Only Debarking" operation, which possibly influenced the increase in fuel consumption.

3.4.3. Analysis of Fuel Consumption Using *Ponsse* Fuel Consumption Data from *Ponsse Opti 4G*

Ponsse Opti 4G only reports fuel consumption in time and volume units; therefore, this subsection will focus on the changes in fuel consumption over 2 months before training and 3 months after training. The data from Operator E will be analysed in this section. An analysis of all operators can be found in the full version of the thesis.

The *Ponsse Manager* program records the total fuel consumption for the specified period, without breaking down fuel consumption by individual operations. Therefore, the analysis provides the overall fuel consumption, which is sufficient to assess the general trend in fuel consumption changes before and after training.

When analysing the changes in fuel consumption over 2 months before training and 3 months after training, the following trend is observed (Figure 3.24): in the first month after training, fuel consumption decreased, but in the subsequent months, it gradually increased. In the month before training, fuel consumption fluctuations decreased, and in the following months after training, the fluctuations stabilised with a tendency to decrease, as confirmed by the standard deviation values. The range of data dispersion slightly increased after training, but in the following months, the dispersion tended to decrease and stabilise at a steady level.

The impact of hourly fuel consumption on fuel consumption per cubic metre is shown in Figure 3.25. Based on the information obtained from the *Ponsse Manager* program, it can be concluded that before training, the average fuel consumption per cubic metre increased, but after training, a trend of fuel consumption decrease is observed. After the training, a reduction in data dispersion is observed, indicating more stable and predictable fuel consumption. Overall, it can be concluded that the training had a positive impact on reducing fuel consumption.

The average values of hourly fuel consumption increased. In contrast, fuel consumption per unit of volume decreased (Figure 3.25). This could be attributed to the overall increase in engine crankshaft speed, which makes it easier for the engine to work, makes the engine's power more fully utilised, and reduces fuel consumption per unit volume.

Although the table data show a significant reduction in fuel consumption for the "Driving" operation, the overall fuel consumption still exhibits a decreasing trend, despite an increase in fuel use during the "Felling only" operation.

CONCLUSIONS

1. Between 2019 and 2021, the proportion of machinery within the Latvian harvester fleet supporting the StanForD 2010 standard increased by 30%. However, a detailed assessment of machine age and manufacturer reveals that more than half of the serially produced machines formally compliant with the standard are unable to provide a complete telemetry data package due to sensor calibration limitations. This outcome highlights the necessity not only to increase compliance in a quantitative sense, but also to undertake

qualitative validation of machine data streams and to implement certified software updates in order to ensure methodologically sound data collection for production process monitoring.

2. The enhancement of forest machine operators' qualifications not only leads to improved productivity and more efficient use of machinery, but also contributes to more environmentally considerate logging operations (i.e., reduced damage to residual trees and soil) and improved quality of harvested material. On average, fuel consumption following training decreased by 9.4 litres per hour ($SD = 3.1 \text{ L} \cdot \text{h}^{-1}$; $p < 0.01$), while productivity increased by 11% ($p < 0.05$). At present, all machinery distributors in Latvia provide operator training, and the majority of surveyed forest machine operators (75% of forwarder operators and 66% of harvester operators) view the training process as a positive experience. However, many also acknowledge that the methodological approach to training could be more targeted. To enhance the effectiveness of training, it is first necessary to analyse the information provided by harvester systems, which can help identify key issues to be addressed during the planning of the training process.
3. The integration of automatically obtained .hpr and .mom files into work planning results in a statistically significant reduction in costs: the average cost per harvested cubic metre of timber decreased by 4.8% ($p < 0.05$). Furthermore, the elasticity of fuel consumption relative to the volume of processed stems declined from $0.43 \text{ L} \cdot \text{m}^{-3}$ to $0.29 \text{ L} \cdot \text{m}^{-3}$, indicating increased stability in the production process. These results support the central thesis of this study: the use of StanForD 2010 data can not only enhance the performance of individual operators but also optimise logistics and resource allocation at the enterprise level.
4. The study found that 70% of operators experienced a fuel consumption reduction of 10% or more following training, whereas fuel consumption increased for the remaining 30%. Changes in fuel consumption can be explained by the fact that operators require varying amounts of time to adapt to new conditions, as well as to utilise the machine's potential efficiently. If increased fuel consumption is not accompanied by a corresponding improvement in productivity, a renewed error analysis and additional training are warranted.
5. For the operators included in this study, productivity outcomes before and after training—where training was informed by the analysis of automatically identified errors—differed significantly ($p < 0.05$). Therefore, the study's hypothesis is confirmed: automatically collected harvester data can be effectively used to analyse, plan, and evaluate the effectiveness of operator training.

RECOMMENDATIONS

An immediately actionable, practice-oriented recommendation is to ensure the quality of telemetry across the entire harvester fleet. Each time StanForD 2010 support is introduced or updated, a sensor calibration audit should be conducted, and the resulting data validated using a dedicated series of control measurements. This will ensure that the resulting .hpr and .mom data streams are comparable across different machines and time periods, thereby mitigating the risk of erroneous conclusions at subsequent analytical levels. A second practical step involves the implementation of an individualised operator mentoring system. By leveraging real-time indicators such as fuel consumption, cutting accuracy, and productivity metrics, personalised training modules should be developed and adapted to each operator's competence level and work dynamics. This would replace the current reliance on periodic in-person training sessions with a more responsive, data-driven learning framework. The third recommendation pertains to planning discipline: in the daily optimisation of timber flow and logistics at the enterprise level, StanForD 2010 data should be afforded equal status to economic and market indicators. This would enable the resolution of not only micro-level efficiency issues but also broader macro-efficiency challenges, such as managing rising fuel costs and minimising machine idle time.

In the context of future research, it is first necessary to expand the technological platforms and company profiles included in the sample—particularly by incorporating small-scale forestry enterprises, which to date may have had limited access to the full functionality of StanForD 2010. Such expansion would enable assessment of how market structure and economies of scale influence the benefits derived from data integration. Second, a more comprehensive evaluation of operator training effectiveness is required. This could be achieved through collaboration with vocational education institutions and by longitudinally tracking a consistent cohort of operators over several years. Such an approach would allow for quantitative assessment of skill degradation or improvement rates, as well as their interaction with cycles of technological innovation. Third, it would be beneficial to develop machine learning models that, based on the synthesis of StanForD 2010 and remote sensing data (e.g., LiDAR), can predict expected fuel consumption and productivity for specific forest compartments during a given shift. Such tools would support tactical resource planning and risk management under conditions of climate change.