SVEUČILIŠTE U ZAGREBU - ŠUMARSKI FAKULTET
ZAVOD ZA ŠUMARSKE TEHNIKE I TEHNOLOGIJE

Svetošimunska 25

10000 Zagreb

Projekt: Optimizacija sustava pridobivanja drva i šumske prometne infrastrukture na strateško-taktičkoj razini planiranja

Završno izvješće

1. Uvod

Projekt je osmišljen i proveden u cilju vrednovanja parametara ključnih za optimizaciju sustava pridobivanja drva i šumske prometne infrastrukture na strateško-taktičkoj razini planiranja. Analizirani su terenski i sastojinski čimbenici koji u interakciji sa šumskom prometnom infrastukturom definiraju čimbenike ograničenja prilikom izbora mogućeg/pogodnog sustava pridobivanja drva. Primarna i skundarna šumska prometna infrastruktura pri tome ima dvojaku ulogu. U prvom redu, igra odlučujuću ulogu u omogućavanju primjene pojedinih sustava pridobivanja drva (ovisno o zahtjevnosti terenskih čimbenika). Nadalje, optimalni raspored primarne i sekundarne šumske infrastrukture direktno utječe na učinkovitost sredstava primarnog (i daljinskog) transporta drva, a kod mehaniziranih sredstava sječe i izrade drva preduvjet je koji omogućuje rad na pogodan način.

Nakon definiranja ogranučavajućih čimbenika može se pristupiti izboru mogućih sustava pridobivanja drva sukladno značajkama pojedinih sustava te šumskih strojeva kojima se pojedini sustavi formiraju. Podlogu pri izboru mogućih sustava pridobivanja drva predstavlja Katalog sustava pridobivanja drva u kojem je identificirano i opisano dvanaest sustava pridobivnja drva s naglaskom na područje primjene, ograničenja, zahtjeve za sekundarnom mrežom šumskih prometnica i okolišnu pogodnost. Podlogu pak za optimalno formiranje pojedinih sustava pridobivanja drva predstavlja Katalog šumskih strojeva u kojemu je prikazano i sistematizirano 95 motornih pila lančanica, 61 harvesterska glava, 60 harvestera, 26 skidera, 51 forvarder, 31 šumska žičara i 44 iverača.

Mogući sustavi pridobivanja drva vrednuju se višekriterijskim modelom za ocjenu pogodnosti i djelotvornosti kojim se analiziraju ekonomski, ekološki, ergonomski, energijski i estetski kriteriji (5E) u cilju odabira optimalnog sustava bilo na strateškoj ili pak na taktičkoj razini planiranja.

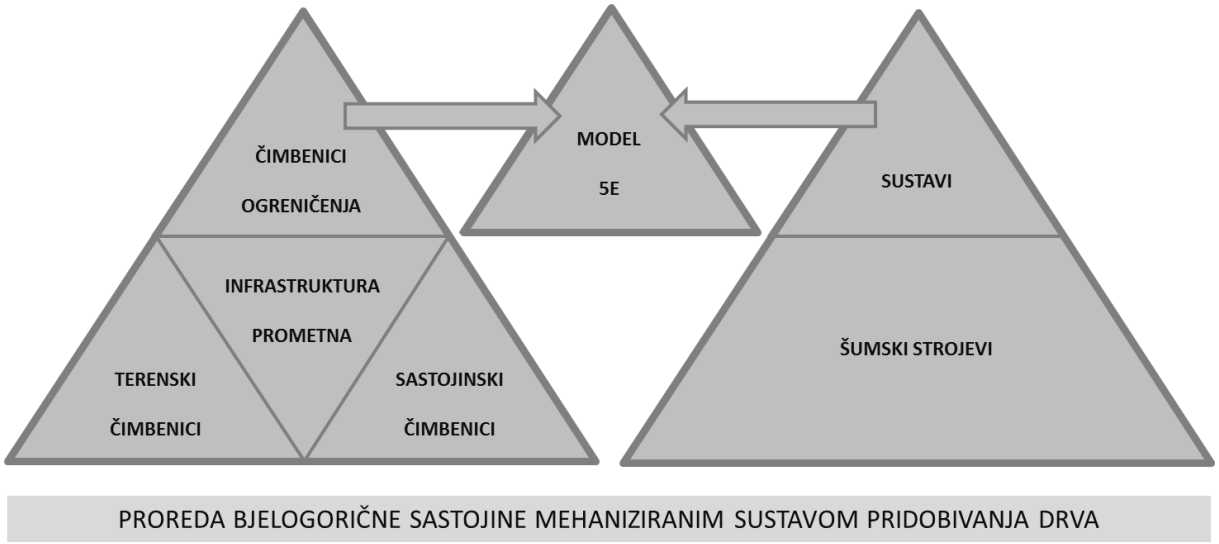

Slika 1.1 Koncept Projekta

Koncept Projetka testiran je glavnim pokusom, proredom bjelogorične sastojine mehaniziranim sustavom pridobivanja drva.

Odabir glavnog pokusa uvjetovan je prisutnom i očekivanom nestašicom radne snage, posebice pri radovima ručno-strojne sječe i izrade, i posljedično neminovnošću uviđenja strojne sječe i izrade i u prirodne sastojine.

Cilj je glavnoga pokusa odrediti pogodnost primjene mehaniziranoga sustava pridobivanja drva u prorednim bjelogoričnim sastojinama u Rebublici Hrvatskoj, odnosno utvrditi razinu učinkovitosti primjene te ekološke, ergonomske, energijske i estetske posljedice primjene navedenoga sustava.

Ovo, Završno izvješće sadrži prikaz tijeka istraživanja te razultate istraživanja. Na temelju analize i sinteze rezultata formulirane su glavne spoznaje u obliku konkretnih preporuka, smjernica i zaključaka istraživanja.

Glavni rezultati Projekta te preporuke, smjernice i zaključci proizašli provedbom Projekta u tekstu su naznačeni sjenčanjem.

2. Određivanje reljefnih područja šuma sa stajališta pridobivanja drva i otvaranja

2.1 Uvod

Kao terenske čimbenike šuma određenog zemljopisnog položaja, koji uvjetuju stupanj težine, mogućnosti i ograničenja izvođenja mehaniziranih šumskih radova uopće, većina autora navodi: nagib terena, površinske prepreke te nosivost podloge (Conway 1976, Staff i Wiksten 1984, Löffler 1984, Silversides i Sundberg 1988, Saarilahti 2002A). Terenski čimbenici imaju velik utjecaj na odabir mehaniziranih sredstava rada kao i na njihovu učinkovitost, a samim time i na troškove rada (Bojanin 1980, Kulušić 1990, Poršinsky 2005).

Pri razredbi terena razlikuju se dvije razine pristupa (Saarilahti 2002B). Prvu razinu predstavlja opisna (deskriptivna, primarna) razredba terena koja opisuje teren prema mjerljivim značajkama i raščlanjuje ga u razrede neovisno o primijenjenim tehnologijama (Mellgren 1980, Berg 1992). Drugu razinu pristupa čini namjenska (funkcionalna ili sekundarna) razredba koja povezuje mogućnost primjene određenih tehnologija pridobivanja drva s razredima terenskih čimbenika (MacDonald 1999, Rowan 1995, Owende i dr. 2002).

Glavna prednost opisne razredbe terena je njena zasnovanost na razredima čimbenika šumskih terena te neovisnost o vrsti i tipu strojeva, čime je osigurana stalnost razredbe, odnosno izbjegnuta potreba za ponovnom razredbom terena pri uvođenju u rad novih tipova strojeva (Davis i Reisinger 1990).

Primjenom GIS-a, osigurana je brza manipulacija datotekama prostornih podataka te omogućeno brzo uočavanje mogućih terenskih problema povezanih s određenim tehnologijama šumskih radova (Saarilahti 2002B).

Izradba razredbi terena za šumarstvo započinje u Norveškoj nakon II. Svjetskog rata (Löffler 1984), dok su sami počeci istraživanja terenskih čimbenika i njihovog utjecaja na kretnost vozila vezani za američku vojsku, ondosno WES laboratorij (*US Army Engineer Waterway Experiment Station*) te datiraju iz srpnja 1945. godine (Fatherree 2006). Kieslinger (1953) u Njemačkoj radi razredbu terena za period od 1861. do 1946., dok se u skandinavskim zemljama tom tematikom prvi bave: Jakobson (1965), Mattsson-Mărn (1946), Putkisto (1964), Samset (1975). Löffler (1979) zaključuje da je šumarstvo prihvatilo razredbu terena kao važan logički alat pri gospodarenju šumama, planiranju radova u šumarstvu te provedbu radova pridobivanja drva. Isti autor (1984), navodi da su tehničke mogućnosti ograničene, a troškovi su šumarskih radova uvjetovani pristupačnosti šumskog terena. Zbog tih ovisnosti, vrsta i obuhvatnost upravljanja u šumi također ovisi o pristupnosti mjestu rada. Osim radova pridobivanja drva to uključuje i ostale šumsko-uzgojne radove, zaštitu šuma te otvaranje šuma. Samset (1975) utvrđuje da pristupačnost šumi (u gospodarskome smislu) ovisi o: 1) prometnoj infrastrukturi (otvorenosti šume) i uvjetima (načinu) transporta, te 2) terenskim uvjetima unutar mreže prometnica.

Razredba terena podrazumijeva označivanje i razvrstavanje šumskog zemljišta u ovisnosti o njegovoj pristupačnosti ili ovisno o stupnju težine izvođenja šumskih radova (Löffler 1984).

Temelj većine (područje Europe i Sjeverne Amerike) razredbi terena danas je NSR razredba (Eriksson i dr. 1975). Ona sadrži opsežnu podjelu stalnih terenskih čimbenika te se danas u cijelosti koristi na području skandinavskih zemalja (osim u Finskoj) i u Kanadi (Saarilahti 2002A).

Eriksson i dr. (1975) navode da zbog kompleksnosti terenskih uvjeta postoje različiti načini i razine razredbi terena:

⇒ Regionalna razredba terena: namijenjena za velika šumska područja (na nacionalnoj razini), registracija pokusnih ploha (nisu zabilježene na kartografskim prikazima), rezultati prikazuju relativne distribucije između čimbenika.

⇒ Lokalna razredba terena: namijenjena za manja šumska područja, registracija pokusnih ploha koje se obavezno ucrtavaju na karte sitnog mjerila.

⇒ Makro-razredba terena: dijeli šumske površine u jedinice za koje vrijede isti ili gotovo isti terenski uvjeti.

⇒ Mikro-razredba terena: detaljna razredba terena, nastala mjerenjima na pokusnim plohama

⇒ Opisna razredba terena: opisuje terenske uvjete putem njegovih mjerljivih značajki i na dugoročnoj je razini.

⇒ Namjenska razredba terena: opisuje razinu teškoće izvođenja radova (operativnih metoda). Kako se razine mehaniziranosti mijenjaju sa vremenom, tako je i ova razredba kratkoročnog karaktera te se zasniva na opisnoj razredbi terena.

Samset (1975) navodi da namjenska razredba terena zastarijeva s tehnološkim i operativnim razvojem radnih metoda, dok je opisnu razredbu također potrebno poboljšati te početi opisivati terenske uvjete na makro i mikro reljefnim razinama.

Rowan (1977) u svojoj knjizi »Terrain classification« koristi i dorađuje skandinavski sustav razredbe terena i tako postavlja temelje britanske razredbe, a 1996. godine Agencija šumarske komisije izdaje Tehničko priopćenje 16/95 sa sažetim prikazom (s ciljem korištenja u praksi) Rowanove razredbe. Svrha ove razredbe je pomoć pri dugoročnome planiranju radova pridobivanja drva, detaljnome operativnom planiranju i detaljnome opisu radilišta.

Neovisno o geografskom mjestu nastanka pojedinih opisnih razredbi terena, one su sve zasnovane na tri najvažnija terenska čimbenika (nosivost tla, površinske prepreke, nagib terena) koji su najčešće razvrstani u pet razreda (tablica 2.1).

Tablica 2.1 Osnovna podjela terenskih čimbenika u pet razreda terena

Nosivost (čvrstoća) tla		Površinske prepreke		Nagib terena	
1	Vrlo čvrsto tlo	1	Vrlo ravan teren	1	Ravničasti teren
2	Čvrsto tlo	2	Djelomično ravan teren	2	Blago nagnuti teren
3	Osrednje čvrsto tlo	3	Djelomično neravan teren	3	Umjereno nagnuti teren
4	Meko tlo	4	Neravan teren	4	Strmi teren
5	Vrlo meko tlo	5	Vrlo neravan teren	5	Vrlo strmi teren

Radi pojednostavljenja prikaza međudjelovanja pojedinih razreda terenskih čimbenika opisne razredbe terena (velik broj mogućih kombinacija), teren se prikazuje u obliku troznamenkastoga broja, gdje prvi broj označava – razred nosivosti tla, drugi broj – razred površinskih prepreka i treći broj – razred nagiba terena. Tako npr. teren oznake 2.1.3. znači: teren s vrlo čvrstim tlom, bez površinskih prepreka, dobro stanje tla, umjerenoga nagiba.

Britanska šumarska komisija (Anon. 1975) razlikuje tri razine razredbe terena ovisno o veličini površine, točnosti opisanih detalja, razini planiranja radova i dr. (tablica 2.2).

Tablica 2.2 Britanska razredba terena (Anon. 1975)

Primjena razredbe terena		Veličina jedinične površine koja se promatra	Malena zasebna jedinica koja se može odrediti	Temelji opisa i razredbe	Zahtjevi točnosti podataka
(1)	Dugoročno planiranje gospodarenja (5 – 10 godina)				
1.1.	Široka procjena šumskog zemljišta s obzirom na mogućnosti i teškoće gospodarenja šumom (ocjena staništa)	Velika (srednja)	Ne	Srednje stanje	Niski
1.2.	Procjena potreba i prvenstva s obzirom na istraživanja i razvoj radnih metoda i opreme	Velika (srednja)	Ne	Srednje stanje	Niski do srednji
1.3.	Statističke informacije o stanju terena za različite potrebe	Velika	Ne	Srednje stanje	Srednji
1.4.	Opće planiranje otvaranja šuma (potrebe i procjena troškova)	Srednja do velika	Ne	Srednje stanje	Niski do srednji
(2)	Srednjeročno planiranje gospodarenja (2 – 5 godina)				
2.1.	Raspolaganje s opremom, odluke o potrebama za opremom	Srednja (velika)	Ne	Srednje stanje	Srednji
2.2.	Procjena troškova i proizvodnje	Srednja	Da (ne)	Srednje stanje	Srednji
2.3.	Planiranje gradnje cesta	Srednja	Da	Srednje stanje	Srednji
2.4.	Procjena prodanog drva	Srednja	Da	Srednje stanje	Srednji
(3)	Kratkoročno planiranje radova, procjena radilišta i nadopune (ispod 2 godine)				
3.1.	Procjena, kontrola i analiza troškova i proizvodnje pojedinih radova (utjecaj terena i pristupačnosti na jedinične troškove i satnu proizvodnju)	Mala	Da	Trenutno stanje	Srednji do veliki
3.2.	Izbor optimalnog radnog postupka i opreme za postojeću činidbu na određenom radilištu	Mala	Da	Trenutno stanje	Srednji do veliki
3.3.	Utvrđivanje omjera nadnica i ugovora u pridobivanju drva (do stupnja dok na njih utječe teren)	Mala	Da	Trenutno stanje	Srednji do veliki
3.4.	Detaljni opis radilišta i postupak za izvješće studija rada, za znanstvene potrebe i promijenjena iskustva (nova saznanja)	Mala	Da	Trenutno stanje	Veliki

Tablica 2.3 Kanadska razredba terena (Mellgren 1980)

Razred		1 – Vrlo dobar		2 – Dobar		3 – Srednji		4 – Loš		5 – Vrlo loš	
Čimbenici	Vodni režim tla (ljeti)	Dobro osušeno i drenirano tlo		Osušeno tlo		Svježe tlo		Vlažno tlo	Mokro tlo	Vrlo mokro tlo	Vrlo mokro tlo
	Tekstura tla	Grubo-zrnati pjesci, pješčenjaci		Srednje-zrnati pijesci, pjeskovita ilovača		Sitno-zrnati pijesci, pjeskoviti silt, glinoviti silt			Silt, glinoviti silt i pjeskovita glina, organski ostatak do 60 cm dubine tla		Organski ostatak više od 60 cm dubine tla
	Porijeklo	Prekambrijski nanosi, pijesci i kalko-fluvijalni nanosi		Glacijalni nanosi		Lakustrijski i fluvijalni nanosi			Stratificirani glacio-lakustrijski nanosi		Trestetišta,
	Površinske prepreke	Vrlo ravan teren		Djelomično ravan teren		Djelomično neravan teren		Neravan teren		Vrlo neravan teren	
		Visina ili dubina prepreke (cm) i učestalost prepreke (kom/100 m^2)									
		10 – 30	0 – 4	10 – 30 30 – 50	0 – 4 1 – 4	10 – 30 30 – 50 50 – 70	> 4 5 – 40 1 – 4	10 – 30 30 – 50 50 – 70 70 – 90	> 4 5 – 40 1 – 4 1 – 4	10 – 30 30 – 50 50 – 70 70 – 90 > 90	> 4 > 40 > 4 > 4 > 0
	Nagib, %	>10		10 – 20		20 – 33		33 – 50		>50	
Vegetacijski indikatori	Vrste drveća	*Pinus banksiana*, *Betula papyrifera*, *Populus tremuloides*		*Pinus banksiana*, *Betula papyrifera*, *Populus tremuloides, Abies balsamea, Picea glauca, Pinus strobus*		*Abies balsamea, Picea glauca, Populus tremuloides, Pinus banksiana*, *Picea mariana*		*Abies balsamea, Picea mariana*, *Picea glauca, Populus* sp.	*Picea mariana*, *Larix laricina, Thuja occidentalis*	*Picea mariana*, *Larix laricina, Sqalix* sp.	*Picea mariana* 'Nana', *Larix lariciana*
	Prizemno rašće	Lišajevi, *Arctostaphylos* sp., mahovine iz porodice *Hypnaceae*, travnate zajednice		Travnate zajednice, mahovine iz porodice *Hypnaceae*		Mahovine iz porodice *Hypnaceae,* travnate zajednice			*Alnus* sp., *Sphagnum* sp., *Rhododendron* sp., *Kalmia* sp.		*Chamaedaphne callyculata, Sphagnum* sp., *Rhododendron* sp., *Betula nana*
NGP, kPa		>200		70 – 200		40 – 70			20 – 40		<20

Kanadska se razredba terena (Mellgen 1980) temelji na norveškim i švedskim razredbama, te se zasniva na tri glavna terenska čimbenika koji utječu na kretnost vozila (tablica 2.3), ali i na

vegetacijskim indikatorima (tipične vrste drveća i prizemnog rašća) te daje preporuke za dopuštene dodirne tlakove vozila na tlo (*NGP*).

Skandinavska razredba trenena iz 1992. (Berg 1992) opisnog je karaktera te uzima u obzir sljedeće terenske čimbenike: 1) nosivost tla, 2) površinske prepreke, 3) nagib terena, 4) vrstu i pokrov tla, 5) stjenovitost, 6) panjeve i šumski ostatak te 7) tvrdoću snijega. Služi za primjenu u praksi te na jednostavan način objašnjava kako odrediti veličinu pojedinog čimbenika (tablica 2.4). Stanje tla, autor opisuje kroz vrstu tla, vlažnost tla i navodi moguću stabilizaciju tla različitim materijalima. Površinske prepreke dijeli u 4 razreda visine i ovisno o njihovom udjelu, svrstava teren u pojedine razrede. Ispitivanja stjenovitosti služe za određivanje postotnog udjela stijena ili kamenja (do dubine tla od 20 cm) ovisno o ispitivanoj šumskoj površini (uzorak točaka može biti nasumičan ili sistematski). Tvrdoća snijega procjenjuje se na većem uzorku površine gdje se u određeni dio zasiječe snijeg i odredi čvrstoća ručnim testom.

Tablica 2.4 Skandinavska razredba terena (Berg 1992)

<table>
<tr><td>Razred</td><td colspan="2">1</td><td colspan="2">2</td><td>3</td><td>4</td><td>5</td></tr>
<tr><td>Vlažnost tla</td><td colspan="2">Dobro osušeno</td><td colspan="2">Osušeno</td><td>Svježe</td><td>Vlažno</td><td>Vrlo vlažno</td></tr>
<tr><td>Tekstura tla</td><td colspan="2">Grubo-zrnati pjesci</td><td colspan="2">Sitno-zrnati pijesci, glinoviti silt</td><td>Pjeskoviti sitno-zrnati silt</td><td>Glinoviti silt</td><td>Glinasta</td></tr>
<tr><td>Operativno</td><td colspan="2">Moguća vožnja tokom cijele godine.</td><td colspan="2">Moguća vožnja tokom cijele godine – oprez u vrijeme topljenja snijega i dužeg kišnog perioda.</td><td>Oprez kod udolina, korištenja teških vozila i brojnih prolazaka vozila istim pravcem.</td><td>Potrebna stabilizacija; korištenje teških vozila jedino na smrznutome tlu.</td><td>Korištenje kotačnih vozila jedino kada je tlo smrznuto.</td></tr>
<tr><td>Organski materijal</td><td colspan="2">Malo (ljeti mrvičast)</td><td colspan="2">< 5 cm</td><td>5 – 15 cm</td><td>15 – 30</td><td>>30 cm</td></tr>
<tr><td rowspan="2">Površinske prepreke</td><td colspan="2">Vrlo ravan teren</td><td colspan="2">Djelomično ravan teren</td><td>Djelomično neravan teren</td><td>Neravan teren</td><td>Vrlo neravan teren</td></tr>
<tr><td colspan="7">Broj prepreka (kom/ha) i međusobna udaljenost (m)</td></tr>
<tr><td>H20 (10 – 30 cm)</td><td>40 – 400
5 – 16 m</td><td>400 – 4000
1,6 – 5 m</td><td>400 – 4000
1,6 – 5 m</td><td>> 4000
< 1,6 m</td><td>> 4000
< 1,6 m</td><td>> 4000
< 1,6 m</td><td rowspan="4">Svi uvjeti iznad 4</td></tr>
<tr><td>H40 (30 – 50 cm)</td><td rowspan="3">4 – 40
16 – 50 m</td><td rowspan="3">0</td><td>40 – 400
5 – 16 m</td><td rowspan="3">4 – 40
16 – 50 m</td><td>400 – 4000
1,6 – 5 m</td><td>400 – 4000
1,6 – 5 m</td></tr>
<tr><td>H60 (50 – 70 cm)</td><td rowspan="2">4 – 40
16 – 50 m</td><td>40 – 400
5 – 16 m</td><td rowspan="2">40 – 400
5 – 16 m</td></tr>
<tr><td>H80 (> 70 cm)</td><td>4 – 40
16 – 50 m</td></tr>
<tr><td rowspan="2">Stjenovitost, %</td><td colspan="7">Udio = (broj uočenih stijena * 100) / ukupan br.ispitivanih točaka</td></tr>
<tr><td colspan="2">0</td><td colspan="2">1 – 20</td><td>21 – 40</td><td>41 – 60</td><td>61 – 100</td></tr>
<tr><td>Nagib, %</td><td colspan="2">0 – 10</td><td colspan="2">10 – 20</td><td>20 – 33</td><td>33 – 50</td><td>> 50</td></tr>
<tr><td>Šumski ostatak i panjevi</td><td colspan="2">Prekriveno 10 % površine, ostatak debljine do 10 cm</td><td colspan="2">Prekriveno 60 – 70 % površine, ostatak rijetko deblji od 20 cm</td><td>Prekriveno 60 –90 % površine, ostatak rijetko deblji od 30 cm</td><td>Prekriveno 90 – 100 % površine, ostatak deblji od 30 cm</td><td>Svi uvjeti iznad 4</td></tr>
</table>

Sa naglaskom na okolišnu pogodnost, 2002. godine nastaje EcoWood razredba terena (tablica 2.5) kao svojevrstan operativni protokol za radove pridobivanja drva na ekološki osjetljivim područjima (Owende i dr. 2002). Kao rezultat navedenoga projekta nastaje i preporuka o primjeni (korištenju) pojedinih sredstava privlačenja drva s obzirom na prisutne terenske čimbenike (tablica 2.6).

Tablica 2.5 EcoWood razredba terena (Owende i dr. 2002)

Razred	Stanje podloge	Neravnost terena						Nagib	
		Opis	Visina prepreke, cm	Visina prepreka, cm					
				20	40	60	80		
				Prosječna udaljenost, m					
1	Dobro	Ravan	H 20	1,6 – 5 5 – 16	> 16	> 16	> 16	Blag	< 8° ili 14 %
			H 20 – 40	< 1,6 1,6 – 5	> 16 5 – 16	> 16 > 16	> 16 > 16		
2	Prosječno	Djelomično neravan	H 40 – 60	< 1,6 < 1,6	1,6 – 5 1,6 – 5	5 – 16 1,6 – 5	> 16 > 16	Srednji	8° – 14° ili 14 – 25 %
			H 40 – 80	< 1,6 1,6 – 5	< 1,6 1,6 – 5	5 – 16 1,6 – 5	5 – 16 5 – 16		
3	Loše	Neravan	H 40 – 80	< 1,6 < 1,6	< 1,6 < 1,6	1,6 – 5 < 1,6	5 – 16 < 1,6	Strmi	> 14° ili > 25 %
4	Vrlo loše (kretnost onemogućena)								

Tablica 2.6 EcoWood razredba terena za privlačenje drva (Owende i dr. 2002)

1.1.1	2.1.1	3.1.1	4.1.1
Forvarder, skider, konj			Forvarder sa postavljenim polugusjenicama, šumska žičara
1.1.2	2.1.2	3.1.2	4.1.2
Forvarder, skider, konj		Forvarder, forvarder sa postavljenim polugusjenicama, šumska žičara	
1.1.3	2.1.3	3.1.3	4.1.3
Forvarder, skider, konj		Šumska žičara	
1.2.1	2.2.1	3.2.1	4.2.1
Forvarder, skider, konj			Forvarder sa postavljenim polugusjenicama, šumska žičara
1.2.2	2.2.2	3.2.2	4.2.2
Forvarder, konj	Forvarder, forvarder sa postavljenim polugusjenicama	Forvarder sa postavljenim polugusjenicama, šumska žičara	
1.2.3	2.2.3	3.2.3	4.2.3
Forvarder sa postavljenim lancima, šumska žičara		Šumska žičara	
1.3.1	2.3.1	3.3.1	4.3.1
Forvarder, šumska žičara		Forvarder sa postavljenim polugusjenicama, šumska žičara	
1.3.2	2.3.2	3.3.2	4.3.2
Forvarder, šumska žičara	Forvarder, forvarder sa postavljenim polugusjenicama, šumska žičara	Šumska žičara	
1.3.3	2.3.3	3.3.3	4.3.3
Šumska žičara			

Velika je važnost ujednačenosti razredbi terena jer jedino su u tom slučaju moguće usporedbe i izmjene znanja te iskustava na međunarodnoj razini. Značajke i troškovi radnih operacija se ne mogu objašnjavati i predviđati ako radni uvjeti (značajke okruženja) nisu poznati.

Primjenom suvremenih metoda (GIS), poznavanjem terenskih značajki (čimbenika), tehnoloških mogućnosti šumarskih vozila (proizvodnost, okolišna pogodnost) te načina gospodarenja šumama (sječna gustoća, otvorenost šuma) nastaju brojni modeli i sustavi za potporu odlučivanja čiji su temelj upravo razredbe terena odnosno prometnost terena.

2.2 Prikupljanje dostupnih prostornih podataka i njihova prilagodba za analizu

Razredba terena za šumarstvo predstavlja podjelu šumskih površina u jedinice, za koje vrijedi isti ili barem sličan stupanj poteškoća sa stajališta izvođenja bilo koje vrste šumskih radova (Owende i dr. 2002). Razredbe terena za izvođenje šumskih radova namijenjene su praktičnoj primjeni pri: planiranju radova pridobivanja drva i njege šuma, kontroli izvođenja radova, ocjeni pogodnosti mehaniziranih sredstava rada te njihovoj međusobnoj usporedbi, razvoju mehaniziranih sredstava rada, planiranju tržišta, odnosno kao podloge pri sklapanju ugovora s privatnim poduzetnicima (Mellgren 1980) te planiranju budućeg otvaranja šuma šumskom prometnom infrastrukturom.

Za određivanje reljefnih područja gospodarskih šuma republike Hrvatske sa stajališta pridobivanja drva i otvaranja šuma prikupljeni su i analizirani prostorni podatci vezani uz:

- Nagib terena
- Indeks neravnosti terena
- Stjenovitost tla
- Način vlaženja tla
- Rizik od erozije
- Biljne zajednice
- Drvnu zalihu
- Srednju udaljenost privlačenja drva

2.2.1 Nagib terena

Nagib terena spada u grupu makrotopografskih značajki terena, koje utječu na kretanje vozila, pri čemu se svi kotači vozila sukobljavaju s jednakim makrotopografskim vrijednostima. Među makrotopografske značajke terena ubrajaju se:

- Inklinacija terena ili kut nagiba terena – prikazuje se kao vertikalni profil određenog presjeka terena, a uobičajeno se iskazuje kao postotak nagiba (100 tg α);
- Smjer nagiba terena predstavlja uzdužni nagib terena u smjeru kretanja vozila, a može biti pozitivan (kretanje vozila uz nagib), odnosno negativan (kretanje vozila niz nagib). Nagib terena u smjeru vožnje, ograničava uporabu strojeva s obzirom na kut uzdužne stabilnosti vozila. Osim uzdužnog nagiba terena, vozila za kretanje po bespuću koja se primjenjuju u eksploataciji šuma pod utjecajem su i bočnog nagiba;
- Duljina nagiba određene inklinacije;
- Oblik nagiba predstavlja način razvedenosti nagnute površine (konkavan, konveksan, terasast).
- Ekspozicija predstavlja izloženost nagnute površine stranama Svijeta.

Nagib terena određene šumske površine, zbog utjecaja na siguran rad vozila, najbitniji je čimbenik pri izboru sredstava privlačenja drva. Löffler (1984) raščlanjuje nagib terena u pet razreda, i to s obzirom: na inklinaciju terena, duljinu te oblik nagiba (tablica 2.7). Isti autor, navodi da značenje duljine nagiba terena treba poimati kroz slučajeve neprekinute (od podnožja do vrha padine terena) i prekinute (pravilno položeni nagibi unutar terasa) duljine nagiba, dok za oblike nagiba terena navodi da su pogodni za opis manjih površina terena.

Tablica 2.7 Raščlamba kuta, duljine te oblika nagiba terena (Löffler 1984)

Razredi kuta nagiba terena	Opis terena	Raspon vrijednosti			Razredi duljine nagiba terena	Raspon Vrijednosti
		%	°			
1	Ravničasti teren	0 – 10	0 – 6		1	25 – 100 m
2	Blago nagnuti teren	10 – 20	6 – 11		2	100 – 200 m
3	Umjereno nagnuti teren	20 – 33	11 – 18		3	200 – 300 m
4	Strmi teren	33 – 50	18 – 27		4	300 – 700 m
5	Vrlo strmi teren	> 50	> 27		5	> 700 m

Razredba oblika nagiba terena					
Oblici nagiba terena	Pravilan nagib (R)	Terasast nagib (T)	Valoviti nagib (U)	Konkavni nagib (V)	Konveksni nagib (X)
Izgled nagiba terena					

U današnje vrijeme digitalni modeli reljefa (DMR) pružaju osnovne kvantitativne informacije o površini Zemlje (Varga i Bašić 2013). Isti autori navode da većina pružatelja podataka i profesionalnih korisnika rabi izraz digitalni model reljefa i za digitalni model terena (eng. *Digital Terrain Model*, DTM) i za digitalni model površine (eng. *Digital Surface Model*, DSM).

Digitalni model terena najčešće se odnosi na fizičku površinu Zemlje (visinu stvarne površine), dok digitalni model površine opisuje gornju plohu koja uključuje i visine vegetacije, izgrađene objekte i ostale površinske objekte, a visine fizičke površine opisuje jedino u područjima gdje nema navedenih objekata (Maune 2007).

Digitalni modeli reljefa daju podatke o visinama i položaju točaka na terenu te se iz njih mogu dalje dobiti različiti geomorfološki parametri poput nagiba terena (iznosa i smjera), indeksa zakrivljenosti terena, indeksa vlažnosti tla i dr. (Beven i Kirkby 1979, Hirt i dr. 2010).

Varga i Bašić (2013) zaključuju da su kvalitetni digitalni modeli reljefa potrebni u gotovo svim geoznanstvenim aplikacijama i primjenama.

Uzroci nastajanja pogrešaka i razlika između digitalnih modela reljefa su mnogobrojni, a neki su od njih: mjerna tehnika (lasersko ili fotogrametrijsko snimanje površine Zemlje), razvedenost reljefa (nizinsko ili planinsko područje), tip površine (površina Zemlje s vegetacijom ili bez vegetacije i izgrađenih objekata), razlučivost modela, pogreške vertikalnog datuma (srednje razine mora ili modela geoida), horizontalno neslaganje modela i drugi.

2.2.2 Indeks neravnosti terena

Neravnost reljefa (eng. *terrain ruggeddness*) određena je nagibom, oblicima nagiba te smjerom pružanja nagiba na nekoj površini. Ona utječe na bogatstvo biljnog i životinjskog svijeta, hidrološke prilike, demografiju, a samim time i na pristupnost šumskim površinama. Određivanje neravnosti reljefa često je korišteno u svrhu proučavanja staništa životinja, njihovih migracija i kretanja (Fabricius i Coetzee 1992, Canon i Bryant 1997), prilikom proučavanja biodiverziteta biljaka te ekološkog modeliranja (Van Niel i dr. 2004), u hidrološkim istraživanjima kretanja i zadržavanja vode na/u tlu (Huang i Jiang 2002, Hjerdt i dr. 2004), u istraživanjima o širenju požara i njihovom utjecaju na biodiverzitet (Wimbery i Riley 2007).

Beasom i dr. (1983) predstavljaju metodu određivanja neravnosti terena na temelju slojnica i kota sa topografskih karata, a Koeln i dr. (1996) navode da razvojem (i ubrzavanjem) rada računala i računalnih programa dostupnost prostornih podataka postaje veća.

Riley i dr. (1998, 1999) razvijaju indeks neravnosti terena (eng. *Terrain Ruggedness Index* – TRI) koji se zasniva na podacima o nadmorskim visinama dobivenih sa digitalnih modela visina terena (DEM – eng. *Digital Elevation Model*). Autori na temelju korjenovane razlike u nadmorskoj visini i smjeru pružanja nagiba između točaka na terenu određuju sedam razreda neravnosti terena:

1. Ravan teren: 0 – 80 m
2. Gotovo ravan teren: 81 – 116 m
3. Djelomično ravan teren: 117 – 161 m
4. Djelomično neravan teren: 162 – 239 m
5. Neravan teren: 240 – 497 m
6. Vrlo neravan teren: 498 – 958 m
7. Potpuno neravan teren: 959 – 4367 m.

2.2.3 Stjenovitost tla

Površinske prepreke spadaju u grupu mikrotopografskih značajki terena, koje su neovisne o makrotopografiji terena, a obuhvaćaju sve neravnosti terena, odnosno površinske prepreke koje utječu na kretanje jednog ili više kotača vozila. Procjena stupnja prekrivenosti tla stijenama i kamenom jedan je od elemenata za određivanje kakvoće i proizvodnosti staništa (Čavlović 2010). Isti autor u nacionalnoj inventuri šuma navodi da na 55,11 % površina privatnih i državnih šuma nema kamenitosti, na 16,99 % površina je udjel kamenitosti od 0 do 25 %, na 10,91% površina je udjel kamenitosti 26 do 50 %, a na 15,77 % površina je kamenitost preko 50 % (na 1,2 % površine šuma kamenitost nije procijenjena). Nadalje autor zaključuje da cijela nizinska zona, najveći dio brdske zone (77 %), cio visokogorske (26 %) i submenditeranske zone (14 %) čine površine šuma bez kamenitosti. Unutar eumediteranske zone postoji gotovo apsolutna kamenitost.

Površinske prepreke terena koje ograničavaju kretanje vozila po šumskom bespuću predstavljaju površinska mikroreljefna ispupčenja (stijenje, kamenje, džombe) i uleknuća (vodotoci, jarci, vrtače), zatim dubeća stabla, panjevi posječenih stabala te otpad pri sječi i izradbi. Löffler (1984) površinske prepreke sa stajališta kretnosti vozila opisuje kao:

- Depresije (uleknuća) s čvrstim i jasno određenim rubovima (duboke najmanje 0,2 m pri čemu se depresije s promjerom 6 puta većim od dubine ne uzimaju u obzir);
- Kamenje, stijenje i terenske zapreke visine najmanje 0,1 m.

Sve raščlambe neravnosti terena (površinskih prepreka) za potrebe izrade razredba terena kod izvođenja šumskih radova određene su veličinom i rasporedom površinskih prepreka određene šumske površine. Löffler (1984) i Rowan (1995) navode da se površinske prepreke utvrđuju na primjernim plohama, kružnoga ili kvadratnog oblika, najmanje ploštine od 100 m^2, te se dijele u četiri visinska razreda: H20 (10 – 30 cm), H40 (30 – 50 cm), H60 (50 – 70 cm) i H80 (> 70 cm).

Ovisno o autorima, raščlambe površinskih prepreka terena, zasnovane su s obzirom na visinu i međusobnu udaljenost površinskih prepreka, na visinu i učestalost prepreka po jedinici površine odnosno učestalost prepreka određenog visinskog razreda opisanu s gustoćom po jedinici površine, ali i međusobnim razmakom.

Prema američkom priručniku za pedološka istraživanja (Anon. 2017) broj, veličina i razmak između stijena/kamenja na površini tla (ali i ispod površine) utječu na način korištenja i gospodarenja tlom. Autori dijele površinske prepreke odnosno stjenovitost i kamenitost tla u 5 razreda:

1. Do 0,10 % udio stijena
2. Udio od 0,11 – 3% stijena
3. Udio od 3,01 – 15 % stijena
4. Udio od 15,01 – 50 % stijena
5. Više od 50,1 % stijena na površini tla.

2.2.4 Način vlaženja tla

Način vlaženja tla opisuje kretanje i zadržavanje vode u tlu. Prema namjenskoj pedološkoj karti republike Hrvatske (Bogunović i dr. 1997) način vlaženja tla može biti automorfni, gdje se tlo vlaži isključivo oborniskim vodama koje se ne zadržavaju u tlu. Smeiglejni način je vlaženje tla podzemnom vodom ispod 1 m dubine. Pseudoglejni je stagnirajućom oborinskom vodom, hipoglejni isključivo podzemnom vodom do površine, epiglejni vlaženje poplavnim i slivenim (gornjim) vodama koje leže na tlu, amfiglejni vlaženje podzemnom i gornjom vodom i pseudoglej-glejni je kombinirani način vlaženja stagnirajućom oborinskom i podzemnom vodom.

2.2.5 Rizik od erozije

Prema Husnjaku (2000) potencijalni je rizik od erozije tla vodom definiran kao temeljna osjetljivost tla prema eroziji tla vodom i to ne uzimajući u obzir vegetacijski pokrov ili način korištenja. Potencijalni rizik predstavlja dakle najgori mogući slučaj, odnosno procjena potencijalnog rizika od erozije tla vodom bazira se na pretpostavci da se cjelokupno područje istraživanja koristi kao obradivo. Osnovne značajke nekog terena koje imaju dominantni utjecaj na potencijalni rizik od erozije tla vodom su erodibilnost tla, erozivnost oborina i nagib terena.

Indeks potencijalnog rizika određen je na temelju slijedećeg proračuna:

$$Indeks\ potencijalnog\ rizika = Klasa\ erodibilnosti\ tla \cdot Klasa\ erozivnosti\ oborina \cdot Klasa\ nagiba\ terena \quad (1)$$

Nakon proračuna indeksa potencijalnog rizika erozije tla vodom, izdvojeni su klase i potklase potencijalnog rizika o erozije (tablica 2.8).

Tablica 2.8 Klase potencijalnog rizika od erozije tla vodom

Klasa potencijalnog rizika od erozije	Opis rizika	Indeks potencijalnog rizika
1	Nizak rizik	> 0 – 5
2	Umjereni rizik	> 5 – 11
3	Visok rizik	> 11

Isti autor navodi da sa druge strane stvarni rizik od erozije tla vodom predstavlja stvarni, aktualni ili postojeći rizik od erozije s obzirom na sadašnji vegetacijski pokrov i način korištenja. Na područjima s drugom klasom vegetacijskog pokrova koja predstavlja obradiva područja, odnosno sva područja koja nisu pod šumom, potencijalni rizik je ujedno i stvarni rizik od erozije tla vodom, dok se na područjima s prvom klasom vegetacijskog pokrova koja predstavlja površine pod šumom i permanentnim pašnjacima, visina rizika od erozije tla vodom smanjuje za jedan, ali samo kod druge i treće klase potencijalnog rizika, dok se prva klasa ne mijenja. Shodno tome, na područjima s umjerenim i visokim potencijalnim rizikom od erozije tla vodom i područjima s prvom klasom vegetacijskog pokrova, umjereni potencijalni rizik predstavlja niski stvarni rizik dok visoki potencijalni rizik predstavlja umjereni stvarni rizik (tablica 2.9).

Tablica 2.9 Matrica za određivanje klasa stvarnog rizika od erozije tla vodom

Klasa potencijalnog rizika od erozije	Klasa vegetacijskog pokrova	Stvarni rizik od erozije tla vodom	
		Klasa	Opis klase
1	1	1	Nizak rizik
	2	1	Nizak rizik
2	1	1	Nizak rizik
	2	2	Umjeren rizik
3	1	2	Umjeren rizik
	2	3	Visok rizik

2.2.6 Biljne zajednice

Za svrsihodnu ekološko-biološku raščlambu reljefa, apsolutne visine nisu dovoljno realan oslonac jer su one iako stalne često i nepostojani bioekološki pokazatelj i razdjeljivač jer ovisno o vrlo utjecajnim ostalim reljefnim čimbenicima vrlo variraju na pojedinom ili udaljenijim lokalitetima unitar istih reljefnih oblika (Bertović 1999). Isti autor nadalje navodi da je iznenađujuće što se u gotovo svim reljefnim interpretacijama zanemaruje već odavno znanstveno dobro opisan i poznat biljni svijet, iako je šumska i ostala vegetacija istaknuti reljefni i zemljopisni čimbenik, posebno u Hrvatskoj, najsigurniji u obilježbi i omeđenju osnovnih reljefnih oblika tj. nizina, brda, gora, a osobito pretplaninskih područja i planina. Autor definira pojam *bioklimat* kao prostorno definirano područje (lokalitet), s izraženim osobitostima podneblja (klimatski tip) i s određenim, toj klimi, prilagođenim vegetacijskim tipom (biljnom zajednicom). Stoga i pojedine reljefne pojase i potpojase predstavljaju njima analogno oblikovani bioklimati s njihovim neposredno uočljivim biocenozama edifikatorima, primarnim zonalnim i intrazonalnim te ostalim sekundarnim fitocenozama.

Pilaš i dr. (2014) izdvajaju jedanaest šumskih bioklimata zasnovanih na sličnim klimatskim prilikama koji se rasprostiru duž hrvatskog teritorija te koji predstavljaju prostornu raspodjelu glavnih tipova šumskim zajednica:

A. Pretplaninske šume klekovine (*Hyperico grisebachii-Pinetum mugi*)
B. Pretplaninske bukove i smrekove šume (*Lonicero caeruleae-Piceetum, Ranunculo platanifolii-Fagetum*)
C. Jelove, bukovo-jelove te smrekove šume (*Calmagrostio-Abietetum, Blechno-Abietetum, Omphalodo-Fagetum, Festuco drymeiae-Abietetum, Aremonio-Piceetum*)
D. Brdske bukove šume (*Lamio orvale-Fagetum, Vicio oroboidi-Fagetum, Cephalantero longifoliae-Fagetum, Helleboro nigri-Pinetum sylvestris*)
E. Brežuljkaste šume hrasta kitnjaka (*Luzulo-Quercetum petraeae, Querco-Castaneetum sativae, Epimedio-Carpinetum betuli, Festuco drymeiae-Carpinetum betuli, Querco-Ostryetum carpinifoliae*)
F. Šume sladuna i cera (*Quercetum frainetto-cerris*)
G. Nizinske šume hrasta lužnjaka i poplavne šume (*Salici-Populetum, Frangulo-Alnetum, Leucojo aestivi-Fraxinetum angustifoliae, Genisto elatae-Quercetum roboris, Carpino betuli-Quercetum roboris*)
H. Submediteranske šume bukve i crnog bora (*Seslerio autumnalis-Fagetum, Ostryo-Fagetum, Ostryo-Pinetum nigrae, Junipero sibiricae-Pinetum dalmaticae*)
J. Submediteranske šume medunca i crnog graba (*Querco pubescenti-Ostryetum carpinifoliae, Molinio arundinaceae-Quercetum pubescentis, Ostryo-Abietetum, Erico manipuliflorae-Pinetum dalmaticae*)
K. Submediteranske šume medunca i bijelog graba (*Querco-Carpinetum orientalis*)
L. Mediteranske šume i makije alepskog bora i hrasta crnike (*Fraxino orni-Quercetum ilicis, Myrto-Quercetum ilicis, Ostryo-Quercetum ilicis, Querco ilici-Pinetum dalmaticae, Querco ilici-Pinetum halepensis, Junipero phoeniceae-Pinetum halepensis, Pistacio lentisci-Juniperetum phoeniceae, Oleo-Pistacietum lentisci*)

2.2.7 Drvna zaliha

Prema nacionalnoj inventuri šuma (Čavlović 2010) drvna zaliha po hektaru na razini RH iznosi 232,22 m^3, na razini državnih šuma 255,57 m^3, a na razini privatnih šuma 155,84 m^3. Preciznost procijenjene drvne zalihe na razini RH iznosi 2,00 % odnosno uz 95-postotnu vjerojatnost drvna zaliha od 552,1 mil. m^3 nalazi se u rasponu od 541,1 – 563,2 mil. m^3. Prosječna drvna zaliha po hektaru privatnih šuma iznosi oko 60 % zalihe državnih šuma, pa privatne šume s površinskim udjelom od 23 % čine samo 15 % ukupne drvne zalihe. Kako je udio drvne zalihe neposredno vezan s površinom i sastavom šuma izraženim prosječnom zalihom po hektaru, čak se polovica ukupne drvne zalihe odnosi na površinski najzastupljeniju brdsko-gorsku zonu, dok se najveći dio ostale polovice odnosi na površinski podjednaku zastupljene visokogorsku i nizinsku zonu. S višestruko manjom drvnom zalihom (6 – 8 puta), drvna zaliha submediteranske i eumediteranske zone čini manje od 6 % ukupne drvne zalihe. Drvna zaliha po hektaru najveća je unutar visokogorske zone, na ukupnoj razini i razini

državnih šuma. To može obrazložiti preborni način gospodarenja najzastupljeniji u toj cijeloj zoni, za koji je normalna i karakteristična veća prosječna zaliha nego u regularnim šumama. Relativno visoka zaliha (iznad 300 m^3/ha) u nizinskoj zoni svjedoči o većoj zastupljenosti starijih sastojina. Unutar privatnih šuma drvna je zaliha po jedinici površine, osim u submediteranskoj i eumediteranskoj zoni, uglavnom na razini oko 60 % i nizinskoj i visokogorskoj zoni. Brdskogorska zona u kojoj su privatne šume i najzastupljenije (75 %) ističe se relativno visokom drvnom zalihom privatnih šuma od 226 m^3/ha (85 % u odnosu na državne šume).

Raspodjela drvne zalihe prema nekima od glavnih vrsta drveća i vlasništvu prikazana je u tablici 2.10.

Tablica 2.10 Drvna zaliha pojedinih vrsta drveća prema vlasništvu (Čavlović 2010)

Vrsta drveća	Drvna zaliha po vrstama drveća i vlasništvu					
	Državne šume		Privatne šume		Ukupno	
	m^3/ha	%	m^3/ha	%	m^3/ha	%
Obična bukva	95,45	37,35	32,60	20,91	80,87	34,82
Obični grab	20,75	8,12	23,10	14,82	21,25	9,15
Poljski jasen	9,52	3,73	0,41	0,26	7,41	3,19
Hrast kitnjak	21,51	8,42	20,67	13,26	21,28	9,16
Hrast lužnjak	37,33	14,61	6,65	4,27	30,21	13,01
Obična jela	18,54	7,25	0,57	0,37	14,38	6,19
Obična smreka	6,79	2,66	1,54	0,99	557	2,40
Crni bor	3,61	1,41	1,12	0,72	3,03	1,30
Alepski bor	1,98	0,77	3,44	2,21	2,31	0,99
Hrast crnika	0,66	0,26	1,74	1,12	0,9	0,39

2.2.8 Srednja udaljenost privlačenja drva

Kao podlogu za teoriju transporta drva, Matthews (1942) je prvi formulirao teorijski okvir koji povezuje geometriju (raspored) mreže prometnica i njenu funkcionalnu povezanost s udaljenošću privlačenja drva, koja podrazumjeva: 1) dvo-dimenzijski model (ravan teren), 2) pravocrtno pružanje jednoliko raspoređenih paralelnih cesta na jednakom međusobnom razmaku, 3) jednolik raspored posječenoga drva u prostoru koje se privlači najkraćim putem na najbližu cestu pri čemu je srednja udaljenost privlačenja drva jednaka četvrtini razmaka među cestama.

Ispunjenjem pretpostavki teorijskoga okvira, primjenjive su sljedeće ovisnosti:

$$g_c = \frac{10000 \cdot L}{e \cdot L} = \frac{10000}{e} \qquad (2)$$

$$s_t = \frac{e}{4} = \frac{2500}{g_c} \qquad (3)$$

gdje su:

g_c gustoća cesta, m/ha

s_t teorijska udaljenost privlačenja drva, m

e razmak između cesta (širina pojasa otvaranja), m

L duljina ceste (duljina pojasa otvaranja) cesta, m

Na Matthewsov teorijskom modelu zasniva se i optimalna otvorenost šuma, koja predstavlja krajnji cilj otvaranja šumskih područja, a polazi od metode najmanjih zbirnih troškova privlačenja drva te troškova vezanih uz postojanje (građenje i održavanje) šumskih cesta (Dietz i dr. 1988, Sundberg i Silversides 1988, Pičman i dr. 1997, Sessions 2007). Najmanji zbirni trošak izgradnje šumske ceste i privlačenja drva izračunava se na način, da se njegova prva derivacija po udaljenosti između šumskih cesta izjednači s nulom (izraz 4). Model najmanjih zbirnih troškova privlačenja drva i gradnje

šumskih prometnica zasniva se na postavci da što je mreža šumskih prometnica gušća, to su veći troškovi gradnje prometnica, a transport drva jeftiniji i obratno.

$$e_{opt} = 200 \cdot \sqrt{\frac{c_{ces}}{\frac{2 \cdot C_{sr}}{v \cdot V_t} \cdot V_{ha}}} \qquad (4)$$

gdje su:

e_{opt} optimalan razmak među cestama, km
c_{ces} jedinični trošak gradnje i održavanja šumske ceste, HRK/km
C_{sr} trošak strojnoga rada (kalkulacija) sredstva privlačenja drva, HRK/h
v brzina kretanja (ne)opterećenoga vozila, km/h
V_t obujam tovara sredstva privlačenja drva, m^3/tura
V_{ha} sječna gustoća šumskoga područja, m^3/ha

Sabadi (1992) te Pentek i dr. (2004), za metodu najmanjih ukupnih troškova pridobivanja drva kao postupka iznalaženja optimalne otvorenosti određenog šumskog područja, navode da je podložna velikoj rastezljivosti, zbog utjecaja jediničnoga troška gradnje šumske prometnice, vrste i tipa traktora kojim se privlači drvo, kao i intenziteta sječa određene šumske površine.

Segebaden (1964) navodi da zbog različitosti orografije terena te nepravilnosti šumskih površina i mreže prometnica, opće primjenjiva i matematički točna, ovisnost udaljenosti privlačenja drva i gustoće mreže šumskih cesta ne postoji. Isti autor, nadopunjuje geometrijski model Matthewsa (1942), uzimajući u obzir: 1) nepravilnost mreže cesta koja se pojavljuje u stvarnosti i 2) odstupanje privlačenja drva od pravocrtnoga i okomitog kretanja prema cesti, uslijed djelovanja terenskih čimbenika šumskoga bespuća (nagib terena, površinske prepreke, nosivost podloge). S ciljem valoriziranja udaljenosti privlačenja drva u stvarnome životu, pomoću metode mreže točaka, definira pet tada novih parametara: 1) srednju geometrijsku udaljenost privlačenja, 2) srednju stvarnu udaljenost privlačenja, 3) faktor mreže prometnica (cesta), 4) faktor privlačenja drva te 5) ukupni faktor korekcije.

Geometrijska udaljenost privlačenja drva je najkraća udaljenost od zadane točke u prostoru do najbliže ceste. Srednja geometrijska udaljenost privlačenja drva neke površine šuma je aritmetička sredina geometrijskih udaljenosti privlačenja drva beskonačnoga broja točaka jednoliko raspoređenih predmetnom površinom, pri čemu svaka točka predstavlja beskonačno malu površinu (izraz 5).

$$\bar{s}_{\mathrm{g}} = \frac{\sum_{i=1}^{n} s_{\mathrm{g_i}}}{n} \qquad (5)$$

Srednja stvarna udaljenost privlačenja drva je aritmetička sredina ostvarenih udaljenosti privlačenja drva od beskonačnoga broja točaka jednoliko raspoređenih po površini, do mjesta na šumskoj cesti gdje se sabire drvo (izraz 6).

$$\bar{s}_{\mathrm{d}} = \frac{\sum_{i=1}^{n} s_{\mathrm{d_i}}}{n} \qquad (6)$$

Faktor mreže prometnica, određen je kao odnos srednje geometrijske i srednje teorijske udaljenosti privlačenja (izraz 7), a uvažava postojeće nepravilnosti mreže primarne prometne šumske infrastrukture (cesta), ali i površine šuma, u odnosu na teorijski model, uslijed morfoloških parametara reljefa (nagib terena, razvedenost reljefa, gustoća i razvedenost hidrografske mreže), odnosno primijenjenog sustava primarnog otvaranja šuma. Faktor mreže prometnica, koristi se za pretvorbu srednje teorijske udaljenosti privlačenja (izračunate iz gustoće cesta određenoga šumskog područja) u srednju geometrijsku udaljenost privlačenja (izraz 8), a najčešće se iskazuje na razini gospodarske jedinice.

$$f_{\mathrm{m}} = \frac{\bar{s}_g}{s_t} = \frac{\bar{s}_g}{\frac{2500}{g_c}} = \frac{\bar{s}_g \cdot g_c}{2500} \tag{7}$$

$$\bar{s}_{\mathrm{g}} = s_t \cdot f_m \tag{8}$$

Dietz i dr. (1984) navode da se vrijednosti faktora mreže prometnica kreću u rasponu od 1,2 (nizina) do 2,0 (brdsko-planinsko područje).

Faktor korekcije privlačenja drva predstavlja odnos srednje stvarne i srednje geometrijske udaljenosti privlačenja drva (izraz 9), a uvažava odstupanje (povećanje) udaljenosti privlačenja drva u odnosu na najkraću udaljenost do šumske ceste (pomoćnoga stovarišta) uslijed djelovanja: 1) terenskih čimbenika te oblika i rasporeda sekundarne mreže šumskih prometnica, 2) mogućnosti prihvata drva korištenim sredstvom privlačenja drva (skider – duljina vučnoga uža vitla, forvarder – doseg prihvata drva dizalicom i dr.), 3) načina kretanja drva do pomoćnoga stovarišta (centralno i paralelno privlačenje drva).

$$f_{\mathrm{p}} = \frac{\bar{s}_d}{\bar{s}_g} = \frac{\bar{s}_d}{\frac{2500}{g_{\mathrm{c}}} \cdot f_m} = \frac{\bar{s}_{\mathrm{d}} \cdot g_{\mathrm{c}} \cdot f_{\mathrm{m}}}{2500} \tag{9}$$

Faktor korekcije privlačenja drva, koristi se za pretvorbu srednje geometrijske udaljenosti privlačenja u srednju stvarnu udaljenost privlačenja (izraz 10), a najčešće se iskazuje za radilišta – sječine (odjel, odsjek). Ovaj faktor korekcije sastoji se od faktora horizontalnog zaobilaženja prepreka i faktora vertikalne korekcije nagiba terena (1/cos α).

$$\bar{s}_{\mathrm{d}} = \bar{s}_{\mathrm{g}} \cdot f_p \tag{10}$$

Faktor privlačenja drva se kreće u rasponu od 1,2 do 2,5 ovisno o reljefnome području (Dietz i dr. 1984, Segebaden 1964, Enache 2013), obliku mreže prometnica (Sessions 2007), nadzoru i organizaciji radova privlačenja drva (Stankić 2010), metodi i sredstvu rada (Folegatti 2011).

Sveukupni faktor korekcije teorijske srednje udaljenosti privlačenja drva, predstavlja interakciju faktora mreže prometnica i faktora privlačenja drva – korekcije geometrijske srednje udaljenosti privlačenja (izraz 11), a služi za neposredno pretvaranje teorijske srednje udaljenosti privlačenja u stvarnu srednju udaljenost privlačenja drva (izraz 12). Ovaj faktor, iskazuje se za veće šumsko područje.

$$f_{\mathrm{p}} = f_{\mathrm{m}} \cdot f_p \tag{11}$$

$$\bar{s}_{\mathrm{d}} = s_{\mathrm{g}} \cdot f_p \tag{12}$$

Dietz i dr. (1984) navode da se vrijednosti sveukupnog faktora korekcije kreću u rasponu od 1,6 (nizina) do 3,6 (brdsko-planinsko područje).

Iz sažetoga prikaza, srednje udaljenosti privlačenja drva, kao parametra koji na nekoj šumskoj površini opisuje prosječnu udaljenost na kojoj se privlači drvo od mjesta sječe stabla (panja) do mjesta gdje se drvo sabire (pomoćno stovarište), te samim time snažno utječe na djelotvornost privlačenja drva, uočljive su njezine različite inačice, prvenstveno vezane za:

⇒ teorijski model, odnosno stvarno stanje na terenu,

⇒ veličinu odnosne šumske površine (gospodarska jedinica, odjel ili odsjek),

⇒ položaj šumske površine u odnosu na prostorni raspored šumskih cesta (geometrijska) u odnosu na prevaljenu udaljenost micanja drva (stvarna) određenim sredstvom privlačenja drva.

Pentek (2002) pri izračunu prosječne srednje udaljenosti privlačenja drva koristi izraz za izračun vagane aritmetičke sredine, pojedinih, za svaki odjel izračunatih vrijednosti, gdje se kao težine (ponderi) mogu uzimati parametri odjela: površina, drvna zaliha, sječna gustoća, odnosno očekivana kakvoća etata. Bumber (2011) kao pondere pri analizi otvorenosti šuma kroz strukturu prihoda drva u prostoru i vremenu koristi faktor položaja sječina i faktor položaja etata, koji su idejno zasnovani na faktoru mreže prometnica.

Euklidska udaljenost (izračunata putem računalnog programa ArcGIS, alat *Euclidean distance* unutar alata *Spatial Analyst*) izuzetno je dobar alat za određivanje prosječne geometrijske udaljenosti privlačenja drva na razini gospodarske jedinice, odnosno srednjih geometrijskih udaljenosti privlačenja drva pojedinih odjela/odsjeka (Bumber 2011). Isti autor, navodi da euklidska udaljenost odgovara Segebadenovim (1964) temeljima određivanja srednje geometrijske udaljenosti privlačenja drva.

2.3 Geostatička obrada prostornih podataka

Za obradu podataka korišteni su slijedeći programski paketi: ArcGIS 10.1 i QGIS 2.14.3 za prostornu analizu podataka. Mapsource i Garmi Base Camp za prebacivanje i pretvorbu podataka snimljenih GPS-om.

Analizirani su prostorni podaci vezani za državne gospodarske šume te privatne šume čija ukupna površina u ovoj razredbi terena iznosi 1 989 647 ha, od čega su površine bez iskazane drvne zalihe (degradirani oblici) u iznosu od 633 774 ha. U analizi prostornih podataka rabljeni su samo poligoni (odsjeci) kojima je pridružena oznaka šumske fitocenoze u atributnoj tablici. Prilikom daljnjih analiza po pojedinim značajkama korišteni su prostorni podaci državnih i privatnih šuma sa iskazanom drvnom zalihom bez degradiranih i inih površina kao što su pašnjak ilirske i stepske vlasulje, šikare, drače i primorske krkavine, kamenjara ljekovite kadulje i kovilja, pretplaninska rudina golog šaša i alpske sunčanice, zajednice rogoza itd.

2.3.1 Nagib terena

Nagib terena je određen na temelju analize digitalnih modela visina terena u programskome paketu ArcGIS 10.1 putem alata *Spatial Analyst Tools* → *Surface* → *Slope*. Navedena aplikacija koristi algoritam izračuna nagiba prema Burrough i McDonell (1998):

$$Nagib = \sqrt{\left(\frac{dz}{dx}\right)^2 + \left(\frac{dz}{dy}\right)^2} \tag{13}$$

$$\frac{dz}{dx} = \frac{[(c + 2f + i) - (a + 2d + g)]}{8 \cdot x(širina_ćelije)} \tag{14}$$

$$\frac{dz}{dx} = \frac{[(g + 2h + i) - (a + 2b + c)]}{8 \cdot y(visina_ćelije)} \tag{15}$$

gdje su:

dz – razlika u nadmorskoj visini,
dx – udaljenost u *x* smjeru,
dy – udaljenost u *y* smjeru,
e – ćelija za koju se računa nagib,
a ... i – susjednih 8 ćelija oko ćelije *e*.

Na osnovi preporuka za kategorizaciju nagiba terena pri izvođenju šumskih radova (Mellgren 1980, Löffler 1984, Berg 1992 i Rowan 1995), nagib terena na razini RH je podijeljen u 5 kategorija: 1) Ravničarski teren 0 – 10 %, 2) Blago nagnuti teren 10 – 20%, 3) Umjereno nagnuti teren 20 – 33 %, 4) Strmi teren 33 – 50 % i 5) Vrlo strmi teren > 50 %. Analiza u navedene kategorije nagiba provedena je pomoću alata *Spatial Analyst Tools* → *Reclass*.

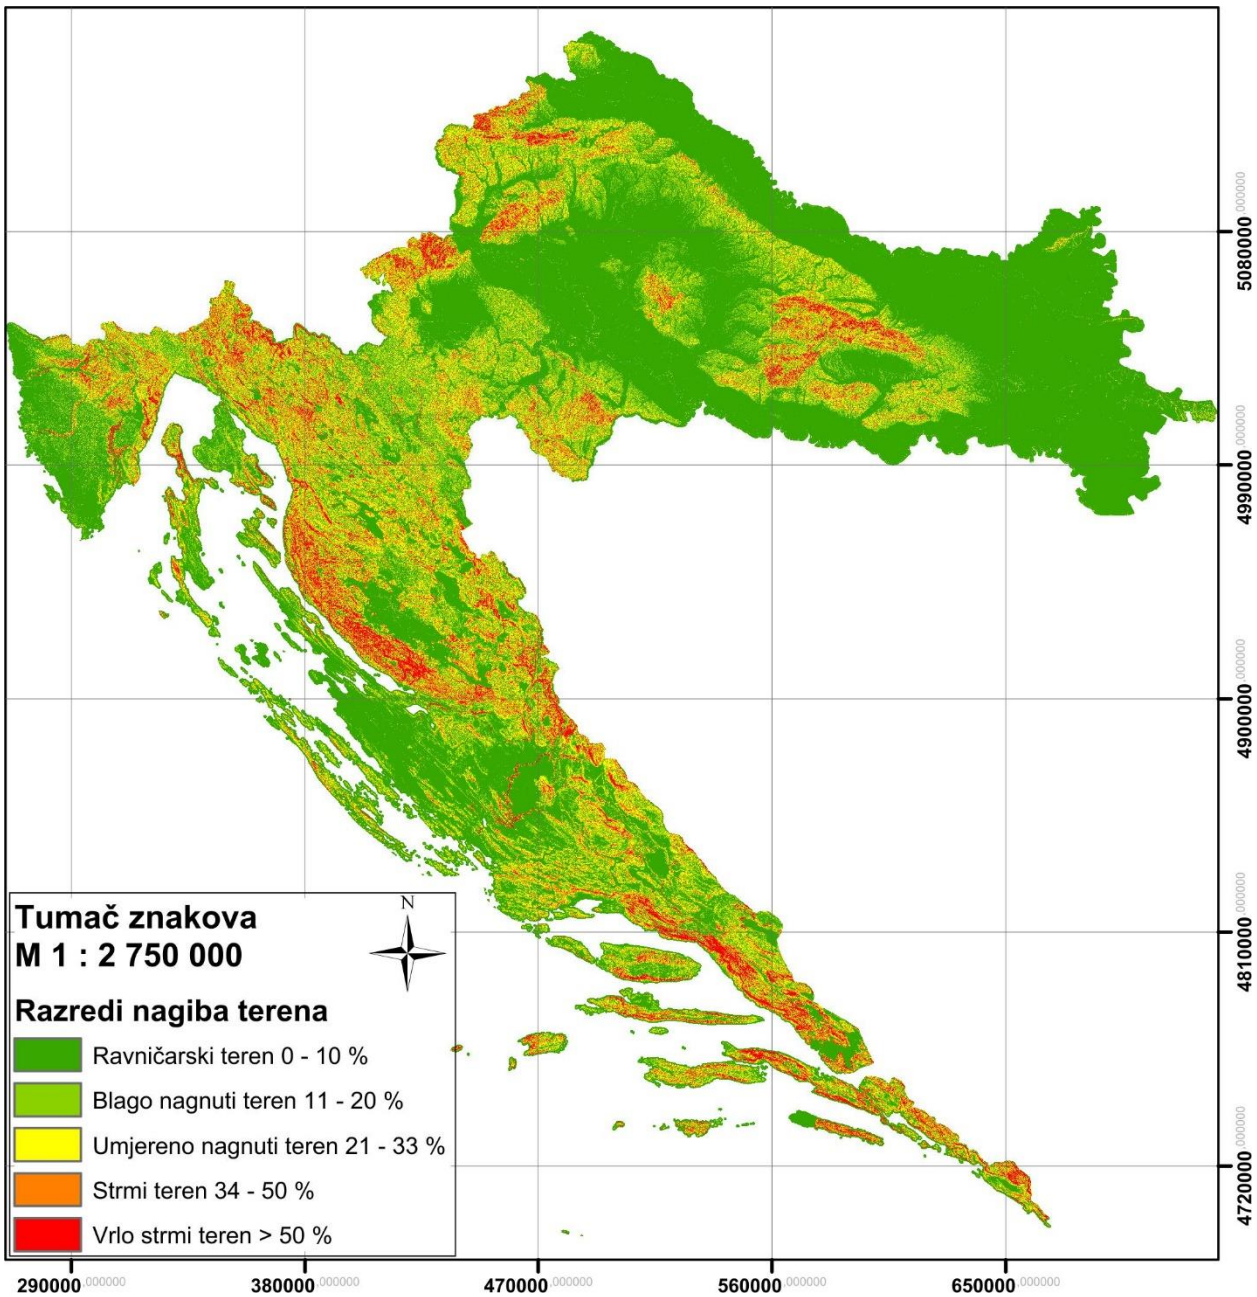

Slika 2.1 Nagib terena u Republici Hrvatskoj

Udjeli nagiba po ukupnoj površini iznose: 1) ravničarski teren 54,73 %, 2) blago nagnuti teren 17,38 %, 3) umjereno nagnuti teren 14,20 %, 4) strmi teren 9,13 % i 5) vrlo strmi teren 4,56 %. Dok se nagibi šumskih površina sa iskazanom drvnom zalihom kreću u slijedećim udjelima: 1) ravničarski teren 30,88 %, 2) blago nagnuti teren 20,74 %, 3) umjereno nagnuti teren 23,02 %, 4) strmi teren 17,11 % i 5) vrlo strmi teren 8,25 %. Iz navedenog se može zaključiti da je 48,38 % šumskim površina sa iskazanom drvnom zalihom na nagibu terena iznad 20 %, dok je pojedinačno najzastupljeniji ravničarski terenu iznosu od 30,88 %.

2.3.2 Indeks neravnosti terena

Indeks neravnosti terena putem alata izračunat je pomoću alata *Spatial Analyst Tools* → *Map Algebra* → *Raster Calculator* na temelju podataka visina te smjera pružanja nagiba terena (slika 2.2) prema smjernicama (Riley i dr. 1999). Računanje indeksa neravnosti temelji se na ukupnoj promjeni (sumi) visine terena i smjera pružanja nagiba između središnje (0,0) ćelije i njenih 8 susjednih ćelija.

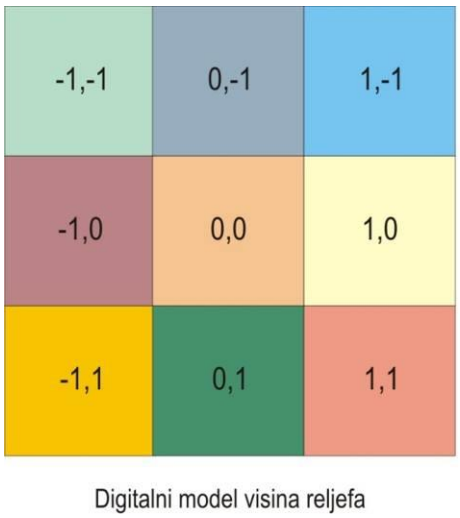

$$TRI=\sqrt{[((ell1(0,0)-ell1(-1,-1))^2+(ell1(0,0)-ell1(0,-1))^2+(ell1(0,0)-ell1(1,-1))^2+(ell1(0,0)-ell1(1,0))^2+((ell1(0,0)-ell1(1,1))^2+(ell1(0,0)-ell1(0,1))^2+(ell1(0,0)-ell1(-1,1))^2+(ell1(0,0)-ell1(-1,0))^2]}$$

Slika 2.2 Shema načina izračuna indeksa neravnosti terena

Prema Riley i dr. (1998, 1999) određeno je sedam razreda neravnosti terena te su dobiveni udjeli u ukupnoj površini (slika 2.3):

1. Ravan teren: 0 – 80 m na 77,04 % površine
2. Gotovo ravan teren: 81 – 116 m na 10,95 % površine
3. Djelomično ravan teren: 117 – 161 m na 7,71 % površine
4. Djelomično neravan teren: 162 – 239 m na 3,82 % površine
5. Neravan teren: 240 – 497 m na 0,47 % površine
6. Vrlo neravan teren: 498 – 958 m na 0,0062 % površine
7. Potpuno neravan teren: 959 – 4367 m na 0,0038 % površine.

Udjeli indeksa neravnosti terena na državnim i privatnim šumskim površinama sa iskazanom drvnom zalihom su: 1) ravan teren na 55,56 % površine, 2) gotovo ravan teren na 18,24 % površine, 3) djelomično ravan teren na 16,51 % površine, 4) djelomično neravan teren na 8,85 % površine, 5) neravan teren na 0,83 % površine i 6) vrlo neravan teren na 0,01 % površine.

Indeks neravnosti terena zajedno sa podacima o nagibu i stjenovitosti sa gledišta pridobivanja drva i otvaranja šuma daje informaciju o potrebi gradnje sekundarne mreže šumskih prometnica (izgradnja traktorskih puteva u odnosu na traktorske vlake) te sam oblik mreže (perasti raspored, riblja kost i slično). Sa stajališta izvođenja šumskih radova, Riley-eva kategorizacija je pregruba te će primjenjivost indeksa neravnosti terena, kao terenskog pokazatelja izvođenja šumskih radova biti predmet budućih istraživanja.

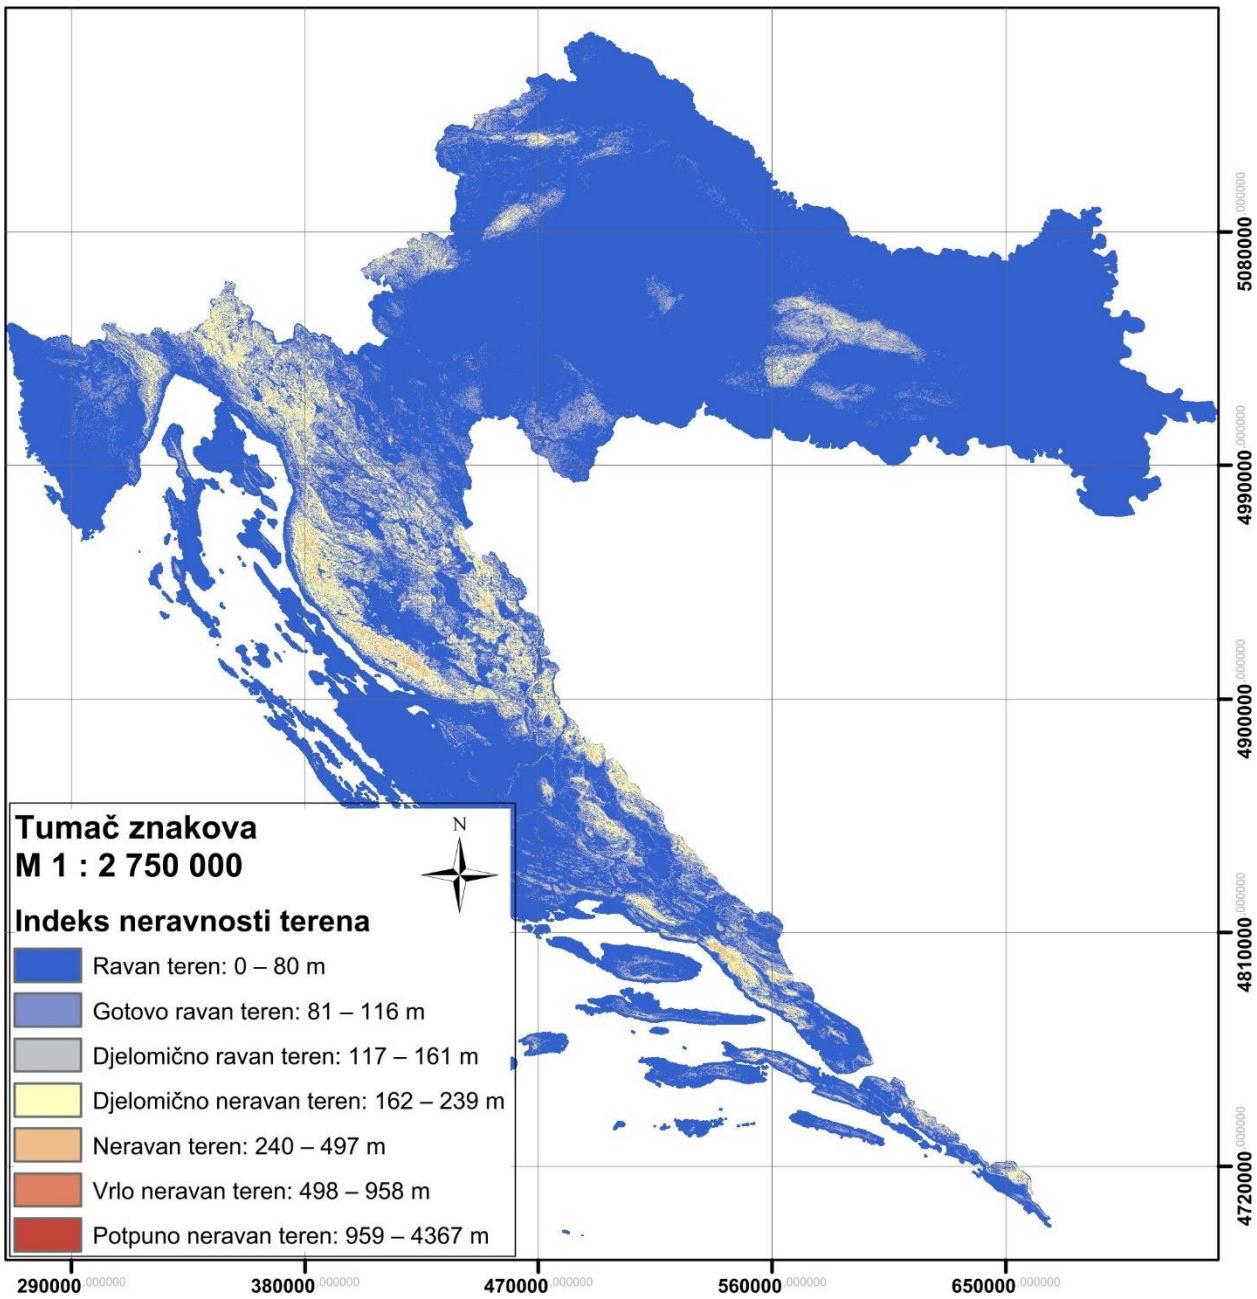

Slika 2.3 Indeks neravnosti terena u Republici Hrvatskoj

2.3.3 Stjenovitost tla

Na više od polovice šuma nema stjenovitosti što uključuje nizinske šume (77 %), dio visokogorskih šuma (26 %) i dio submediteranske zone (14 %) dok unutar eumediteranske zone postoji gotovo potpuna stjenovitost (Čavlović 2010).

Iako bi sa gledišta izvođenja radova pridobivanja drva te otvaranja šuma svakako bilo korisno imati podatke o visini površinskih prepreka posebno jer je poznato da taj podatak još nije sastavni dio opisa sastojina (obrasci O2 ili O3) osnova i programa gospodarenja šumama. S obzirom da su terenska istraživanja stjenovitosti i kamenitosti šumskog tla dugotrajna i vrlo skupa (Đuka 2014) u budućnosti se preporuča korištenje LiDAR snimaka visoke rezolucije na temelju kojih će digitalni modeli terena biti puno točniji. Geostatička obrada prostornih podataka uključivala je pretvorbu vektorskih podataka u rasterske korištenjem *Conversion Tools → To Raster → Polygon to Raster*, a zatim i *Spatial Analyst Tools → Reclass* naredbi.

Površinske su prepreke odnosno stjenovitost i kamenitost tla podijeljeni u 5 razreda sa pripadajućim udjelima u ukupnoj površini RH (slika 2.4):

1. Do 2 % udjela stijena na 59,81 % površine,
2. Udio od 3 – 10 % stijena na 5,23 % površine,
3. Udio od 11 – 25 % stijena na 4,61 % površine,
4. Udio od 26 –50 % stijena na 5,07 % površine,
5. Udio od 51 – 90 % stijena na 25,28 % površine.

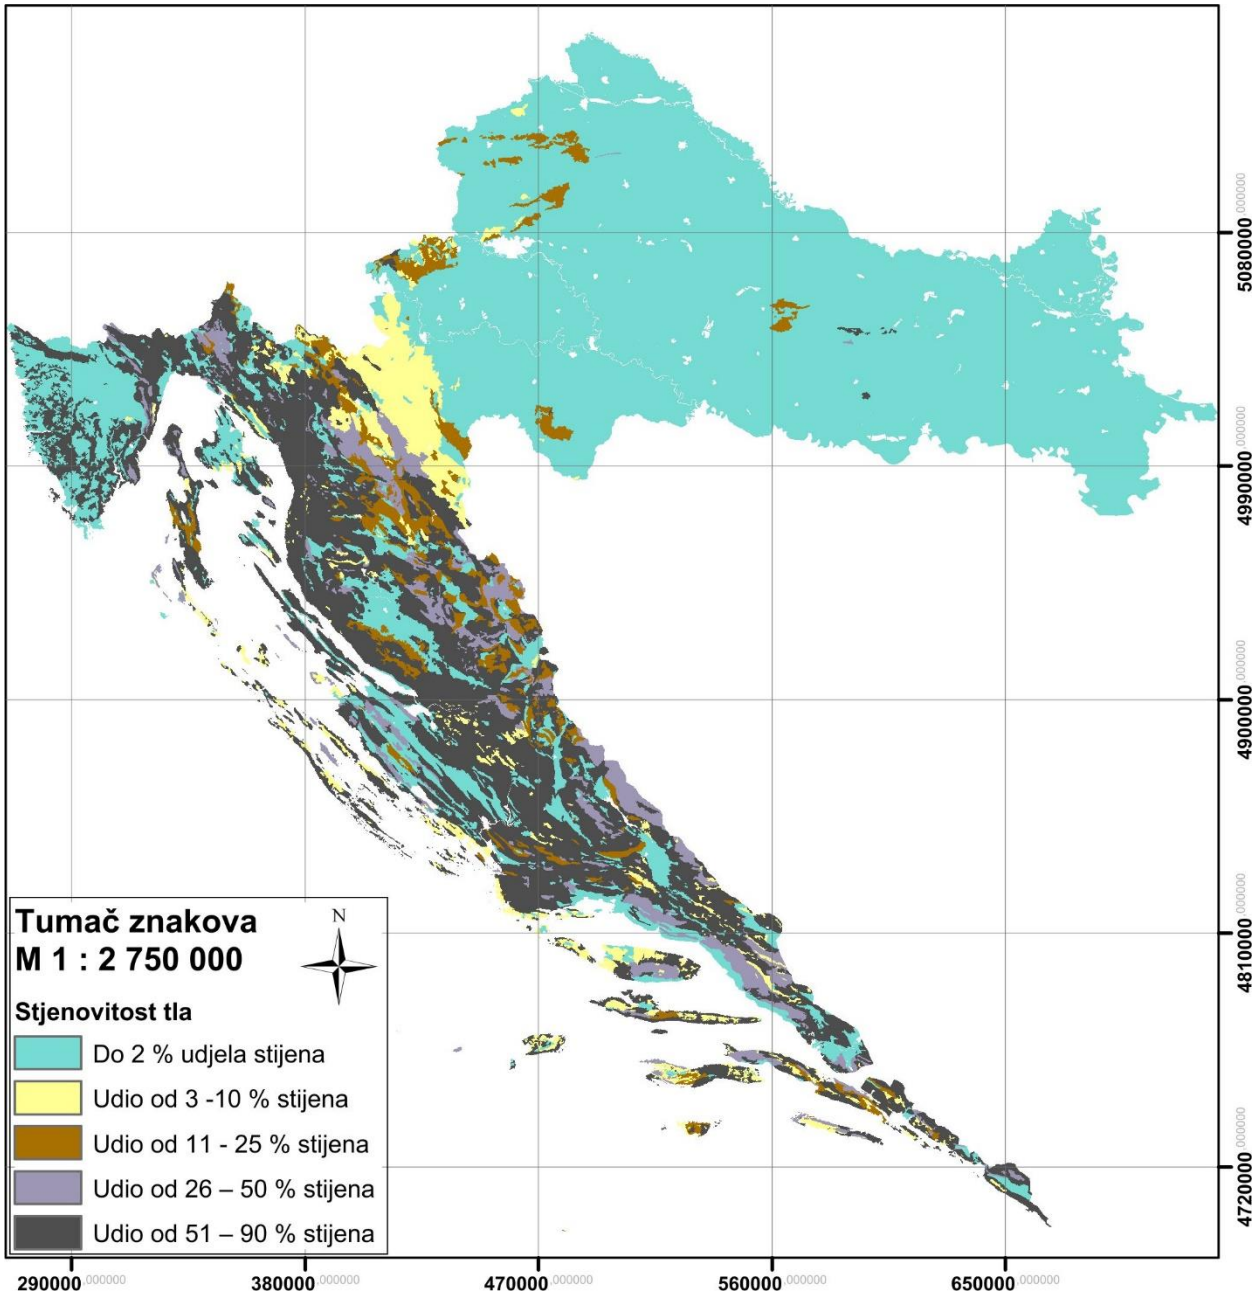

Slika 2.4 Stjenovitost tla u Republici Hrvatskoj

Udjeli pojedinih razreda stjenovitosti u državnim i privatnim gospodarskim šumama sa iskazanom drvnom zalihom kreću se u slijedećim omjerima: 1) do 2 % stijena na 58,31 % površine šuma, 2) do 10 % stijena na 5,14 % površine šuma, 3) do 25 % stijena na 6,60 % površine šuma, 4) do 50 % stijena na 5,44 % površine šuma i 5) do 90 % stijena na 24,51 % površine šuma. Može se zaključiti da većina šumske površine (preko polovice) ne sadrži površinske prepreke, ali treba naglasiti i činjenicu da je na 24,51 % šuma udio površinskih prepreka od 51 do 90 % površine što će svakako iskazati svoj utjecaj ne samo na oblike mreže primarne i sekundarne šumske infrastrukture već i na radne uvjete te proizvodnost vozila korištenih za pridobivanje drva.

2.3.4 Način vlaženje tla

Načini vlaženja tla (slika 2.5) podijeljeni su u 8 razreda prema Bogunoviću i dr. (1997): 1) aluvijalni – tla uz rijeke uključujući nanose i pijeske na 0,91 % ukupne površine RH, 2) amfiglejni zajedno sa podrazredima amfiglejno-epiglejni te amfiglejno-hipoglejni na 7,84 % ukupne površine RH, 3) automorfni te podrazred automofrno-amfiglejni na 70,60 % ukupne površine RH, 4) epiglejni na 2,54 % ukupne površine RH, 5) hipoglejni te podrazred hipoglejno-epiglejni na 0,92 % ukupne površine RH, 6) poseudoglejni te podrazred pseudoglejno-glejni na 11,29 % ukupne površine RH, 7) semiglejni na 3,78 % ukupne površine RH i 8) hidromeliorirani na 2,12 % ukupne površine RH.

Geostatička obrada prostornih podataka je i u ovome slučaju uključivala pretvorbu vektorskih podataka u rasterske korištenjem *Conversion Tools → To Raster → Polygon to Raster*, a zatim i korištenje *Spatial Analyst Tools → Reclass* naredbi.

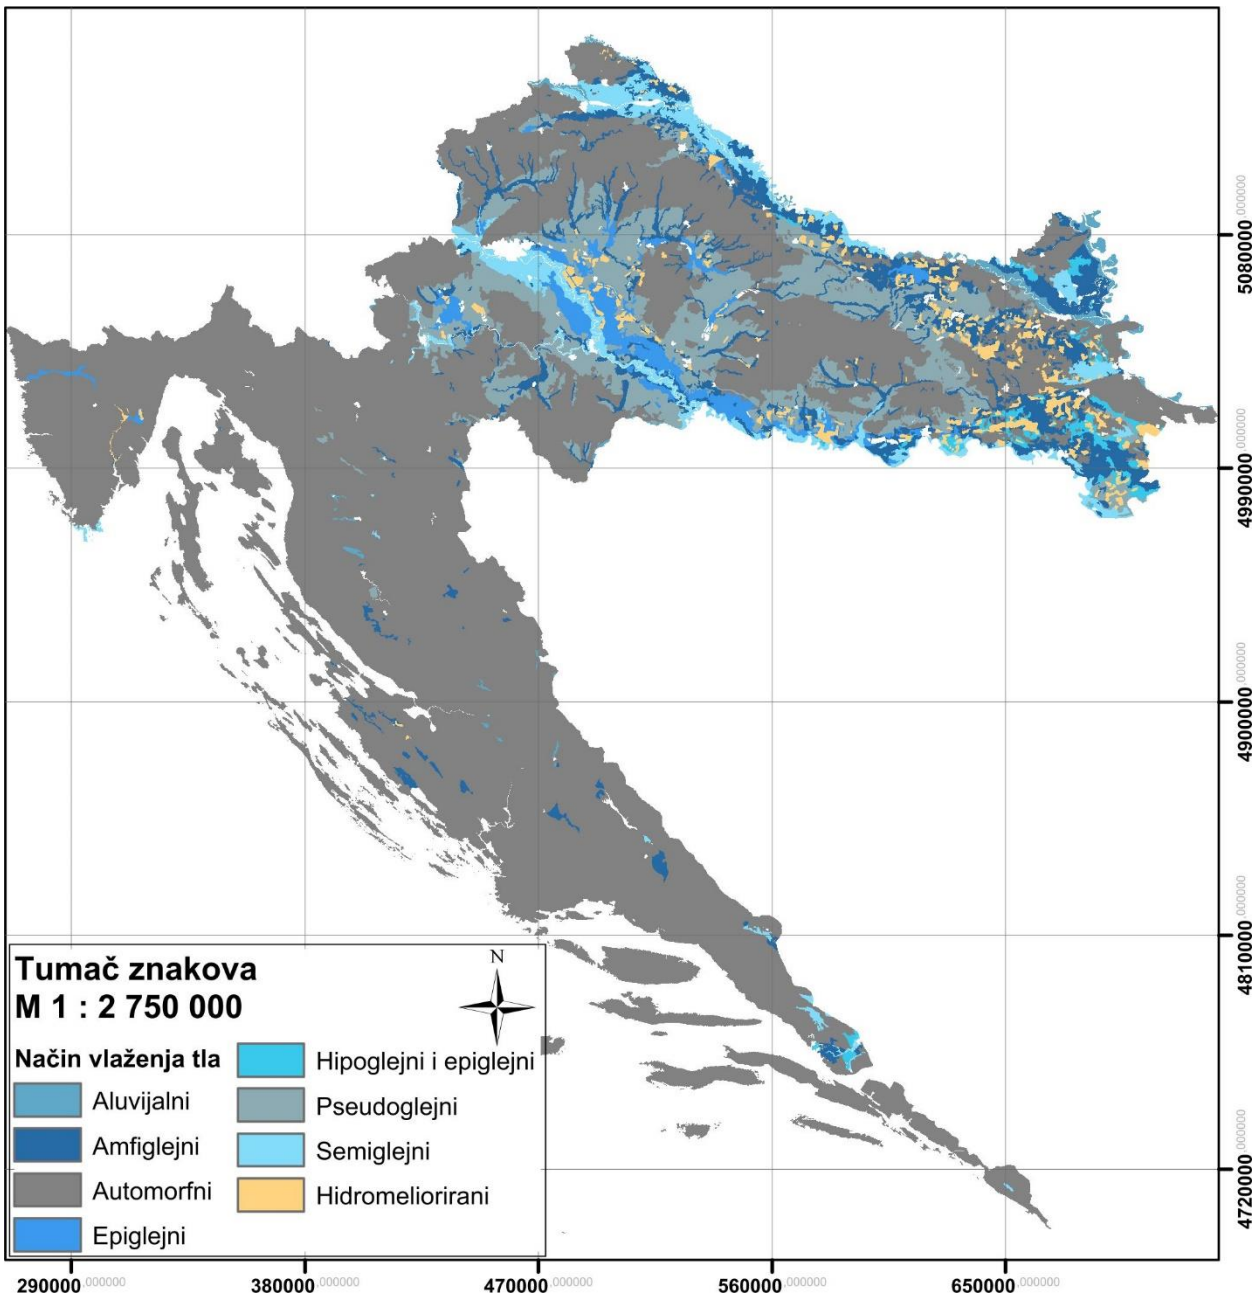

Slika 2.5 Načini vlaženja tla u Republici Hrvatskoj

Udjeli pojedinih razreda načina vlaženja tla u državnim i privatnim gospodarskim šumama sa iskazanom drvnom zalihom kreću se u slijedećim omjerima: 1) aluvijalni na 1,04 % šuma, 2) amfiglejni na 5,60 % šuma, 3) automorfni na 76,17 % šuma, 4) epiglejni na 3,29 % šuma, 5) hipoglejni na 0,67 % šuma, 7) semiglejni na 1,22 % šuma i 8) hidromeliorirani na 0,28 % šuma.

Znakovito je da se na preko 70 % površine šuma vlaženje tla odvija isključivo oborinskim vodama koje se ne zadržavaju dugo u tlu. Na ostalih 23,83 % šumskih površina svoj utjecaj iskazuju podzemne, poplavne te stagnirajuće oborinske vode koje utječu na razinu nosivosti tla, vrijeme izvođenja radova pridobivanja drva, ali i korištenje dodatne opreme na vozilima npr. polugusjenice na forvarderima, lanci na skiderima itd.

2.3.5 Rizik od erozije

Stvaran rizik od erozije vodom (slika 2.6) predstavlja postojeći rizik od erozije s obzirom na sadašnji vegetacijski pokrov i način korištenja tla. Prema Čavloviću (2010) na oko 60 000 ha (2,6 %) šuma očit je utjecaj erozije šumskog tla. Najveći se dio odnosi na eroziju uzrokovanu vodom (34 400 ha), a nešto manje na eroziju vjetrom (1060 ha). U usporedbi sa državnim šumama, u privatnima postoji manji udio šuma pod utjecajem erozije. Utjecaj erozije jači je u submediteranskome i eumediteranskome području. Dok se u apsolutnome smislu utjecaj erozije vidi na najvećim površinama unutar brdske zone (vodna erozija) i submediteranske zone (eolska erozija).

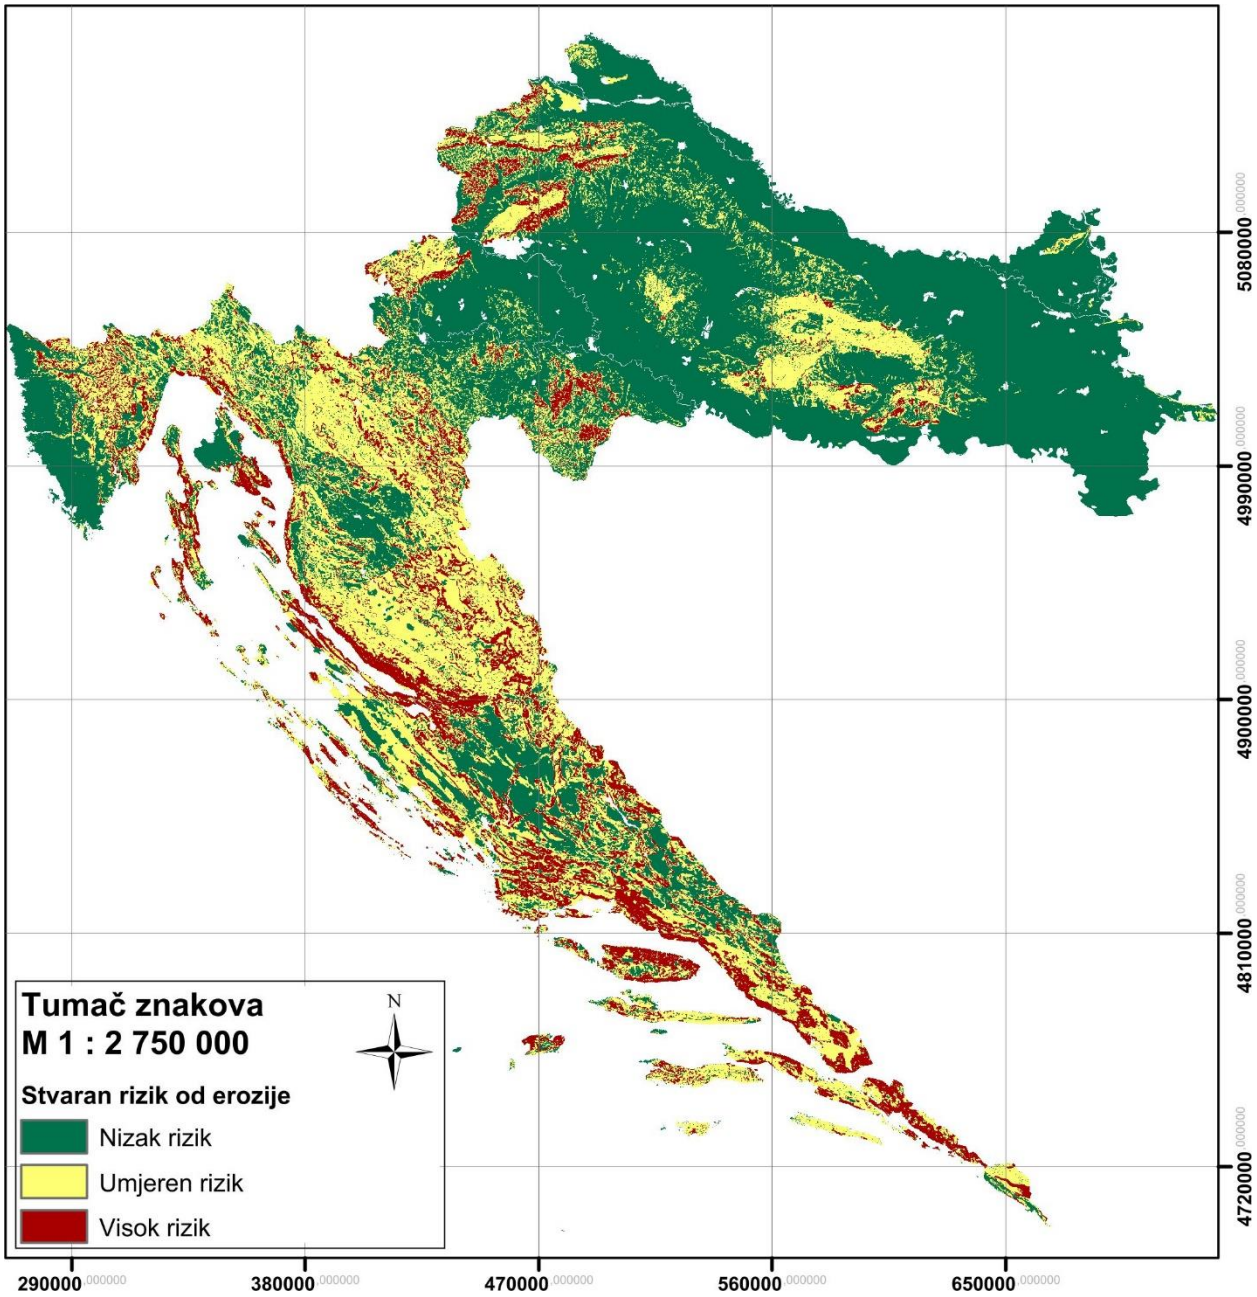

Slika 2.6 Stvaran rizik od erozije u Republici Hrvatskoj

U RH na 54,29 % ukupne površine je nizak rizik od erozije vodom, dok je na 32,29 % površine taj rizik umjeren. Na preostalih 13,42 % ukupne površine je visok rizik od erozije vodom. Kako je i već

navedeno stvaran rizik od erozije vodom nastao je na temelju podloge potencijalnog rizika od erozije tla vodom i karte vegetacijskog pokrova. Dok udjeli stvarnog rizika od erozije vodom u državnim i privatnim gospodarskim šumama sa iskazanom drvnom zalihom iznose: 1) nizak rizik od erozije je u 52,13 % šuma, 2) umjeren rizik od erozije je u 42,45 % šuma i 3) visok rizik od erozije je u 5,42 % šuma.

Analiza je provedena temeljem pretvorbe vektorskih podataka u rasterske korištenjem *Conversion Tools → To Raster → Polygon to Raster* te *Spatial Analyst Tools → Reclass* naredbi.

Na šumskim terenima umjerenog, a pogotovo visokog rizika od erozije, uzdužni nagib sekundarne šumske infrastrukture ne smije prelazati 20 %.

2.3.6 Biljne zajednice

Analiza je provedena na način da su se 122 fitocenoze koje se mogu pronaći u gospodarskim i privatnim šumama RH podijelile u deset prethodno navedenih bioklimata (slika 2.7), bez prisutnosti bioklimata F – šume sladuna i cera. Analiza je uključivala pretvorbu vektorskih podataka u rasterske korištenjem *Conversion Tools → To Raster → Polygon to Raster*, zatim stvaranje novog rastera koji će uključivati i državne i privatne gospodarske šume i to alatom *Data management Tools → Raster → Raster Dataset → Mosaic to New Raster*.

Tablica 2.11 Površine i udjeli bioklimata u gospodarskim šumama

Oznaka bioklimata	Ime bioklimata	Ukupna površina bioklimata*	Udio bioklimata	Površina bioklimata sa drvnom zalihom većom od 0 m³	Udio bioklimata sa drvnom zalihom većom od 0 m³, %
		ha	%	ha	%
A	Pretplaninske šume klekovine	178,65	0,01	167,4	0,01
B	Pretplaninske bukove i smrekove šume	34 938,69	1,76	34 232,33	2,52
C	Jelove, bukovo-jelove te smrekove šume	188 863,40	9,49	185 762,25	13,70
D	Brdske bukove šume	365 337,41	18,36	331 099,27	24,42
E	Brežuljkaste šume hrasta kitnjaka	355 240,17	17,85	311 679,18	22,99
G	Nizinske šume hrasta lužnjaka i poplavne šume	356 222,12	17,90	288 310,88	21,26
H	Submediteranske šume bukve i crnog bora	73 237,72	3,69	66 251,29	4,89
J	Submediteranske šume medunca i crnog graba	86 365,53	4,34	25 145,39	1,85
K	Submediteranske šume medunca i bijelog graba	400 665,53	20,14	80 151,63	5,91
L	Mediteranske šume i makije alepskog bora i hrasta crnike	128 597,81	6,46	33 072,48	2,44
Ukupno		1 989 647,03	100,00	1 355 872,12	100,00

*Odnosi se na površine obuhvaćene istraživanjem

Iz tablice 2.11 vidljivo je da u kontinentalnom dijelu teritorija RH brdske bukove šume (D) brežuljkaste šume hrasta kitnjaka (E) te nizinske šume hrasta lužnjaka i poplavne šume (G) zajedno zauzimaju 54,11 % površine, dok su najbrojnije u submediterankoj zoni šume medunca i bijelog graba sa udjelom od 20,14 % po površini. Također se može zaključiti da šume u submediteranskoj i mediteranskoj zoni su većinom u degradiranim stadijima bez iskazane drvne zalihe. Tako su submediteranske šume medunca i crnog graba (J) sa 86 365,53 ha površine smanjene na 25 145,39 ha sa iskazanom drvnom zalihom iznad 0 m^3/ha, u submediteranskim šumama medunca i bijelog graba (K) taj pad je izraženiji. Tako je u bioklimatu K sa početnih 400 665,53 ha površine došlo do smanjenja na čak 80 151,63 ha sa iskazanom drvnom zalihom većom od 0 m^3/ha. Primjetno je smanjenje površine i u mediteranskim šumama i makijama alepskog bora i hrasta crnike (L) sa početnih 128 597,81 ha na tek 33 072,48 ha.

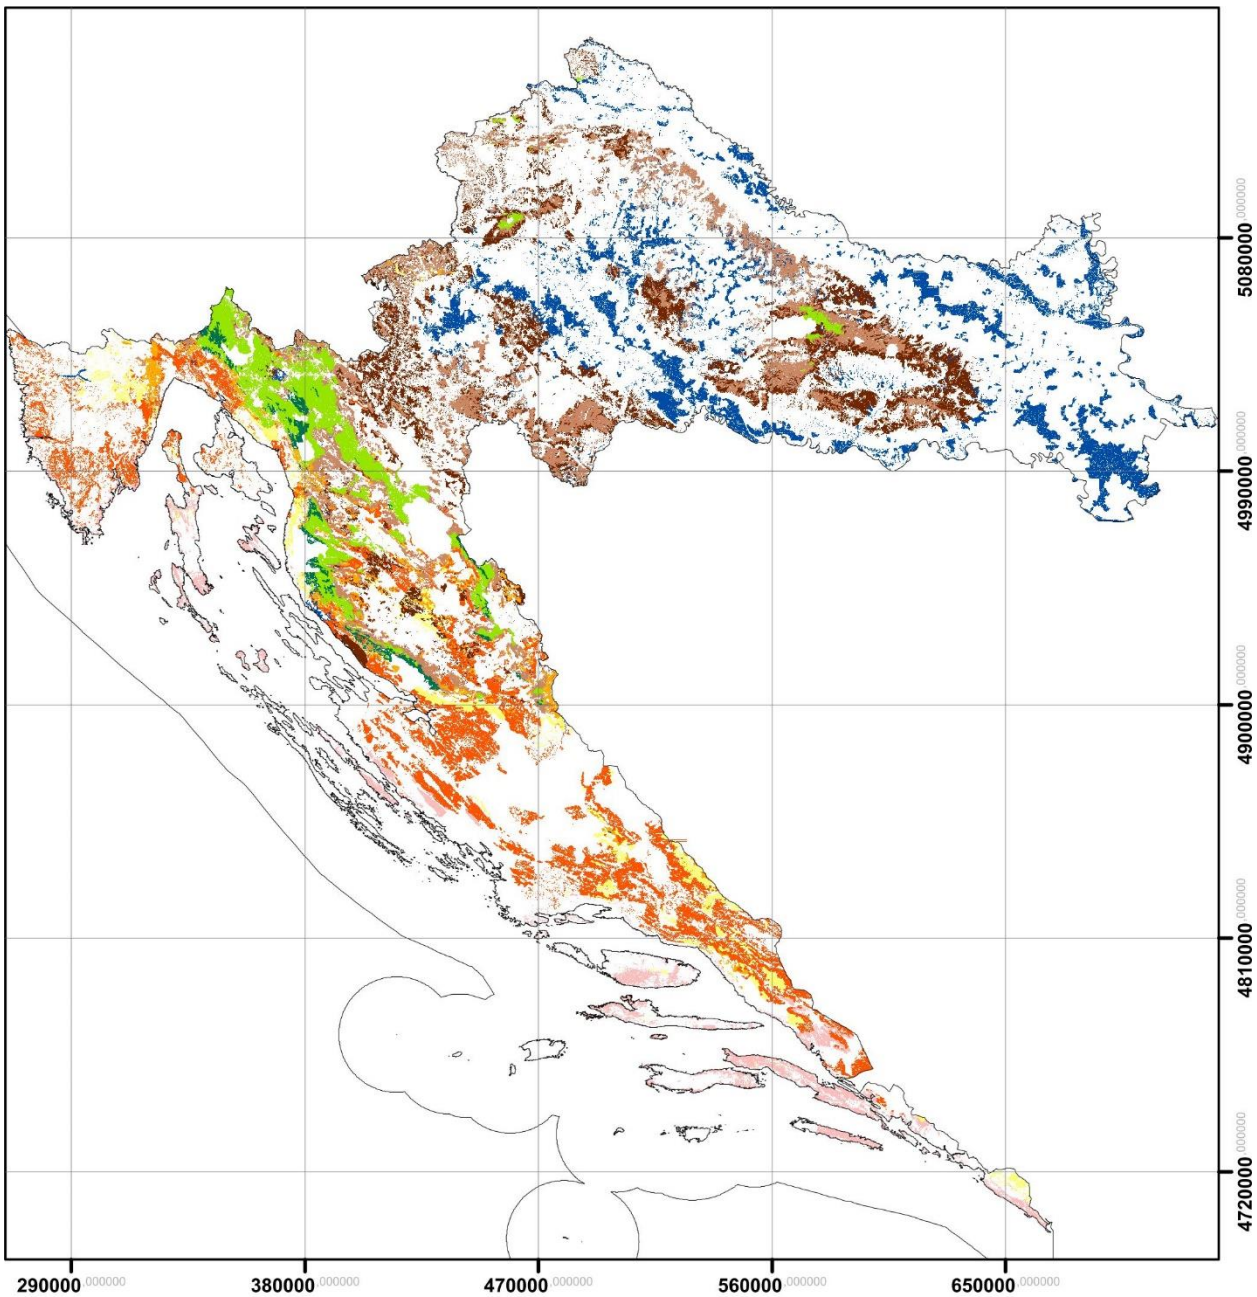

Tumač znakova
M 1 : 2 750 000

Bioklimati

- A - Pretplaninske šume klekovine
- B - Pretplaninske bukove i smrekove šume
- C - Jelove, bukovo-jelove te smrekove šume
- D - Brdske bukove šume
- E - Brežuljkaste šume hrasta kitnjaka
- G - Nizinske šume hrasta lužnjaka i poplavne šume
- H - Submediteranske šume bukve i crnog bora
- J - Submediteranske šume medunca i crnog graba
- K - Submediteranske šume medunca i bijelog graba
- L - Mediteranske šume i makije alepskog bora i hrasta crnike

Slika 2.7 Bioklimati istraživanog područja

2.3.7 Drvna zaliha

Drvna zaliha je podijeljena u 11 razreda (slika 2.8), dok su površine sa neiskazanom drvnom zalihom (odnosno drvnom zalihom jednakoj 0 m^3/ha) isključene iz ovog prikaza:

1. 1 – 100 m^3/ha na 14,86 % površine,
2. 101 – 200 m^3/ha na 23,86 % površine,
3. 201 – 300 m^3/ha na 25,89 % površine,
4. 301 – 400 m^3/ha na 21,34 % površine,
5. 401 – 500 m^3/ha na 11,08 % površine,
6. 501 – 600 m^3/ha na 2,67 % površine,
7. 601 – 700 m^3/ha na 0,31 % površine,
8. 701 – 800 m^3/ha na 0,02 % površine,
9. 801 – 900 m^3/ha na 0,00152 % površine,
10. 901 – 1000 m^3/ha na 0,000604 % površine,
11. > 1000 m^3/ha na 0,000594 % površine.

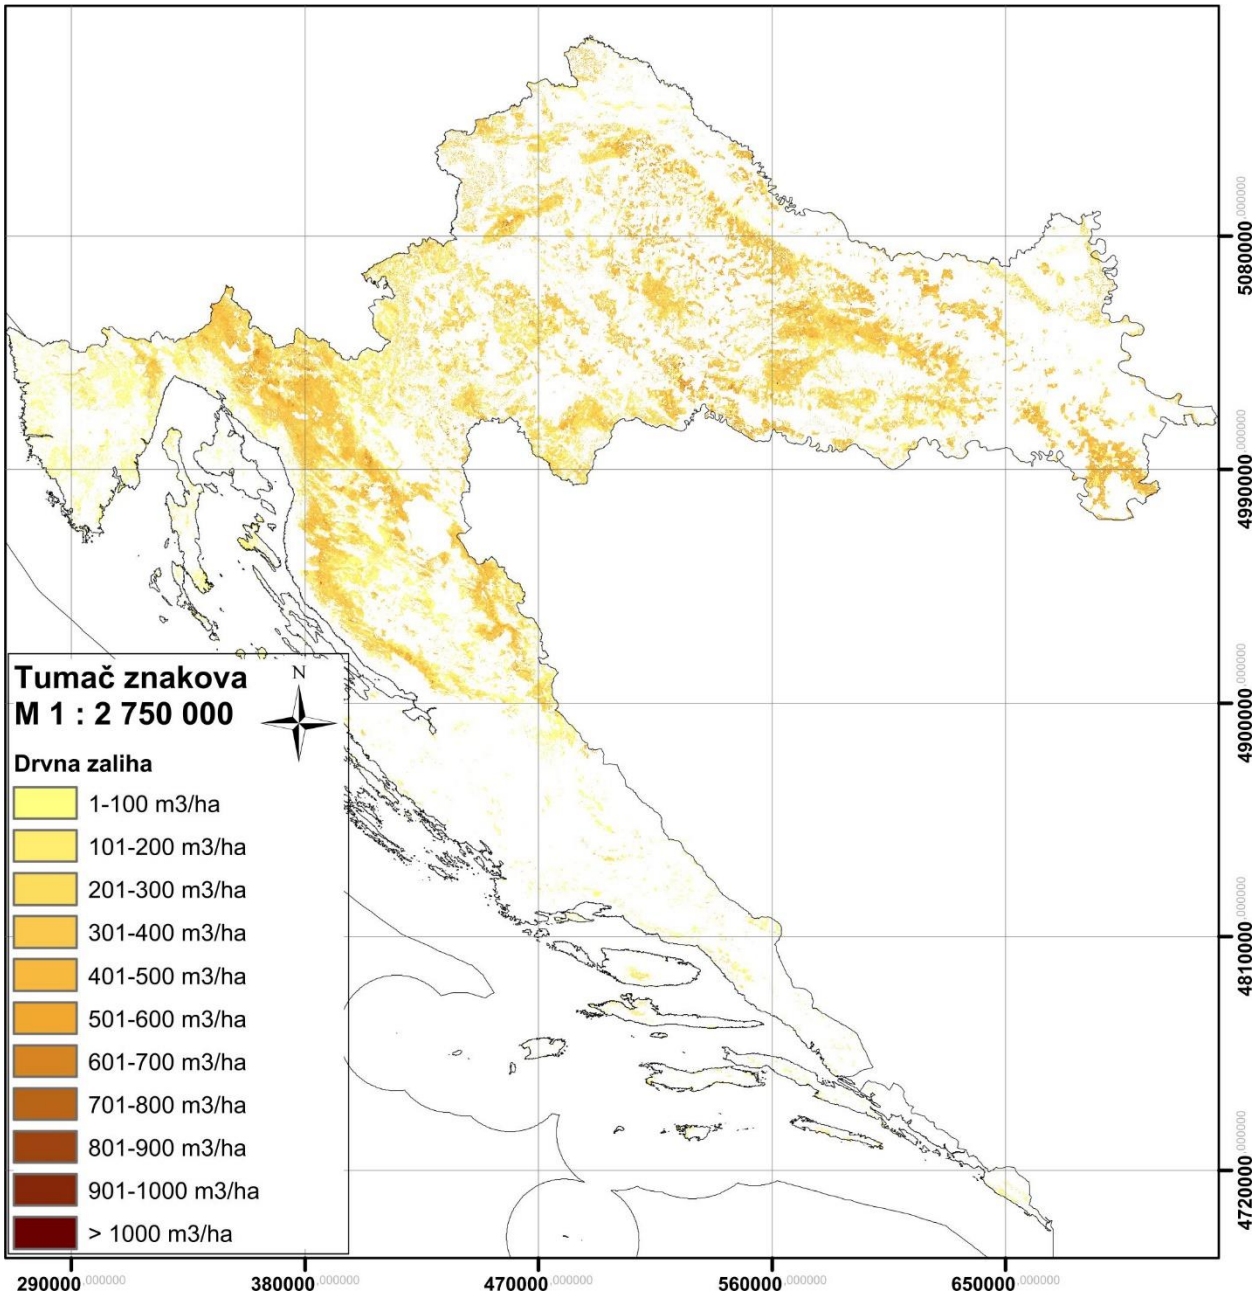

Slika 2.8 Drvna zaliha istraživanog područja

Treba napomenuti da drvna zaliha iznad 700 m^3/ha najčešće pripada površinama kao što su šumski sjemenski objekti, posebni rezervati unutar gospodarskih šuma te zaštitna zemljišta. Površine tih područja sa visokom drvnom zalihom se u prosjeku kreću oko 2,49 ha dok je najveća površina tek 17,50 ha.

Najveći dio šuma (97 %) sadrži drvnu zalihu od 1 do 500 m^3/ha koja je relativno ravnomjerno raspoređena u prvih 5 razreda.

Analiza je provedena temeljem pretvorbe vektorskih podataka u rasterske korištenjem *Conversion Tools → To Raster → Polygon to Raster* te *Spatial Analyst Tools → Reclass* naredbi.

2.3.8 Srednja udaljenost privlačenja drva

Srednja udaljenost privlačenja drva (s_d) iskazana (slika 2.9) je na temelju geometrijske (euklidske) udaljenosti šumskih površina do prve najbliže primarne prometne infrastrukture. Analiza je provedena alatima *Spatial Analyst Tools → Distance → Euclidean Distance* te alatima *Spatial Analyst Tools → Reclass* kako bi se dobilo šest razreda srednje udaljenosti privlačenja drva sa intervalom od 200 m.

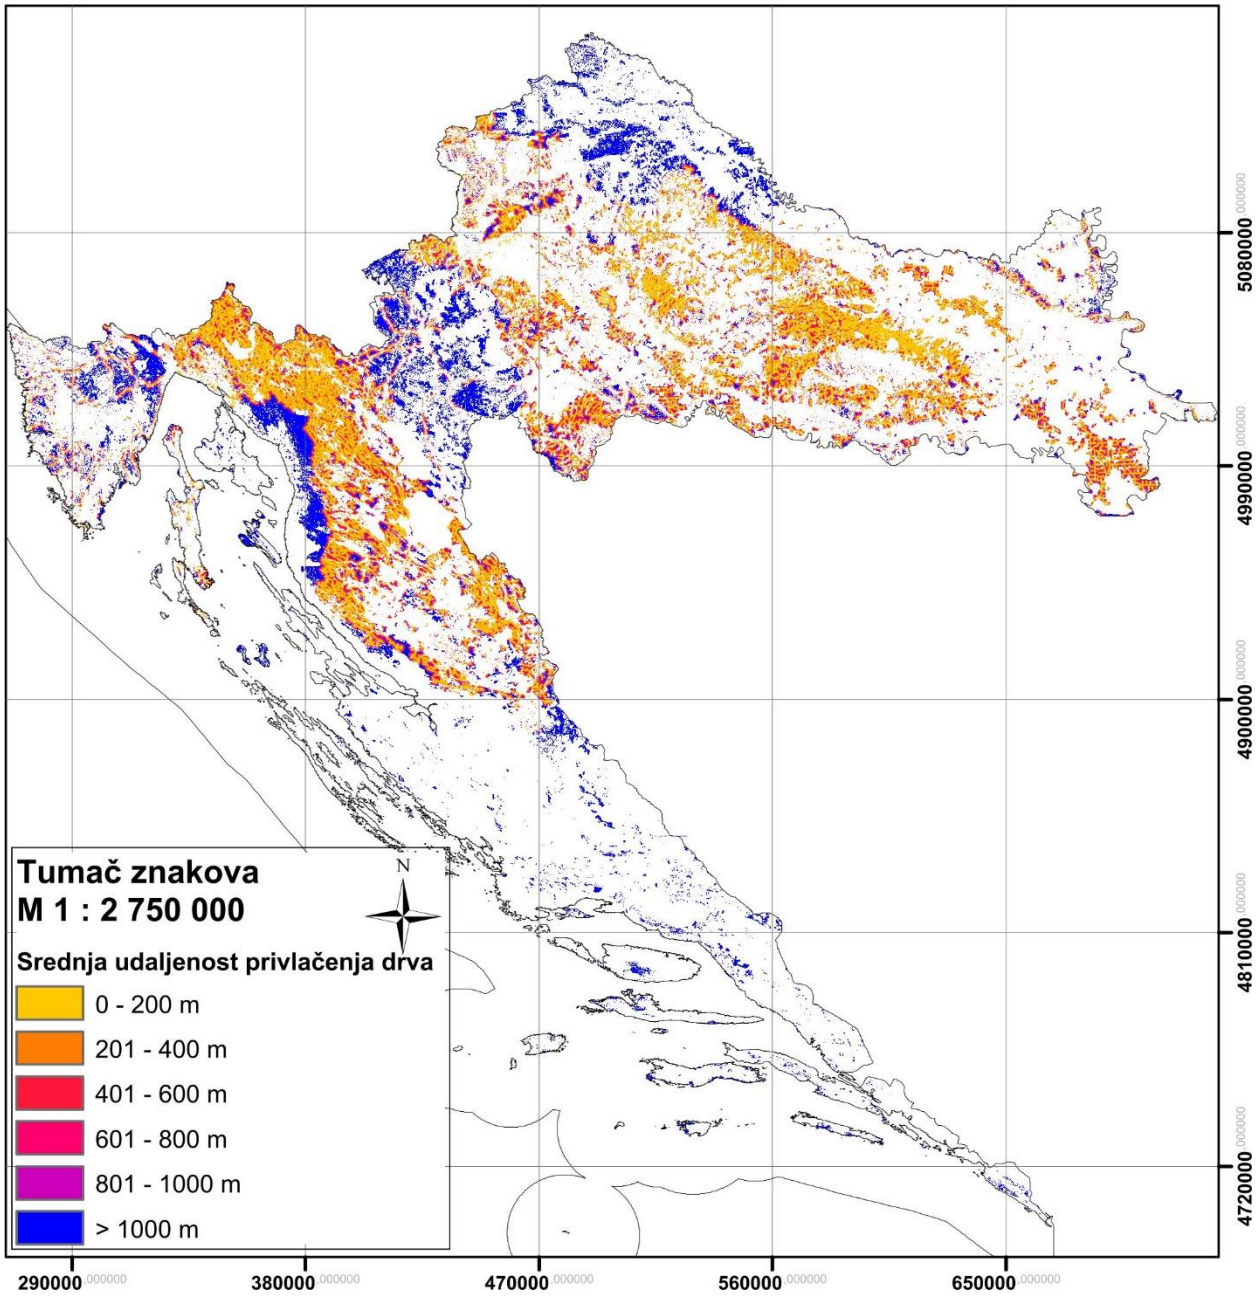

Slika 2.9 Srednja udaljenost privlačenja drva na istraživanome području

Udjeli površina pojedinog razreda srednje udaljenosti privlačenja drva iznose:

1. s_d = 0 – 200 m pripada 30,38 % površine šuma,
2. s_d = 201 – 400 m pripada 20,64 % površine šuma
3. s_d = 401 – 600 m pripada 12,06 % površine šuma
4. s_d = 601 – 800 m pripada 6,86 % površine šuma
5. s_d = 801 – 1000 m pripada 4,12 % površine šuma
6. s_d > 1000 m pripada 25,94 % površine šuma.

Posebno valja napomenuti da polučene rezultate analiza srednje geomerijske udaljenosti privlačenja drva treba uzimati sa rezervom jer u korištenoj bazi prostornih podataka primarne prometne šumske infrastrukture nedostaju podatci vezani za područja Uprava šuma podružnica Buzet, Senj, Split, Karlovac i Koprivnica.

2.4 Definiranje reljefnih područja temeljem provedene analize

Reljefna područja su određena na temelju prostornog rasporeda 10 navedenih bioklimata te su za svaki pojedini bioklimat analizirani podaci o nagibu terena, indeksu neravnosti terena, stjenovitosti tla, načinima vlaženja tla, stvarnoj opasnosti od erozije tla vodom, drvnoj zalihi te srednjoj udaljenosti privlačenja drva.

2.4.1 Bioklimat A Pretplaninske šume klekovine

Bioklimat Pretplaninske šume klekovine pridolazi na 167,4 ha površine (slika 2.10). Javljaju se četiri razreda drvne zalihe od čega je najzastupljeniji razred od 101 – 200 m^3/ha na 37,42 % površine, idući po zastupljenosti jest razred od 301 – 400 m^3/ha na 27,12 % površine.

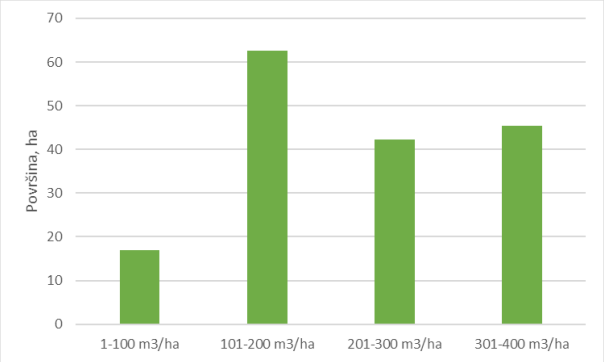

Slika 2.10 Razredi drvne zalihe bioklimata A po površini

Način vlaženja tla je u potpunosti (100 % površine) automorfni što znači da nema pojave poplavnih i slivnih voda na tome području.

Indeks neravnosti terena (slika 2.11) pokazuje da je na 61,42 % površine teren djelomično neravan, dok treći i peti razred TRI-a zajedno zauzimaju 35,98 % šumske površine. Površine sa najvišim udjelom drvne zalihe (301 –400 m^3/ha) u iznosu od 89,82 % pridolaze na djelomično ravnome i djelomično neravnome terenu.

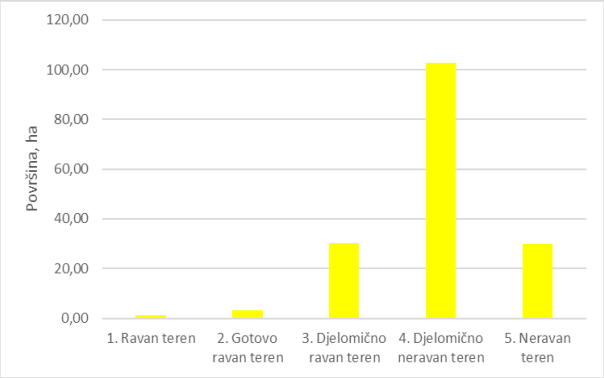

Slika 2.11 Indeks neravnosti terena po površini bioklimata A

Stjenovitost tla je iskazana u tri razreda: 1) 11 – 25 % udjela stjenovitosti tla pridolazi na 24,04 % površine, 2) 26 – 50 % udjela stjenovitosti tla je na 65,78 % površine, dok je 3) 51 – 90 % udjela stjenovitosti na 10,17 % površine bioklimata.

Analiza nagiba terena (slika 2.12) pokazuje da je 67,23 % ovoga bioklimata na terenima sa nagibom iznad 34 % na kojemu se ujedno može i naći najveći dio drvne zalihe.

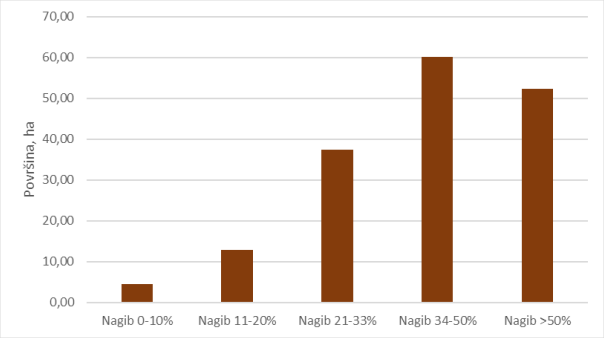

Slika 2.12 Nagibi terena po površini bioklimata A

Šume ovog bioklimata su većinskim dijelom (na 72,63 % površine) na terenima sa umjerenim stvarnim rizikom od erozije tla vodom, dok je 24,92 % terena sa visokim rizikom od erozije tla vodom.

Srednja udaljenost privlačenja drva na području ovog bioklimata je u prosjeku od 677 m sa standardnom devijacijom od 311 m. Analiza srednje udaljenosti privlačenja drva (slika 2.13) pokazala je da na najvećem dijelu površine (57,57 %) šuma bioklimata A, vozila privlače drvo na udaljenostima većim od 600 m. Najveći udio drvne zalihe bioklimata, odnosno na 53,86 % površine sa drvnom zalihom 301 – 400 t m^3/ha te 401 – 500 m^3/ha također zahtijeva udaljenosti privlačenja drva iznad 600 m.

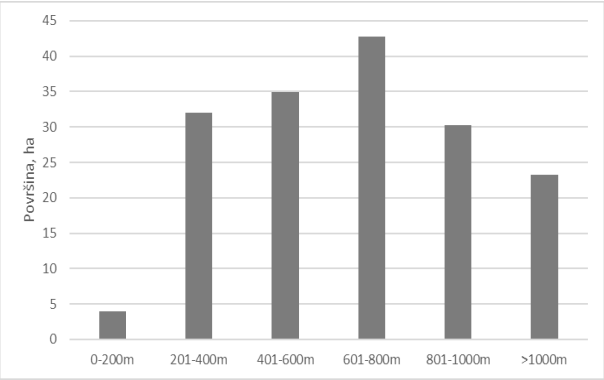

Slika 2.13 Srednja udaljenost privlačenja drva po površini bioklimata A

2.4.2 Bioklimat B pretplaninske bukove i smrekove šume

Bioklimat se razvija ne nadmorskim visinama iznad 1200(1500) m umjereno hladne klime s prosječnom godišnjom temperaturom oko 3,5 °C (Vukelić i dr. 2008). Autori nadalje navode da su ove šume u prvome redu značajne zbog zaštitne uloge odnosno sprječavanja erozije, tla te ublažavanja klimatskih ekstrema kao i očuvanja staništa divljih biljnih i životinjskih vrsta.

Bioklimat Pretplaninske bukove i smrekove šume pridolazi na 34.232,33 ha površine (slika 2.14). Najveći udio po površini vidljiv je u razredu drvne zalihe od 201 do 300 m^3/ha sa 42,88 % dok ga slijedi razred 301 do 400 m^3/ha na 33,69% površine. Viši razredi drvne zalihe od prethodno navedenih pridolaze na tek 6,06 % površine.

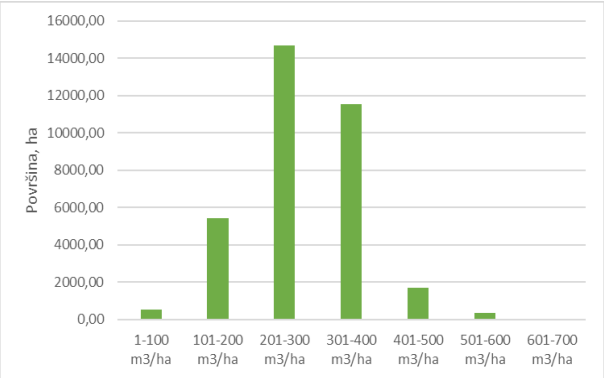

Slika 2.14 Razredi drvne zalihe bioklimata B po površini

Način vlaženja tla je kao i kod prethodnog bioklimata A u potpunosti automorfni što znači da nema pojave poplavnih i slivnih voda na tome području.

Analiza indeksa neravnosti terena je pokazala da se 56,06 % površine nalazi na djelomično neravnome terenu, a da ravan i gotovo ravan teren zauzimaju tek 7,46 % površine ovih šuma. Dok površinski najbrojniji razredi drvne zalihe (od 201 do 400 m^3/ha) u iznosu od 69,73 % površine pridolaze na djelomično neravnome, neravnome i vrlo neravnome terenu.

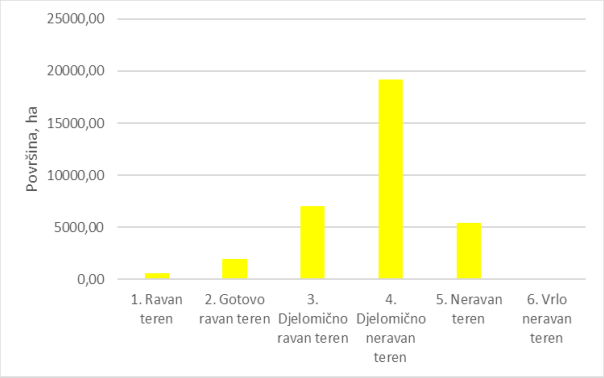

Slika 2.15 Indeks neravnosti terena po površini bioklimata B

Analiza stjenovitosti tla (slika 2.16) pokazala je prisustvo čak pet razreda ovog pokazatelja. Najveći udio površine šuma (72,88 %) sadrži više od 51 % stjenovitosti tla dok je stjenovitost od 0 do 25 % na tek 9,76 % šumskih površina. Najveće površine ovog bioklimata, one sa drvnom zalihom od 201 do 400 m^3/ha na 72,60 % površine također sadrže najnepovoljniji razred stjenovitosti tla, onaj sa udjelima od 51 – 90 % stijena i kamenja.

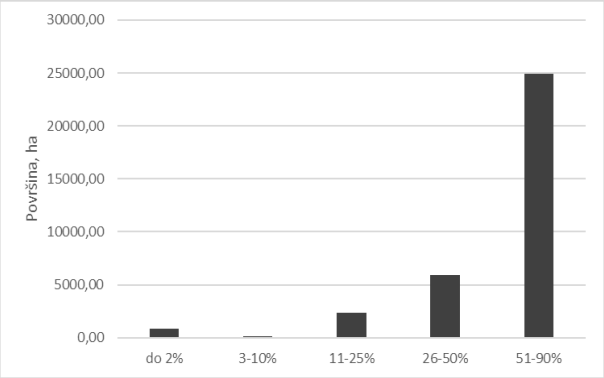

Slika 2.16. Razredi stjenovitosti tla po površini bioklimata B

Analiza nagiba terena (slika 2.17), kao i analiza stjenovitosti terena, pokazuje da se radi o zahtjevnijim terenima sa gledišta pridobivanja drva i otvaranja šuma jer se 60,91 % površine nalazi na nagibima većim od 34 %, odnosno 27,13 % površine je na nagibu terena iznad 50 %. Najveće površine ovog bioklimata, one sa zalihom od 200 do 400 m^3/ha u najvećoj mjeri (58,43 % površine) pridolaze na nagibima terena iznad 34 %.

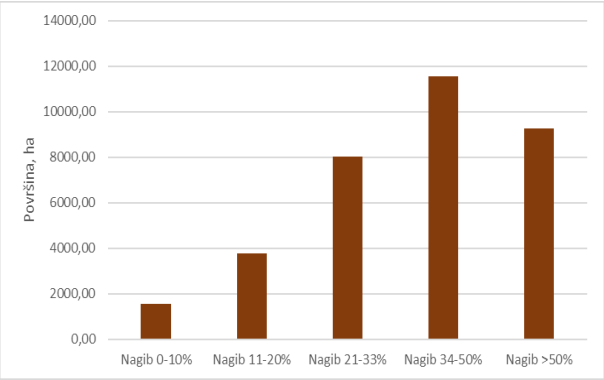

Slika 2.17 Nagibi terena po površini bioklimata B

Prevladava umjereni stvarni rizik od erozije tla vodom na 78,21 % površine ovih šuma, dok je nizak rizik na 19,47 % površine. Najveće površine bioklimata B sa zalihom od 200 do 400 m^3/ha su na 77,95 % svoje površine pod umjerenim stvarnim rizikom od erozije tla, dok je visoki rizik od erozije na tek 1,40 % površine.

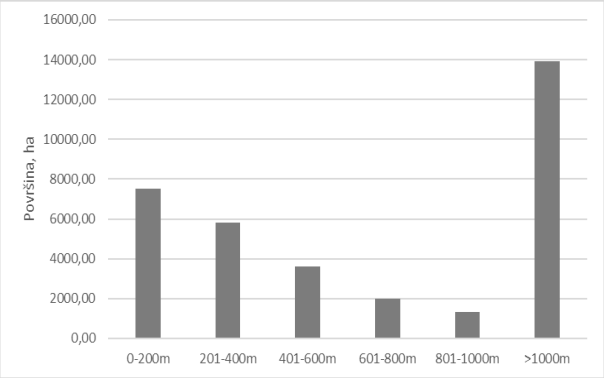

Slika 2.18 Srednja udaljenost privlačenja drva po površini bioklimata B

Srednja udaljenost privlačenja drva na području ovog bioklimata je u prosjeku od 522 m sa standardnom devijacijom od 3495 m. Na 40,72 % površine srednja udaljenost privlačenja drva je preko 1 km, dok se na 38,95 % površine vozila kreću do najvećih 400 m udaljenosti. Najviše drvne zalihe po površini će se primarno transportirati na udaljenostima do 600 m i to u iznosu od 53,16%.

2.4.3 Bioklimat C jelove, bukovo-jelove te smrekove šume

Bioklimat pridolazi na visinama od 600 do 1100 m nadmorske visine dok se panonske bukovo-jelove šume na sjevernim ekspozcijama spuštaju i do 300 m, na primjer na Medvednici (Vukelić i dr. 2008). Autori navode da je prosječna srednja godišnja temperatura od 6 – 9 °C, te da su to šume prirodnog sastava u kojima se gospodari preborno. Bioklimat jelove, bukovo-jelove te smrekove šume pridolazi na 185.762,25 ha površine (slika 2.19). Najveći udio drvne zalihe, 43,65 % pripada razredu od 301 – 400 m^3/ha, dok razredi iznad 601 m^3/ha pridolaze na tek 0,74 % površine ovih šuma.

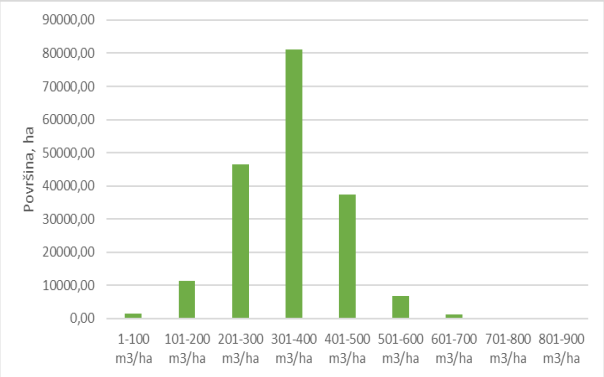

Slika 2.19 Razredi drvne zalihe bioklimata C po površini

Način vlaženja tla je na 99,88 % površine automorfni dok je preostalih 0,12 % površine tla raspoređeno između aluvijalnog, amfiglejnog, epigejnog i pseudoglejnog načina vlaženja tla.

Analiza indeksa neravnosti terena (slika 2.20) pokazuje da je 38,78 % površine na djelomično ravnome terenu. Najzastupljeniji razred drvne zalihe (301 – 400 m^3/ha) u iznosu od 66,92 % pridolazi na djelomično ravnome te djelomično neravnome terenu.

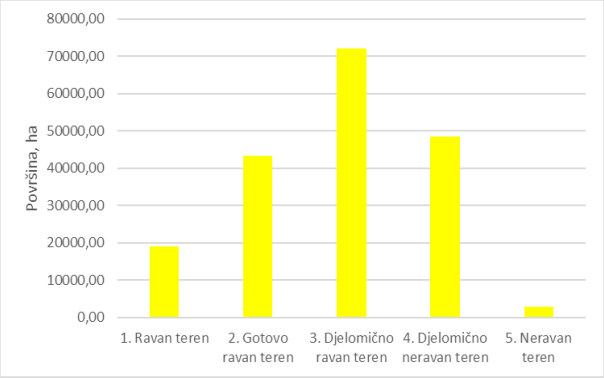

Slika 2.20 Indeks neravnosti terena po površini bioklimata C

Vidljiva je izražena stjenovitost tla (slika 2.21) na više od pola površine ovih šuma (56,82 %) u kojima je prekrivenost tla stijenama ili kamenjem od 51 do 90 % površine tla. Najrašireniji razredi drvne zalihe ovog bioklimata također sadrže izraženu stjenovitost tla. Tako je na 55,68 % površine razreda drvne zalihe od 201 – 300 m^3/ha koji je na 25,00 % površine ovog bioklimata stjenovitost izražena zadnjim najnepovoljnijim razredom sa gledišta izvođenja radova pridobivanja drva te otvaranja šuma, od 50 do 90 % površine. Prostorno najrašireniji razred drvne zalihe (301 – 400 m^3/ha) koji zauzima 43,65 % površine na više od pola svoje površine (62,29 %) također sadrži najnepovoljniji razred stjenovitosti. Treći površinski najzastupljeniji razred drvne zalihe (401 – 500 m^3/ha) na više od polovice svoje površine (55,79 %) također sadrži najviši razred stjenovitosti tla. Takvi uvjeti staništa zajedno sa analiziranim indeksom neravnosti terena te nagibom terena svakako utječu na radove planiranja pridobivanja drva te otvaranja šuma.

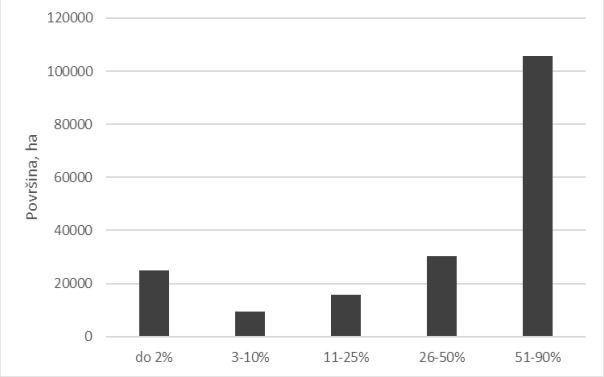

Slika 2.21 Razredi stjenovitosti tla po površini bioklimata C

Analiza nagiba terena pokazala je pomaknutu krivulju više u lijevo, gdje je najveći udio površine ovog bioklimata (30,58 %) na nagibima od 21 – 33 % za razliku od bioklimata A i B, ipak idući površinom najzastupljeniji razred nagiba je onaj od 34 do 50 % sa udjelom površine od 26,30 %. Nagibi terena iznad 21 % zauzimaju 67,75 % šuma ovoga bioklimata.

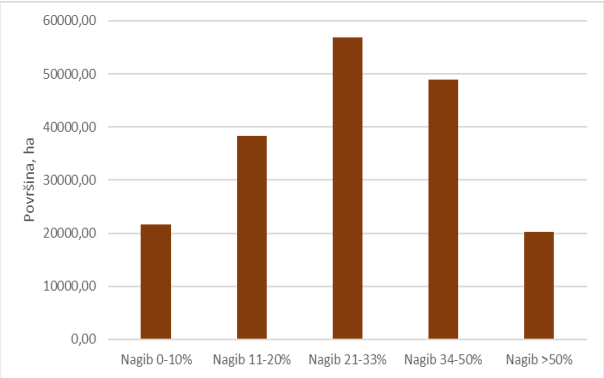

Slika 2.22 Nagibi terena po površini bioklimata C

Stvaran rizik od erozije tla je na 69,78 % površine umjerenog karaktera, dok je nizak rizik od erozije tla na 28,20 % površine ovih šuma.

Srednja udaljenost privlačenja drva na području bioklimata C u prosjeku je od 257 m sa standardnom devijacijom od 287 m. Analiza srednje udaljenosti privlačenja drva (slika 2.23) pokazuje povoljniju situaciju otvorenosti šuma ovih područja gdje je na 51,20 % površine srednja udaljenost privlačenja drva do 200 m, a udaljenosti iznad 600 m zauzimaju 13,87 % površine ovoga bioklimata. Najrašireniji razredi drvne zalihe ovog bioklimata također pokazuju ovakav trend. Tako se u šumama sa drvnom zalihom od 201 – 300 m^3/ha koje zauzimaju 25,00% ovoga bioklimata na 47,88 % površine drvo privlači na udaljenosti do 200 m. U površinski najzastupljenijem razredu drvne zalihe od 301 – 400 m^3/ha, na 52,09 % površine drvo se privlači na udaljenostima do 200 m te u slijedećem površinskim najzastupljenijem razredu drvne zalihe (401 – 500 m^3/ha) se na 54,34 % površine drvo privlači na udaljenostima do 200 m. Ipak, kod ovakvih zaključaka u obzir treba uzeti i činjenicu da se kod analize geometrijske srednje udaljenosti privlačenja ona zasniva na 1) dvo-dimenzijskom modelu ravnog terena sa niskim indeksom neravnosti, 2) pravocrtnome pružanju jednoliko raspoređenih paralelnih cesta na jednakom međusobnom razmaku bez izražene stjenovitosti tla koja dovodi do zaobilaženje prepreka tijekom kretanja vozila te 3) jednolikome rasporedu posječenoga drva u prostoru koje se privlači najkraćim putem na najbližu cestu.

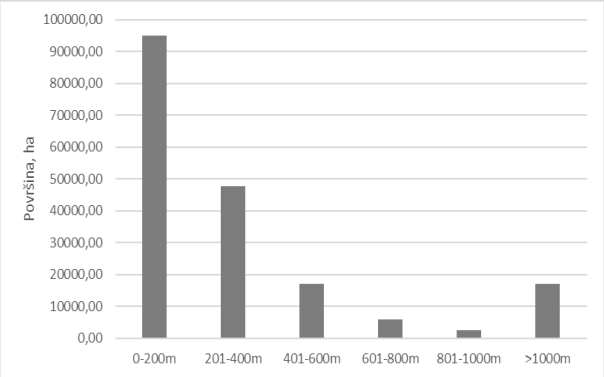

Slika 2.23 Srednja udaljenost privlačenja drva po površini bioklimata C

2.4.4 Bioklimat D brdske bukove šume

Brdske bukove šume javljaju se najčešće na nadmorskim visinama od 300 do 800 m dok je srednja godišnja temperatura najčešće oko 9 °C (Vukelić i dr. 2008). Autori navode da se radi i o visokim stabilnim šumama, ali i o panjačama na strmim terenima zaštitnog karaktera.

Bioklimat brdske bukove šume pridolazi na 331.099,27 ha istraživanog područja (slika 2.24). Površinski su najzastupljeniji razredi od 101 – 400 m^3/ha drvne zalihe koji zajedno zauzimaju 81,57 % površine ovih šuma. Zabilježeni su i podaci o pojavnosti razreda drvne zalihe od 701 pa sve i preko 1000 m^3/ha, ali samo u udjelu 0,02 % ukupne površine.

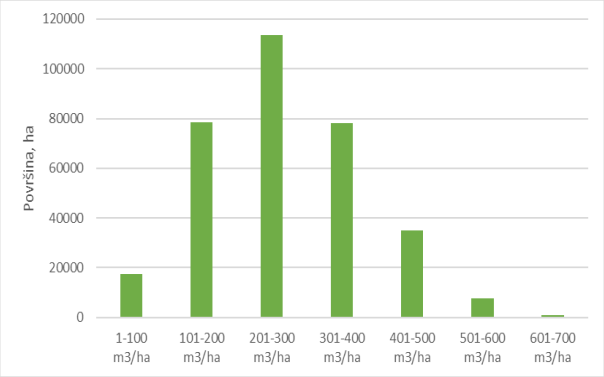

Slika 2.24 Razredi drvne zalihe bioklimata D po površini

Dominanti način vlaženja tla je na 94,54 % površine ovih šumskih zajednica automorfni, dok je idući najzastupljeniji (5,26 % površine) pseudoglejni način vlaženja tla odnosno pojavnost stagnirajućih oborinskih i podzemnih voda.

Analiza indeksa neravnosti terena pokazuje promjenu konfiguracije terena s obzirom na bioklimate A, B i C. U brdskim bukovim šumama dominantni indeks neravnosti terena je upravo ravan teren sa udjelom od 40,52 % u ukupnoj površini što znači da nema naglih promjena smjera nagiba kao kod prijašnjih šumskih zajednica. Ipak, na 22,73 % površine teren je djelomično ravan dok su razredi od 4 do 6 zastupljeni na 8,23 % brdskih bukovih šuma.

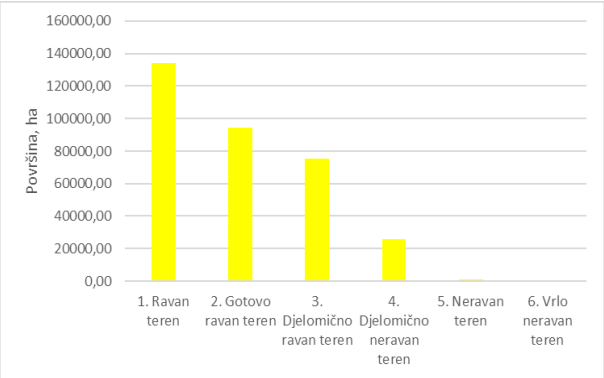

Slika 2.25 Indeks neravnosti terena po površini bioklimata D

Površinski najrašireniji razredi drvne zalihe, oni od 101 – 400 m^3/ha na više od 90 % svoje površine u približnim omjerima sadrže ravan, gotovo ravan i djelomično ravan indeks neravnosti terena (tablica 2.12) što ipak ukazuje na prisutnu varijabilnost smjera pružanja nagiba na ovome području.

Tablica 2.12 Učešće indeksa neravnosti terena na dijelu brdskih bukovih šuma

Razred drvne zalihe, m³/ha	Udio površine TRI, %		
	Ravan teren	Gotovo ravan teren	Djelomično ravan teren
101 – 200	38,17	30,66	23,50
201 – 300	36,80	30,36	23,95
301 – 400	39,58	27,27	23,84

Analiza stjenovitosti je pokazala da iako na 62,39 % površine brdskih bukovih šuma, udio stijena i kamenja je tek ispod 2 % površine, ipak na 16,99 % ovih šuma stjenovitost je vrlo izražena sa udjelima preko 51 % po površini. Takva raznolikost uvjeta će svakako utjecati i na organizaciju radova pridobivanja drva, ali i na uvjete gradnje primarne i sekundarne mreže šumskih prometnica, njihov prostorni raspored te izgled mreže prometnica.

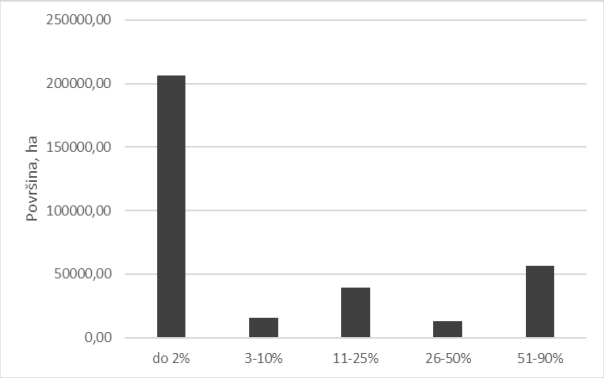

Slika 2.26 Razredi stjenovitosti tla po površini bioklimata D

Analiza nagiba terena (slika 2.27) pokazuje da na području brdskih bukovih šuma dominiraju tri razreda nagiba od 11 do 50 %. Nagibi terena od 34 % pa sve do preko 50 % zauzimaju 36,68 % ovih šuma, što će svakako iskazati svoj utjecaj na odabir sustava pridobivanja drva, posebno kada se u obzir uzme i stjenovitost tla te indeks neravnosti terena.

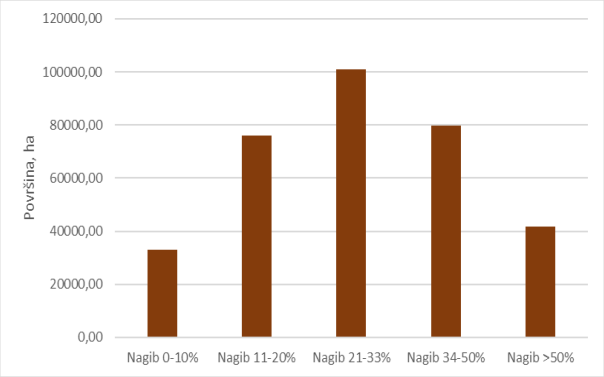

Slika 2.27 Razredi nagiba terena po površini bioklimata D

Površinski najrašireniji razredi drvne zalihe (tablica 2.13) brdskih bukovih šuma sadrže u sličnim omjerima gotovo četiri razreda nagiba terena što također ukazuje na varijabilnost nagiba terena ovih područja.

Tablica 2.13 Učešće razreda nagiba terena na dijelu brdskih bukovih šuma

Razred drvne zalihe, m³/ha	Udio površine nagiba, %			
	Blago nagnuti teren 11 – 20 %	Umjereno nagnuti teren 21 – 33 %	Strmi teren 34 – 50 %	Vrlo strmi teren > 50 %
101 – 200	22,42	30,02	23,59	12,99
201 – 300	20,82	30,89	26,06	13,14
301 – 400	22,61	30,40	25,04	13,34

Na 41,08 % površine brdskih bukovih šuma stvaran rizik od erozije je nizak, dok je na 54,29 % površine on umjeren, ipak na 15 325 ha brdskih bukovih šuma postoji visok stvaran rizik od erozije tla vodom što svakako treba uzeti u obzir prilikom planiranja radova pridobivanja drva.

Srednja udaljenost privlačenja drva na području ovog bioklimata u prosjeku iznosi od 413 m sa standardnom devijacijom od 410 m. Analiza srednje udaljenosti privlačenja drva pokazala je da se na 33,33 % površina brdskih bukovih šuma drvo privlači na udaljenostima do 200 m, ali i da se na 101 459 ha ono privlači na udaljenosti većoj od 600 m. Dok je na 23,15 % površine ovoga bioklimata udaljenost privlačenja drva preko 1 kilometra. Na 90 725 ha brdskih bukovih šuma sa drvnom zalihom od 101 – 400 m^3/ha srednja udaljenost privlačenja drva je od 600 m pa sve do preko 1000 m.

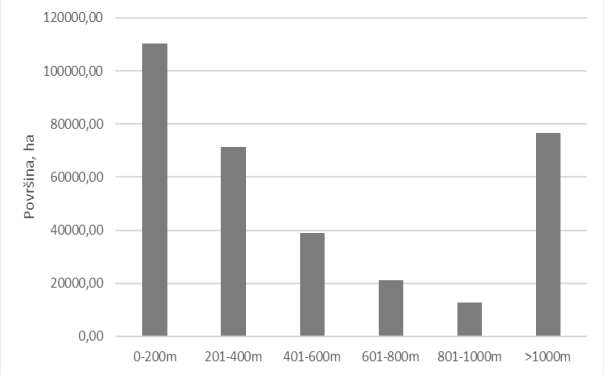

Slika 2.28 Srednja udaljenost privlačenja drva po površini bioklimata D

2.4.5 Bioklimat E brežuljkaste šume hrasta kitnjaka

Bioklimat E ovisno o zajednici pridolazi od 150 pa sve do 700 m nadmorske visine (Vukelić i dr. 2008). Autori navode da se radi i o panjačama (šuma hrasta kitnjaka i pitomog kestena), gospodarski i zaštitnim šumama na strmijim padinama (šuma hrasta kitnjaka s bekicom), šumama sa relativno sačuvanim prirodnim uvjetima te stablima izvrsne kakvoće koje su među najutjecajnijim u kontinentalnom dijelu Hrvatske (šuma hrasta kitnjaka i običnog graba), šumama koje pridolaze na toplijim lokalitetima, dok hladnije zauzima bukva (šuma hrasta kitnjaka i običnog graba s vlasuljom), ali i šikarama te panjačama mediteranske regije hladnije klime sa zaštitnom i općekorisnom funkcijom (šume medunca i crnog graba).

Bioklimat Brežuljkaste šume hrasta kitnjaka zauzima 311.679,18 ha površine. Na 64,81 % površine drvna zaliha je u iznosu od 101 – 300 m^3/ha. Zabilježeni su i podaci o drvnoj zalihi iznad 700 m^3/ha, ali na samo 50,11 ha površine ovoga bioklimata.

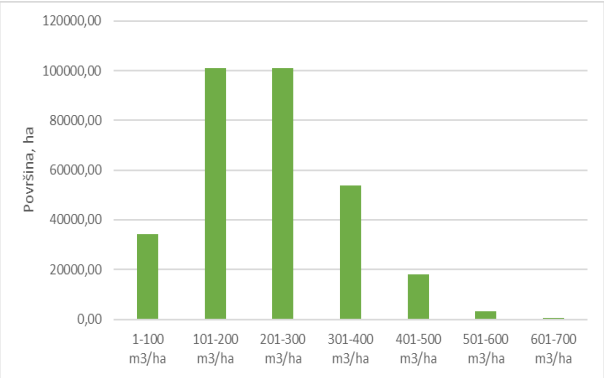

Slika 2.29 Razredi drvne zalihe bioklimata E po površini

Na 77,50 % površine vlaženje tla je automorfno, dok se na 22,07 % brežuljkastih kitnjakovih šuma vlaženje tla pseudoglejno što znači da postoji prisustvo stagnirajućih oborinski i podzemnih voda. Ostalih 0,42 % površine raspoređeno je po ostalim razredima vlaženja tla.

Analiza indeksa neravnosti terena pokazala je da na ovome području nema učestalih promjena smjera i iznosa nagiba terena te da se na 71,63 % površine radi o ravnome terenu.

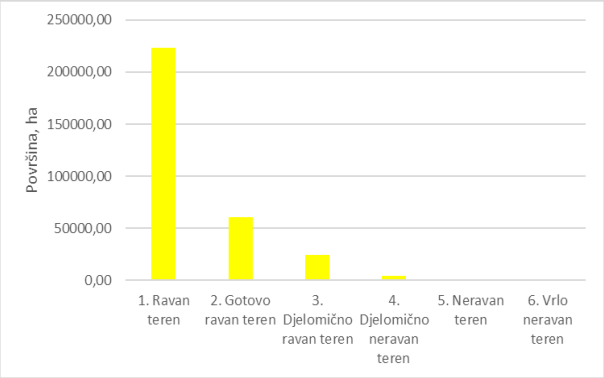

Slika 2.30 Indeks neravnosti terena po površini bioklimata E

Ipak, 3730,32 ha brežuljkastih kitnjakovih šuma javlja na djelomično neravnome do vrlo neravnome terenu što će svakako iskazati svoj utjecaj na planiranje radova pridobivanja drva.

Analiza stjenovitosti terena pokazuje da je na 74,58 % površine stjenovitost tla tek do 2 % udjela, ali i da je na 21 259,96 ha tlo vrlo stjenovito sa udjelom kamenja i stijena iznad 51 % površine. Sličan trend je vidljiv i u prostorno najraširenijim razredima drvne zalihe (od 101 do 300 m^3/ha) na čijih 2902,93 ha se stjenovitost javlja u udjelu od 26 – 50 % površine, a dok se na 11 543,32 ha njen udio povećava na iznad 51 % prekrivenosti tla.

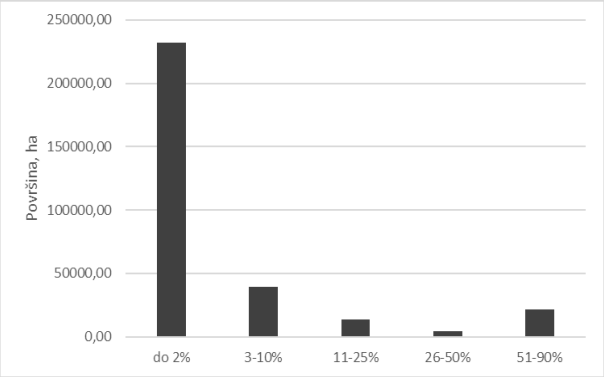

Slika 2.31 Razredi stjenovitosti tla po površini bioklimata E

Analiza nagiba terena pokazuje trend pomicanja podataka u lijevo za razliku od prijašnjih središnjih odnosno lijevih maksimuma bioklimata A, B, C i D. Tako se 33,05 % površine brežuljkastih kitnjakovih šuma nalazi na nagibima terena od 11 do 20 %, a već 29,29 % površine je na nagibima od 21 do 33 %. Ipak ove šume se nalaze i na nagibima strmijim od 34 % i to u iznosu od 64 448,41 ha.

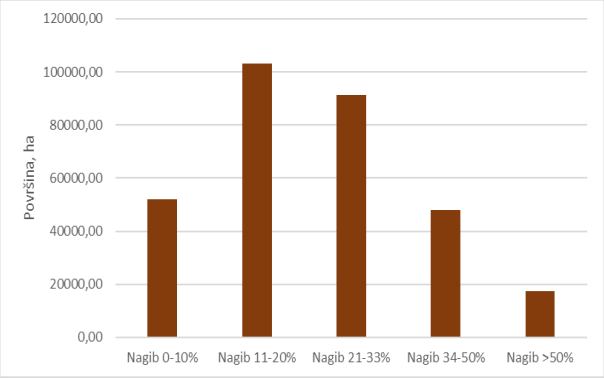

Slika 2.32 Razredi nagiba terena po površini bioklimata E

Na 53,73 % površine ovoga bioklimata stvaran rizik od erozije je nizak, ali na 39,82 % raste na umjerenu opasnost. Najmanji udio, ali u svakome slučaju ne zanemariv su 20 114,99 ha površine

kitnjakovih šuma brežuljkastog područja sa visokom opasnošću od erozije tla vodom, od čega na 15 983,40 ha površine je sadržana drvna zaliha od 101 – 500 m^3/ha.

Srednja udaljenost privlačenja drva na području kitnjakovih šuma u prosjeku iznosi 494 m sa standardnom devijacijom od 449 m. Srednja udaljenost privlačenja drva (slika 2.33) se na najvećem dijelu površine (51,44 %) kreće do 400 m, dok na 22,42 % ona premašuje i udaljenosti od 1 kilometra. Sličan trend je prisutan i kod dva površinski najraširenija razreda drvne zalihe (101 – 300 m^3/ha) gdje se na 47,14 % površine drvo privlači na udaljenosti do 400 m, na 14,01 % do udaljenosti do 600 m, a na 38,40 % površine preko 600 m udaljenosti.

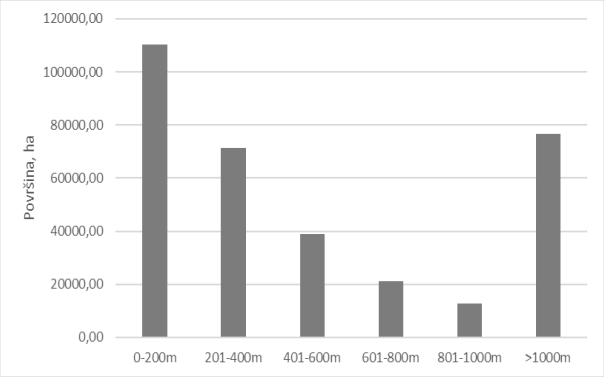

Slika 2.33 Srednja udaljenost privlačenja drva po površini bioklimata E

2.4.6 Bioklimat G nizinske šume hrasta lužnjaka i poplavne šume

Bioklimat G sadrži poplavne šume vrba i topola, poplavne šume hrasta lužnjaka, crne johe i poljskog jasena, ali i šume hrasta lužnjaka izvan dohvata poplava. Nizinske šume lužnjaka i poplavne šume pružaju se na 288.310,88 ha istraživanog područja. Drvna zaliha u razredima od 101 – 500 m^3/ha zauzima 84,23 % površine, a na 2011,95 ha je ona i iznad 700 m^3/ha.

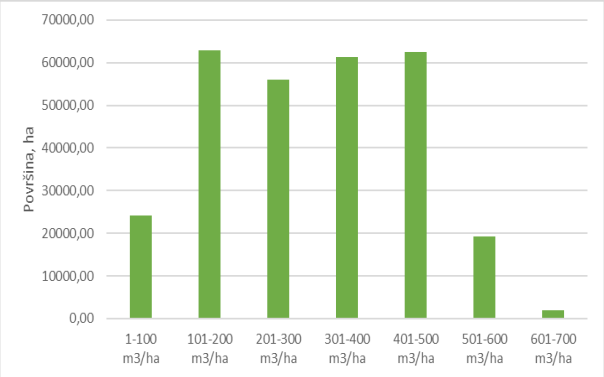

Slika 2.34 Razredi drvne zalihe bioklimata G po površini

Za razliku od prije opisanih bioklimata, u nizinskim šumama lužnjaka i poplavnim šumama najčešći načini vlaženja tla su amfiglejni (27,15 %) te pseudoglejni (26,70 %), dok aluvijalna, epiglejna, hipoglejna i semiglejna tla zajedno čine 29,61 % površine ovih šuma. Na 42,94 % površine akumulirano je najviše drvne zalihe ovoga bioklimata (od 301 – 500 m^3/ha) na tim površinama dominiraju amfiglejno (33,92 %) te pseudoglejno (26,16 %) vlaženje tla dok epiglejno, hipoglejno i semiglejno zajednop zauzimaju dodatnih 24,40 % površine šuma.

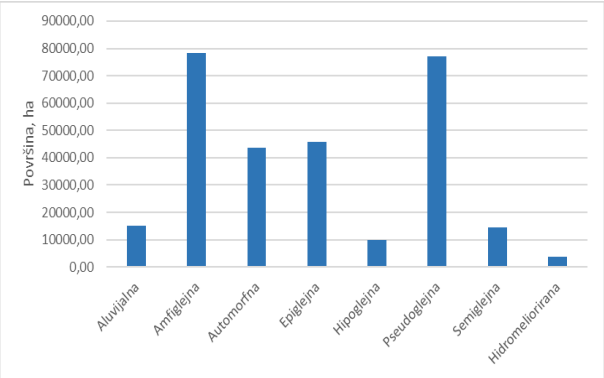

Slika 2.35 Razredi načina vlaženja tla kod bioklimata G

Pojavnost podzemnih, poplavnih, slivnih, oborinskih odnosno stagnirajućih voda na području nizinskih šuma hrasta lužnjaka te poplavnih šuma će značajno utjecati na vrijeme izvođenja radova i dodatno opremanje vozila (udvajanje osovine forvardera, postavljanje polugusjenica na bogi osovinu forvardera, korištenje širih guma na vozilima i slično).

Analiza neravnosti terena pokazala je da na očekivanih 99,48 % površine nema naglih i učestalih promjena smjera nagiba terena, pa indeks neravnosti terena opisuje ove terene kao ravne.

Analiza stjenovitosti bioklimata G pokazala je da je na 99,54 % površine prekrivenost terena stijenama i kamenjem do tek najmanjih 2 % što je i očekivano s obzirom da se radi o nizinskim šumama Hrvatske.

Analiza nagiba terena slijedi već prije navedene pokazatelje indeksa neravnosti terena i stjenovitosti terena, pa je tako na 92,84 % površine bioklimata G nagib terena do 10 %.

Stvaran rizik od erozije tla vodom je na većini površine (97,83 %) šuma hrasta lužnjaka te poplavnih šuma nizak.

Analiza srednje udaljenosti privlačenja drva na području nizinskih šuma u prosjeku iznosi 516 m sa standardnom devijacijom od 429 m. Na 52,98 % površine drvo se privlači do 400 m udaljenosti, a sličan trend se pokazuje i na površinama sa najviše drvne zalihe (301 – 500 m^3/ha) gdje je srednja udaljenost privlačenja drva do 400 m na 59,57 % površine.

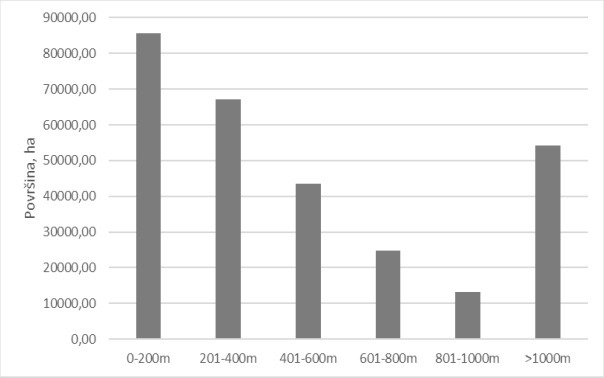

Slika 2.36 Srednja udaljenost privlačenja drva po površini bioklimata G

2.4.7 Bioklimat H submediteranske šume bukve i crnog bora

Šume bioklimata H obuhvaćaju termofilnu zajednicu bukve sa crnim grabom pretežno zaštitne funkcije zbog strmih nagiba te plitkoga tla, primorske bukove šume sa jesenskom šašikom na 650 – 900 m nadmorske visine koje predstavljaju granicu prema mediteranskoj fitogeografskoj regiji, reliktnu zajednicu crnog bora s pustenastom dunjaricom na 700 do 1200 m nadmorske visine te plitkim, skeletoidnim tlima te šume dalmatinskog crnog bora s klečicom (Vukelić i dr. 2008).

Submediteranske šume bukve i crnog bora pružaju se na 66.251,30 ha istraživanog područja, dok je 69,00 % ovih šuma sadrži drvnu zalihu od 101 – 300 m^3/ha (slika 2.37).

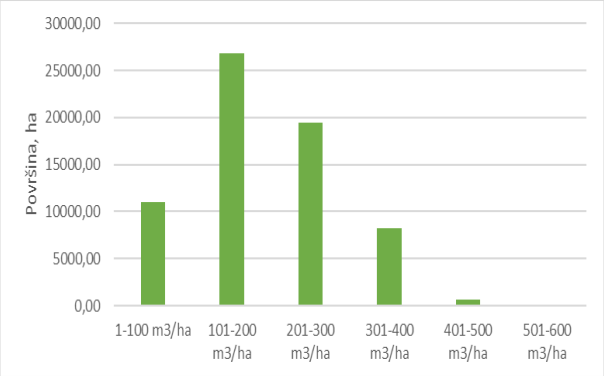

Slika 2.37 Razredi drvne zalihe bioklimata H po površini

Način vlaženja tla je na 99,91 % površine automorfni bez zadržavanja oborinskih voda.

Analiza indeksa neravnosti terena (slika 2.38) pokazala je heterogenost ovih površina. Iako se djelomično ravan teren može naći na 38,14 % površine ovih šuma, djelomično neravan, neravan i vrlo neravan teren zajedno zauzimaju 28,31 % površine bioklimata.

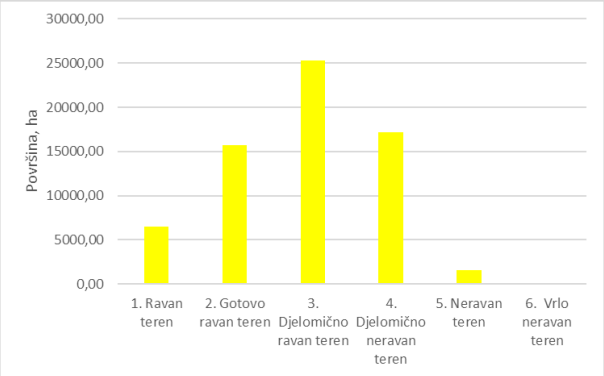

Slika 2.38 Indeks neravnosti terena po površini bioklimata H

Analiza stjenovitosti (slika 2.39) pokazala je da je većina (66,24 %) površina submediteranskih šuma bukve i crnog bora sadrži značaja udio stijena i kamenja po površini (od 51 do 90 %), dok su ostali razredi slabije zastupljeni. Ako se razmotri udio stjenovitosti po površinama sa ukupno najviše drvne zalihe (od 101 – 300 m^3/ha) jasan je sličan trend gdje je 66,13 % površine sa najvećim udjelom stjenovitosti (od 51 do 90 %), razred od 26 – 50 % stijena i kamenja je na 14,05 % površine dok su ostali razredi zastupljeni sa ukupno 19,82 % udjela.

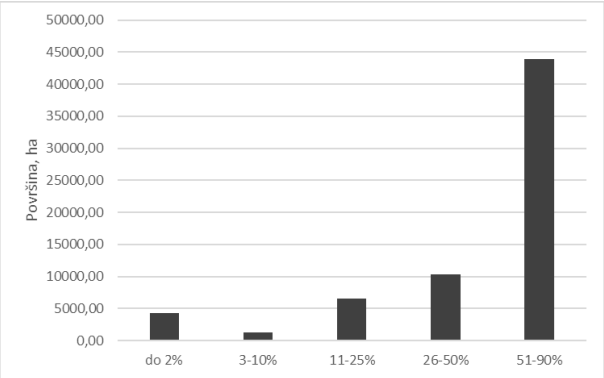

Slika 2.39 Razredi stjenovitosti tla po površini bioklimata H

Analiza nagiba terena (slika 2.40) pokazuje raznolikost ovih površina koja se već uočila i kod analize indeksa neravnosti terena. Dok je najzastupljeniji treći razred nagiba sa udjelom od 29,71 %, nagibi od 34 % na više zauzimaju 41,97 % površine ovih šuma.

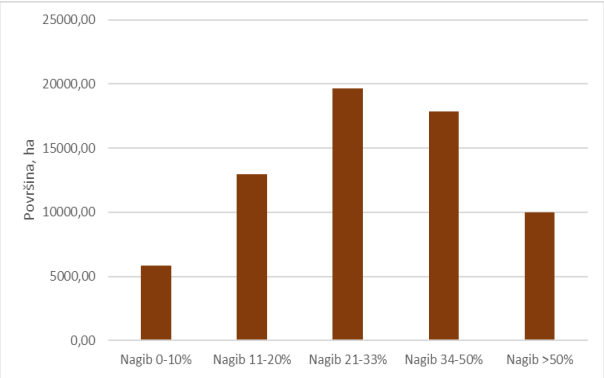

Slika 2.40 Razredi nagiba terena po površini bioklimata H

Analiza stvarnog rizika od erozije tla vodom na području bioklimata submediteranskih šuma bukve i crnog bora pokazala je da je na 24,02 % površine rizik nizak, na 65,82 % površine rizik je umjeren, a na 10,16 % rizik od erozije je visok. Ove podatke zajedno sa podacima o nagibu, indeksu neravnosti terena te udjelima drvne zalihe svakako treba uzeti u obzir prilikom radova pridobivanja drva u smislu zaštitnih zona te okolišne pogodnosti.

Analiza srednje udaljenosti privlačenja drva na području submenditernskih šuma bukve i crnog bora u prosjeku iznosi 560 m sa standardnom devijacijom od 490 m. Ove površine su slabije otvorene od većine prije opisanih bioklimata te 36,07 % površine zahtijeva privlačenje drva iznad 1 kilometra. Ako se usporedi srednja udaljenost privlačenja za prostornim rasporedom drvne zalihe bioklimata H, vidljivo je da se na 30,97 % površine drvo privlači na udaljenosti većoj od 1 kilometra, dok je na 54,80 % privlačenje drva do 600 m udaljenosti.

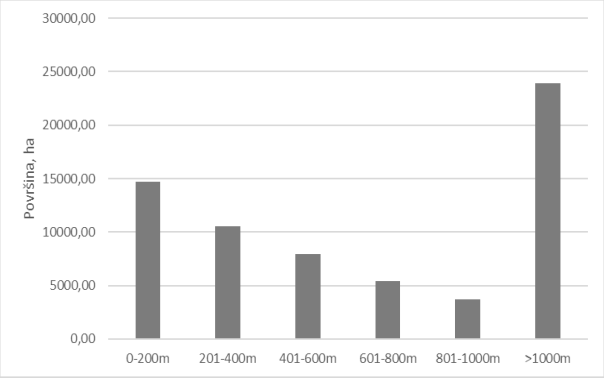

Slika 2.41 Srednja udaljenost privlačenja drva po površini bioklimata H

2.4.8 Bioklimat J submediteranske šume medunca i crnog graba

Šume bioklimata J obuhvaćaju mješovite šume medunca i crnoga graba – najčešće degradirane šume sa zaštitnom i općekorisnom funkcijom koje se ekstrazonalno javljaju i u SZ Hrvatskoj; šume duba i crnoga jasena na kraškim poljima i visini od 460 – 600 m u raznim degradacijskim stadijima; šume dalmatinskog crnog bora s resikom koje se rasprostiru na višim, svježijim i humidnijim položajima dalmatinskih otoka; termofilne šume jele i crnoga graba koje dolaze na vrtačastim platoima i visini od 700 do 1150 m te su najčešće zaštitnog karaktera i niskog uzgojnog oblika te šume hrasta medunca sa beskoljenkom (Vukelić i dr. 2008).

Bioklimat Submediteranske šume medunca i crnog graba zauzima 25.145,39 ha površine istraživanog područja. Za razliku od prijašnjih bioklimata, a temeljem analize drvne zalihe (slika 2.42) ovdje je vidljivo da se radi o većinom degradiranim šumskim površinama gdje je najveći udio drvne zalihe po površini (76,34 %) upravo u prvome razredu.

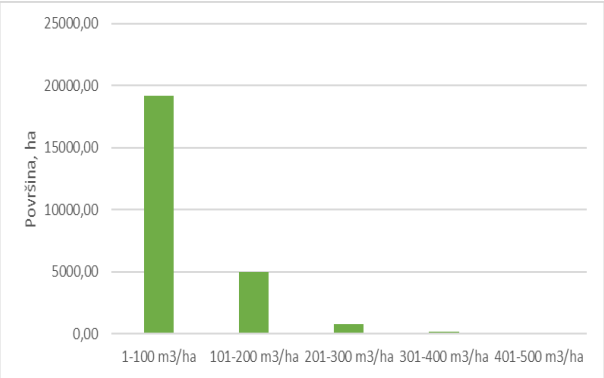

Slika 2.42 Razredi drvne zalihe po površini bioklimata J

Način vlaženja tla je na području submediteranskih šuma medunca i crnog graba očekivano pretežno (u 98,82 % slučajeva) automorfni što znači da nema utjecaja ni zadržavanja podzemnih, poplavnih, slivnih i stagnirajućih voda.

Analiza indeksa neravnosti terena (slika 2.43) pokazuje da se radi o nešto blažim terena sa gledišta promjena smjera i pružanja nagiba u usporedbi sa submediteranskim šumama bukve i crnog bora. Na ovim područjima u 64,99 % slučaja prevladavaju ravan i gotovo ravan teren, dok klase 4, 5 i 6 zauzimaju tek 2391,30 ha površine ovih šuma.

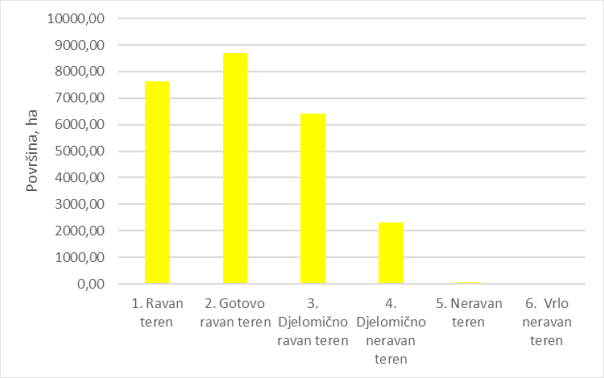

Slika 2.43 Indeks neravnosti terena po površini bioklimata J

Analiza stjenovitosti terena (slika 2.44) pokazala je da su površine najpovoljnijeg razreda 1 (do 2 % površine prekriveno stijenama i kamenjem) i najnepovoljnijeg razreda 5 (od 51 do 90 % površine prekriveno stijenama i kamenjem) vrlo slično zastupljeni odnosno sa 37,09 % te 40,18 % površine.

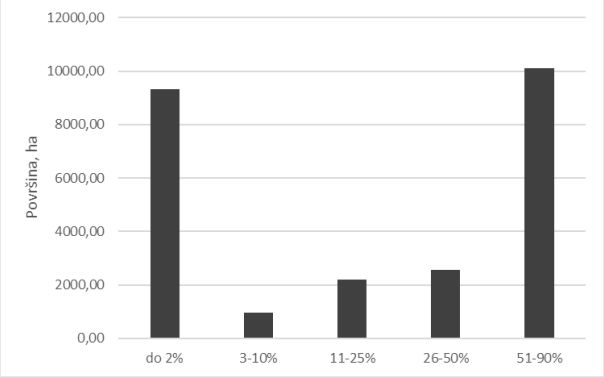

Slika 2.44 Razredi stjenovitosti tla po površini bioklimata J

Analiza nagiba terena (slika 2.45) pokazuje da se radi o heterogenim terenima, gdje je 40,20 % površine na nagibima iznad 34 %, a 31,50 % površine je do nagiba terena od 20%.

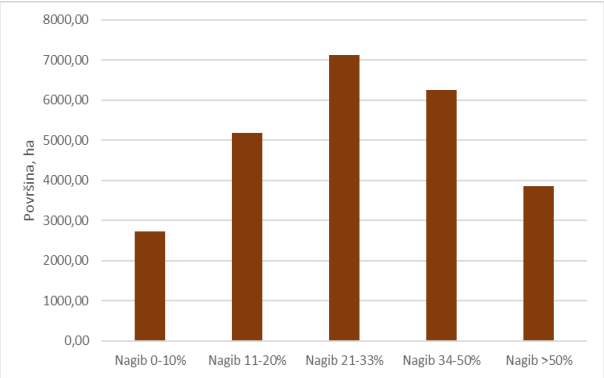

Slika 2.45 Razredi nagiba terena po površini bioklimata J

Stvaran rizik od erozije tla vodom na području submediteranskih šuma medunca i crnog graba je pretežno (64,35 % površine) umjeren, dok je na 19,47 % površina rizik visok. Ove podatke treba sagleda u kontekstu smanjene količine drvne zalihe te raznolikosti nagiba terena ovih šuma te načine i uvjete gospodarenja ovim šumama prilagoditi dobivenim podacima provedenih analiza.

Analiza srednje udaljenosti privlačenja drva na području submenditernskih šuma medunca i crnog graba u prosjeku iznosi 862 m sa standardnom devijacijom od 554 m. Analiza srednjih udaljenosti provlačenja drva (slika 2.46) pokazala je da se radi o slabije otvorenim površinama (u usporedbi sa prije opisanim bioklimatima) gdje se na 62,41 % površine drvo privlači na udaljenostima iznad 1 kilometra.

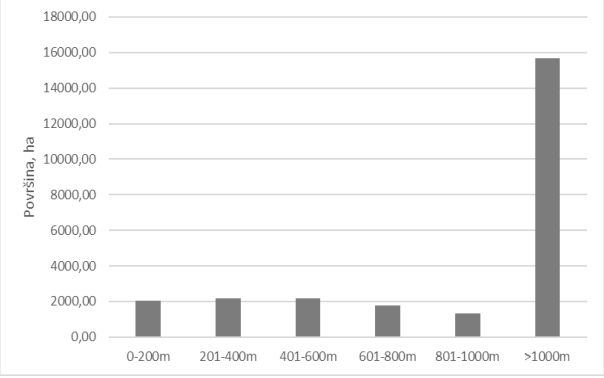

Slika 2.46 Srednja udaljenost privlačenja drva po površini bioklimata J

2.4.9 Bioklimat K submediteranske šume medunca i bijelog graba

Šume bioklimata K rijetko čine suvisle proizvodne šumske sastojine zbog višegodišnjeg antropogenog utjecaja no ipak veći dio tih sastojina nalazi se u progresiji (Vukelić i dr. 2008).

Bioklimat submediteranskih šuma medunca i bijelog graba pridolazi na 80 151,64 ha površine istraživanog područja. Kao i kod bioklimata H vidljiv je manji udio drvne zalihe koja je najvećim dijelom zastupljena u razredu od 1 do 100 m^3/ha na 76,99 % površine (slika 2.47). Razredi od 301 – 700 m^3/ha zajedno zauzimaju tek 381,24 ha površine ovoga bioklimata.

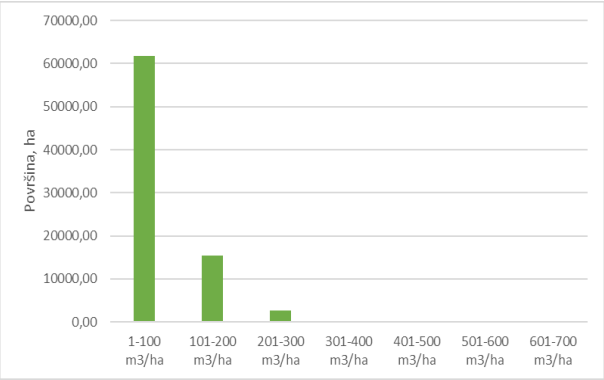

Slika 2.47 Razredi drvne zalihe po površini bioklimata K

Način vlaženja tla je očekivano automorfni gdje na 99,78 % površine neće biti utjecaja podzemnih, poplavnih, slivnih ili stagnirajućih oborinskih voda.

Analiza indeksa neravnosti terena (slika 2.48) pokazuje da se na 61,42 % površine submediternskih šuma medunca i bijelog graba radi o ravnome terenu dok zahtjevnije kategorije terena (od 4 do 6 razreda) 3840,41 ha površina ovih šuma.

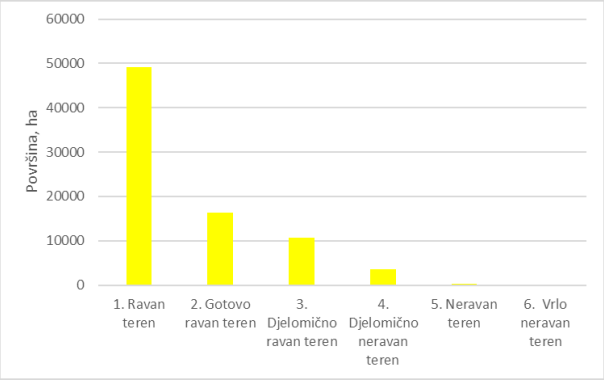

Slika 2.48 Indeks neravnosti terena po površini bioklimata K

Za razliku od šuma medunca i crnog graba, u šumama medunca i bijeloga graba vidljiv je veći udio stjenovitosti po površini (slika 2.49) što je i očekivano s obzirom da se radi o zajednicama na kršu. Tako na čak 66,35 % površine udio kamenja i stijena po površini tla kreće u omjeru od 51 do 90%.

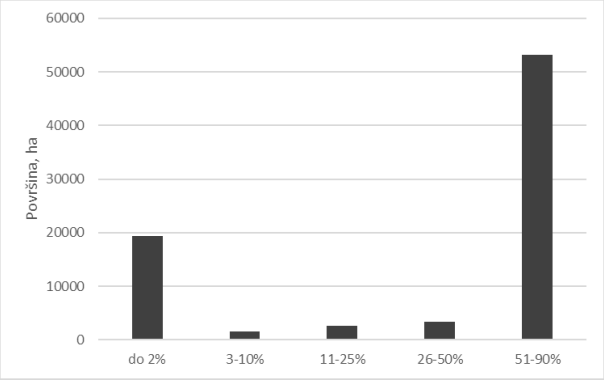

Slika 2.49 Razredi stjenovitosti tla po površini bioklimata K

Analiza nagiba terena (slika 2.50) pokazala je da se na 35,29 % površine radi o blažim nagibima terena do 10 %, ali ne treba ni zanemariti činjenicu da je 21,29 % površine na nagibima iznad 34 %. Slična situacija je i u površinski najzastupljenijem razredu drvne zalihe (od 1 do 100 m^3/ha) gdje se 23 948,47 ha površine nalazi na nagibima do 10 %, ali i 11624,74 ha na nagibima od 34 do preko 50 %.

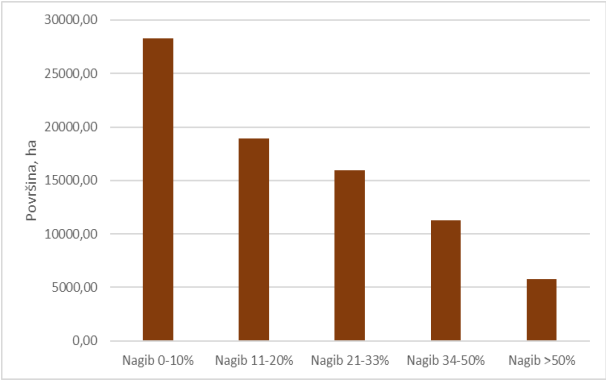

Slika 2.50 Razredi nagiba terena po površini bioklimata K

Analiza procjene stvarnog rizika od erozije tla vodom pokazala je da je na 46,32 % površina ovih šuma rizik od erozije nizak, dok je na 40,60 % površine on umjeren. Ipak ne treba zanemariti činjenicu da na 10 477,14 ha šuma medunca i bijeloga graba postoji visok rizik od erozije tla vodom.

Analiza srednje udaljenosti privlačenja drva na području submenditernskih šuma medunca i bijelog graba u prosjeku iznosi 705 m sa standardnom devijacijom od 526 m. Analiza (slika 2.51) je pokazala da su ovo većinom nedovoljno otvorene šume gdje se na 41,61 % površine drvo privlači na udaljenosti iznad 1 kilometra. Ipak na 34 519,64 ha najveća srednja udaljenost privlačenja je do 600 m.

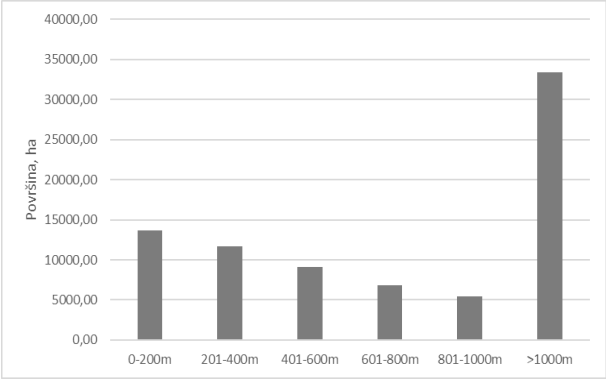

Slika 2.51 Srednja udaljenost privlačenja drva po površini bioklimata K

2.4.10 Bioklimat L mediteranske šume i makije alepskog bora i hrasta crnike

Šume bioklimata L su većinom degradirana staništa zbog antropogenog utjecaja te velike ugroženosti od požara (Vukelić i dr. 2008). Analiza bioklimata Mediteranskih šuma i makija alepskog bora i hrasta crnike pokazala je da se ovaj bioklimat rasprostire na 33072,48 ha površine. Površinski najzastupljeniji razred drvne zalihe, onaj najniži, može se naći na 64,20 % površine ovih šuma, dok drvne zalihe od 201 – 400 m^3/ha ima na tek 1250,42 ha površine.

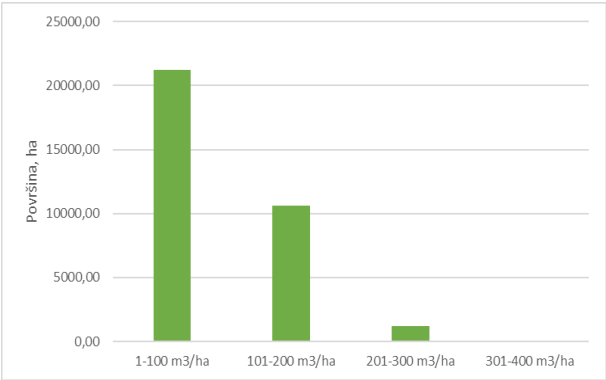

Slika 2.52 Razredi drvne zalihe po površini bioklimata L

Način vlaženja tla je na 98,38 % površine automorfni što znači da nema utjecaja podzemnih, poplavnih te stagnirajućih oborinskih voda na području ovih šuma.

Analiza indeksa neravnosti terena (slika 2.53) pokazala je da se na 88,73 % površine ovih šuma radi o ravnome terenu bez izraženih i čestih promjena smjera nagiba terena. Tereni sa razredima 4, 5 i 6 indeksa neravnosti terena zauzimaju tek 134,42 ha površine mediteranskih šuma i makija alepskog bora i hrasta crnike.

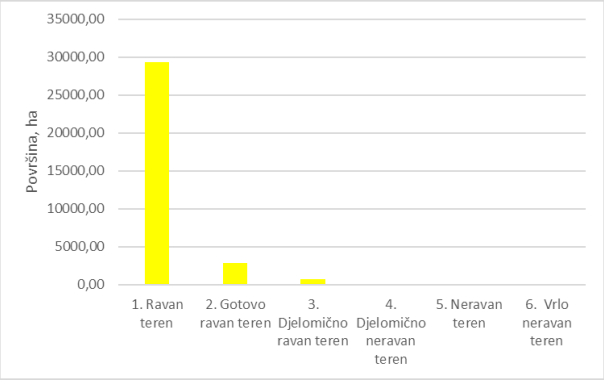

Slika 2.53 Indeks neravnosti terena po površini bioklimata L

Analiza stjenovitosti bioklimata L (slika 2.54) pokazuje da se očekivano radi o krškim terenima gdje je na 61,62 % površine udio stjenovitosti po površini tla od 51 do 90 %. Ipak povoljniji razredi (do 10 % stjenovitosti tla) zauzimaju 8526,19 ha površine.

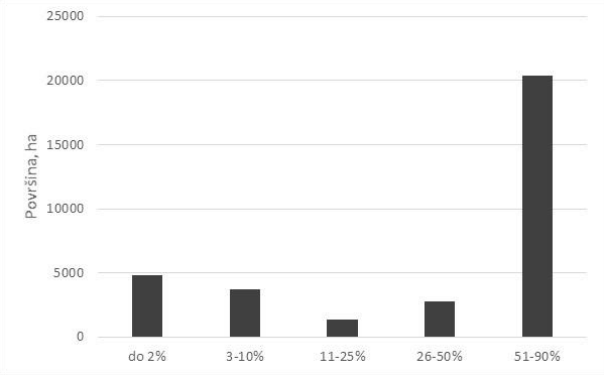

Slika 2.54 Razredi stjenovitosti tla po površini bioklimata L

Analiza nagiba terena (slika 2.55) pokazala je heterogenost ovih terena, ipak sa naglaskom na blaže nagibe gdje 56,51 % terena sadrži nagibe do 20 %. Najnepovoljniji nagibi terena, oni iznad 50 % pridolaze na 9,77 % površine šuma bioklimata L.

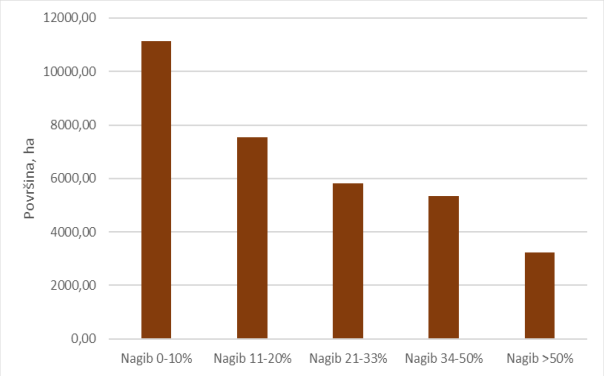

Slika 2.55 Razredi nagiba terena po površini bioklimata L

Na 36,20 % površina mediteranskih šuma i makija alepskog bora i hrasta crnike, stvaran rizik od erozije tla je nizak, dok je na 42,86 % on umjeren. Ipak ne treba zanemariti činjenicu da je na 6923,72 ha površine ovih šuma stvaran rizik od erozije tla vodom visok.

Analiza srednje udaljenosti privlačenja drva (slika 2.56) na području mediteranskih šuma i makija alepskog bora i hrasta crnike u prosjeku iznosi 645 m sa standardnom devijacijom od 526 m. većina površina ovoga bioklimata (75,89 %) je slabo otvoreno područje gdje je privlačenje drva na udaljenostima iznad 1 kilometra. Na površinama koje sadrže drvnu zalihu od 101 do 400 m^3/ha prevladava upravo šesti najnepovoljniji razred srednje udaljenosti privlačenja (> 1000 m) na 9887,09 ha.

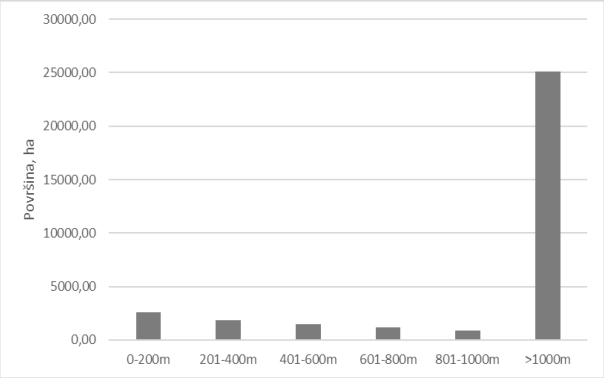

Slika 2.56 Srednja udaljenost privlačenja drva po površini bioklimata L

2.5 Šumska prometna infrastruktura i kretnost šumskih vozila

Prilikom odabira sustava pridobivanja drva, s ciljem izvođenja šumskih radova na djelotvoran, siguran i okolišno prihvatljiv način, posebnu pažnju treba posvetiti i: 1) primarnoj otvorenosti šuma, 2) sekundarnoj otvorenosti šuma, 3) dodatnom opremanju šumskih vozila.

Polučene rezultate primarne otvorenosti šuma treba treba uzimati sa rezervom jer u korištenoj bazi prostornih podataka primarne prometne šumske infrastrukture nedostaju podatci vezani za područja Uprava šuma podružnica Buzet, Senj, Split, Karlovac i Koprivnica. Svakako postojeću (ali i planiranu) primarnu otvorenost šuma treba iskazivati putem kvantitativnog (gustoća primarne šumske prometne infrastrukture) i kvalitativnog (geometrijska udaljenost privlačenja drva) pokazatelja primarne otvorenosti šuma.

Posebno treba istaknuti potrebu za ugradnjom kriterija izračuna gustoće primarne šumske prometne infrastrukture u podzakonske akte, gdje će se duljina pojedine šumske ceste i protupožarne prosjeke s elementima šumske ceste te javnih ili nerazvrstanih cesta koja se uzima u obzir pri obračunu gustoće primarne šumske prometne infrastrukture određivati temeljem osnovnog/eliminacijskog i posebnih/prostornih kriterija.

Osnovni/eliminacijski kriterij

Šumska cesta i protupožarna prosjeka s elementima šumske ceste te javna ili nerazvrstana cesta, odnosno njezina pojedina dionica, koja se uzima u obzir pri obračunu gustoće primarne šumske prometne infrastrukture, mora zadovoljavati ove osnovne/eliminacijske podkriterije:

a) ima izgrađenu kolničku konstrukciju (gornji ustroj),

b) u većoj mjeri ispunjava bitne minimalne tehničke značajke nužne za prijevoz drva solo kamionom,

c) ne postoji prometnom signalizacijom regulirano ograničenje osovinskog prometnog opterećenja manje od 10 tona i ukupnog prometnog opterećenja manje od 26 tona,

d) do ceste se može privlačiti drvo pri čemu se šumska vozila neće kretati po nešumskom zemljištu (poljoprivredno zemljište, urbanizirano zemljište i sl.),

e) uz javne i nerazvrstane ceste moguće je formirati pomoćno stovarište.

Posebni/prostorni kriteriji

a) Šumska cesta i protupožarna prosjeka s elementima šumske ceste te javna ili nerazvrstana cesta, odnosno njezina pojedina dionica, koja se može koristiti pri održivom gospodarenju šumama, a poglavito za utovar šumskih drvnih proizvoda, koja čitavom svojom duljinom prolazi kroz šumu i/ili preko šumskog zemljišta i koja šumu otvara dvostrano, se uzima u obračun gustoće primarne šumske prometne infrastrukture čitavom svojom duljinom (100 % duljine).

b) Šumska cesta i protupožarna prosjeka s elementima šumske ceste te javna ili nerazvrstana cesta, odnosno njezina pojedina dionica, koja se može koristiti pri održivom gospodarenju šumama, a poglavito za utovar šumskih drvnih proizvoda, koja čitavom svojom duljinom prolazi kroz šumu i/ili preko šumskog zemljišta i koja šumu, zbog različitih ograničenja, otvara jednostrano, se uzima u obračun gustoće primarne šumske prometne infrastrukture s polovicom svoje duljine (50 % duljine).

c) Šumska cesta i protupožarna prosjeka s elementima šumske ceste te javna ili nerazvrstana cesta, odnosno njezina pojedina dionica, koja se može koristiti pri održivom gospodarenju šumama, a poglavito za utovar šumskih drvnih proizvoda, koja prolazi granicom gospodarske jedinice ili najviše do 250 m udaljenosti od granice s njene vanjske ili najviše do 125 m udaljenosti od granice s njene unutarnje strane, a čija trasa generalno prati smjer pružanja granice, se uzima u obračun gustoće primarne šumske prometne infrastrukture s polovicom svoje duljine (50 % duljine).

d) Šumska cesta i protupožarna prosjeka s elementima šumske ceste te javna ili nerazvrstana cesta, odnosno njezina pojedina dionica (minimalne duljine 500 m), koja se može koristiti pri održivom gospodarenju šumama, a poglavito za utovar šumskih drvnih proizvoda, koja dolazi do granice gospodarske jedinice pod približno pravim kutom (90° ± 20°) i na granici završava, se uzima u obračun gustoće primarne šumske prometne infrastrukture s duljinom od 250 m. Ukoliko je duljina spomenute sastavnice primarne šumske prometne infrastrukture manja od 500 m, ista se uzima u obračun otvorenosti s polovicom svoje duljine. Ukoliko predmetna sastavnica primarne šumske prometne infrastrukturene ne završava na granici već ulazi u površinu gospodarske jedinice, na nju se, primjenjuju ostali posebni kriteriji određivanja gustoće primarne šumske prometne infrastrukture.

e) Šumska cesta i protupožarna prosjeka s elementima šumske ceste te javna ili nerazvrstana cesta, odnosno njezina pojedina dionica, koja se može koristiti pri održivom gospodarenju šumama, a poglavito za utovar šumskih drvnih proizvoda, koja dolazi blizu granice gospodarske jedinice koja je predmet zahvata primarnog otvaranja šuma pod približno pravim kutom (90° ± 20°), ali završava s vanjske strane granice, se uzima u obračun gustoće primarne šumske prometne infrastrukture s duljinom od 250 m umanjenom za polovicu udaljenosti njezina završetka od granice.

Isto tako, postojeća (ali i planirana) geometrijska (euklidska) udaljenost privlačenja drva, trebala bi se određivat metodom pravilne mreže točaka (razmaka 10 × 10 m), te na taj način kvalitativno opisat dobrotu prostornoga rasporeda primarne šumske prometne infrastrukture. Iskazuje se u metrima, kao prosječna vrijednost na razini gospodarske jedinice, odnosno kao srednja vrijednost na razini odsjeka.

Sekundarna šumska prometna infrastruktura objedinjuje sve vrste sekundarnih šumskih prometnica (traktorske putove, traktorske vlake i žične linije), a služi prvenstveno za primarni transport (privlačenje) drva.

Traktorske vlake su negrađene sekundarne šumske prometnice, prosječeni i/ili obilježeni dijelovi za šumska vozila prometnog terena (udužnoga nagiba <20(25) %). Ograničavanje kretanja šumskih vozila po mreži traktorskih vlaka smanjuje se površina gaženja tla pri privlačenju drva, odnosno njegovog oštećivanja (sabijanja) čime dolazi do izražaja osnovna ideja ove vrste sekundarnih šumskih prometnica – okolišna pogodnost.

Traktorske putovi su građene sekundarne šumske prometnice (samo donji ustroj – zemljorad) udužnoga nagiba <20(25) %, na terenima neprometnima za šumska vozila. Traktorski putovi omogućavaju kretnost šumskim vozilima na terenima sa izraženim nepovoljnim (među)djelovanjem nagiba terena te površinskih prepreka (kamenitost/stjenovitost terena).

U budućnosti bi valjalo sve traktorske vlake i putove snimiti GPS prijamnikom, osnovati bazu prostornih podataka te na taj način stvoriti bitnu podlogu potrebnu za odabir sustava pridobivanja drva.

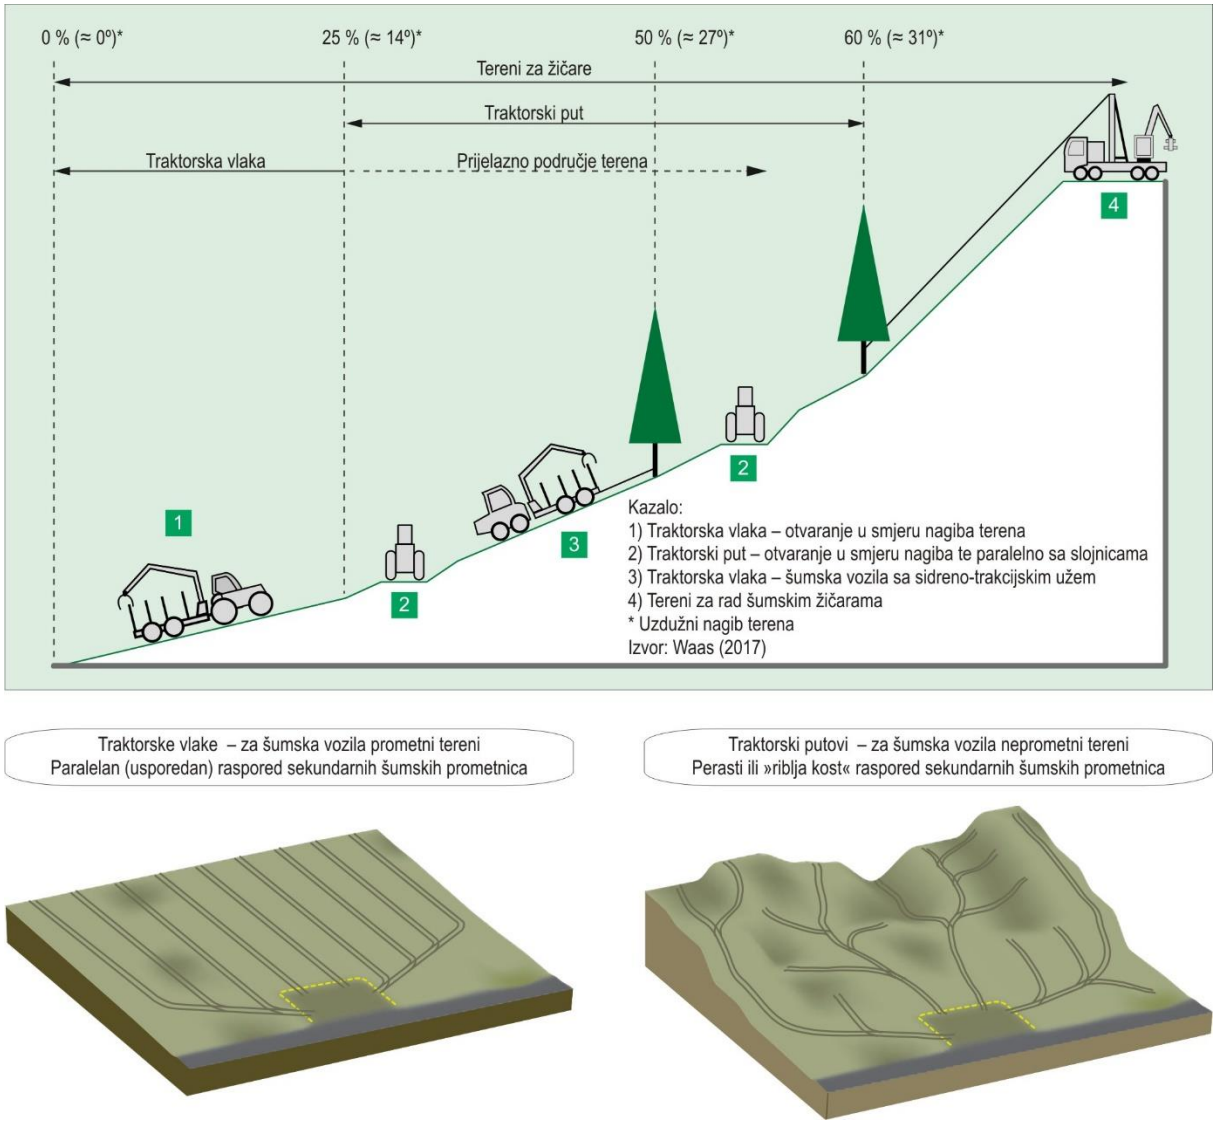

Slika 2.57 Sekundarne šumske prometnice

U ograničenim uvjetima nosivosti podloge, kretanjem šumskih vozila dolazi do oštećivanja (sabijanja) šumskog tla, čiji su osnovni uzroci visoki dodirni tlakovi i klizanje kotača. Posebno valja istaknuti da je klizanje kotača pri uporabi kotačnih šumskih vozila na tlima ograničene nosivosti njihov ograničavajući čimbenik kretnosti.

S ciljem osiguranja kretnosti šumskih vozila na slabo nosivim podlogama, ali i zaštite šumskog tla od oštećivanja, šumska se vozila treba dodatno opremiti: lancima i gusjenicama za kotače vozila, odnosno polugusjenicama za udvojene kotače u tandem rasporedu. Korištenjem lanaca ne povećava se dodirna površina, već se reducira klizanje kotača na nenosivim podlogama, odnosno zaštićuju se gume na kamenitim podlogama. Višestruke koristi opremanja kotača udvojene (bogi) osovine

fovardera u ograničenim uvjetima nosivosti podloge očituju se kroz: 1) zaštitu tla od oštećivanja, zbog povećanja površine dodira, odnosno smanjenja dodirnoga tlaka, 2) osiguranje kretnosti vozila smanjenjem klizanja kotača, ali i dubine kolotraga odnosno otpora kotrljanja vozila, 3) osiguranje djelotvornosti izvoženja drva, 4) smanjenje potrošnje goriva zbog smanjenja klizanja kotača, 5) povećanje bočne stabilnosti forvardera pri utovaru i istovaru drva, ali i pri kretanju vozila pogotovo pri radu na nagnutim terenima.

Dodatno opremanje šumskih vozila je neposredna mjera kojom se smanjuje oštećivanje šumskog tla uslijed kretanja šumskih vozila. Ovu mjeru valja poimati kroz podloge: 1) Karta načina vlaženja tla u Republici Hrvatskoj te 2) Kartu stvarnog rizik od erozije u Republici Hrvatskoj, ali i 3) pri izvođenju radova u područjima ekološke mreže.

Slika 2.58 Dodatno opremanje šumskih vozila

Tablica 2.14 Značajke opremanja kotača vozila pri različitim uvjetima rada

	Gume (pneumatici)	Lanci na gumama	Polugusjenice na gumama tandem kotača
Suha i čvrsta nosiva tla	Flotacijski »neagresivni« dezen pneumatika omogućuje kretnost šumskih vozila te smanjuje utjecaj vibracija na vozilo i vozača. **PRIKLADNO**	Zaštićuju gume na radilištima sa izraženom kamenitošću i stjenovitošću podloge, koja bi mogla dovesti do pojačanoga trošenja ili oštećivanja pneumatika. **RAZMOTRITI**	Nepotrebno korištenje, ukoliko kretnost vozila nije otežana. Uporaba polugusjenica može dovesti do oštećenja tla, povećane potrošnje goriva uslijed povećanja mase vozila ali i porasta vibracija. Korištenje polugusjenica na kamenitim terenima produljuje vijek uporabe guma, što ipak ne opravdava njihovo korištenje. **NEPRIKLADNO**
Smeđa tla pri umjerenim klimatskim prilikama	Kretnost je šumskim vozilima omogućena uz korištenje standardnih pneumatika. **PRIKLADNO**	Zbog djelotvornosti, mogu se koristiti na gumama kotača jedne osovine sa ciljem osiguranja dodatne trakcije vozila na dijelovima radilišta koji to zahtijevaju. **RAZMOTRITI**	Nepotrebno korištenje, ukoliko postoje manje površine radilišta sa povećanom vlagom tla kretnost vozilu osigurati slaganjem zastora šumskog ostatka. **NEPRIKLADNO**
Glinovita vlažna tla	Dezen se gazne površine gume ispunjava blatom što smanjuje kretnost vozila. Gume sa trakcijskim dezenom gazne površine imaju mogućnost samočišćenja. (Pro)klizavanje je kotača očekivano uz narušenu kretnost vozila. **NEPRIKLADNO**	Lanci povećavaju prijanjanje kotača sa tlom, ali ne i dodirnu površinu te uzrokuju premještanje slojeva tla. **RAZMOTRITI**	Korištenje polugusjenica povećati će prijanjanje kotača sa tlom, ali ujedno će i oštetiti njegovu površinu premiještanjem njegovih površinskih slojeva. Ipak, povećanjem dodirne površine kotača omogućiti će se privlačenje drva u uvjetima povećane vlažnosti tla. **RAZMOTRITI**
Tla umjerene nosivosti na strmim terenima	Na graničnim nagibima terena, u slučaju ispunjavanja dezena gazne površine tlom, dolazi do smanjenja kretnosti šumskih vozila uslijed (pro)klizavanja kotača. **NEPRIKLADNO**	Lanci povećavaju prijanjanje kotača na tlo, ali u manjoj mjeri u odnosu na polugusjenice. **RAZMOTRITI**	Korištenje polugusjenica omogućiti će izvrsnu kretnost vozila uz/niz nagib terena sve do graničnih nagiba koje vozilo može savladati. Dizajn polugusjenica mora se zasnivati na boljem prijanjanju na podlogu, pri čemu posebnu požnju valja posvetiti mogućim oštećenjima šumskih cesta. **PRIKLADNO**
Vlažna tla, slabe nosivosti	Pneumatici kotačnih šumskih vozila za privlačenje drva ne osiguravaju njihovu kretnost ukoliko se ne koriste neke druge operativne metode za poboljšanje kretnosti vozila (npr. slaganje zastora šumskog ostatka). **NEPRIKLADNO**	Lanci mogu povećati prijanjanje kotača sa tlom i smanjiti njihovo (pro)klizavanje, ali u nedovoljnoj mjeri, što u konačnici dovodi do propadanja vozila i stvaranja kolotraga. **NEPRIKLADNO**	Polugusjenice sa širim elementima, pogodne su za rad na tlima slabe nosivosti tla jer povećavaju prijanjanje na tlo bez propadanja vozila uslijed povećanja dodirne površine. Ovisno o razini vlažnosti / nosivosti tla, mogu se koristiti u kombinaciji sa lancima na prednjim kotačima vozila. **PRIKLADNO**
Snijeg na tlu slabe nosivosti	Nakupljanje snijega u žlijebovima gazne površine pneumatika dovodi do upitnog prijanjanja kotača sa tlom. Pneumatici sa visokim rebrima, isto tako, će se ispuniti snijegom, uz moguća veća oštećenja površinskih slojeva tla. **NEPRIKLADNO**	Lanci osiguravaju bolje prijanjanje kotača na tlo uz nepromjenjenu dodirnu površinu, što dovodi do oštećenja tla i pojave erozionih procesa. **RAZMOTRITI**	Polugusjenice su prikladne za korištenje, uslijed povećane dodirne površine i smanjuju mogućnost propadanja vozila, posebice tijekom perioda otapanja snijega. Preporuča se korištenje specijaliziranih polugusjenica za snježne uvjete kako ne bi došlo do oštećenja bogi ovjesa vozila. **RAZMOTRITI**
Snijeg na smrznutome tlu	Nakupljanje snijega u žlijebovima gazne površine pneumatika dovest će do neprijanjanja kotača sa tlom. **NEPRIKLADNO**	Lanci na pneumaticima kotača vozila osigurat će njihovu kretnost uslijed smanjenja (pro)klizavanja kotača. **PRIKLADNO**	Korištenjem je polugusjenica moguća pojava vibracija, sličnih onima u uvjetima suhog i čvrstog tla, koje će nepovoljno utjecati na vozača vozila. **RAZMOTRITI**

Literatura

Anon., 1975: The Forestry Commission System of Terrain Description and Classification. BRITISH FORESTRY COMMISSION, Harvesting and Marketing Division, Edinburgh.

Berg, S., 1992: Terrain Classification System for Forestry Work. Forskningsstiftelsen Skogsarbeten, Kolding Lyntryk, Denmark, 1–28.

Bertović, S., 1999: Reljef i njegova prostorna raščlamba. Šumarski list 123(11–12): 543–563.

Beven, K., M. J. Kirkby, 1979: A physically based variable contributing area model of basin hydrology. Hydrology Science Bulletin 24(1979): 43–69.

Bogunović, M., Ž. Vidaček, Z. Racz, S. Husnjak, M. Sraka, 1997: Namjenska pedološka karta Republike Hrvatske i njena uporaba. Agronomski glasnik: Glasilo Hrvatskog agronomskog društva, 59(5-6): 363–399.

Bojanin, S., 1980: Problemi klasifikacije šumskih terena. Mehanizacija šumarstva 5(5-6): 179–187.

Bumber, Z., 2011: Primjena GIS-a pri analizi otvorenosti G.J. Šiljakovačka dubrava II kroz strukturu prihoda drva u prostoru i vremenu. Magistarski rad, Šumarski fakultet Sveučilišta u Zagrebu, 1–139.

Burrough, P. A., R. A. McDonell, 1998: Principles of Geographical Information Systems (Oxford University Press, New York), 1–190.

Canon, S. K., F. C. Bryant, 1997: Bedsite characteristics of pronghorn fawns. Journal of Wildlife Management, 61(1997): 1134–1141.

Čavlović, J., 2010: Prva nacionalna inventura šuma Republike Hrvatske. Ministarstvo regionalnog razvoja, šumarstva i vodnoga gospodarstva Republike Hrvatske i Šumarski fakultet Sveučilišta u Zagrebu, Zagreb, 1–300.

Conway, S., 1976: Logging practices. Principles of timber harvesting systems. Miller Freeman Publications, 1–432.

Davis, C. J., T. W. Reisinger, 1990: Evaluating Terrain for Harvesting Equipment Selection. Journal of Forest Engineering, 2(1): 9–16.

Dietz, P., W. Knigge, H. Löffler, 1984: Walderschlieβung. Verlag Paul Parey, Hamburg, DNR, 1–426.

Enache, A., M. Kühmaier, K. Stampfer, V. D. Ciobanu, 2013: An integrative decision support tool for assessing forest road options in a mountainous region in Romania. Croat. j. for. eng. 34 (1): 43–60.

Eriksson, T., G. Nilsson, G. Skrămo, 1975: The Inter-Nordic Project of Forest Terrain and Machines in 1972–1975. Acta Forestalia Fennica, vol.164: 1–44.

Fabricius, C., K. Coetzee, 1992: Geographic information systems and artificial intelligence for predicting the presence or absence of mountain reedbuck. South Afr.J.Wildl.Rs., 22(1992): 80–86.

Fatherree, B. H., 2006: The History of Geotechnical Engineering at Waterways Experiment Station 1932–2000. http://gsl.erdc.usace.army.mil/gl-history/.

Folegatti, B., M. Smidt, T. Macdonald, 2010: Wander factors for skid distance estimation in pine thinnings. Proceedings pf precision Forestry Symposium, March 2, Stellenbosch, South Africa, 1–49.

Hirt, C., M. Filmer, W. Featherstone, 2010: Comparison and validati on of the recent freely available ASTER GDEM ver1, SRTM ver4.1 and GEODATA DEM9S ver3 digital elevation models over Australia. Australian Journal of Earth Sciences, 57(3): 337–347.

Hjerdt, K. N., J. J. McDonnell, J. Seibert, A. Rodhe, 2004: A new topographic index to quantify downslope controls on local drainage; Water Resources Research 40(5).

Huang, B., B. Jiang, 2002: AVTOP: a full integration of TOPMODEL into GIS. Environmental 507 Modelling & Software 17(2002): 261–268.

Husnjak, S., 2000: Procjena rizika erozije tla vodom metodom kartiranja u Hrvatskoj. Disertacija. Agronomski fakultet Sveučilišta u Zagrebu.

Kieslinger, G., 1953: Bodenklassen im Tiefbau. Österreichische Bauzeitschrift. Heft 1. Jakobson, A., 1965: Terrängtransportarbete med traktor. Skogsäagaren 2.

Koeln, G. T., L. M. Cowardin, L. L. Strong, 1996: Geographical information systems. Research and management techniques for wildlife and habitats. Wildlife Society, Bethseda, USA, str. 540–566. Beasom, S.L., Wiggers, E.P., Giardino, J.R., 1983: A technique for assessomg land surface ruggedness. Journal of Wildlife Management, 47(1983): 1163–1166.

Löffler, H. J., 1984: Terrain classification for forestry. Report TIM/EFC/WP.1/R.51, 24 August 1984, EU Timber Committee and FAO-ILO, 1–55.

MacDonald, AJ., 1999: Harvesting Systems and Equipment in British Columbia. FERIC, Handbook No., HB-12: 1–197.

Matthews, D. M., 1942: Cost Control in the Logging Industry. McGraw–Hill Book Company Inc., New York, USA, 1–374.

Maune, D. F., 2007: Digital Elevati on Model Technologies and Applications: The DEM Users Manual. American Society for Photogrammetry and Remote Sensing Bethesda, Maryland, USA.

Mellgren, P. G., 1980: Terrain Classification for Canadian Forestry. FERIC, 1–13.

Owende, P. M . O., J. Lyons, R. Haarlaa, A. Peltola, R. Spinelli, J. Molano, S. M. Ward, 2002: Operations protocol for Eco-efficient Wood Harvesting on Sensitive Sites. Project ECOWOOD, Funded under the EU 5th Framework Project (Quality of Life and Management of Living Resources). Contract No. QLK5-1999-00991 (1999 – 2002), 1–74.

Pentek, T., 2002: Računalni modeli optimizacije mreže šumskih cesta s obzirom na dominatne utjecajne čimbenike. Doktorska disertacija, Šumarski fakultet Sveučilišta u Zagrebu. 1–271.

Pentek, T., D. Pičman, H. Nevečerel, 2004: Srednja udaljenost privlačenja drva. Šum. list 128(9–10): 545–558.

Pičman, D., T. Pentek, M. Družić, 1997: Utjecaj troškova izgradnje i održavanja šumskih cesta na njihovu optimalnu gustoću u nizinskim šumama Hrvatske. Meh. šumar. 22(2): 95–101. Sabadi, R., 1992: Ekonomika šumarstva. Školska knjiga, Zagreb, 1–280.

Pilaš, I., I. Medved, J. Medak, D. Medak, 2014: Response strategies of the main forest types to climatic anomalies across Croatian biogeographic regions inferred from FAPAR remote sensing data. Forest ecology and management, 326: 58–78.

Poršinsky, T., 2005: Djelotvornost i ekološka pogodnost forvardera Timberjack 1710 pri izvoženju oblovine iz nizinskih šuma Hrvatske. Disertacija, Šumarski fakultet Sveučilišta u Zagrebu, 1–170.

Putkisto, K., 1964: Metsämaastomme kuljetusteknillisten ominaisuuksien inventointi. Summary: The importance of a forestland survey in Finland from the view point of timber transportation. Metsätaoloudellinen Aikakauslehti 10.

Riley, S. J., 1989: Integration od environmental , biological and human dimensions for management of mountain lions (*Puma concolor*) in Montana. Ph.D Dissertation, Cornell University, Ithaca, NY, USA, 1–247.

Riley, S. J., S. D. DeGloria, R. Elliot, 1999: A Terrain ruggedness Index that Quantifies Topographic Heterogeneity. Intermountain Journal of Sciences, vol. 5 (1–4): 23–27.

Riley, S. J., S. D. DeGloria, R. Elliot, 1999: A Terrain ruggedness Index that Quantifies Topographic Heterogeneity. Intermountain Journal of Sciences, vol. 5 (1–4): 23–27.

Rowan, A. A., 1977: Terrain classification. Forestry Commission, Forestry Record 114. Her Majesty's Stationery Office (HMSO), Edinburgh, 1–24.

Saarilahti, M., 2002A: Dynamic terrain classification – Modelling of the seasonal variation of the trafficability on forest sites. Soil interaction model. Development of a protocol for ecoefficient wood harvesting on sensitive sites (Ecowood), Appendix report no. 1, 1–22.

Saarilahti, M., 2002B: Modelling of the wheel and soil. Soil interaction model. Development of a protocol for ecoefficient wood harvesting on sensitive sites (Ecowood), Appendix report no 8, 1–37.

Samset, I., 1975: The accessibility of forest terrain and its influence on forestry conditions in Norway. Reports of the Norwegian Forest Research Institute 32.1, 1–92.

Segebaden, G., 1964: Studies of Cross-Country Transport Distances and Road Net Extension. Studia Forestalia Suecica 18: 1–70.

Silversides., C. R., U. Sundberg, 1988: Operational Efficiency in Forestry – Volume 1: Analysis. Kluwer Academic Publishers – Forest Sciences, Dodrechts/Boston/Lancaster, 1–219

Staff, K. A., N. A. Wiksten, 1984: Tree harvesting techniques: Planning of tree harvesting. Kluwer Academic Publisher. MTP Press Limited. 1–371.

Stankić, I., 2010: Višekriterijsko planiranje izvođenja drva forvarderima iu nizinskih šuma Hrvatske. Doktorska disertacija, Šumarski fakultet Sveučilišta u Zagrebu, 1–123.

Van Niel, K. P., S. W. Laffan, B. G. Lees, 2004: Effect of error in the DEM on environmental variables for predictive vegetation modeling. Journal of Vegetation Science 15(6): 747–756.

Varga, M., T. Bašić, 2013: Procjena kvalitete i usporedba globalnih digitalnih modela reljefa na ozemlju. Kartografija i geoinformacije, vol. 20(12): 4–17.

Vukelić, J., S. Mikac, D. Baričević, D. Bakšić, R. Rosavec, 2008: Šumska staništa i šumske zajednice u Hrvatskoj–Nacionalna ekološka mreža. Državni zavod za zaštitu prirode, Zagreb, 263 str.

3. Katalog sustava pridobivanja drva

Pridobivanje drva (eng. *logging*, *harvesting*) je skup tehnoloških operacija nužnih za pretvorbu dubećih stabla u željeni šumski proizvod i njegovu dopremu iz šume do mjesta uporabe. U navedenim operacijama ljudi koriste alate, opremu i strojeve te oblikuju sustav pridobivanja drva u određenoj sječini, a pri tome rad mogu obavljati različitim metodama pridobivanja drva, ovisno o stupnju izrade kraj panja i obliku u kojemu se drvo transportira do stovarišta (Pulkki 1997).

U svijetu su poznate tri glavne metode pridobivanja drva: sortimentna (eng. *Cut-to-length*, *Shortwood*), deblovna (eng. *Tree-length*) i stablovna s različitim inačicama (eng. *Full tree*, *Whole tree*, *Complete tree*) ovisno o tome koristi li se samo nadzemna biomasa stabla ili i panj bez ili s dijelom korijenja. Sustavi se obično dijele s obzirom na stupanj mehaniziranosti na: nemehanizirane, djelomično mehanizirane i mehanizirane. Detaljnijom podjelom moguće je razlikovati i visokomehanizirane sustave, u kojima se samo sječa obavlja ručno-strojno, a svi ostali postupci strojno od potpuno mehaniziranih sustava, u kojima se svi postupci obavljaju strojno (Heinrich 1998).

Različite inačice pojedinih sustava pridobivanja drva s obzirom na glavne sastavnice (strojeve) i različite metode pridobivanja drva uobičajeno je prikazivati u grafičkom obliku (Warkotsch 1975, Löffler 1989, Heinimann 2001, Erler i Weiß 2003, Erler i Dög 2009).

Slika 3.1 Djelomično mehanizirani sustav pridobivanja oblog drva sortimentnom metodom – Prikaz korištenjem modela matrice (Löfller 1989)

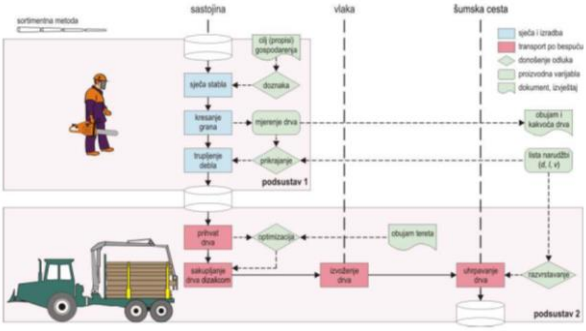

Slika 3.2 Djelomično mehanizirani sustav pridobivanja oblog drva sortimentnom metodom – Prikaz korištenjem teorije simulacije proizvodnih sustava (Heinimann 2001)

Katalog sustava pridobivanja drva (Prilog 1) sastoji se od opisnog i grafičkog dijela. Opis pojedinih sustava pridobivanja drva temelji se na dostupnim izvorima literature, a odabir u Katalogu prikazanih sustava pridobivanja drva temelji se na posebnostima pridobivanja drva u Republici Hrvatskoj uvažavajući prvenstveno trenutno prevladavajuće sustave i metode pridobivanja drva nastale dugogodišnjim razvojem tehnoloških postupaka prilagođenih gospodarenju prirodnim šumama različitih terenskih i sastojinskih uvjeta. No, značajan dio Kataloga posvećen je i sustavima pridobivanja drva recentno uvedenim u naše šumarstvo, kao i sustavima pridobivanja drva čija tehnička i tehnološka rješenja naslućuju mogućnost uspješne primjene u hrvatskom šumarstvu.

Pri grafičkom prikazu sustava pridobivanja drva korištena je metoda funkciograma (njem. *Funktiogramme*) koju preporuča KWF (*Kuratorium für Waldarbeit und Forsttechnik e.V.*), a razvili su je i opisali Erler i Dög (2009). Navedeni grafički prikaz na jednostavan i jasan način predočuje dijelove sustava i glavne procese. U vertikalnoj ravnini opisuje tijek pretvorbe dubećeg stabla u drvni sortiment, a u horizontalnoj ravnini postupke transporta drva od panja do stovarišta.

S obzirom da su opisi i prikazi sustava i metoda pridobivanja drva najčešće nastajali u okruženju prevladavajućeg udjela četinjača pozornost autora je gotovo isključivo usmjerena izradi drvnih sortimenata oblog drva iz raspoložive deblovine stabla. U ovome Katalogu posebna je pažnja posvećena tehnološkim procesima izrade prostornoga drva (koje ne mora nužno biti izrađeno kao sortiment oblog drva). Isti su procesi sistematizirani i prikazani ili kao sastavni dio sustava pridobivanja (oblog) drva ili pak kao posebni sustavi pridobivanja drva koji izvorište sirovine nalaze u biomasi stabla koja preostaje nakon izrade i transporta oblog drva.

Literatura

Erler, J., M. Weiß, 2003: Netz-Darstellung von Arbeitsverfahren. Forsttechnische Informationen 54 (9): 103–107.

Erler, J., M. Dög, 2009: Funktiogramme für Holzernteverfahren. Forsttechnische Informationen 61 (9-10): 14–17.

Heinimann, H. R., 2001: Verfahrenstechnik III – Analyse, Gestaltung un Steuerung technischer Produktions-systeme. Swiss Federal Institute of Technology Zurich, 1–26.

Heinrich, H., 1998: Recent developments on environmentally friendly forest road construction and wood transport in mountainous forests. Proceedings of the Seminar on environmentally sound forest roads and wood transport, Sinnaia, FAO Rome, 366–376.

Löffler, H., 1989: Forstliche Verfahrenstechnik (Holzernte) für Studierende der Forstwirtschaft: Manuskript zu der Lehrveranstaltung. Lehrstuhl für Forstl. Arbeitswiss. u. Verfahrenstechnik d. Univ., 1–516.

Pulkki, R., 1997: Cut-to-length, tree-length or full tree harvesting? Central Woodlands 1 (3): 22–27, 37.

Warkotsch, W., 1975: Darstellung und Analyse von Systemen und Verfahren der Holzernte. Allgemeine Forstzeitschrift 41.

4. Katalog šumskih strojeva i morfološka raščlamba

4.1 Uvod

Katalog šumskih strojeva je izrađen da bi se korištenjem morfoloških značajki grupe strojeva, dobivenih analizom iz baze podataka, mogao/li izabrati tip/ovi stroja/eva koji odgovara/ju zadanom/im kriteriju/ima. Dakle, polazište izbora tipa stroja je baza tehničkih i ev. drugih podataka važnih za morfološku analizu koji se u većini slučajeva mogu kvantificirati, a zatim iz kataloga strojeva izabrati.

Na Šumarskome fakultetu u Zagrebu stvaranje baze tehničkih podataka šumskih strojeva ima dugu tradiciju i prvu je takvu bazu za morfološku raščlambu napravio Sever (1981) za skidere, potaknut prijedlogom Bekkera (1956, 1960, 1969) za analizom dobrote terenskih vozila morfološkom analizom. Kao kuriozitet za ovu bazu podataka može se navesti da je bila izrađena bez primjene računala.

Prvu računalnu bazu tehničkih podataka forvardera načinio je Horvat (1993), a za ostala šumska vozila opisali su ju Sever i Horvat (1992a i 1992b). U tim se prvim radovima o bazama podataka šumskih strojeva i njima pridruženi morfološkim raščlambama govori o njihovoj primjeni pri definiranju zajedničkih značajki pojedine grupe strojeva i ocjeni pojedinoga tipa stroja unutar familije.

Krajem 90-tih godina i početkom 2000-tih napravljene su prve baze tehničkih podataka svih značajnijih grupa strojeva: adaptiranih poljoprivrednih traktora, iverača, žičara, harvestera, harvesterskih glava, kamionskih dizalica, šumskih poluprikolica i dr. Veliki dio ovih baza stvarali su studenti Šumarskoga fakulteta u Zagrebu za svoje diplomske radove. Posljednju takvu bazu je napravio Musić (2007) za motorne pile lančanice.

Za potrebu ovoga projekta većina je postojećih baza podataka izabranih grupa strojeva:

1. Motornih pila lančanica,
2. Harvesterskih glava,
3. Harvestera,
4. Skidera
5. Forvardera,
6. Šumskih žičara i
7. Iverača,

nadopunjavana podacima novih tipova strojeva koji su poslije uvršteni u Katalog šumskih strojeva. Podaci o novim tipovima strojeva su pronalaženi na portalima proizvođača. Zbog toga a uslijed raznovrsnoga načina prikazivanja podataka na pojedinome portalu, za poneke tipove strojeva se nisu mogli naći svi željeni podaci. Ovaj su dio posla uglavnom radili studenti.

Kao zaključak može se reći da obnovljene baze tehničkih podataka imaju trajnu vrijednost dok je Katalog šumskih strojeva ograničene upotrebljivosti tj. traje sve dok poneki proizvođač ne promjeni, odnosno, proizvede novi tip stroja. Ovo posebno vrijedi za proizvođače motornih pila lančanica koji praktički svake godine mijenjaju proizvodni program koji puta samo promjenom naziva stroja.

U nastavku će se prikazati neke osnovne značajke Kataloga šumskih strojeva, njihove baze tehničkih podataka te primjena morfološke raščlambe za neke značajke svake od 7 gore navedenih familija strojeva.

Sam Katalog šumskih strojeva je prilog ovome Izvješću (Prilog 2).

4.2 Motorne pile lančanice (mp)

Nadopunjenu bazu podataka (Musić 2007) Poršinsky i dr. (2008) su iskoristili za prvu veliku morfološku raščlambu motornih pila lančanica. Podijelili su motorne pile u 4 kategorije:

1. Profesionalne,
2. Poluprofesionalne,
3. Za vrt i hobi te
4. Jednoručne.

Ova podjela je prihvaćena i u ovome Izvješću jer se iz ovisnosti mase i snage motora (slika 4.1) mogu jasno razabrati područja ove 4 kategorije motornih pila (u daljnje tekstu MP).

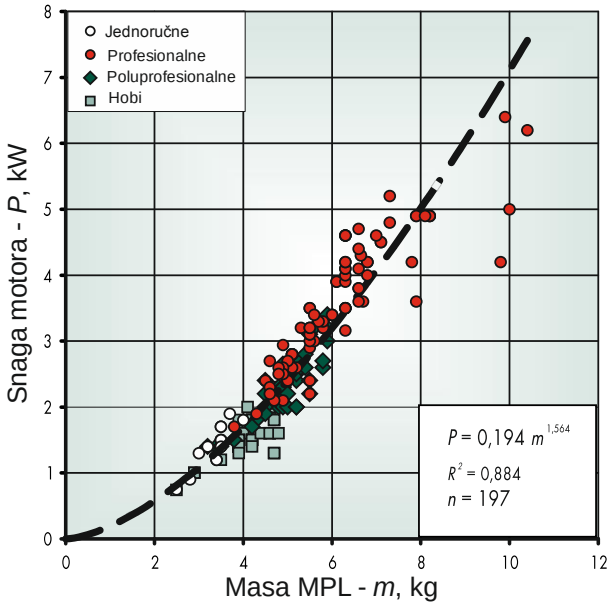

Slika 4.1 Ovisnost snage motora o masi MP

Još bolju potvrdu ovoga daje dijagram na slici 4.2 raspodjele mase MP prema ove 4 kategorije:

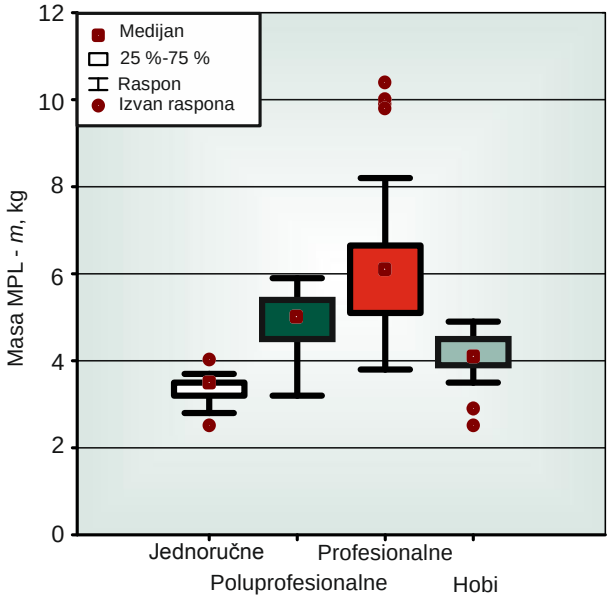

Slika 4.2 Raspored masa 4 kategorije MP

Ovakva kategorizacija ima najveći utjecaj na cijenu MP što je razvidno iz slike 4.3.

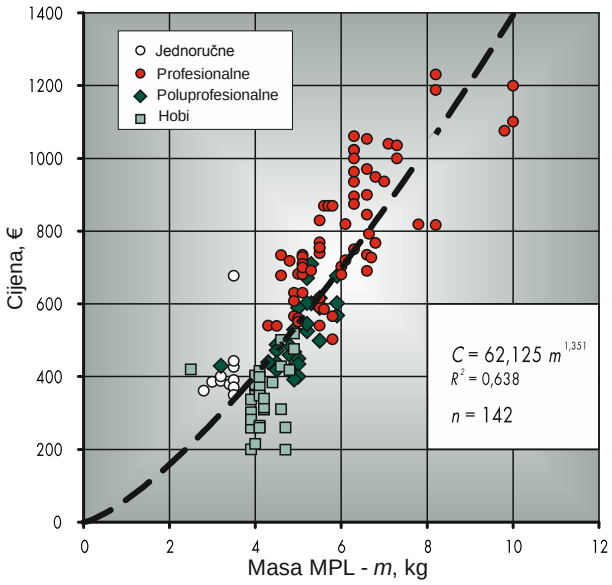

Slika 4.3 Ovisnost cijene MP o njenoj masi i kategoriji

Ovisnost zapremine motora o masi MP prikazane na slici 4.4 ima **jako čvrstu vezu** kao i ovisnost snage motora i mase što znači i da su ove dvije značajke snaga i zapremina cilindra motora također čvrsto povezane. Prema ovome svejedno je koji od tehničkih parametara izabrati kao ulazni jer su ostala dva definirana uniformnom značajkom cijele familije.

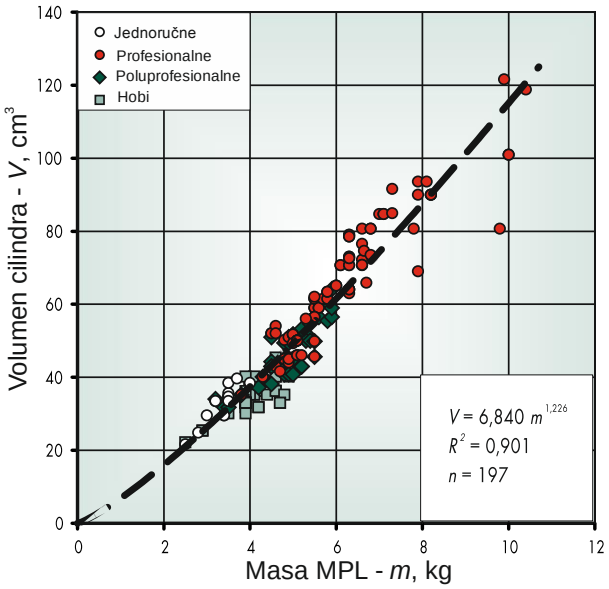

Slika 4.4 Ovisnost volumena motora MP o masi

Primjerice, ako bi se značajke MP birale prema manualu ARMEF-CTBA-IDF koji preporuča izbor MP ovisnosti o promjeru stabla i to zapreminu njenoga motora – slika 4.5.

Nakon izbora volumena motora, definiranja željene kategorije, masa MP se može odrediti iz slike 4.1, a približna cijena iz slike 4.3.

U manualu ARMEF-CTBA-IDF se nalazi i prijedlog duljine vodilice pa je zbog toga i ovaj tehnički pokazatelj uvršten u bazu podataka.

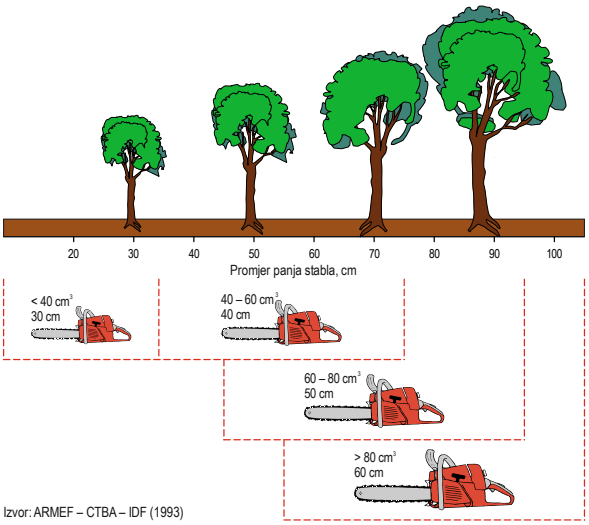

Slika 4.5 Izbor MP (zapremina cilindra) prema promjeru stabla

Morfološka raščlamba na slici 4.6 pokazuje da su zapremine rezervoara za gorivo i ulja za podmazivanje lanca MP također u čvrstoj vezi (jednoobrazna značajka familije) što znači da su nakon izbora volumena motora/snage motora/mase MP veličine rezervoara definirane.

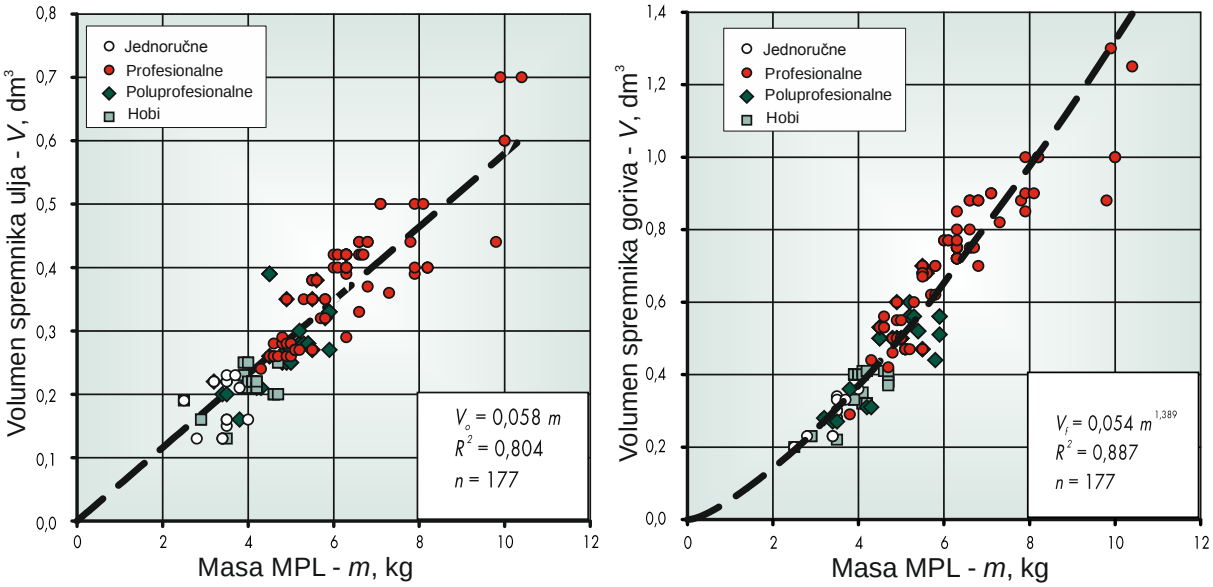

Slika 4.6 Ovisnosti volumena oba spremnika MP o njenoj masi

Najveći problem primjene MP su njihove nepovoljne ergonomske značajke – prevelike vrijednosti vibracija na ručicama i buke. Dok se utjecaj buke na sjekača može smanjiti nošenjem osobnih zaštitnih sredstava, utjecaj vibracija je moguće ublažiti samo ograničavanjem trajanja rada s MP.

Da su ove ergonomske značajke zaista nepovoljne prikazuju dijagrami na slici 4.7 (ovisnost buke o masi MP) i slici 4.8 (ovisnost vibracija na ručicama MP o njenoj masi).

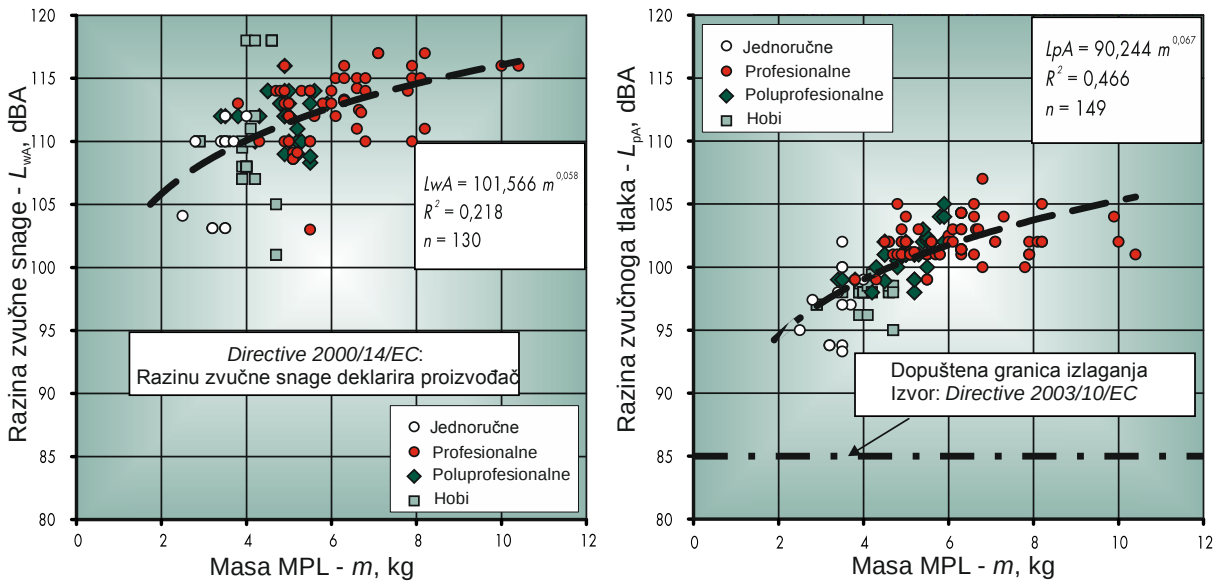

Slika 4.7 Ovisnost razine buke o masi MP

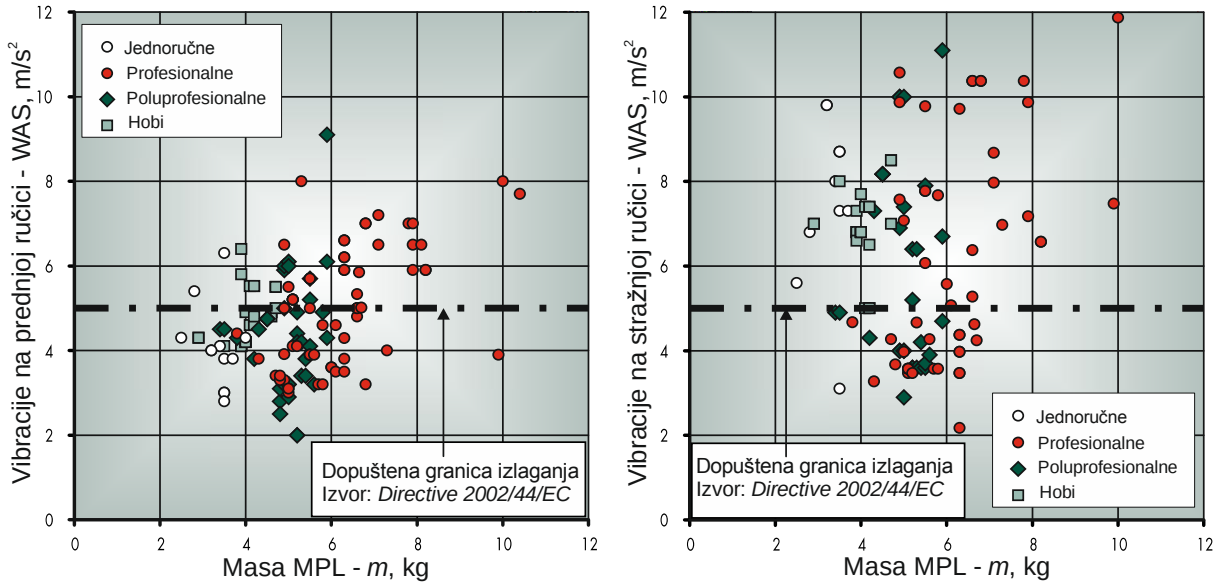

Slika 4.8 Ovisnost vibracija na ručicama MP o masi

Slika 7 pokazuje da je razina zvučnoga tlaka znatno iznad dopuštene granice izlaganja prema Direktivi Europske komisije 2003/10/EC. Tako je primjerice za MP mase 6 kg srednja (izjednačena) razina zvučnoga tlaka 102 dBA što je za 17 dBA više od dopuštene granice. To znači da je razina zvučnoga tlaka oko **50 puta** veća od dopuštene. To izgleda alarmantno i ukazuje da se osobno zaštitno sredstvo mora izabrati s posebnom pažnjom korištenjem dijagrama frekventne analize buke za pojedini model posebno.

Veličina vibracija na prednjoj i stražnjoj ručici (slika 4.8) s ucrtanom dopuštenom granicom od 5 ms^{-2} prema Direktivi EK 2002/44/EC pokazuju da se za istu masu mogu naći motorne pile iznad i ispod dopuštene granice. Tako, primjerice, za MP mase oko 6 kg postoje MP koje zadovoljavaju kriterij EK. Zanimljivo je i to da poluprofesionalnih i profesionalnih MP ima čije su vibracijske značajke zadovoljavajuće dok ih takvih MP za vrt i hobi gotovo nema.

Na temelju ovih razmatranja napravljena je baza podataka MP koja sadržava navedene značajke i koja ima više od 200 modela. Izgled ove baze u MS Excel softveru pokazuje slika 4.9.

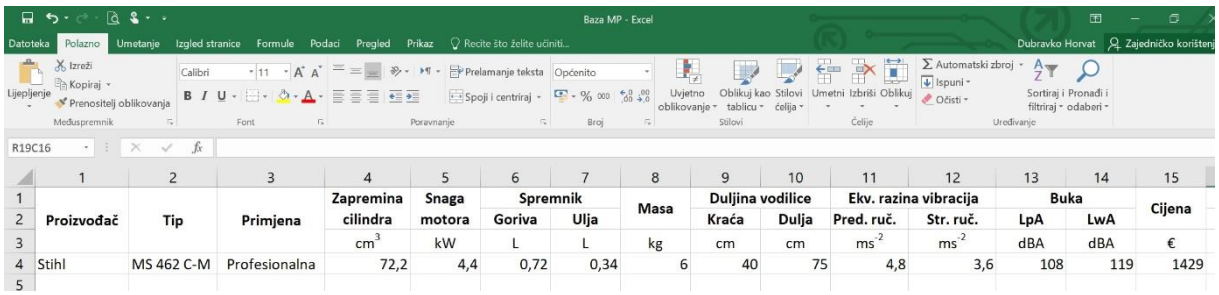

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	Proizvođač	Tip	Primjena	Zapremina cilindra	Snaga motora	Spremnik		Masa	Duljina vodilice		Ekv. razina vibracija		Buka		Cijena
2						Goriva	Ulja		Kraća	Dulja	Pred. ruč.	Str. ruč.	LpA	LwA	
3				cm^3	kW	L	L	kg	cm	cm	ms^{-2}	ms^{-2}	dBA	dBA	€
4	Stihl	MS 462 C-M	Profesionalna	72,2	4,4	0,72	0,34	6	40	75	4,8	3,6	108	119	1429
5															

Slika 4.9. Izgled baze podataka MP

Za potrebe ovoga Izvješća a na temelju činjenice da proizvođači MP često mijenjaju svoje modele u bazu (Katalog) dodani su podaci 95 novih modela. Izgled jedne stranice kataloga za motornu pilu Stihl MS 462 C-M pokazuje slika 4.10.

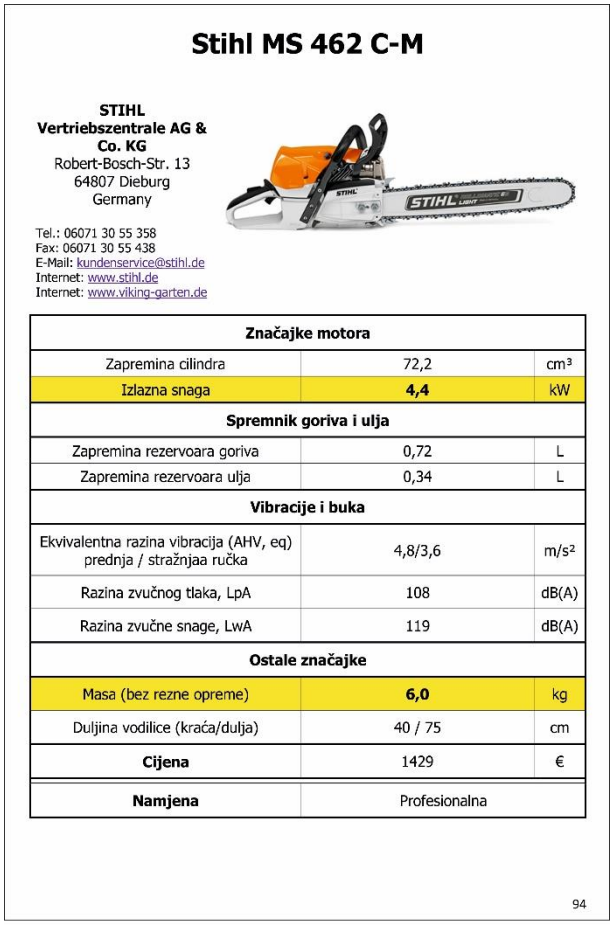

Stihl MS 462 C-M

STIHL Vertriebszentrale AG & Co. KG
Robert-Bosch-Str. 13
64807 Dieburg
Germany

Tel.: 06071 30 55 358
Fax: 06071 30 55 438
E-Mail: kundenservice@stihl.de
Internet: www.stihl.de
Internet: www.viking-garten.de

Značajke motora		
Zapremina cilindra	72,2	cm³
Izlazna snaga	**4,4**	kW
Spremnik goriva i ulja		
Zapremina rezervoara goriva	0,72	L
Zapremina rezervoara ulja	0,34	L
Vibracije i buka		
Ekvivalentna razina vibracija (AHV, eq) prednja / stražnjaa ručka	4,8/3,6	m/s²
Razina zvučnog tlaka, LpA	108	dB(A)
Razina zvučne snage, LwA	119	dB(A)
Ostale značajke		
Masa (bez rezne opreme)	**6,0**	kg
Duljina vodilice (kraća/dulja)	40 / 75	cm
Cijena	1429	€
Namjena	Profesionalna	

94

Slika 4.10 Izgled jedne stranice Kataloga motornih pila lančanica

Na temelju podataka o ovoj MP može se reći da duljinom vodilice od 75 cm može zadovoljiti obaranje i stabala najvećega promjera te da su vibracije na ručicama ispod dopuštenih granica. U slučaju da je njena masa prevelika (6 kg) može se tražiti model manje mase primjerice Stihl MS 362 C-M koji je mase 5,6 kg ali ima kraću vodilicu (50 cm). Značajno je i to da su ergonomske značajke manjega modela bitno bolje.

4.3 Harvesterske glave

Prvu bazu podataka harvesterskih glava na Šumarskome fakultetu napravio je u svome diplomskom radu Bručić (1997), dakle u doba kada još niti jedan harvester nije u Hrvatskoj radio. Jedan od ciljeva ovoga projekta je bio istraživanje mogućnosti primjene strojne sječe i izrade odnosno harvestera. Zbog postojanja navedene baze podataka harvesterskih glava upravo su one izabrane za prvu analizu njihovih tehničkih značajki.

Kako je navedeno u prethodnim polugodišnjim izvješćima baza tehničkih značajki harvesterskih glava prikazana je na slici 4.11 i trenutno obuhvaća više od 50 raznih modela.

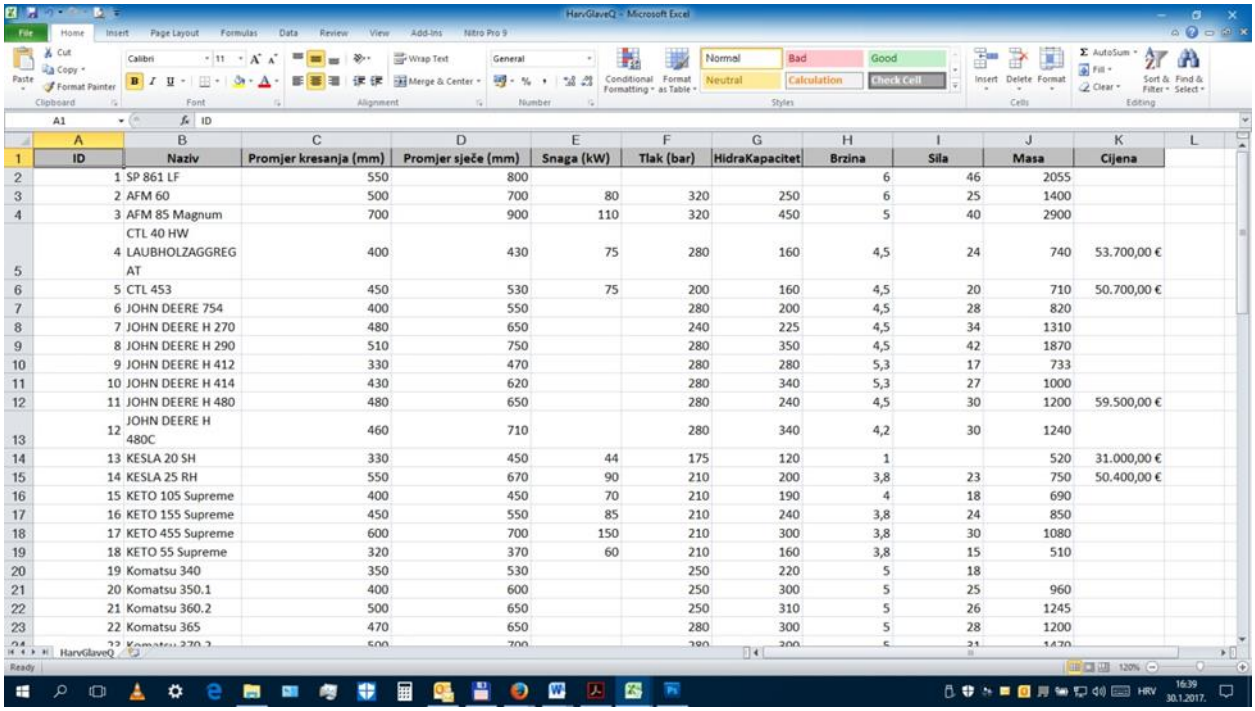

ID	Naziv	Promjer kresanja (mm)	Promjer sječe (mm)	Snaga (kW)	Tlak (bar)	HidraKapacitet	Brzina	Sila	Masa	Cijena
1	SP 861 LF	550	800				6	46	2055	
2	AFM 60	500	700	80	320	250	6	25	1400	
3	AFM 85 Magnum	700	900	110	320	450	5	40	2900	
4	CTL 40 HW LAUBHOLZAGGREGAT	400	430	75	280	160	4,5	24	740	53.700,00 €
5	CTL 453	450	530	75	200	160	4,5	20	710	50.700,00 €
6	JOHN DEERE 754	400	550		280	200	4,5	28	820	
7	JOHN DEERE H 270	480	650		240	225	4,5	34	1310	
8	JOHN DEERE H 290	510	750		280	350	4,5	42	1870	
9	JOHN DEERE H 412	330	470		280	280	5,3	17	733	
10	JOHN DEERE H 414	430	620		280	340	5,3	27	1000	
11	JOHN DEERE H 480	480	650		280	240	4,5	30	1200	59.500,00 €
12	JOHN DEERE H 480C	460	710		280	340	4,2	30	1240	
13	KESLA 20 SH	330	450	44	175	120	1		520	31.000,00 €
14	KESLA 25 RH	550	670	90	210	200	3,8	23	750	50.400,00 €
15	KETO 105 Supreme	400	450	70	210	190	4	18	690	
16	KETO 155 Supreme	450	550	85	210	240	3,8	24	850	
17	KETO 455 Supreme	600	700	150	210	300	3,8	30	1080	
18	KETO 55 Supreme	320	370	60	210	160	3,8	15	510	
19	Komatsu 340	350	530		250	220	5	18		
20	Komatsu 350.1	400	600		250	300	5	25	960	
21	Komatsu 360.2	500	650		250	310	5	26	1245	
22	Komatsu 365	470	650		280	300	5	28	1200	

Slika 4.11 Dio baze podataka harvesterskih glava

Nakon prethodnog istraživanja rada harvestera na području šumarije Gerovo (pokus je detaljnije opisan u Izvješćima za prvo i drugo polugodište istraživanja) zaključeno je da su najvažniji tehničko/proizvodni parametri harvesterskih glava 3 promjera:

1 sječni promjer,
2 promjer prerezivanja,
3 promjer kresanja.

Zbog toga su u morfološkoj raščlambi promatrane upravo ovisnosti ova tri promjera o masi harvesterske glave.

Ovisnost sječnih (sječivih) promjera i promjera prerezivanja o masi harvesterske glave pokazuje slika 4.12. Očekivano, glave veće mase mogu obrađivati stabla većih promjera ali je važno zapaziti da je trend porasta promjera konkavna krivulja. Iskazanom harvesterskom glavom Ponsee H7 bio je opremljen harvester u istraživanju obavljenom u Gerovu.

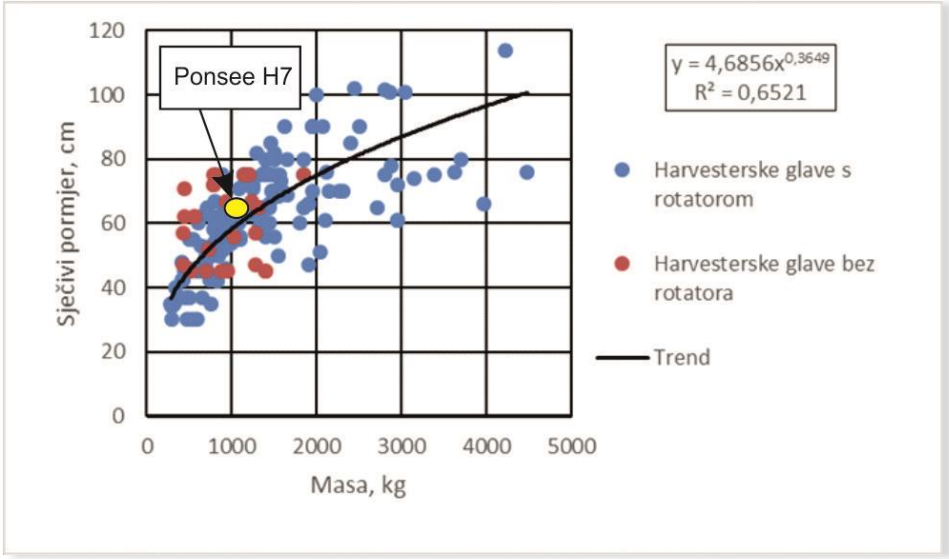

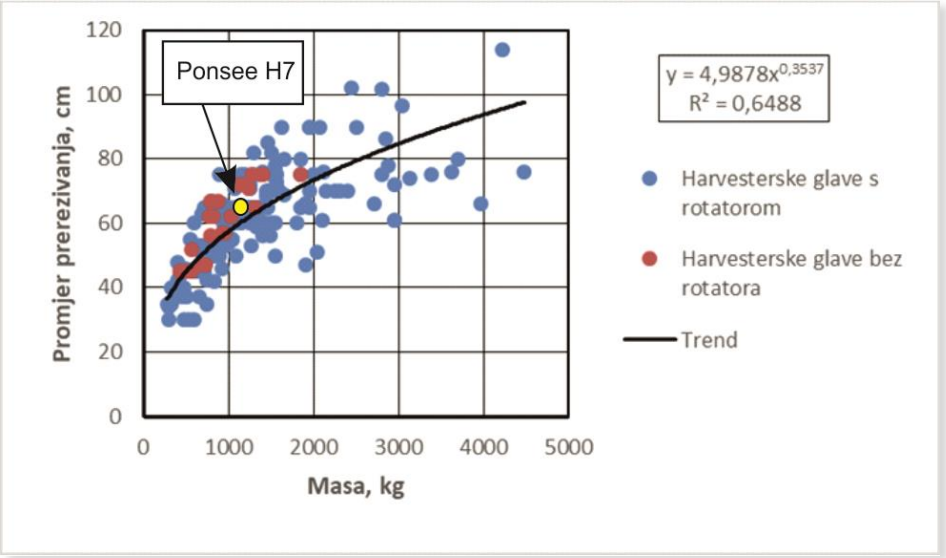

Slika 4.12 Ovisnost sječnih i promjera prerezivanja o masi harvesterske glave

Zapaža se kako su ova dva promjera vrlo slična (pokazuje to i gotovo identična krivulja izjednačenja) te je za ocjenu mogućnosti glava (promjeri stabala) dovoljno promatrati jedan od ova dva promjera.

Nadalje, zapaža se da se analiza može jednako dobro raditi za iskazanu masu harvesterske glave s ili bez rotatora. Očekivano harvesterske glave bez rotatora mogu prerezati stablo većega promjera u odnosu na harvesterske glave s rotatorom.

Ovisnost promjera kresanja grana o masi harvesterskih glava pokazuje slika 4.13 Prva su dva promjera potpuno jasna a treći promjer (prerezivanja) pokazuje do kojega promjera stabla se mogu sječi grane što je vrlo nepouzdan podatak s obzirom da ne uzima u obzir vrstu drveća već samo geometriju noževa za kresanje. Vjerojatno je ipak riječ o crnogoričnom drveću.

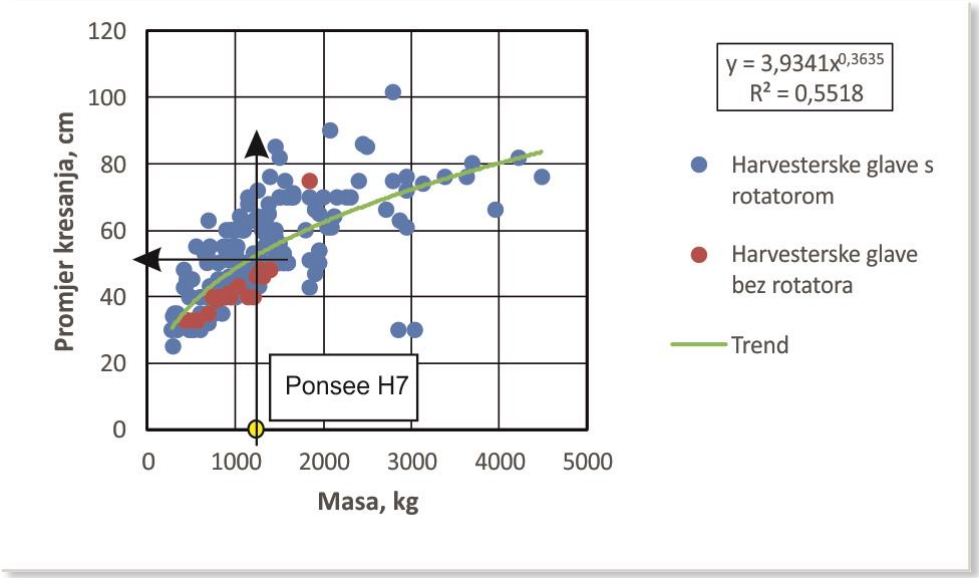

Slika 4.13 Ovisnost promjera kresanja o masi harvesterske glave

Očekivano, teže harvesterske glave mogu procesuirati deblja stabla. Za glavu Ponsee H7 očekivani promjer kresanja je oko 50 cm. Zanimljivo je da u slučaju promatranja harvesterskih glava sa/bez rotatora postoju obrnuto ponašanje nego u slučaju promjera prerezivanja tj. Harvesterska glava bez rotatora može kresati grane na manjem promjeru.

Za razliku od slike 4.8, u slici 4.9 zapaža se da su harvesterske glave s masom iskazanom s rotatorom, grupirane u donjem dijelu distribucije podataka što znači da u analizama ipak treba razlikovati masu harvesterske glave s i bez rotatora. U nastavku istraživanja razdvojit će se analiza za ove dvije podgrupe.

U Katalogu su uključeni podaci 61 modela harvesterskih glava 15 proizvođača, a izgled jedne stranice pokazuje slika 4.14.

PONSSE H7

PONSSE OYJ
Ponssentie 22
FIN-74200 Vieremä
Finska
Internet: www.ponsse.com

TEHNIČKI DETALJI	
Tip	Harvester head equipped with delimbing tools, feed rollers, hydr. chain saw and electr. linear and diameter measurement
Promjer kresanja	600 mm
Sječni promjer	640 mm
Snaga	130 kW
Hidraulični sistem	Open single-circuit hydr. system
Radni tlak	280 bar
Protok	
Spremnik ulja	300 Litara
Sječni sistem	1 fixed and 4 hydr. moving delimbing knives
Uređaj za posmak	3 spiked rollers
Posmična brzina	5,0 m/s
Sila posmaka	30 kN
Mjerni uređaj	PONSSE Opti4G
Masa s rotatorom	1200 kg
Cijena	70000 €

33

Slika 14. Jedna stranica Kataloga šumskih strojeva

4.4 Harvesteri

Posljednja morfološka raščlamba harvestera na napravio je za potrebe svoga diplomskog rada Granić (2013). Njegova je baza nadopunjena i prikazana je na slici 4.15.

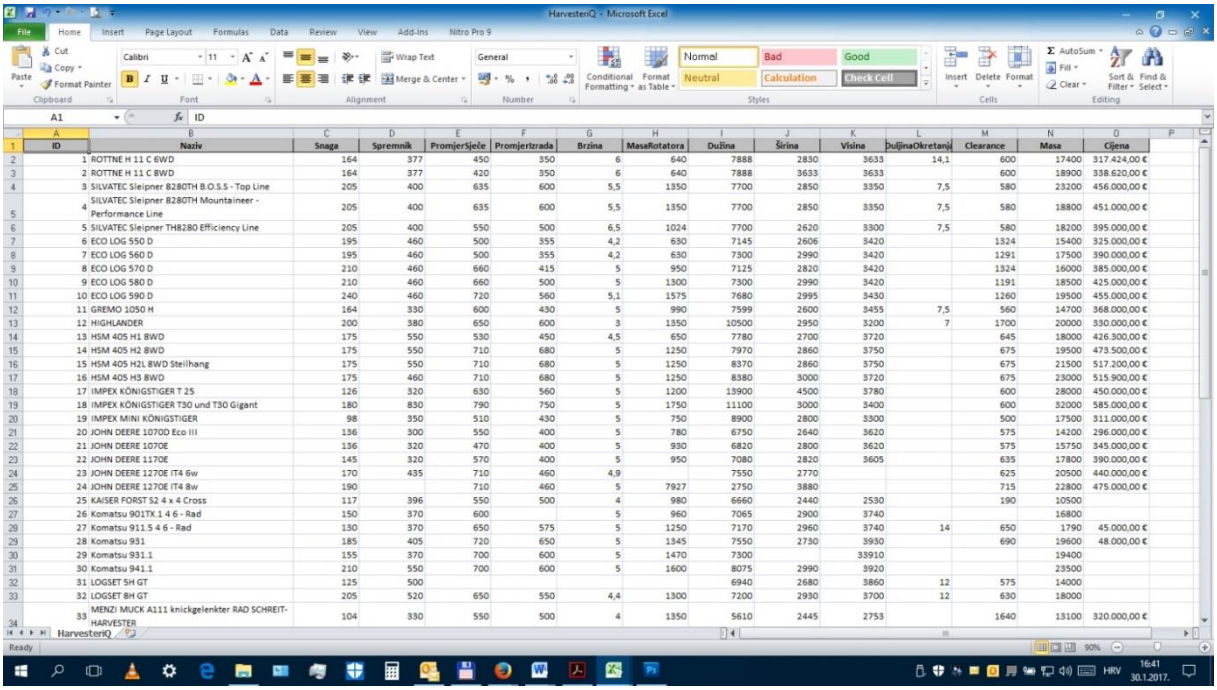

ID	Naziv	Snaga	Spremnik	PromjerSječe	Promjerlzrada	Brzina	MasaRotatora	Dužina	Širina	Visina	DuljinaOkretanja	Clearance	Masa	Cijena
1	ROTTNE H 11 C 6WD	164	377	450	350	6	640	7888	2830	3633	14,1	600	17400	317.424,00 €
2	ROTTNE H 11 C 8WD	164	377	420	350	6	640	7888	3633	3633		600	18900	338.620,00 €
3	SILVATEC Sleipner 8280TH B.O.S.S - Top Line	205	400	635	600	5,5	1350	7700	2850	3350	7,5	580	23200	456.000,00 €
4	SILVATEC Sleipner 8280TH Mountaineer - Performance Line	205	400	635	600	5,5	1350	7700	2850	3350	7,5	580	18800	451.000,00 €
5	SILVATEC Sleipner TH8280 Efficiency Line	205	400	550	500	6,5	1024	7700	2620	3300	7,5	580	18200	395.000,00 €
6	ECO LOG 550 D	195	460	500	355	4,2	630	7145	2606	3420		1324	15400	325.000,00 €
7	ECO LOG 560 D	195	460	500	355	4,2	630	7300	2990	3420		1291	17500	390.000,00 €
8	ECO LOG 570 D	210	460	660	415	5	950	7125	2820	3420		1324	16000	385.000,00 €
9	ECO LOG 580 D	210	460	660	500	5	1300	7300	2990	3420		1191	18500	425.000,00 €
10	ECO LOG 590 D	240	460	720	560	5,1	1575	7680	2995	3430		1260	19500	455.000,00 €
11	GREMO 1050 H	164	330	600	430	5	990	7599	2600	3455	7,5	560	14700	368.000,00 €
12	HIGHLANDER	200	380	650	600	3	1350	10500	2950	3200	7	1700	20000	330.000,00 €
13	HSM 405 H1 8WD	175	550	530	450	4,5	650	7780	2700	3720		645	18000	426.300,00 €
14	HSM 405 H2 8WD	175	550	710	680	5	1250	7970	2860	3750		675	19500	473.500,00 €
15	HSM 405 H2L 8WD Steilhang	175	550	710	680	5	1250	8370	2860	3750		675	21500	517.200,00 €
16	HSM 405 H3 8WD	175	460	710	680	5	1250	8380	3000	3720		675	23000	515.900,00 €
17	IMPEX KÖNIGSTIGER T 25	126	320	630	560	5	1200	13900	4500	3780		600	28000	450.000,00 €
18	IMPEX KÖNIGSTIGER T30 und T30 Gigant	180	830	790	750	5	1750	11100	3000	3400		600	32000	585.000,00 €
19	IMPEX MINI KÖNIGSTIGER	98	350	510	430	5	750	8900	2800	3300		500	17500	311.000,00 €
20	JOHN DEERE 1070D Eco III	136	300	550	400	5	780	6750	2640	3620		575	14200	296.000,00 €
21	JOHN DEERE 1070E	136	320	470	400	5	930	6820	2800	3620		575	15750	345.000,00 €
22	JOHN DEERE 1170E	145	320	570	400	5	950	7080	2820	3605		635	17800	390.000,00 €
23	JOHN DEERE 1270E IT4 6w	170	435	710	460	4,9		7550	2770			625	20500	440.000,00 €
24	JOHN DEERE 1270E IT4 8w	190		710	460	5	7927	2750	3880			715	22800	475.000,00 €
25	KAISER FORST S2 4 x 4 Cross	117	396	550	500	4	980	6660	2440	2530		190	10500	
26	Komatsu 901TX.1 4 6 - Rad	150	370	600		5	960	7065	2900	3740			16800	
27	Komatsu 911.5 4 6 - Rad	130	370	650	575	5	1250	7170	2960	3740	14	650	1790	45.000,00 €
28	Komatsu 931	185	405	720	650	5	1345	7550	2730	3930		690	19600	48.000,00 €
29	Komatsu 931.1	155	370	700	600	5	1470	7300		33910			19400	
30	Komatsu 941.1	210	550	700	600	5	1600	8075	2990	3920			23500	
31	LOGSET 5H GT	125	500					6940	2680	3860	12	575	14000	
32	LOGSET 8H GT	205	520	650	550	4,4	1300	7200	2930	3700	12	630	18000	
33	MENZI MUCK A111 knickgelenkter RAD SCHREIT-HARVESTER	104	330	550	500	4	1350	5610	2445	2753		1640	13100	320.000,00 €

Slika 4.15 Nadopunjena baza podataka harvestera

Harvesteri su prema vrsti pogona i broju kotača podijeljeni u 4 skupine:

1. 4-ero kotačni,
2. 6-ero kotačni,
3. 8-ero kotačni i
4. Gusjenični.

U prvoj morfološkoj analizi harvestera napravljenoj u Izvješću za prvo polugodište (slika 4.16) zapaženo je da se ovisnost važne značajke okolišne pogodnosti – nominalnoga tlaka na tlo (NGP) treba odvojeno promatrati za ove četiri kategorije kako pokazuje slika 4.17.

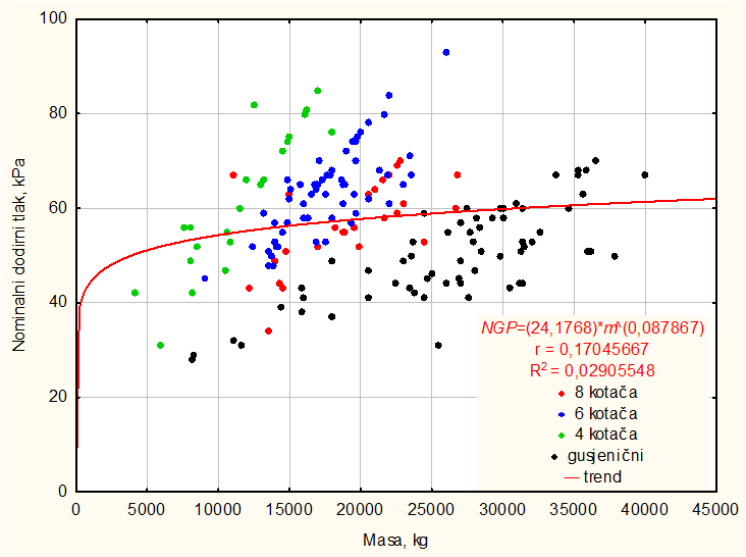

Slika 4.16 Ovisnost NGP-a o masi harvestera s jednom linijom izjednačenja

U slučaju ovakve analize ne samo da je veliko rasipanje podataka već je u rasponu promatranih masa linija izjednačenja gotovo vodoravna. To bi značilo da ovisnost NGP-a o masi harvestera ne

postoji tj. Da harvesteri bez obzira na masu imaju isti NGP (pa čak i unutar jedne kategorije) što je prilično nevjerojatno.

Zbog toga je za ovu ovisnost napravljena nova analiza tako da se kategorije razdvoje. Dobiveni rezultat prikazan na slici 4.17 je blizak očekivanjima.

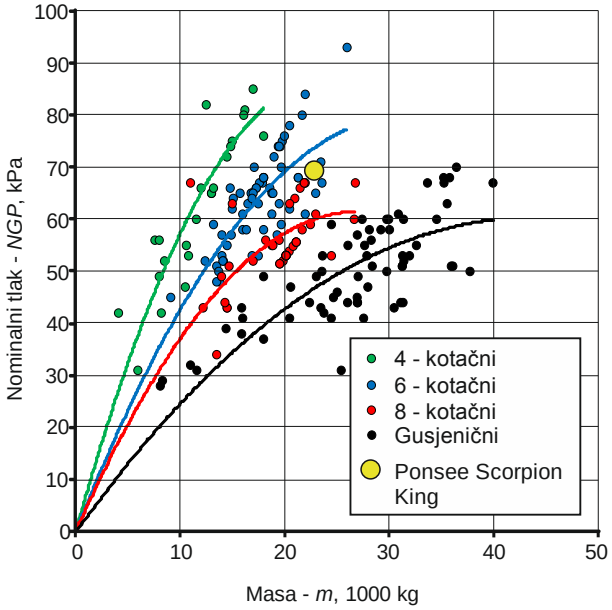

Slika 4.17 Ovisnost NGP-a o masi harvestera odvojeno po kategorijama

U dijagramu na slici 4.17 gdje su uneseni su podaci za ispitivani harvester Ponsee Scorpion King, zapažaju se da su linije izjednačenja sada »logične« i to iz razloga što:

1. Harvesteri većih masa u pojedinoj kategoriji imaju veći NGP,
2. Četvero kotačni harvesteri imaju najveći a gusjenični najmanji NGP.

Jedna od važnih operativnih značajki harvestera je masa harvesterske glave koju mogu na svojoj dizalici nositi. Ta je značajka u odnosu na masu harvestera prikazana na slici 4.18.

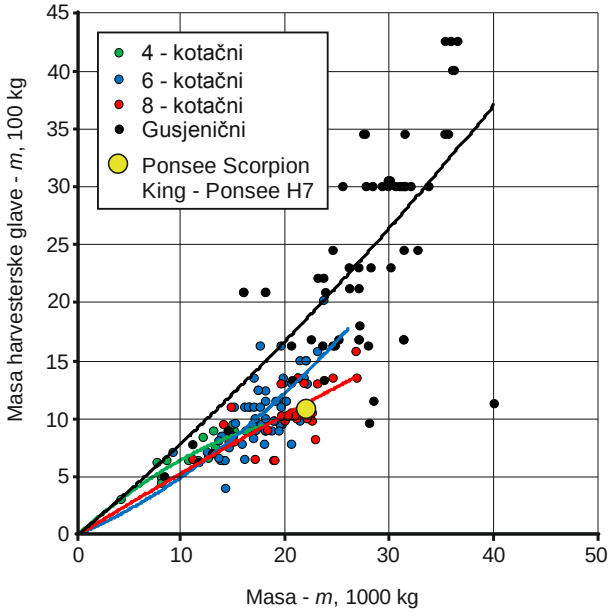

Slika 4.18 Ovisnost mase harvesterske glave o masi harvestera

Ova analiza pokazuje da je u ovom slučaju opravdano posebno promatrati samo skupinu gusjeničnih harvestera a da se kotačni mogu promatrati zajedno. Ipak, ova je analiza pokazala jednu zanimljivost a to je da 8-ero kotačni harvesteri mogu biti opremljeni lakšim glavama nego ostali kotačni? U dijagram su uneseni i podaci za harvester Ponsee Scorpion King opremljenog s harvesterskom

glavom Ponsee H7. Ovaj se 8-ero kotačni harvester s pripadajućom harvesterskom glavom potpuno uklapa u liniju izjednačenja.

Tražeći razlog ovoj anomaliji napravljena je analiza ovisnosti podiznoga momenta dizalice o masi harvestera prikazana na slici 4.19.

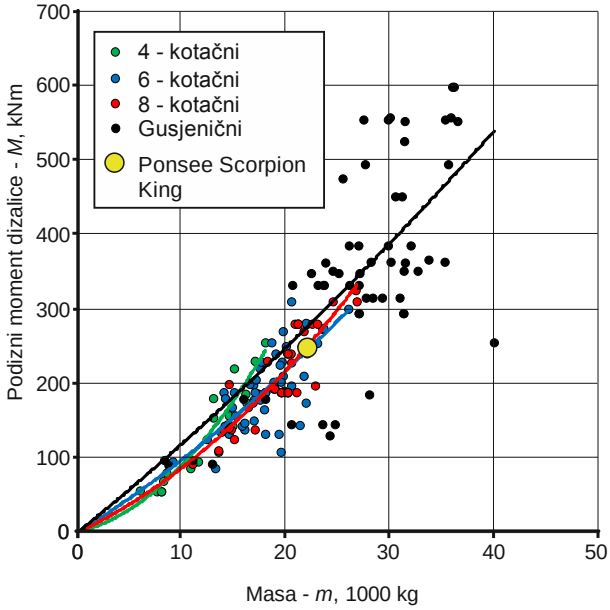

Slika 4.19 Ovisnost podiznoga momenta dizalice o masi harvestera

Iz prikazanoga dijagrama na slici 4.19 zapaža se da se za ovaj odnos parametara mogu sve 4 skupine promatrati zajedno. Isto tako može se reći da nosivost dizalice nije uzrok smanjenju mase harvesterskih glava kod 8-ero kotačnih. Da bi se izbjegla ova anomalija potrebno je ili više podataka ili promatrati kotačne harvestere kao jednu skupinu. Očekivano harvesteri veće mase imaju dizalice većega podiznog momenta.

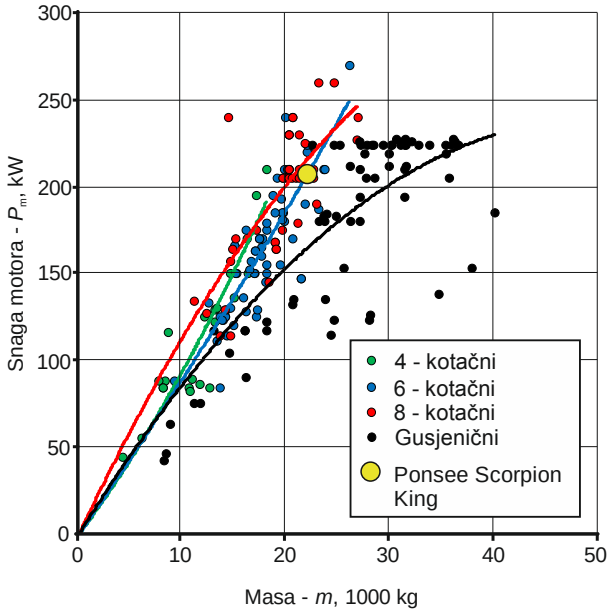

Slika 4.20 Ovisnost snage motora harvestera o njegovoj masi

Usporedba mase harvestera i snage njihovih motora prikazana na slici 4.20 ponovo pokazuje da se kotačni harvesteri mogu promatrati zajedno a gusjenični odvojeno. Zanimljivo, ali i očekivano, gusjenični harvesteri imaju, relativno, u odnosu na vlastitu masu najmanju snagu motora.

Širina harvestera važan je pokazatelj okolišne pogodnosti ali i mogućnosti transporta po javnim cestama. Širinom od oko 3 m (srednja širina) harvester Ponsee Scorpio King premašuje dopuštenu širinu za kamione što znači da će se morati transportirati pod pratnjom. Visinom od malo ispod 4 m

(3720 mm) zahtjeva prijevoz posebnim niskopodnim prikolica. Ovo, naravno, vrijedi i za ostale harvestere osim za nekolicinu četverokotačnih. Ovu ovisnost pokazuje slika 4.21.

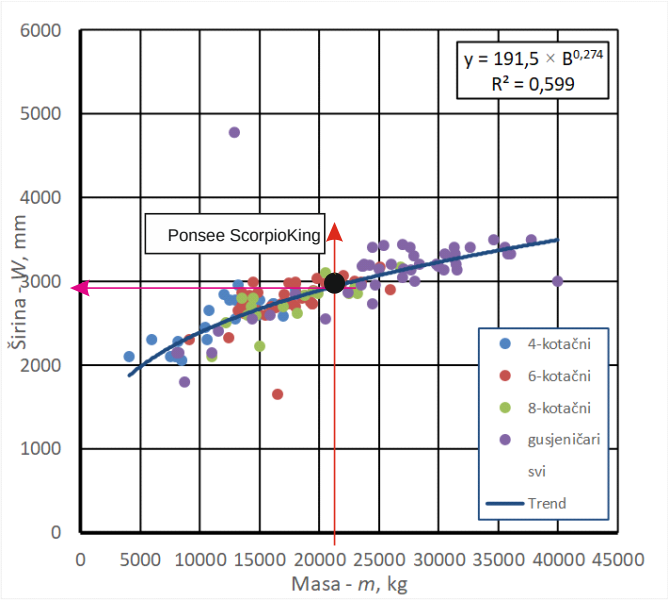

Slika 4.21. Ovisnost širine harvestera o masi

U Katalog je uvršteno 60 modela 16 proizvođača kako pokazuje slika 4.22.

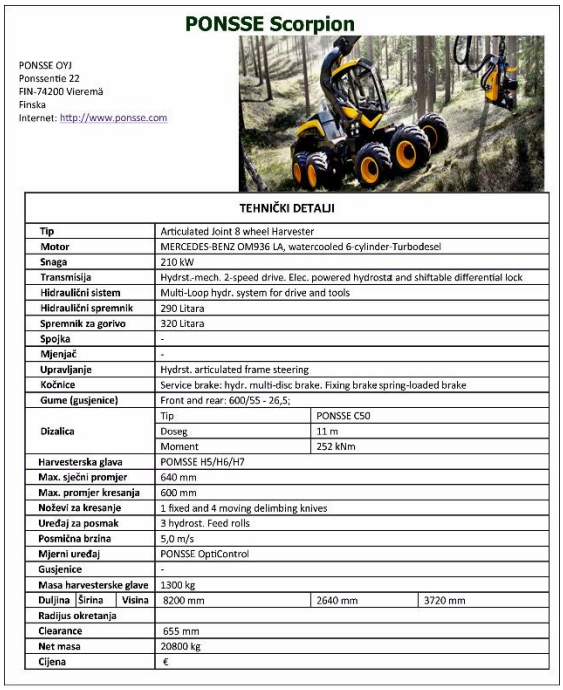

PONSSE Scorpion

PONSSE OYJ
Ponssentie 22
FIN-74200 Vieremä
Finska
Internet: http://www.ponsse.com

TEHNIČKI DETALJI			
Tip	Articulated Joint 8 wheel Harvester		
Motor	MERCEDES-BENZ OM936 LA, watercooled 6-cylinder-Turbodesel		
Snaga	210 kW		
Transmisija	Hydrst.-mech. 2-speed drive. Elec. powered hydrostat and shiftable differential lock		
Hidraulični sistem	Multi-Loop hydr. system for drive and tools		
Hidraulični spremnik	290 Litara		
Spremnik za gorivo	320 Litara		
Spojka	-		
Mjenjač	-		
Upravljanje	Hydrst. articulated frame steering		
Kočnice	Service brake: hydr. multi-disc brake. Fixing brake spring-loaded brake		
Gume (gusjenice)	Front and rear: 600/55 - 26,5;		
Dizalica	Tip	PONSSE C50	
	Doseg	11 m	
	Moment	252 kNm	
Harvesterska glava	POMSSE H5/H6/H7		
Max. sječni promjer	640 mm		
Max. promjer kresanja	600 mm		
Noževi za kresanje	1 fixed and 4 moving delimbing knives		
Uređaj za posmak	3 hydrost. Feed rolls		
Posmična brzina	5,0 m/s		
Mjerni uređaj	PONSSE OptiControl		
Gusjenice	-		
Masa harvesterske glave	1300 kg		
Duljina | Širina | Visina	8200 mm	2640 mm	3720 mm
Radijus okretanja	-		
Clearance	655 mm		
Net masa	20800 kg		
Cijena	€		

Slika 4.22 Izgled jedne stranice Kataloga harvestera

4.5 Skideri

Prva bazu podataka skidera (Sever, 1981) pretvorena je u računalnu (Sever i Horvat 1992a, Sever i Horvat 1992b) te je kasnije nadopunjavana i korištena za različite svrhe; korištena je u analizi dobrote rada skidera kao što su napravili Horvat i dr. (2007), a najvažnija je bila primjena u dva tehnologijska projekta MZOŠ RH – »Razvoj, izrada i ispitivanje prototipa skidera mase 7 t« iz programa TEST, te»Razvoj, izrada i ispitivanje specijalnog šumskog vozila – skidera mase 7 t« iz programa RAZUM. Rezultat ova dva projekta je bila izrada prototipa domaćeg skidera Ecotrac 120V koji je danas u redovitoj proizvodnji te je najbrojniji skider u Hrvatskoj. Veliko obnovu ove baze napravio je Šušnjar (2005). Od toga doba baza je stalno nadopunjavana, uglavnom u sklopu

diplomskih radova studenata Šumarskoga fakulteta, a posljednju nadopunu je napravio Batinić (2013). Izgled trenutne baze podataka skidera pokazuje slika 4.23.

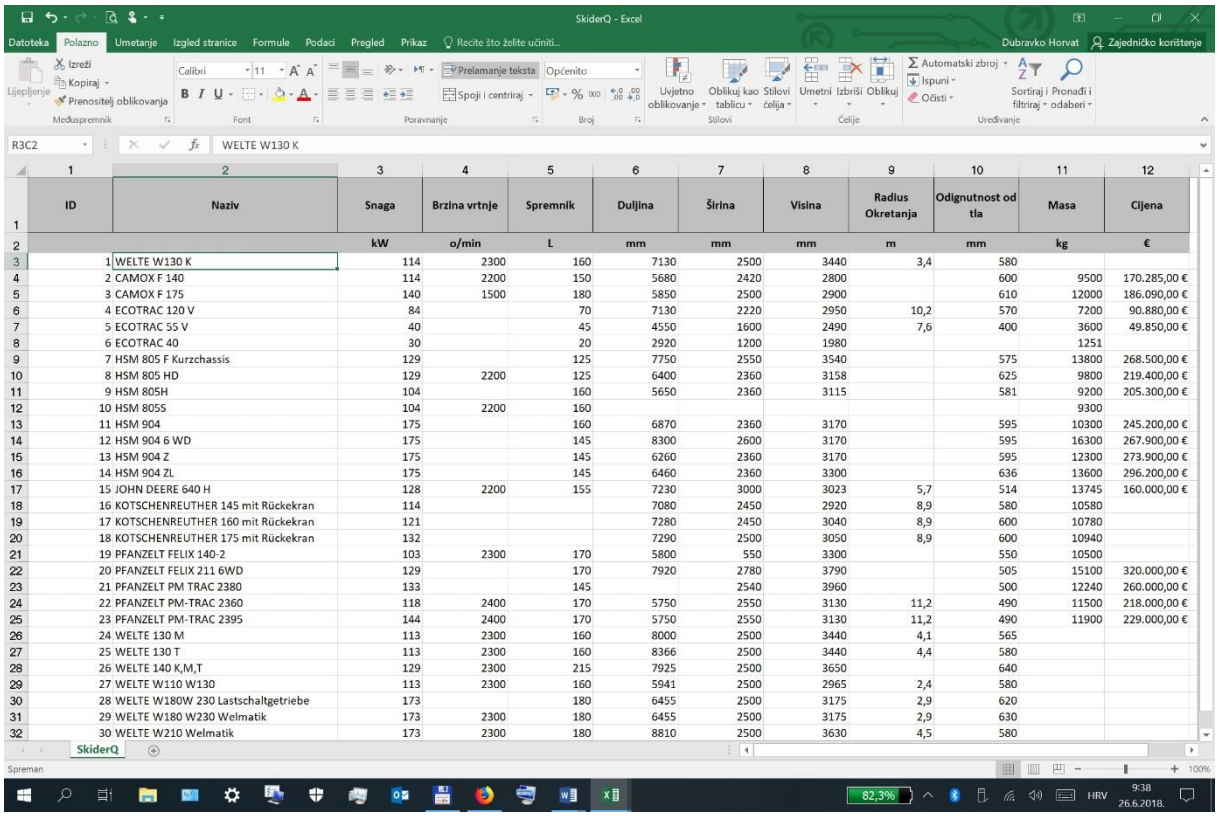

ID	Naziv	Snaga	Brzina vrtnje	Spremnik	Duljina	Širina	Visina	Radius Okretanja	Odignutnost od tla	Masa	Cijena
		kW	o/min	L	mm	mm	mm	m	mm	kg	€
1	WELTE W130 K	114	2300	160	7130	2500	3440	3,4	580		
2	CAMOX F 140	114	2200	150	5680	2420	2800		600	9500	170.285,00 €
3	CAMOX F 175	140	1500	180	5850	2500	2900		610	12000	186.090,00 €
4	ECOTRAC 120 V	84		70	7130	2220	2950	10,2	570	7200	90.880,00 €
5	ECOTRAC 55 V	40		45	4550	1600	2490	7,6	400	3600	49.850,00 €
6	ECOTRAC 40	30		20	2920	1200	1980			1251	
7	HSM 805 F Kurzchassis	129		125	7750	2550	3540		575	13800	268.500,00 €
8	HSM 805 HD	129	2200	125	6400	2360	3158		625	9800	219.400,00 €
9	HSM 805H	104		160	5650	2360	3115		581	9200	205.300,00 €
10	HSM 805S	104	2200	160						9300	
11	HSM 904	175		160	6870	2360	3170		595	10300	245.200,00 €
12	HSM 904 6 WD	175		145	8300	2600	3170		595	16300	267.900,00 €
13	HSM 904 Z	175		145	6260	2360	3170		595	12300	273.900,00 €
14	HSM 904 ZL	175		145	6460	2360	3300		636	13600	296.200,00 €
15	JOHN DEERE 640 H	128	2200	155	7230	3000	3023	5,7	514	13745	160.000,00 €
16	KOTSCHENREUTHER 145 mit Rückekran	114			7080	2450	2920	8,9	580	10580	
17	KOTSCHENREUTHER 160 mit Rückekran	121			7280	2450	3040	8,9	600	10780	
18	KOTSCHENREUTHER 175 mit Rückekran	132			7290	2500	3050	8,9	600	10940	
19	PFANZELT FELIX 140-2	103	2300	170	5800	550	3300		550	10500	
20	PFANZELT FELIX 211 6WD	129		170	7920	2780	3790		505	15100	320.000,00 €
21	PFANZELT PM TRAC 2380	133		145		2540	3960		500	12240	260.000,00 €
22	PFANZELT PM-TRAC 2360	118	2400	170	5750	2550	3130	11,2	490	11500	218.000,00 €
23	PFANZELT PM-TRAC 2395	144	2400	170	5750	2550	3130	11,2	490	11900	229.000,00 €
24	WELTE 130 M	113	2300	160	8000	2500	3440	4,1	565		
25	WELTE 130 T	113	2300	160	8366	2500	3440	4,4	580		
26	WELTE 140 K,M,T	129	2300	215	7925	2500	3650		640		
27	WELTE W110 W130	113	2300	160	5941	2500	2965	2,4	580		
28	WELTE W180W 230 Lastschaltgetriebe	173		180	6455	2500	3175	2,9	620		
29	WELTE W180 W230 Welmatik	173	2300	180	6455	2500	3175	2,9	630		
30	WELTE W210 Welmatik	173	2300	180	8810	2500	3630	4,5	580		

Slika 4.23. Dio baze podataka skidera

Morfološka je raščlamba skidera napravljena puno puta i ovdje će se dati samo najvažniji naglasci.

Sever (1981) je skidere temeljem tadašnje razine znanja podijelio u dvije skupine:

1. Srednji skideri mase do 5 t
2. Skideri mase veće od 5 t

Današnji pokazatelji primjene skidera, a što je i **prijedlog ovoga projekta**, upućuju da se skideri mogu podijeliti u tri skupine:

1. Proredni (mali) skideri mase ispod 5 t
2. Skideri (najčešći, univerzalni) mase između 5 t i 10 t
3. Veliki skider mase iznad 10 t namjenjeni najtežim sastojinskim i reljefnim uvjetima i stabalnoj metodi

Ovakva je podjela prikazana u morfološkoj raščlambi koja slijedi. U dijagrame su uneseni podaci za dva domaća skidera: Ecotrac 55v (proredni) i Ecotrac 120V (skider). To podupire i trenutni broj skidera u poduzeću »Hrvatske šume« kako su prikazali Beuk i dr. (2007).

Dijagramom na slici 4.24 pokazana je ovisnost snage motora o masi skidera na kojoj se zapaža jako čvrsta veza promatranih parametara. Položaj prorednoga skidera Ecotrac 55V je točno na liniji izjednačenja što podupire ugradnju motora povećane snage u odnosu na njegove prve inačice. Upitno je samo dimenzioniranje mjenjača. Skider Ecotrac 120V opremljen je motorom snage nešto iznad linije izjednačenja, što nije jedini slučaj među tom familijom, ali je bio izričiti zahtjev šumarske struke tijekom njegovoga konstruiranja.

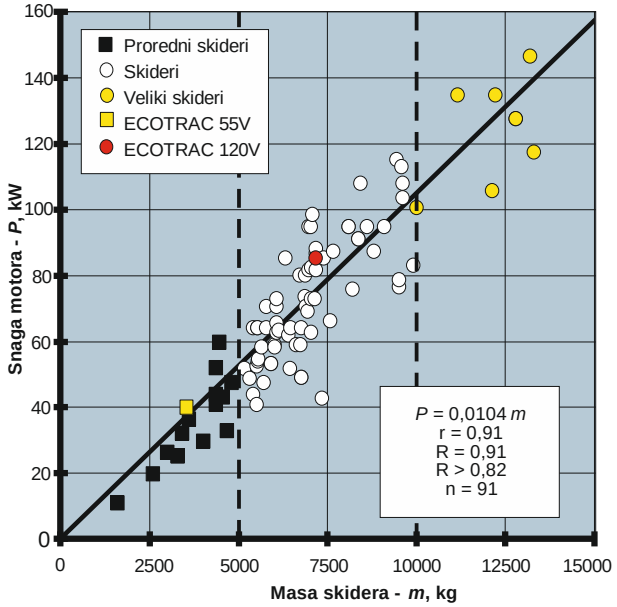

Slika 4.24 Ovisnost snage motora o masi skidera

Dimenzijske značajke skidera prikazane su u nizu od 3 dijagrama na slikama 4.25, 4.26 i 4.27.

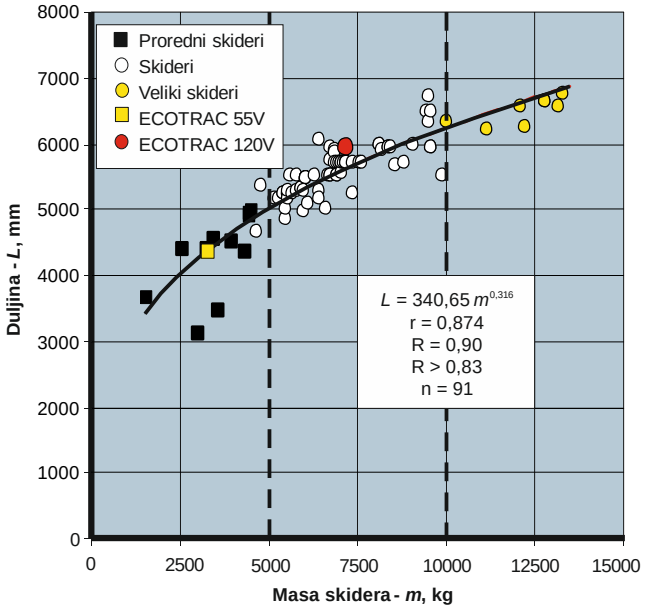

Slika 4.25. Ovisnost duljine o masi skidera

Osim izrazito čvrste veze (slika 4.25) zapaža se povoljni konkavni oblik krivulje izjednačenja te da je domaći proredni skider na krivulji. Domaći skider je nešto iznad krivulje izjednačenja, opet ne kao izuzetak.

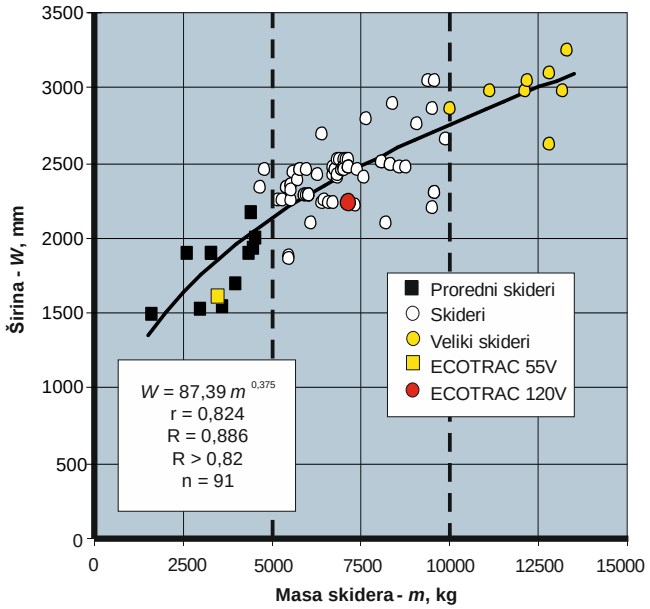

Slika 4.26 Ovisnost širine i mase skidera

Ovisnost širine o masi skidera je također s čvrstom, konkavnom vezom. Obadva domaća skidera su ispod linije izjednačenja što se može smatrati povoljnom značajkom osim ako nije ugrožena bočna stabilnost. Posebno mala širina od 1600m Ecotraca 55V bila je zahtijevana od šumarske prakse tijekom njegovoga projektiranja.

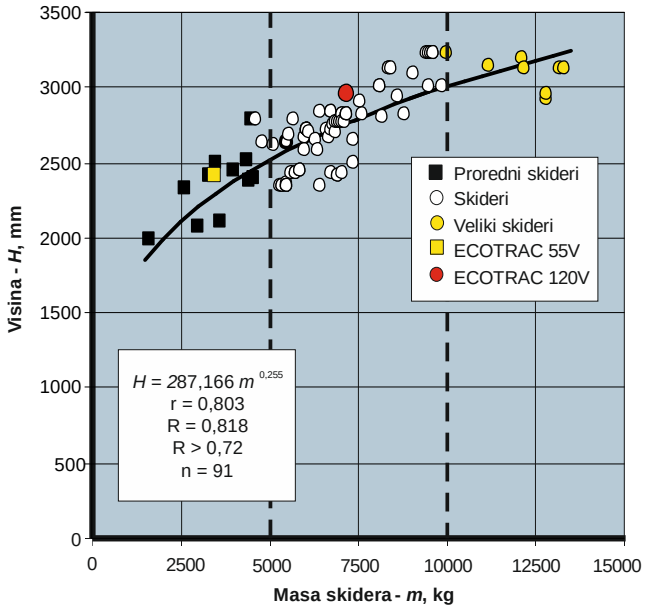

Slika 4.27 Ovisnost visine skidera o njegovoj masi

Čvrsta veza između visine i mase skidera je opet čvrsta i povoljno konkavna. Oba su domaća skidera iznad linije izjednačenja što se može tumačiti činjenicom da su opremljeni kabinama koje zadovoljavaju FOPS i ROPS standarde kao i sve konstrukcijske, sigurnosne i ergonomske zahtjeve ISO standarda za kabine šumskih vozila.

U Katalogu šumskih strojeva prikazane su značajke 27 novijih modela 6 proizvođača a jednu stranicu prikazuje slika 4.28.

U podacima su uvršteni i neki tehnički detalji koji se ne mogu kvantificirati ali mogu pomoći kod izbora kao što je opis mjenjača. U posebnu su kolonu izdvojeni podaci o vitlu koji su također značajni za izbor, primjerice, opremanje jednobubanjskim ili dvobubanjskim vitlom. Skideri u principu dolaze opremljeni vitlom ali se u slučaju da značajke vitla nisu odgovarajuće može nabaviti skider bez vitla te naknadno ugraditi vitlo kao što je bio čest slučaj u Hrvatskoj nakon nabave skidera Timberjack

240C. Ovakva se dodatna ugradnja ne preporučuje pogotovo što se tada moraju dodatno regulirati uvjeti garancije.

ECOTRAC 120 V

HITTNER d.o.o.
Pakracka ulica 10
HR-43000 Bjelovar
Hrvatska
Tel.:00385(0)43/244111
E-mail: info@hittner.hr
Internet: www.hittner.hr

TEHNIČKI DETALJI

Tip	Articulated steered forestry tractor, 4 same size wheels. All wheel drive and double-drum winch	**Vitlo**	Electro-hydraulic double winch Typ VH 80
Motor	Aircooled DEUTZ Typ F6L-914 Diesel engine	**Ulazna sila**	80 Kn
Snaga	84 KW	**Izlazna sila**	50 kN
Broj okretaja		**Unutarnji R bubnja**	200 mm
Spojka	Multi disc clutch	**Vanjski R bubnja**	490 mm
Mjenjač	Synchronised shift gearbox with 10 forward gears and 2 reverse gears	**Duljina užeta**	70 m
Osovina	Axle with differential lock	**Promjer užeta**	14 mm
Upravljanje	Hydraulic articulated frame steering	**Pomoćno uže**	-
Kočnice	Hydraulic disc brake oil-cooled Parking brake	**Prosječna brzina užeta**	0,63 m/s
Spremnik	70 Litara	**Pogon**	Hydrostatic
Prednja odrivna daska	Hydraulic tilt able via 2 hydraulic cylinders	**Reduktor vitla**	Worm wheel gear box
Stražnja odrivna daska	hydraulic lift and low able	**Spojka vitla**	Hydr. disc cluch
Gume	16.9 - 30 R, 14 pr	**Kočnica vitla**	Hydr. multi disc-brake
Sigurnosni sistem	Steel protection cabin	**Upravljač vitla**	Electro-hydraulic with joystic
Duljina / širina / visina	7130 mm / 2220 mm / 2950 mm		
Visina težišta			
Radius okretanja	10,2 m		
Clearance	570 mm		
Masa	**Pred.Osovin**		
	Straž.Osovin		
	Net masa	7200 kg	
Ostalo			
Cijena	**90880** €		

Slika 4.28 Jedna stranica Kataloga skidera

4.6 Forvarderi

Tehničko-tehnološko istraživanje rada forvardera na Šumarskome fakultetu u Zagrebu ima dugogodišnju tradiciju s obzirom da je njihova primjena u hrvatskome šumarstvu započela krajem 70-tih godina prošloga stoljeća. Najopsežnija su istraživanja obuhvaćena doktoratima (Horva, 1994, Poršinsky 2005, Stankić 2010, Pandur 2013) većinom članova tima u ovome projektu. Sustav harvester-forvarder prvi istražuje Vusić (2013).

Prva digitalizirana baza podataka forvardera (Sever i Horvat 1992, Horvat 1993) se tijekom godina stalno obnavljala a posljednja nadopuna prije rada na ovome projektu je bila 2013 godine (Pandur 2013, Golubović 2013). Posljednja nadopuna u svrhu istraživanja na ovome projektu napravljena je 2016. godine kao diplomski rad (Barešić 2016) u kojem su analizirane smjernice razvoja forvardera.

Baza tehničkih podataka forvrdera prikazana je na slici 4.29.

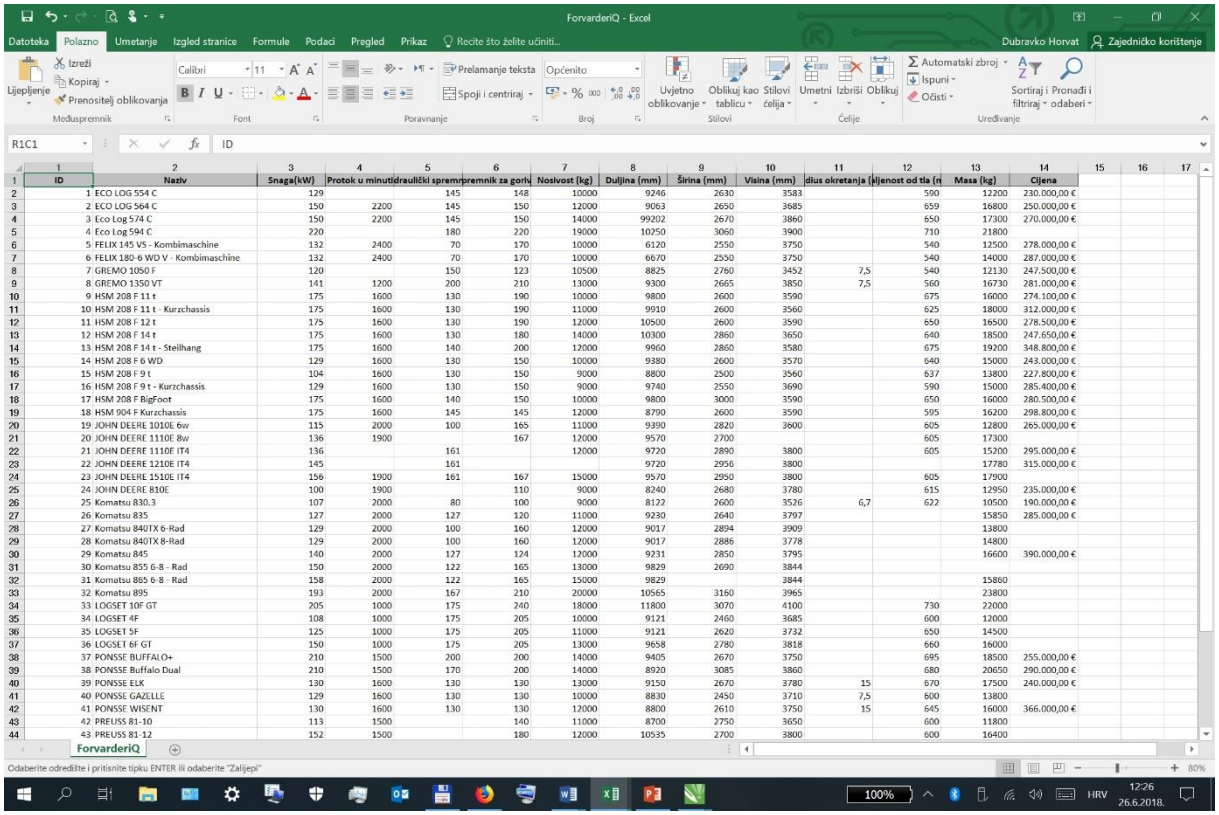

ID	Naziv	Snaga(kW)	Protok u minuti	draulički sprem	premnik za gorivo	Nosivost (kg)	Duljina (mm)	Širina (mm)	Visina (mm)	dius okretanja (	ljenost od tla (m	Masa (kg)	Cijena
1	ECO LOG 554 C	129		145	148	10000	9246	2630	3583		590	12200	230.000,00 €
2	ECO LOG 564 C	150	2200	145	150	12000	9063	2650	3685		659	16800	250.000,00 €
3	Eco Log 574 C	150	2200	145	150	14000	99202	2670	3860		650	17300	270.000,00 €
4	Eco Log 594 C	220		180	220	19000	10250	3060	3900		710	21800	
5	FELIX 145 VS - Kombimaschine	132	2400	70	170	10000	6120	2550	3750		540	12500	278.000,00 €
6	FELIX 180-6 WD V - Kombimaschine	132	2400	70	170	10000	6670	2550	3750		540	14000	287.000,00 €
7	GREMO 1050 F	120		150	123	10500	8825	2760	3452	7,5	540	12130	247.500,00 €
8	GREMO 1350 VT	141	1200	200	210	13000	9300	2665	3850	7,5	560	16730	281.000,00 €
9	HSM 208 F 11 t	175	1600	130	190	10000	9800	2600	3590		675	16000	274.100,00 €
10	HSM 208 F 11 t - Kurzchassis	175	1600	130	190	11000	9910	2600	3560		625	18000	312.000,00 €
11	HSM 208 F 12 t	175	1600	130	190	12000	10500	2600	3590		650	16500	278.500,00 €
12	HSM 208 F 14 t	175	1600	130	180	14000	10300	2860	3650		640	18500	247.650,00 €
13	HSM 208 F 14 t - Steilhang	175	1600	140	200	12000	9960	2860	3580		675	19200	348.800,00 €
14	HSM 208 F 6 WD	129	1600	130	150	10000	9380	2600	3570		640	15000	243.000,00 €
15	HSM 208 F 9 t	104	1600	130	150	9000	8800	2500	3560		637	13800	227.800,00 €
16	HSM 208 F 9 t - Kurzchassis	129	1600	130	150	9000	9740	2550	3690		590	15000	285.400,00 €
17	HSM 208 F BigFoot	175	1600	140	150	10000	9800	3000	3590		650	16000	280.500,00 €
18	HSM 904 F Kurzchassis	175	1600	145	145	12000	8790	2600	3590		595	16200	298.800,00 €
19	JOHN DEERE 1010E 6w	115	2000	100	165	11000	9390	2820	3600		605	12800	265.000,00 €
20	JOHN DEERE 1110E 8w	136	1900		167	12000	9570	2700			605	17300	
21	JOHN DEERE 1110E IT4	136		161		12000	9720	2890	3800		605	15200	295.000,00 €
22	JOHN DEERE 1210E IT4	145		161			9720	2956	3800			17780	315.000,00 €
23	JOHN DEERE 1510E IT4	156	1900	161	167	15000	9570	2950	3800		605	17900	
24	JOHN DEERE 810E	100	1900		110	9000	8240	2680	3780		615	12950	235.000,00 €
25	Komatsu 830.3	107	2000	80	100	9000	8122	2600	3526	6,7	622	10500	190.000,00 €
26	Komatsu 835	127	2000	127	120	11000	9230	2640	3797			15850	285.000,00 €
27	Komatsu 840TX 6-Rad	129	2000	100	160	12000	9017	2894	3909			13800	
28	Komatsu 840TX 8-Rad	129	2000	100	160	12000	9017	2886	3778			14800	
29	Komatsu 845	140	2000	127	124	12000	9231	2850	3795			16600	390.000,00 €
30	Komatsu 855 6-8 - Rad	150	2000	122	165	13000	9829	2690	3844				
31	Komatsu 865 6-8 - Rad	158	2000	122	165	15000	9829		3844			15860	
32	Komatsu 895	193	2000	167	210	20000	10565	3160	3965			23800	
33	LOGSET 10F GT	205	1000	175	240	18000	11800	3070	4100		730	22000	
34	LOGSET 4F	108	1000	175	205	10000	9121	2460	3685		600	12000	
35	LOGSET 5F	125	1000	175	205	11000	9121	2620	3732		650	14500	
36	LOGSET 6F GT	150	1000	175	205	13000	9658	2780	3818		660	16000	
37	PONSSE BUFFALO+	210	1500	200	200	14000	9405	2670	3750		695	18500	255.000,00 €
38	PONSSE Buffalo Dual	210	1500	170	200	14000	8920	3085	3860		680	20650	290.000,00 €
39	PONSSE ELK	130	1600	130	130	13000	9150	2670	3780	15	670	17500	240.000,00 €
40	PONSSE GAZELLE	129	1600	130	130	10000	8830	2450	3710	7,5	600	13800	
41	PONSSE WISENT	130	1600	130	130	12000	8800	2610	3750	15	645	16000	366.000,00 €
42	PREUSS 81-10	113	1500		140	11000	8700	2750	3650		600	11800	
43	PREUSS 81-12	152	1500		180	12000	10535	2700	3800		600	16400	

Slika 4.29 Baza podataka forvardera

Prva analiza koja je napravljena odnosila se na ovisnost snage motora o masi forvardera prikazana na slici 4.30.

Razvrstavanje forvardera je napravljeno kao i kod harvestera na temelju vrste pogona (broj kotača) a gusjenični nisu promatrani. U dijagramu je istaknut položaj forvardera Timberjack 1110D koji je tijekom pokusa u šumariji Gerovo radio u paru s harvesterom Ponsee Scorpio King.

Uočena veza za sve vrste forvardera između parametara (masa-snaga) je srednje do jake čvrstoće što znači da je izborom forvardera neke mase praktički izabrana i snaga njegovoga motora. Može se zapaziti da forvardera mase manje od 10 t gotovo da nema pa se stoga može reći da tzv. prorednih forvardera na tržištu i nema. Pri tome treba na umu imati činjenicu da bi proredni forvarderi, na temelju hrvatskoga iskustva s traktorskim prorednim ekipažama, trebali biti opremljeni i vitlom (dvobubanjskim).

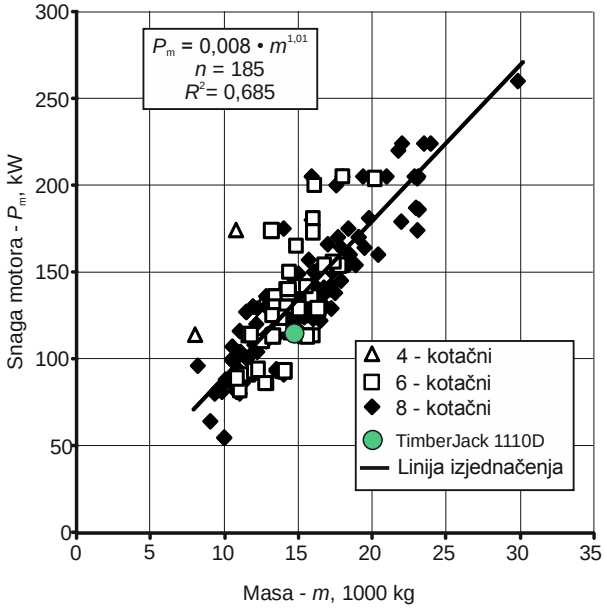

Slika 4.30 Ovisnost snage motora o masi dizalice

Forvarder Timberjack 1110D mase oko 15 t se nalazi u području masa forvardera kakvi bi zadovoljili potrebe privlačenja drva nakon oplodnih sječa za koje smatramo da trebaju biti između 12 i 17 t. Nakon određivanja raspona traženih masa za forvardere treba pogledati kakva se nosivost treba očekivati. Iz toga je razloga u dijagramu na slici 4.31 prikazana ovisnost nosivosti forvardera o njegovoj masi.

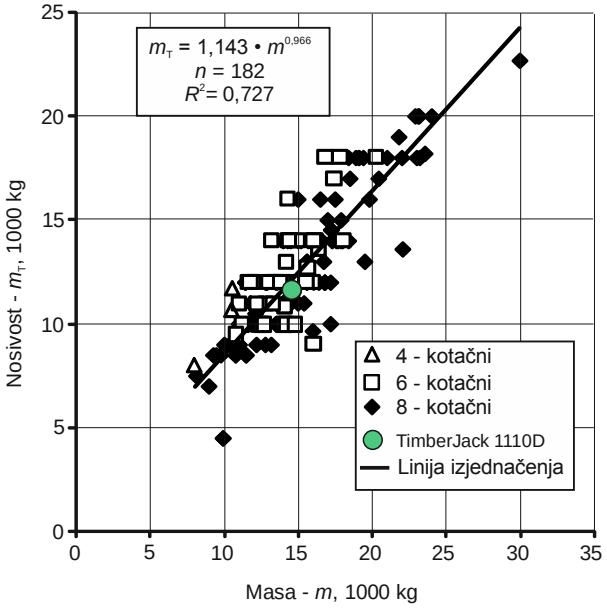

Slika 4.31 Ovisnost nosivosti forvardera o njegovoj masi

Veza je ovih parametara čvrsta što znači da nakon izbora mase forvardera treba očekivati i određenu nosivost. Primjerice za forvarder mase 15 t očekuje se nosivost od 12,5 t a na dijagramu se vidi da postoje forvarderi s masom od 15 t koji imaju nosivost 10 t ali i takvi čija je nosivost 17 t. Ako je nosivost kriterij za izbor forvardera tada treba izabrati onaj veće nosivosti jer će tada i okolišni i energijski kriteriji biti bolji. Promatrani forvarder TJ 1110D je praktički na granici izjednačenja.

Važan okolišni parametar forvardera, jednako kao i harvestera, je nominalni tlak na tlo (NGP). Ovisnost ovoga parametra o masi forvardera prikazana je na slici 4.32.

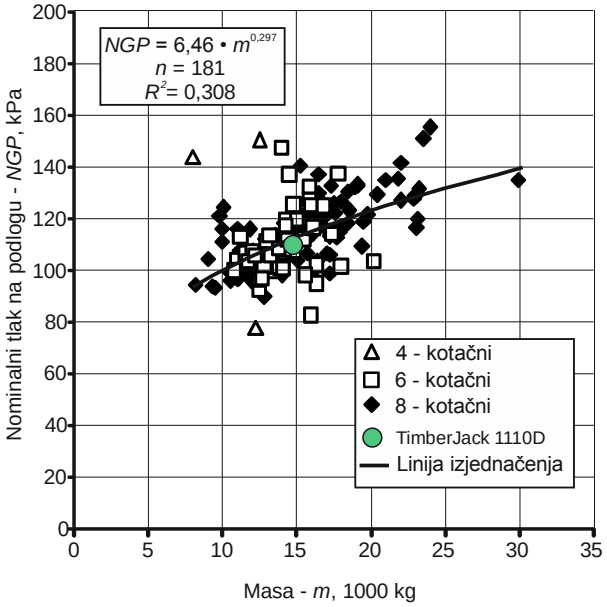

Slika 4.32 Ovisnost NGP-a o masi forvardera

Iz dijagrama se zapaža da, logično, teži forvarderi imaju veći NGP. Krivulja izjednačenja je određena slabom vezom (rasipanje podataka) i tek je blago rastuća i malo konkavna što znači da se može zamijeniti i pravcem. Ono što je dobro je da nije proporcionalna tj. forvarder dvostruko veće mase neće imati i dvostruko veći NGP.

Promatrani forvarder TJ 1110D ima NGP oko 110 kPa što je znatno više od uparenoga mu harvestera Ponsee Scorpio. Temeljem preporuka EcoWood klasifikacije (tablica 4.1) ovaj se forvarder može rabiti samo na izuzetno čvrstim tlima s konusnim indeksom većim od 500 kPa.

Tablica 4.1- EcoWood raščlamba razreda čvstoće tla (Owende i dr. 2002)

Čvrstoća (nosivost) tla		Parametri čvrstoće tla*			Dopušteno opterećenje
		Konusni indeks	Modul elastičnosti	Otpor tla na smicanje	vozila na tlo
Razredi	Opis	*CI*, kPa	*E*, MPa	τ, kPa	*NGP*, kPa
1	**Čvrsto tlo**	> 500	> 60	> 60	> 80
2	**Osrednje čvrsto tlo**	300 – 500	20 – 60	20 – 60	60 – 80
3	**Meko tlo**	< 300	< 20	< 20	40 – 60
4	**Vrlo meko tlo**	<< 300	<< 20	<< 20	< 40

Na radilištu u šumariji Gerovo, gdje je obavljen pokus, izmjereni je konusni indeks tla bio veći od 1000 kPa što znači da se ovaj forvarder može upotrebljavati bez opasnosti za preveliko zbijanje tla.

Ako ga se pak želi rabiti na osrednje čvrstome tlu treba se opremati polugusjenicama na oba nogi sustava kotača jer je tada površina nalijeganja 1,75 puta veća za rijetke, sve do 3 puta veća za guste polugusjenice.

Forvarderi su zbog svog temeljnog principa prevoženja drvnih sortimenata izrazito velika vozila pa je zbog toga u dijagramima na slikama 4.33, 4.34 i 4.35 obavljena analiza ovisnosti gabaritnih dimenzija forvardera o njegovoj masi. Duljina je forvardera u srednje jakoj do jakoj vezi s njegovom masom, konkavna je i blago zakrivljena. Za skupinu forvardera između 12 i 15 t treba očekivati duljinu između 9 i 9,5 m.

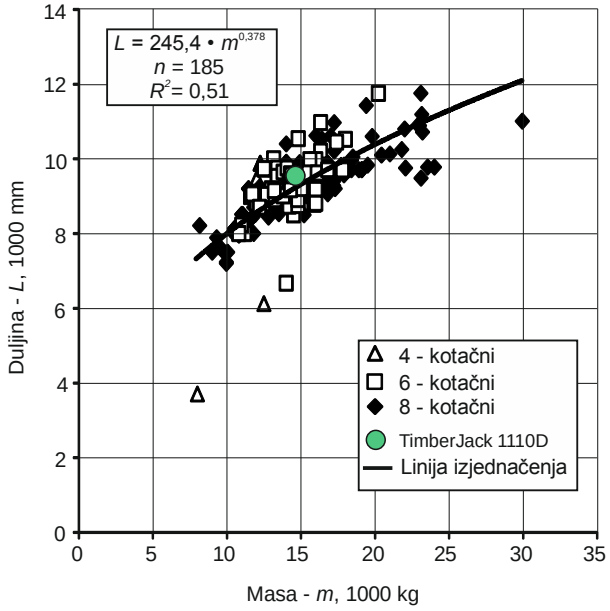

Slika 4.33 Ovisnost duljine forvardera o njegovoj masi

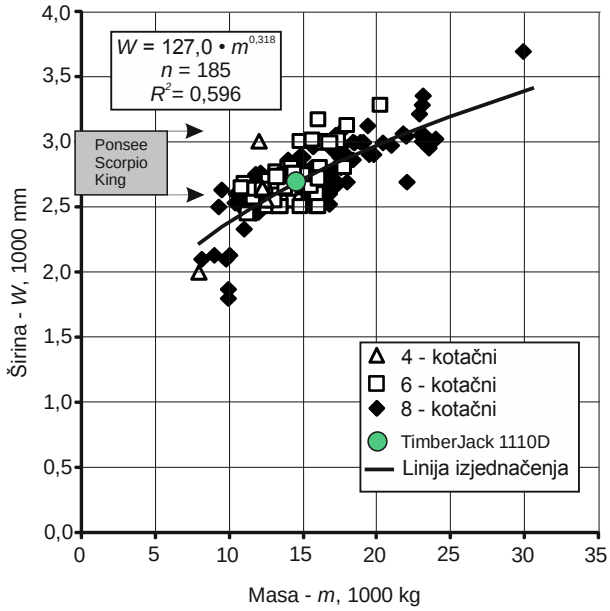

Slika 4.34 Ovisnost širine forvardera o njegovoj masi

Ovisnost je širine forvardera o njegovoj masi pokazuje nešto bolju povezanost od ovisnosti širine. Promatrani je forvarder na liniji izjednačenja koja je kao i u slučaju duljine blago konkavno zakrivljena. Širinom od više od 2,55 m spada u skupinu vozila koja se moraju transportirati u pratnji na posebnim prikolicama. U isti su dijagram unesene i širine harvestera Ponsee Scorpio (najmanja i najveća). Kako su potrebne usaglašene širine ovih vozila, odnosno širina harvestera bi trebala biti najmanje jednaka širini uparenog mu forvardera znači da treba izbjegavati harvester s uskim gumama što je povoljnije i sa stajališta zbijanja tla (NGP-a).

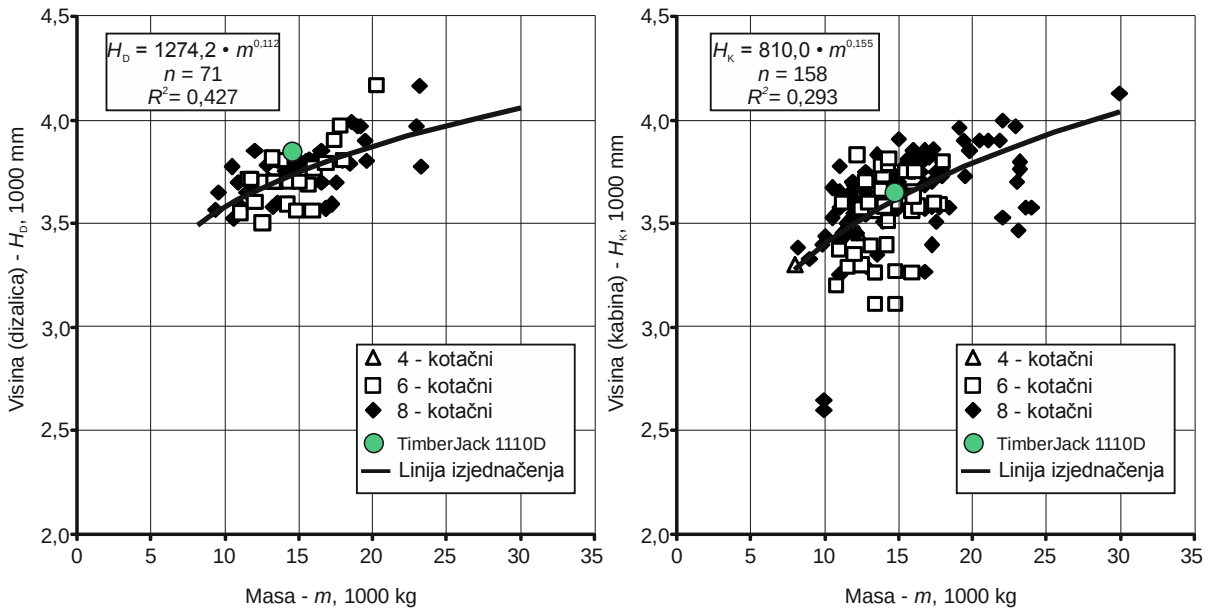

Slika 4.35 Ovisnost visine do kabine i dizalice o masi forvardera

Ovisnost dvije visine forvardera, do kabine i do dizalice, pokazuje slabiju vezu (pogotovo visina do kabine) od ovisnosti duljine i širine o masi. Visine gotovo svih forvardera su manje od 4 m što pokazuje da će se neki ipak morati transportirati na niskopodnim prikolicama.

U Katalog su uvrštena 52 modela 11 proizvođača, a stranicu forvardera koji je po svojim eksploatacijskim značajkama sličan analiziranom pokazuje slika 4.36.

JOHN DEERE 1110E IT4

JOHN DEERE Forestry OY
Box 474
Fin-33101 Tampere
Finska
Internet: www.deere.com

TEHNIČKI DETALJI		
Broj kotača	8	
Motor	John Deere 6068 PowerTech Plus with turbocharger ard intercooler, 6 cylinders, displacement 6.8 l	
Snaga	136 kW	
Transmisija	Hydrostatic-mechanical two-speed gearbox, traction:160 kN	
Osovina	Bogie axles front and rear; hydromechanical; Differential lock front and rear; 6-wheel	
Upravljanje	Proportional steering with electric mini levers ± 44 °	
Kočnice	When the service brake is hydraulically operated ol-immersed brakes; Parking and emergency brakes are actuated by springs; The framebrake is automatically actuated.	
Hidraulični sistem	Load sensing, variable power	
Kapacitet pumpe	140 l/min	
Radni tlak		
Hidraulični spremnik	161 Litara	
Spremnik za gorivo	-	
Gume	-	
Nosivost	12000 kg	
Duljina	9570 mm	
Širina	2890 mm	
Visina	3800 mm	
Radijus okretanja	-	
Odignutost od tla	605 mm	
Dizalica	Tip	John Deere CF5 - Crane with telescope
	Doseg	7,2 – 10 m
	Podizni moment	102 kNm
	Okretni moment	-
Masa	Prednja osovina	
	Stražnja osovina	
	Net masa	15200 kg
Ostalo	-	
Cijena	295000 €	

Slika 4.36 Stranica iz Kataloga forvardera

4.7 Šumske žičare

Postoje različite metode i načini razredbe šumskih žičara a s obzirom na ponudu na tržištu one su u ovome Izvješću podijeljene u tri grupe

1. Traktorske žičare,
2. Vučene žičare,
3. Kamionske.

Prvu veliku analizu mogućnosti korištenja šumskih žičara na području napravili su Horvat i dr (2010). U Završnome izvješću dan je pregled stanja tržišta šumskih žičara ali bez morfološke analize. Prvu takvu analizu napravila je Murgić (2015) u svome diplomskom radu.

Nadopunjenu bazu podataka prikazuje slika 4.37.

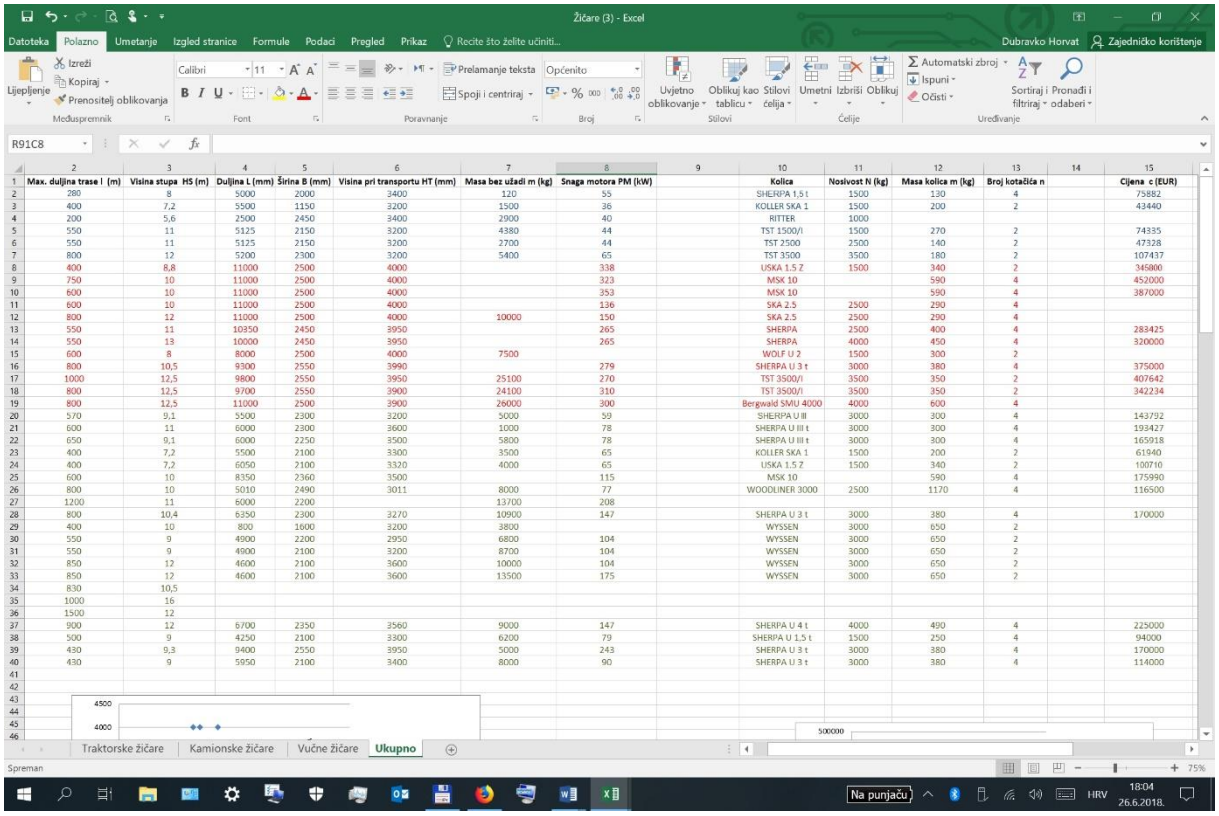

Max. duljina trase l (m)	Visina stupa H5 (m)	Duljina L (mm)	Širina B (mm)	Visina pri transportu HT (mm)	Masa bez užadi m (kg)	Snaga motora PM (kW)	Kolica	Nosivost N (kg)	Masa kolica m (kg)	Broj kotačića n	Cijena c (EUR)
280	8	5000	2000	3400	120	55	SHERPA 1,5 t	1500	130	4	75882
400	7,2	5500	1150	3200	1500	36	KOLLER SKA 1	1500	200	2	43440
200	5,6	2500	2450	3400	2900	40	RITTER	1000			
550	11	5125	2150	3200	4380	44	TST 1500/I	1500	270	2	74335
550	11	5125	2150	3200	2700	44	TST 2500	2500	140	2	47328
800	12	5200	2300	3200	5400	65	TST 3500	3500	180	2	107437
400	8,8	11000	2500	4000		338	USKA 1,5 Z	1500	340	2	345000
750	10	11000	2500	4000		323	MSK 10		590	4	452000
600	10	11000	2500	4000		353	MSK 10		590	4	387000
600	10	11000	2500	4000		136	SKA 2,5	2500	290	4	
800	12	11000	2500	4000	10000	150	SKA 2,5	2500	290	4	
550	11	10350	2450	3950		265	SHERPA	2500	400	4	283425
550	13	10000	2450	3950		265	SHERPA	4000	450	4	320000
600	8	8000	2500	4000	7500		WOLF U 2	1500	300	2	
800	10,5	9300	2550	3990		279	SHERPA U 3 t	3000	380	4	375000
1000	12,5	9800	2550	3950	25100	270	TST 3500/I	3500	350	2	407642
800	12,5	9700	2550	3900	24100	310	TST 3500/I	3500	350	2	342234
800	12,5	11000	2500	3900	26000	300	Bergwald SMU 4000	4000	600	4	
570	9,1	5500	2300	3200	5000	59	SHERPA U III	3000	300	4	143792
600	11	6000	2300	3600	1000	78	SHERPA U III t	3000	300	4	193427
650	9,1	6000	2250	3500	5800	78	SHERPA U III t	3000	300	4	165918
400	7,2	5500	2100	3300	3500	65	KOLLER SKA 1	1500	200	2	61940
400	7,2	6050	2100	3320	4000	65	USKA 1,5 Z	1500	340	2	100710
600	10	8350	2360	3500		115	MSK 10		590	4	175990
800	10	5010	2490	3011	8000	77	WOODLINER 3000	2500	1170	4	116500
1200	11	6000	2200		13700	208					
800	10,4	6350	2300	3270	10900	147	SHERPA U 3 t	3000	380	4	170000
400	10	800	1600	3200	3800		WYSSEN	3000	650	2	
550	9	4900	2200	2950	6800	104	WYSSEN	3000	650	2	
550	9	4900	2100	3200	8700	104	WYSSEN	3000	650	2	
850	12	4600	2100	3600	10000	104	WYSSEN	3000	650	2	
850	12	4600	2100	3600	13500	175	WYSSEN	3000	650	2	
830	10,5										
1000	16										
1500	12										
900	12	6700	2350	3560	9000	147	SHERPA U 4 t	4000	490	4	225000
500	9	4250	2100	3300	6200	79	SHERPA U 1,5 t	1500	250	4	94000
430	9,3	9400	2550	3950	5000	243	SHERPA U 3 t	3000	380	4	170000
430	9	5950	2100	3400	8000	90	SHERPA U 3 t	3000	380	4	114000

Slika 4.37 Baza podataka žičara

Na temelju ove baze je napravljena morfološka analiza nekoliko najvažnijih parametara. Najvažniji parametar za izbor žičare je duljina trase pa je istražena njena ovisnost o masi žičare za cijelu familiju prikazanu na slici 4.38.

Uzrok relativno malome broju sparenih podataka je to što se masa žičare bez užadi rijetko iskazuje u tehničkim parametrima. Kako je u dosadašnjim analizama upravo masa bila nezavisna varijabla taj je obrazac primijenjen i ovdje. Zamjetno je da traktorske žičare imaju najmanju masu, zatim vučene i kamionske bez kamiona te kamionske zajedno s kamionom.

Uz srednje čvrstu vezu između parametara nepovoljna je konkavna linija izjednačenja koja pokazuje asimptotsko približavanje vrijednosti najdulje trase od nešto više od 1 km.

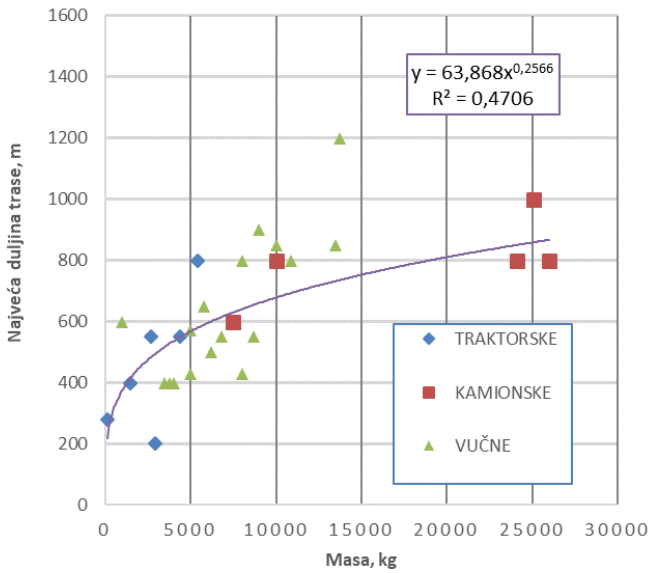

Slika 4.38 Ovisnost najveće duljine trase o vrsti i masi šumske žičare

Iako nije važan eksploatacijski parametar na slici 4.39 prikazana je ovisnost širine žičare o njenoj masi.

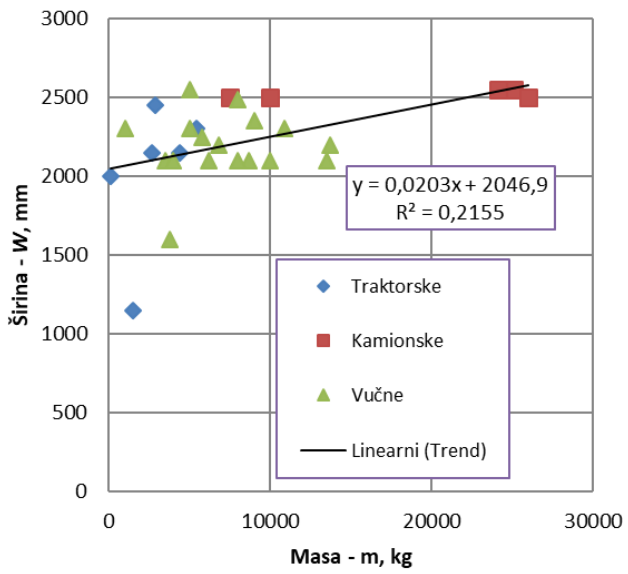

Slika 4.39 Ovisnost širine žičare o njenoj masi

Dijagram na slici 4.39 uz uporabu linearnog regresijskog modela pokazuje slabu korelacijsku vezu parametara. Razlog je vjerojatno taj što su proizvođači ograničili širinu žičare ispod 2,55 m što je granica za transport po javnim putevima i time olakšali transport žičara s radilišta na radilište.

I duljina žičare nije važan eksploatacijski parametar pa ga se neće analizirati ovaj puta.

Ovisnost visine žičare u transportnom položaju prikazan na slici 4.40. također pokazuje nastojanja proizvođača za pojednostavljenjem transporta jer visine niti jednoga od modela ne prelazi ograničavajućih 4,0 m uz linearni, gotovo horizontalni trend.

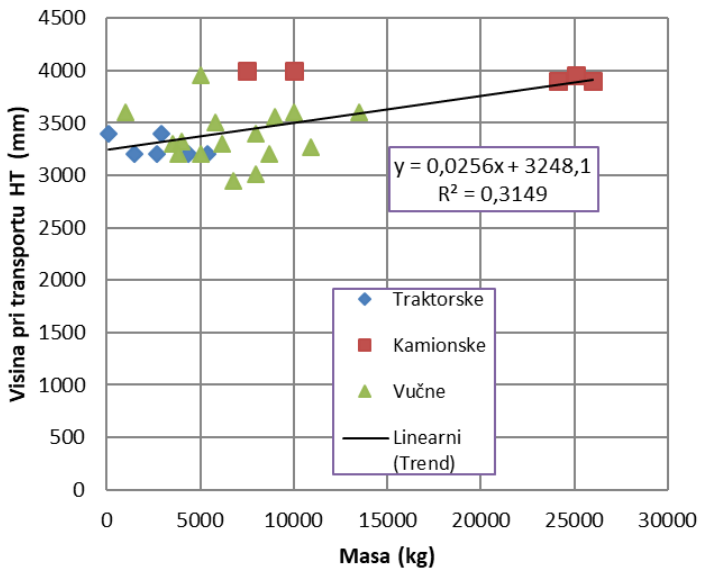

Slika 4.40 Ovisnost transportne visine o masi žičare

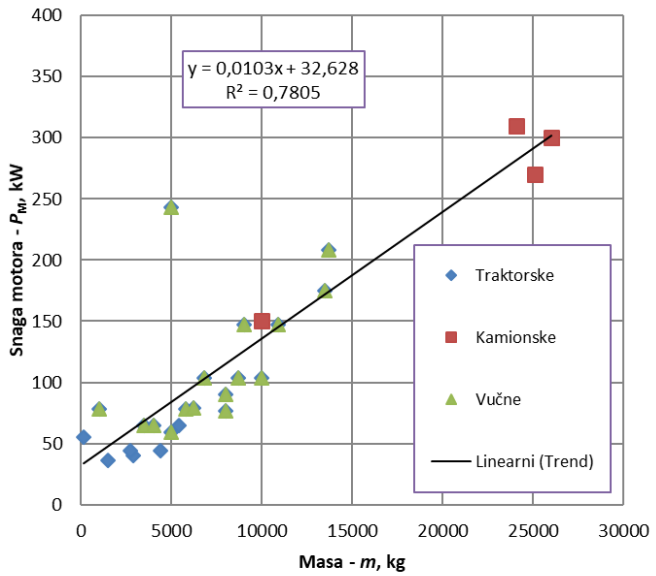

Slika 4.41 Ovisnost snage motora o masi žičare

Ovisnost snage motora žičare i njene mase također je izjednačena linearnom regresijskom krivuljom te uz visoki koeficijent korelacije pokazuje čvrstu vezu ova dva parametra. Ovo je povoljan slučaj jer se za one žičare kod kojih je u tehničkim podacima iskazana snaga motora može preko dijagrama na slici 4.41 doći do mase žičare, a onda i do, primjerice, duljine trase.

Na posljednjem regresijskom dijagramu na slici 4.42 prikazana je ovisnost cijene o masi žičare. Uz ostvarenu jaku vezu između promatranih parametara jasno je da će traktorske žičare biti najjeftinije, zatim vučene a najskuplje kamionske gdje su u dijagramu zajedno s cijenom kamiona.

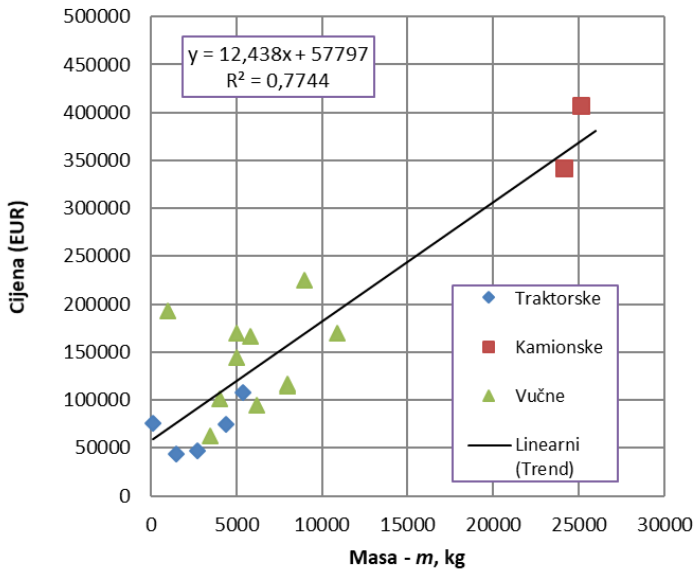

Slika 4.42 Ovisnost cijene o masi i vrsti žičare.

U Katalogu šumskih žičara unesena su 32 modela 11 proizvođača a jednu stranicu Kataloga prikazuje slika 4.43.

SYNCROFALKE 3 t - AM

MM Forsttechnik GmbH
Mayr-Melnhof-Straße 9
A-8130 Frohnleiten
Austrija
Tel.: +43(0)3126/5099-0
Telefax: +43(0)3126/5099-4068
E-mail: office@mm-forsttechnik.at
Internet: www.mm-forsttechnik.at

TEHNIČKI DETALJI	
Tip	Trailer – mounted 3-winch mobile tower yarder, revolv- and tiltable. Hydr. driven winches. Elec. cable remote control with automatic distance and speed control.
Max. duljina trase	800 m
Motor	IVECO 6-cylinder-Turbodiesel with charge air cooling
Snaga	129 kW
Okretaji u min	
Transmisija	Direct drive via hydr. wheel hub motor
Mjenjač	
Kočnice	Tow rope: spring-loaded multi-disc brake; Auxiliarycable: Disc brake Skyline cable: Disc brake
Uređaj za upravljanje	Elec. cable remote control with automatic distanceand speed control. 1 or 2 radio remote controles
Visina stupa	10,9 m
Vitlo nosivog užeta	700 m/20 mm cable diameter
Vitlo vučnog užeta	1600 m/11mm cable diameter
Vitlo povratnog užeta	
Vitlo pomoćnog užeta	1600 m/8,5 mm cable diameter.
Sidereno vitlo	4 x 70 m/18 mm cable diameter
Kolica	MM Sherpa U 3 t
Nosivost	3000 kg
Upravljanje kolicima	Radio remote control
Valjci	4
Duljina	6650 mm
Širina	2440 mm
Visina	3300 mm
Masa bez užadi	14500 kg
Masa kolica	410 kg
Svrha	Transport of wood, trees, materials, up-, downhillor horizontal. Speed: loaded 5,7m/sec; unloaded 9,5m/sec
Ostalo	mounted on lorry. 2. Radio remote control. Hydr. dive
Cijena	258580 €

Slika 4.43 Jedna stranica Kataloga

4.8 Iverači za šumsku biomasu

Prvu je bazu podataka iverača za šumsku biomasu napravio Šušnjar (1998) a posljednju nadopunu je u izradi diplomskog rada napravio Galović (2015). Bazu podatak iverača za šumsku biomasu pokazuje slika 4.44.

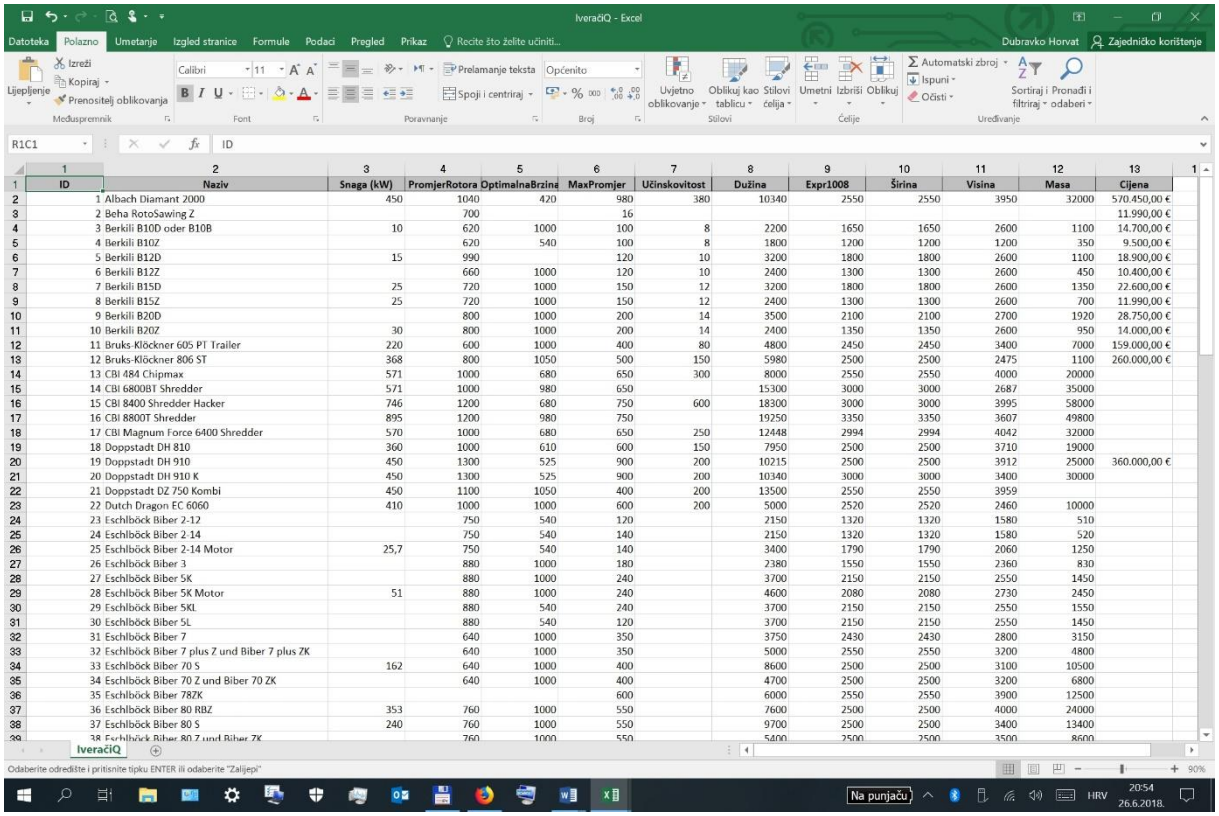

ID	Naziv	Snaga (kW)	PromjerRotora	OptimalnaBrzina	MaxPromjer	Učinskovitost	Dužina	Expr1008	Širina	Visina	Masa	Cijena
1	Albach Diamant 2000	450	1040	420	980	380	10340	2550	2550	3950	32000	570.450,00 €
2	Beha RotoSawing Z		700		16							11.990,00 €
3	Berkili B10D oder B10B	10	620	1000	100	8	2200	1650	1650	2600	1100	14.700,00 €
4	Berkili B10Z		620	540	100	8	1800	1200	1200	1200	350	9.500,00 €
5	Berkili B12D	15	990		120	10	3200	1800	1800	2600	1100	18.900,00 €
6	Berkili B12Z		660	1000	120	10	2400	1300	1300	2600	450	10.400,00 €
7	Berkili B15D	25	720	1000	150	12	3200	1800	1800	2600	1350	22.600,00 €
8	Berkili B15Z	25	720	1000	150	12	2400	1300	1300	2600	700	11.990,00 €
9	Berkili B20D		800	1000	200	14	3500	2100	2100	2700	1920	28.750,00 €
10	Berkili B20Z	30	800	1000	200	14	2400	1350	1350	2600	950	14.000,00 €
11	Bruks-Klöckner 605 PT Trailer	220	600	1000	400	80	4800	2450	2450	3400	7000	159.000,00 €
12	Bruks-Klöckner 806 ST	368	800	1050	500	150	5980	2500	2500	2475	1100	260.000,00 €
13	CBI 484 Chipmax	571	1000	680	650	300	8000	2550	2550	4000	20000	
14	CBI 6800BT Shredder	571	1000	980	650		15300	3000	3000	2687	35000	
15	CBI 8400 Shredder Hacker	746	1200	680	750	600	18300	3000	3000	3995	58000	
16	CBI 8800T Shredder	895	1200	980	750		19250	3350	3350	3607	49800	
17	CBI Magnum Force 6400 Shredder	570	1000	680	650	250	12448	2994	2994	4042	32000	
18	Doppstadt DH 810	360	1000	610	600	150	7950	2500	2500	3710	19000	
19	Doppstadt DH 910	450	1300	525	900	200	10215	2500	2500	3912	25000	360.000,00 €
20	Doppstadt DH 910 K	450	1300	525	900	200	10340	3000	3000	3400	30000	
21	Doppstadt DZ 750 Kombi	450	1100	1050	400	200	13500	2550	2550	3959		
22	Dutch Dragon EC 6060	410	1000	1000	600	200	5000	2520	2520	2460	10000	
23	Eschlböck Biber 2-12		750	540	120		2150	1320	1320	1580	510	
24	Eschlböck Biber 2-14		750	540	140		2150	1320	1320	1580	520	
25	Eschlböck Biber 2-14 Motor	25,7	750	540	140		3400	1790	1790	2060	1250	
26	Eschlböck Biber 3		880	1000	180		2380	1550	1550	2360	830	
27	Eschlböck Biber 5K		880	1000	240		3700	2150	2150	2550	1450	
28	Eschlböck Biber 5K Motor	51	880	1000	240		4600	2080	2080	2730	2450	
29	Eschlböck Biber 5KL		880	540	240		3700	2150	2150	2550	1550	
30	Eschlböck Biber 5L		880	540	120		3700	2150	2150	2550	1450	
31	Eschlböck Biber 7		640	1000	350		3750	2430	2430	2800	3150	
32	Eschlböck Biber 7 plus Z und Biber 7 plus ZK		640	1000	350		5000	2550	2550	3200	4800	
33	Eschlböck Biber 70 S	162	640	1000	400		8600	2500	2500	3100	10500	
34	Eschlböck Biber 70 Z und Biber 70 ZK		640	1000	400		4700	2500	2500	3200	6800	
35	Eschlböck Biber 78ZK				600		6000	2550	2550	3900	12500	
36	Eschlböck Biber 80 RBZ	353	760	1000	550		7600	2500	2500	4000	24000	
37	Eschlböck Biber 80 S	240	760	1000	550		9700	2500	2500	3400	13400	
38	Eschlböck Biber 80 Z und Biber ZK		760	1000	550		5400	2500	2500	3500	8600	

Slika 4.44 Baza podataka iverača za šumsku biomasu

Na temelju raspoložive ponude na tržištu iverača oni su razvrstani u 4 grupe:

- vučeni iverači s pogonom preko priključnog vratila (PV).
- iverači s vlastitim pogonom (na kamionu, prikolici ili vučeni),
- nošeni iverači s pogonom kamionskim motorom,
- samohodni iverači na vlastiti pogon,

Najvažnija eksploatacijska značajka iverača za šumsku biomasu, važna za izbor iverača, je najveći promjer drva koji se može njime iverati. Naravno da prvo treba izabrati vrstu iverača. Ovisnost najvećega promjera drva o masi prikazana je pojedinačno za 4 navedene skupine iverača na slici 4.45.

Iz ovih se dijagrama zapaža da najbrojniji – kamionski iverači s vlastitim motorom ostvaruju i najbolju vezu s eksponencijalnim korelacijskim modelom, gdje su korelacijske krivulje u sva četiri slučaja konkavne. Najslabija je veza ostvarena za samohodne iverače jer su samo 3 modela analizirana.

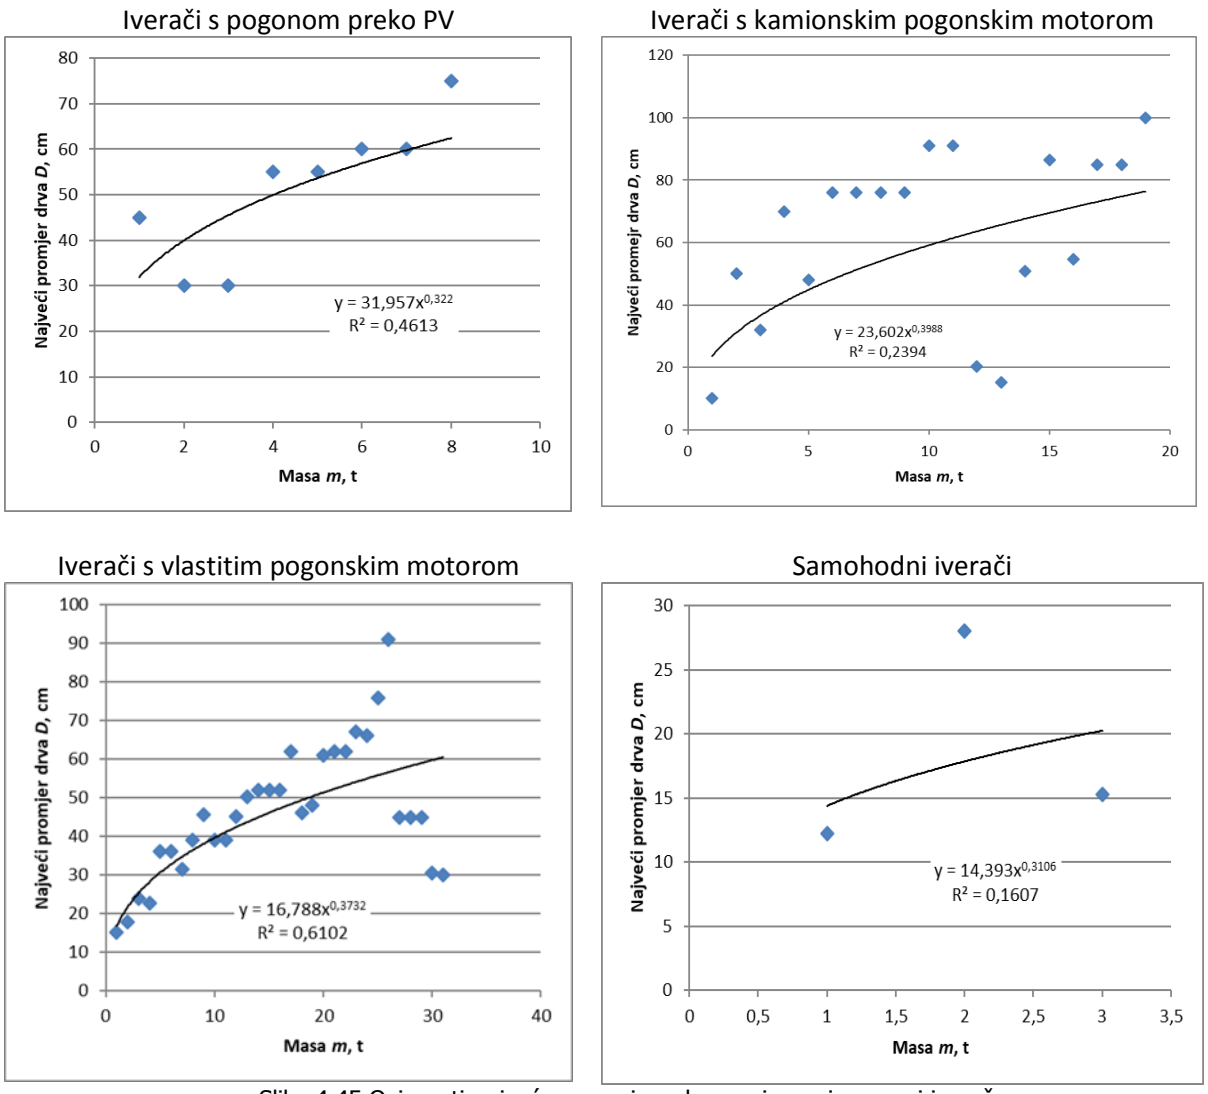

Slika 4.45 Ovisnosti najvećeg promjera drva za iveranje o masi iverača

S obzirom na najbolju ostvarenu korelacijsku vezu ovisnost potrebne snage motora za pogon iverača i njegove mase promatrati će se samo za iverače s vlastitim motorom – slika 4.46.

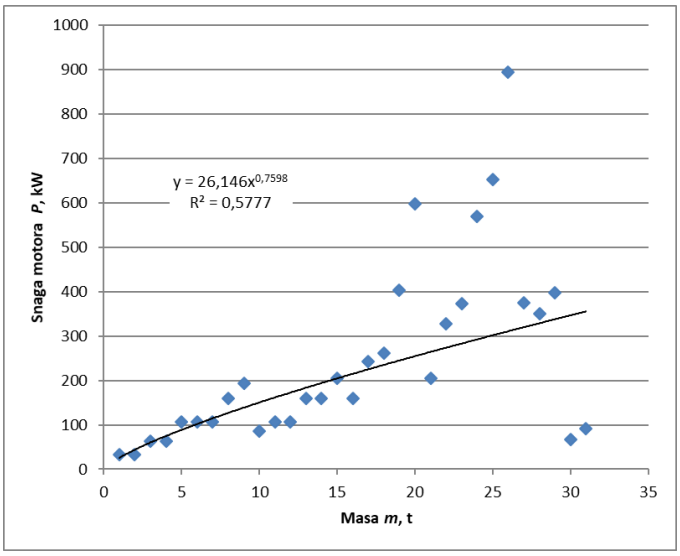

Slika 4.46 Ovisnost potrebne snage o masi iverača s vlastitim motorom

U Katalogu iverača za šumsku biomasu su uneseni podaci 44 modela 6 proizvođača a slika jedne stranice pokazana je na slici 4.47.

JENZ HEM 561 DL

JENZ GmbH
Maschinen- und
Fahrzeugbau
Wegholmer Str. 14
D-32469 Petershagen
Germany

Tel.: +49 (0) 5704/9409-0
E-Mail: info@jenz.de
Internet:
http://www.jenz.de/en/

Osnovne značajke iverača		
Masa	13000	kg
Snaga motora	360	kW
Ulazne značajke drva		
Najveći promjer – meko drvo	56	cm
Najveći promjer – tvrdo drvo	42	cm
Značajke ulaznog ušća i reznog sustava		
Širina ulaza	100	cm
Visina ulaza	65	cm
Promjer rotora	820	cm
Dimenzije		
Duljina	6925	mm
Širina	2550	mm
Visina	2670	mm
Cijena	70000	€
Namjena	Nošeni s motorom	

Slika 4.47 Jedna stranica Kataloga iverača za šumsku biomasu

Literatura

ARMEF-CTBA-IDF ,1993: Manuel d'exploitation forestière, Tome I. Fontainebleau;. París (França)

Batinić, A., 2013: Morfološka raščlamba skidera, Šumarski fakultet Sveučilišta u Zagrebu, diplomski rad, 1–26. Mentor: izv. Prof. Marijan Šušnjar, Izradu pomogao: dr. sc. Zdravko Pandur, prof. dr. sc. Dubravko Horvat, dr. sc. Marko Zorić.

Barešić, P., 2016: Smjernice razvoja forvardera, Šumarski fakultet Sveučilišta u Zagrebu, diplomski rad, 1–24 Mentor: prof. dr. sc. Dubravko Horvat, Izradu pomogao: dr. sc. Zdravko Pandur.

Bekker, M. G., 1960: Off-the-road locomotion, The University of Michigan Press, str. 1–215.

Bekker, M. G., 1956: Theory of land locomotion, The University of Michigan Press, str. 1–499.

Bekker, M. G., 1969: Introduction to Terrain-Vehicle Systems, prijevod Mašinostroenije 1973., str. 1–520.

Beuk, D., Ž. Tomašić, D. Horvat, 2007: Condition and development of forest harvesting mechanisation in the Croatian state forestry. Croatian journal of forest emgineering 28(1): 63–82.

Bručić, G., 1997: Morfološka prosudba nekih značajki harvesterskih glava, Šumarski fakultet Sveučilišta u Zagrebu, diplomski rad, 1–31.

Galović, K., 2015: Morfološka raščlamba iverača, Šumarski fakultet Sveučilišta u Zagrebu, diplomski rad, 1–31, Mentor: izv. Prof. Marijan Šušnjar, Izradu pomogao: dr. sc. Marko Zorić.

Golubović, G., 2013: Morfološka raščlamba forvardera, Šumarski fakultet Sveučilišta u Zagrebu, diplomski rad, 1–20, Mentor: prof. dr. sc. Dubravko Horvat, Izradu pomogao: dr. sc. Zdravko Pandur.

Granić, L., 2013: Morfološka raščlamba harvestera, Šumarski fakultet Sveučilišta u Zagrebu, diplomski rad, 1–27, Mentor: prof. dr. sc. Dubravko Horvat, Izradu pomogao: dr. sc. Zdravko Pandur.

Horvat, D., 1993: Prilog proučavanju prohodnosti vozila na šumskom tlu. Disertacija, Fakultet Strojarstva i brodogradnje Sveučilišta u Zagrebu, 1–234.

Horvat, D., 2001: Morfološke značajke adaptiranih poljoprivrednih traktora s ugradnjom različitih vitala (Morphological characteristics of adapted farming tractors equiped with different winches). Znanstvena knjiga »Znanost u potrajnom gospodarenju hrvatskim šumama«, 525–533.

Horvat, D., T. Poršinsky, A. Krpan, T. Pentek, M. Šušnjar, 2004: Ocjena pogodnosti forvardera morfološkom raščlambom. Strojarstvo : časopis za teoriju i praksu u strojarstvu 46(4-6); 149–160.

Horvat, D., M. Šušnjar, 2005: Tehničke značajke skidera Ecotrac 120V, Istraživanje i studija u okviru projekta »Razvoj, izrada i ispitivanje specijalnog šumskog vozila - skidera mase 7t«, programa RAZUM Ministarstva znanosti, obrazovanja i športa RH, Studija, str. 1–31.

Horvat, D., Ž. Zečić, M. Šušnjar, 2007: Morfološke i proizvodne značajke traktora Ecotrac 120V. Nova mehanizacija šumarstva 28(Posebno izdanje 1): 81–92.

Horvat, D., A. P. B. Krpan, T. Pentek, M. Oršanić, D. Pičman, T. Poršinsky, M. Šušnjar, I. Stankić, H. Nevečerel, D. Drvodelić, 2010: Šumska žičara – Okolišno povoljna tehnika i tehnologija pridobivanja drva iz privatnih šuma na području grada Zagreba. Završno izvješće, Šumarski fakultet Zagreb, str. 1-143.

Murgić, I., 2015: Morfološka raščlamba šumskih žičara, Šumarski fakultet Sveučilišta u Zagrebu, diplomski rad, 1–33, Mentor: prof. dr. sc. Dubravko Horvat, Izradu pomogao: dr. sc. Marko Zorić.

Musić, I., 2007: Morfološka raščlamba motornih pila, Šumarski fakultet Sveučilišta u Zagrebu, diplomski rad, 1–29. Mentor: prof. dr. sc. Tomislav Poršinsky, Izradu pomogao: dr. sc. Andreja Đuka.

Owende, P .M. O. et al., 2002: Operations Protocol for Eco-efficient Wood Harvesting on Sensitive Sites, ECOWOOD Partnership, Dublin, 1–74.

Pandur, Z., 2013: Primjena komercijalnog sustava za praćenje rada strojeva u istraživanju izvoženja drva forvarderom. Doktorska disertacija. Zagreb, Šumarski fakultet, 09.10. 2013, 312 str. Voditelj: Horvat, Dubravko.

Poršinsky, T., 2005: Djelotvornost i ekološka pogodnost forvardera Timberjack 1710 pri izvoženju oblovine iz nizinskih šuma Hrvatske. Doktorska disertacija. Zagreb, Šumarski fakultet, 08. 04. 2005., 170 str. Voditelj: Krpan, Ante.

Poršinsky, T., 2000: Čimbenici učinkovitosti forvardera Timberjack 1210 pri izvoženju oblog drva glavnog prihoda nizinskih šuma Hrvatske. Magistarski rad. Zagreb, Šumarski fakultet, 14.12. 2000., 140 str. Voditelj: Krpan, Ante.

Poršinsky, T., I. Stankić, A. Bosner, T. Pentek, 2008: Morphological Analysis of Chainsaws. In: Proceedings of the 3rd International Scientific Conference FORTECHNEVI 2008, Skoupy, Alois; Machal, Pavel; Marecek, Lukas (ur.). Brno, Mendel University of Agriculture and Forestry, 2008. p. 380 (poster,međunarodna recenzija,sažetak,znanstveni).

Sever, S., 1980: Istraživanje nekih eksploatacijskih parametara traktora kod privlačenja drva. Doktorska disertacija, Šumarski fakultet, Zagreb, str. 1–301.

Sever, S., D. Horvat, 1992a: Skidders and forwarders database as source and help in determining morphological relationships. Proceedings of IUFRO workshop »Computer supported planning of roads and harvesting«, Feldafing, Germany: 196–200.

Sever, S., D. Horvat, 1992b: Logging wheeld tractor databank for assistance in machine family evaluation. Proceedings of IUFRO workshop »Computer supported planning of roads and harvesting«, Feldafing, Germany: 281–288.

Stankić, I., 2010: Višekriterijsko planiranje izvoženja drva forvarderima iz nizinskih šuma Hrvatske. Doktorska disertacija. Zagreb, Šumarski fakultet, 123 str., Voditelj: Poršinsky, Tomislav.

Šušnjar, M., 1998: Istraživanje ovisnosti nekih tehničkih značajki iverača morfološkom raščlambom. Mehanizacija šumarstva 23(3-4): 139–150.

Šušnjar, M., 2005: Istraživanje međusobne ovisnosti značajki tla traktorske vlake i vučne značajke skidera. Doktorska disertacija. Zagreb, Šumarski fakultet, 21.12. 2005., 146 str. Voditelj: Horvat, Dubravko.

Vusić, D., 2013: Pogodnost sustava pridobivanja drvne biomase u smrekovoj šumskoj kulturi. Doktorska disertacija. Zagreb, Šumarski fakultet, 04.10. 2013., 174 str. Voditelj: Zečić, Željko.

Zorić, M., D. Horvat, M. Šušnjar, Z. Pandur, J. Galović, 2014: Morphological analysis of chainsaws - useful decision making tool. Forest engineering: propelling the forest value chain.Gerardmer, France, 2014. p. 1 (poster,međunarodna recenzija,sažetak,znanstveni).

5. Višekriterijski model za analizu djelotvornosti sustava pridobivanja drva

5.1 Razvoj modela za višekriterijsku ocjenu pogodnosti i djelotvornosti pojedinih sustava pridobivanja drva

Vrednovanje sustava pridobivanja drva obuhvaća procjenu njihove djelotvornosti u različitim uvjetima pojedinih orografskih područja. Odluke o primjeni pojedinih sustava pritom se često zasnivaju na standardiziranim financijskim pokazateljima i troškovima po jedinici proizvoda kao glavnoj mjeri učinkovitosti proizvodnje u šumarstvu. Višekriterijska analiza sustava pridobivanja drva ima za cilj razvoj podloga koje će uz predložene kriterije omogućiti obuhvatniju ocjenu i rangiranje postojećih sustava pridobivanja drva s obzirom na glavne utjecajne čimbenike određenih reljefnih područja šuma. Odabir optimalnih sustava pridobivanja drva temeljit će se na utvrđivanju glavnih kriterija njihovoga vrednovanja te višekriterijskoj analizi i ocjeni njihove pogodnosti i djelotvornosti u konkretnim uvjetima pojedinih orografskih područja. Doprinos provedenog istraživanja ogleda se kroz: 1) razvoj i primjenu novih metoda i tehnika u vrednovanju šumarskih tehnologija i postupaka, čime se pridonosi cjelovitijoj ocjeni uspješnosti radnih i proizvodnih procesa u šumarstvu, 2) pružanje podloga za donošenje odluka o pogodnim sustavima pridobivanja drva s obzirom na glavne utjecajne čimbenike njihova odabira i primjene, čime se iskazuje primjenjivost istraživanja u racionalizaciji proizvodnje drva te transfer znanja u gospodarstvo.

Donošenje odluka, kao proces odabira neke od alternativa kojima se rješava dani problem, u šumarstvu je naglašeno zahtjevno i složeno zbog mnogobrojnosti i širokog raspona kriterija uključenih u procese odlučivanja. Takvi utjecaji i kriteriji obuhvaćaju brojna ekonomska pitanja, ekološka i okolišna pitanja, socijalna i druga pitanja. Odabir optimalnog sustava pridobivanja drva u procesu šumarske proizvodnje upravo je primjer takvih odluka. Primjena različitih metoda višekriterijskog odlučivanja kao i različitih tehnika grupnog odlučivanja u takvim se situacijama pokazuje kao važan i potencijalno dobar način pristupanja brojnim šumarskim pitanjima i problemima. Njihova primjena je pritom posebno primjerena u slučajevima gdje je potrebno holistički razmotriti i ocijeniti različite alternative u odlukama, pri čemu je sveobuhvatna analiza naročito otežana mnogobrojnošću teško usporedivih kriterija i suprotstavljenih interesa koji utječu na proces odlučivanja, te je prijedlog odluke nužno utemeljiti na racionalnim argumentima.

Metode i tehnike višekriterijskog odlučivanja prisutne su u šumarstvu već više od 40 godina (Field 1973), no njihova značajnija primjena počinje od 1990-ih godina i brojnih u međuvremenu objavljenih višekriterijskih radova koji se u više područja bave različitim problemima šumarstva. Uvjetno određena područja šumarstva u kojima su dosada primijenjeni višekriterijski modeli obuhvaćaju: pridobivanje drva, prošireno iskorištavanje šuma, očuvanje biološke raznolikosti, održivo gospodarenje, pošumljavanje, regionalno planiranje, šumarsku industriju, rizik i neizvjesnost (Diaz-Balteiro i Romero 2008).

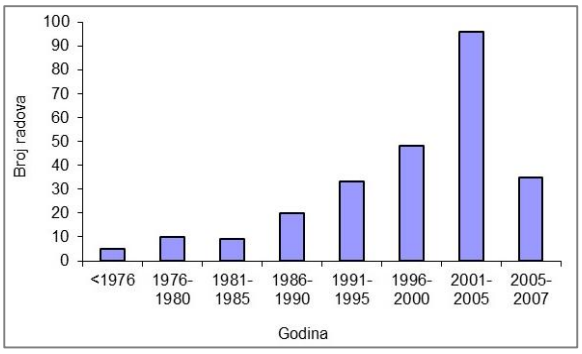

Slika 5.1 Brojnost objavljenih višekriterijskih radova u šumarstvu

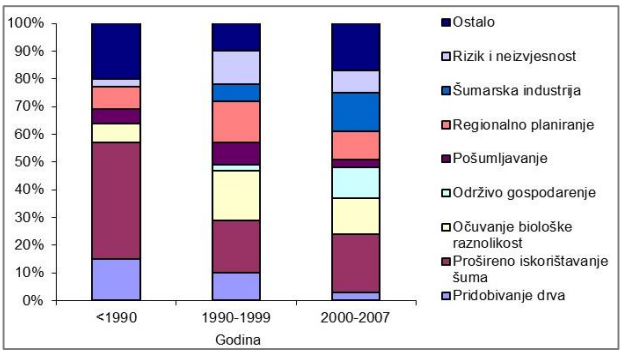

Slika 5.2. Zastupljenost višekriterijskih radova u različitim šumarskim temama

Višekriterijsko odlučivanje spada u široki spektar metoda operacijskih istraživanja. Do danas su razvijene mnogobrojne metode, pri čemu svaka od njih ima svoje matematičke postavke te različite značajke i tehnike koje su primjenjive u odgovarajućim situacijama i slučajevima. Neke od najčešćih

metoda višekriterijskog odlučivanja, od kojih je većina primijenjena u šumarstvu, su npr.: analiza omeđivanja podataka (*Data Envelopment Anlysis, DEA*), analitički hijerarhijski proces (*Analytic Hierarchy Process, AHP*), višeatributna teorija korisnosti (*Multi-Attribute Utility Theory, MAUT*), metode višeg ranga (*Outranking methods*), glasačke tehnike (*Voting methods*), analiza stohastičke višekriterijske prihvatljivosti (*Stochastic Multicriteria acceptability analysis, SMAA*) i dr.

Navedene metode i njihove primjene međusobno se znatno razlikuju. Pritom niti jedna od metoda nije univerzalna i najbolja, čak ni primjenjiva u svim slučajevima, već različitim situacijama i problemima najbolje odgovaraju različite metode. Izbor najbolje ili jednostavno odgovarajuće metode za potporu u odlučivanju zahtijeva poznavanje više modela, njihovih postavki, prednosti i ograničenja kao i karakteristika te zahtjeva specifičnih situacija i problema u planiranju i odlučivanju. U tablici 5.1 prikazane su karakteristike nekih metoda višekriterijskog odlučivanja i njihova usporedba.

Tablica 5.1 Karakteristike metoda višekriterijskog odlučivanja (prema Sarkis i Weinrach 2001)

Metoda	Troškovi primjene	Zahtjev za podacima	Osjetljivost	Razumljivost	Matematička složenost	Fleksibilnost
DEA	S	S	N	N	V	S
AHP	S	S	N	S	N	V
Expert systems	V	V	N	S	V	V
Goal program	S	S	S	N	V	N
MAUT	V	V	S	S	S	V
Outranking	S	S	N	N	S	S
Simulation	V	V	V	V	V	S
Scoring models	N	N	N	V	N	V

* V – visoko; S – srednje; N – nisko

Nakon usporedbe i analize više različitih metoda, za potrebe istraživanja i izradu višekriterijskog modela za ocjenu pogodnosti i djelotvornosti sustava pridobivanja drva kao primjerena je odabrana AHP metoda ili Analitički hijerarhijski proces. Analitički hijerarhijski proces (AHP), prvotno razvijen od Saaty-a (1977, 1980) je često primjenjivana i vrlo popularna metoda u mnogim područjima, uključujući i gospodarenje prirodnim resursima. Mendoza i Sprouse (1989), Murray i Gadow (1991), Kangas (1992) neki su od autora koji su AHP primijenili u šumarstvu, a broj aplikacija se kontinuirano povećava (Ananda i Herath 2003, Wolfslehner i dr. 2005, Šegotić i dr. 2003, 2007).

U usporedbi s drugim metodama, AHP ima nekoliko prednosti sa stajališta višekriterijskog i grupnog odlučivanja. U rješavanju problema odlučivanja objektivne informacije, stručno znanje i subjektivne preferencije se pomoću AHP metode mogu uzeti u razmatranje skupno i istovremeno. Također se u obzir mogu uzeti i kvalitativni kriteriji, dok ostale metode obično traže kvantitativne kriterije za izbor neke od alternativa.

Rješavanje složenih problema odlučivanja pomoću ove metode temelji se na njihovom rastavljanju na komponente: cilj, kriterije (podkriterije) i alternative. Pod ciljem se podrazumijeva stanje sustava koje želimo postići odlukom, a kriteriji su atributi kojima se opisuju alternative i njihova svrha je da direktno ili indirektno daju informacije o tome u kojoj mjeri se pojedinom alternativom ostvaruje željeni cilj. Ti elementi se potom povežu u model s više razina (*hijerarhijsku strukturu*) pri čemu je na vrhu cilj, a na prvoj nižoj razini su glavni kriteriji (slika 5.3). Kriteriji se mogu rastaviti na podkriterije, a na najnižoj razini nalaze se alternative. Druga važna komponenta AHP metode je matematički model pomoću kojeg se računaju prioriteti (težine) elemenata koji su na istoj razini hijerarhijske strukture. Temeljni matematički alat koji se koristi u AHP metodi pritom su matrice.

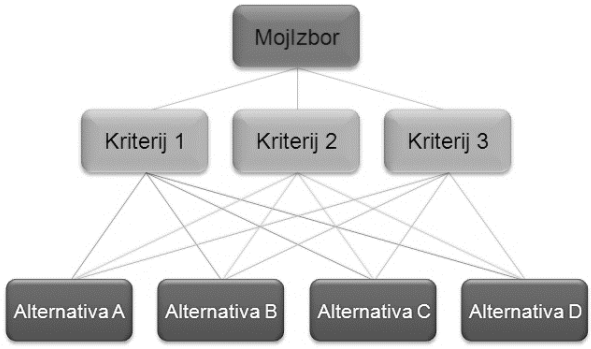

Slika 5.3 Hijerarhijska struktura AHP metode

Metoda je zasnovana na usporedbi u parovima – usporedbi parova kriterija gdje se iskazuje njihova važnost ili težina, te usporedbi parova alternativa, svaka sa svakom, pri čemu se izražava intenzitet ili stupanj preferencije jedne alternative u odnosu na onu s kojom se uspoređuje. Cijeli se proces AHP metode može ukratko opisati u nekoliko koraka: (1) razvije se hijerarhijski model problema odlučivanja s ciljem odabira, kriterijima (podkriterijima) i alternativama, (2) na svakoj razini hijerarhijskog modela u parovima se međusobno uspoređuju elementi tog modela, pri čemu se preferencije donositelja odluke izražavaju uz pomoć Saaty-jeve skale relativne važnosti, (3) iz procjena relativnih važnosti kriterija i unutar njih alternativa, pomoću procedura unutar AHP modela, izračunavaju se lokalni prioriteti (težine, važnosti) kriterija i alternativa pomoću kojih se zatim posebnim postupkom izračunavaju ukupni prioriteti pojedinih alternativa, (4) nakon utvrđivanja rangova provodi se analiza rezultata.

Nedostatak metode je u tome što ne dozvoljava oklijevanje i iskazivanje nesigurnosti u usporedbama. Teškoća je i to što se broj usporedbi značajno povećava s brojem alternativa i kriterija, što može biti vrlo skupo i zahtjevno. Međutim, da bi se prevladala ova ograničenja razvijeni su različiti AHP modeli kakvi su npr. A'WOT metoda (kombinacija AHP metode i SWOT analize) ili analitički mrežni proces (Analytical network process, ANP) koji predstavljaju svojevrsnu nadogradnju osnovne AHP metode.

Popularnost AHP metoda ponajprije se temelji na tome što je vrlo bliska načinu na koji pojedinac intuitivno rješava složene probleme rastavljajući ih na jednostavnije. AHP modeli pritom polaze od ideje usporedbe parova kao praktičnoga, pedagoškog i intuitivnog pristupa. AHP je na taj način snažan i fleksibilan postupak za donošenje odluka koji, svođenjem kompleksnog odlučivanja na usporedbe između parova kriterija tj. alternativa, pomaže u određivanju prioriteta i dovodi do optimalne/racionalne odluke u slučajevima kada se i kvantitativni i kvalitativni aspekti uzimaju u obzir.

U istraživanju sustava pridobivanja drva i razvoju višekriterijskog modela za ocjenu njihove pogodnosti i djelotvornosti u različitim uvjetima pojedinih šumskogospodarskih područja, AHP metoda je primijenjena na način da su provedeni sljedeći koraci: 1) definirani su sustavi pridobivanja drva (alternative), 2) utvrđeni su kriteriji i podkriteriji za ocjenu alternativa, 3) izrađen je i oblikovan anketni upitnik prikladan za istraživanje primjenom AHP metode (Prilog 5.1), 4) provedeno je ispitivanje među šumarskim stručnjacima, 5) obrađeni su upitnici i analizirani odgovori ispitanika u programu Expert Choice, i 6) utvrđeni su rangovi alternativa.

Kao uspoređivane alternative (A) definirani su sljedeći sustavi pridobivanja drva:

- Sustav 1 (A1) – Sjekač i adaptirani poljoprivredni traktor (APT)
- Sustav 2 (A2) – Sjekač i skider s vitlom
- Sustav 3 (A3) – Sjekač i traktorska ekipaža
- Sustav 4 (A4) – Sjekač i forvarder
- Sustav 5 (A5) – Harvester i forvarder
- Sustav 6 (A6) – Sjekač i vučena žičara
- Sustav 7 (A7) – Sjekač i kamionska žičara

Detaljnije značajke i opis definiranih sustava pridobivanja drva prikazani su u Prilogu 5.1 ovoga izvješća (Anketni upitnik za odabir sustava pridobivanja drva AHP metodom).

Kao kriteriji i podkriteriji za ocjenu alternativa i odabir sustava pridobivanja drva definirani su sljedeći parametri i pokazatelji (Tablica 5.2).

Tablica 5.2. Pretpostavljeni kriteriji i parametri za ocjenu sustava pridobivanja drva

Kriteriji	Podkriteriji
Tehnološko-biološki	– Struktura doznačenog drva – Prometnost i prohodnost terena – Primarna i sekundarna otvorenost
Ekonomski	– Proizvodnost – Ekonomičnost
Ekološki	– Oštećenje staništa (tlo, voda) – Oštećenje sastojine (dubeća stabla, pomladak) – Onečišćenje i zagađenje okoliša
Ergonomski	– Fizičko opterećenje radnika – Radni okoliš (buka, vibracije, ozljede…)
Energijski	– Potrošnja goriva, maziva, rezervnih dijelova
Estetski	– Krajobraz i socijalna funkcija šume

Čimbenici koji dodatno opisuju pojedine pod/kriterije prikazani su u Prilogu 5.1 ovoga izvješća (Anketni upitnik za odabir sustava pridobivanja drva AHP metodom).

Za rješavanje problema višekriterijskog odlučivanja i odabir tj. ocjenu sustava pridobivanja korišten je programski paket Expert Choice. Expert Choice je skupni programski paket za podršku odlučivanju, koji se zasniva na Analitičkom hijerarhijskom procesu. Expert Choice omogućuje korisnicima da pokažu znanja i kolektivnu inteligenciju timova koji sudjeluju u postupku donošenja odluka. Program omogućuje strukturiranje hijerarhijskog modela problema odlučivanja na više načina, te uspoređivanje alternativa i kriterija u parovima također na više načina. Posebnu vrijednost programu daju različite mogućnosti provođenja analize osjetljivosti koje se temelje na vizualizaciji posljedica promjena ulaznih podataka. Korištenje programa je jednostavno, a u programskoj dokumentaciji su dobro objašnjeni načini na koje se može razviti model i različite mogućnosti unosa podataka. Program također omogućava kreiranje različitih izvješća.

5.2 Rezultati višekriterijske analize pogodnosti i djelotvornosti sustava pridobivanja drva – primjer Šumarije Bjelovar, GJ »Bjelovarska Bilogora« (odsjeci 14b i 14c)

Za potrebe stručnoga projekta »Optimizacija sustava pridobivanja drva i šumske prometne infrastrukture na strateško-taktičkoj razini planiranja« izrađen je anketni upitnik »Odabir sustava pridobivanja drva AHP metodom« (Prilog 5.1). Anketni upitnik je sa zamolbom za ispunjavanje i potrebnim pojašnjenjima 27. 03. 2018. godine upućen odabranim šumarskim stručnjacima iz Ministarstva poljoprivrede RH i tvrtke Hrvatske šume d.o.o. Kao sudionici u istraživanju (ispitanici) odabrani su šumarski stručnjaci koji su sudjelovali na prezentaciji projekta održanoj 18. 07. 2017. godine u Upravi šuma Podružnici Bjelovar (šumarija Bjelovar). Na predstavljanju projekta oni su upoznati s njegovim zadaćama i ciljevima, istraživačkim poligonom projekta (GJ »Bjelovarska Bilogora«, odsjek 14b i 14c), kao i idejom višekriterijske analize pogodnosti i djelotvornosti sustava pridobivanja drva, odnosno provedbom potrebnoga anketnoga upitnika. Na temelju toga anketni upitnik je upućen na adrese 38 šumarskih stručnjaka. Do 23. 04. 2018. godine ispunjeno je i vraćeno ukupno 8 upitnika, od čega su četiri upitnika zbog previsoke nekonzistentnosti odbačena iz daljnjih obrada. Na slici 5.4 prikazan je dio ispunjenoga anketnoga upitnika.

II. Usporedba u parovima – Podkriteriji (s obzirom na kriterij kojem pripadaju):

TEHNOLOŠKO-BIOLOŠKI

	9	7	5	3	1	3	5	7	9	
Struktura doznačenog drva	☐	☐	☐	☒	☐	☐	☐	☐	☐	Prometnost i prohodnost terena
Struktura doznačenog drva	☐	☐	☒	☐	☐	☐	☐	☐	☐	Primarna i sekundarna otvorenost
Prometnost i prohodnost terena	☐	☐	☐	☐	☒	☐	☐	☐	☐	Primarna i sekundarna otvorenost

EKONOMSKI

	9	7	5	3	1	3	5	7	9	
Proizvodnost	☐	☐	☐	☐	☒	☐	☐	☐	☐	Ekonomičnost

EKOLOŠKI

	9	7	5	3	1	3	5	7	9	
Oštećenje staništa (tlo, voda)	☐	☒	☐	☐	☐	☐	☐	☐	☐	Oštećenje sastojine (dub. stabla...)
Oštećenje staništa (tlo, voda)	☐	☐	☐	☐	☒	☐	☐	☐	☐	Onečišćenje i zagađenje okoliša
Oštećenje sastojine (dub. stabla...)	☐	☐	☐	☐	☐	☐	☐	☒	☐	Onečišćenje i zagađenje okoliša

ERGONOMSKI

	9	7	5	3	1	3	5	7	9	
Fizičko opterećenje radnika	☐	☐	☐	☒	☐	☐	☐	☐	☐	Radni okoliš (buka, vibracije...)

III. Usporedba u parovima – Alternative (s obzirom na pojedini podkriterij):

STRUKTURA DOZNAČENOG DRVA

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☒	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☒	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☒	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☒	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☒	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☒	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☒	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☒	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☒	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☒	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☒	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☒	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☒	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☒	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☒	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☒	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☒	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☒	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☒	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☒	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☒	☐	☐	☐	Sjekač i kamionska žičara

Slika 5.4 Prikaz dijela ispunjenog anketnog upitnika

Ispunjeni upitnici sa usporedbom parova na svakoj razini definiranog hijarerhijskog modela poslužili su kao ulazni podaci za višekriterijsku analizu AHP metodom gdje se je obuhvaćanjem različitih stajališta nastojalo ujediniti rezultate te na taj način doprinijeti donošenju racionalne odluke i izboru optimalnog sustava pridobivanja drva za konkretnu šumsku sastojinu/radilište. Za analize je korišten Programski paket Expert Choice, a rezultati prikazani na slikama 5.5 – 5.8 ilustriraju mogućnosti metode i nalaze istraživanja na primjeru jednoga obrađenoga upitnika.

Temeljni problem u rješavanju višekriterijskog modela je određivanje težina ili važnosti uspoređivanih kriterija i alternativa. U AHP metodi težine kriterija se određuju jednostavnom usporedbom u parovima, što se kasnije koristi za utvrđivanje ukupnih prioriteta i rangiranje pojedinih alternativa. Na slikama 5.5 i 5.6 prikazane su relativne težine definiranih kriterija, odnosno hijerarhijski model problema odlučivanja s težinama pojedinih kriterija i podkriterija određenim na temelju ispunjenoga anketnog upitnika.

	Teh	Eko	Eko	Erg	Ene	Est
Tehnolo		5,0	5,0	5,0	5,0	5,0
Ekonomski			3,0	3,0	1,0	3,0
Ekolo				3,0	3,0	1,0
Ergonomski					3,0	3,0
Energijski						3,0
Estetski	Inc					

Slika 5.5 Relativne važnosti promatranih kriterija

- **Goal: Optimalni sustav pridobivanja drva**
  - **Tehnološko-biološki (L: 0,473)**
    - **Struktura doznaèenog drva (L: 0,281)**
    - **Prometnost i prohodnost terena (L: 0,584)**
    - **Primarna i sekundarna otvorenost (L: 0,135)**
  - **Ekonomski (L: 0,052)**
    - **Proizvodnost (L: 0,500)**
    - **Ekonomièenost (L: 0,500)**
  - **Ekološki (L: 0,169)**
    - **Ošteæenje staništa (L: 0,333)**
    - **Ošteæenje sastojine (L: 0,333)**
    - **Oneèišæenje i zagađenje okoliša (L: 0,333)**
  - **Ergonomski (L: 0,143)**
    - **Fizièko optereæenje radnika (L: 0,750)**
    - **Radni okoliš (L: 0,250)**
  - **Energijski (L: 0,052)**
  - **Estetski (L: 0,112)**

Slika 5.6 Hijerarhijski model problema odlučivanja za odabir optimalnog sustava pridobivanja drva s težinama kriterija

Na prikazanom primjeru vidljivo je da najveća težina u odabiru optimalnog sustava pridobivanja drva pridana tehnološko-biološkim (L: 0,473), a zatim ekološkim (L: 0,169) i ergonomskim kriterijima (L:0,143). Najmanja je važnost u ovom slučaju dodijeljena energijskim (L: 0,052), ekonomskim (L: 0,052) i estetskim kriterijima (L: 0,112). Unutar tehnološko-bioloških kriterija prometnost i prohodnost terena (L: 0,584) su ocijenjeni kao najvažniji kriterij za odabir i primjenu određenog sustava pridobivanja drva na nekom šumskogospodarskom području.

Na temelju utvrđenih težina kriterija i podkriterija određeni su ukupni prioriteti i rangovi definiranih i uspoređivanih alternativa (sustava pridobivanja drva). Kao ulazni podaci za program Expert Choice i AHP metodu pritom su poslužile usporedbe parova alternativa iz upitnika gdje su šumarski stručnjaci po svakome od postavljenih kriterija iskazivali relativnu preferenciju jedne alternative u odnosu na drugu. Utvrđeni rangovi pojedinih alternativa i sinteza podataka za odabir optimalnog sustava pridobivanja drva prikazani su na slici 5.7.

Slika 5.7 Sinteza podataka za odabir optimalnog sustava pridobivanja drva – rang uspoređivanih alternativa

Kao najpogodniji sustav pridobivanja drva za promatranu sastojinu/radilište i definirane kriterije ocijenjen je sustav Harvester i forvarder, odnosno alternativa A5 s rezultatom 0,278. Za njim slijede sustav Sjekač i forvarder (A4) - 0,193, Sjekač i traktorska ekipaža (A3) - 0,144 te Sjekač i kamionska žičara (A7) - 0,124. Najlošije ocijenjenu alternativu predstavlja sustav Sjekač i adaptirani poljoprivredni traktor (A1) - 0,062.

Također je provedena analiza osjetljivosti koja pokazuje osjetljivost alternativa na promjene u težinama kriterija (slika 5.8). Na istom prikazu su vidljive i utvrđene težine pojedinih kriterija, kao i rangovi uspoređivanih alternativa po svakom od postavljenih kriterija i ukupno.

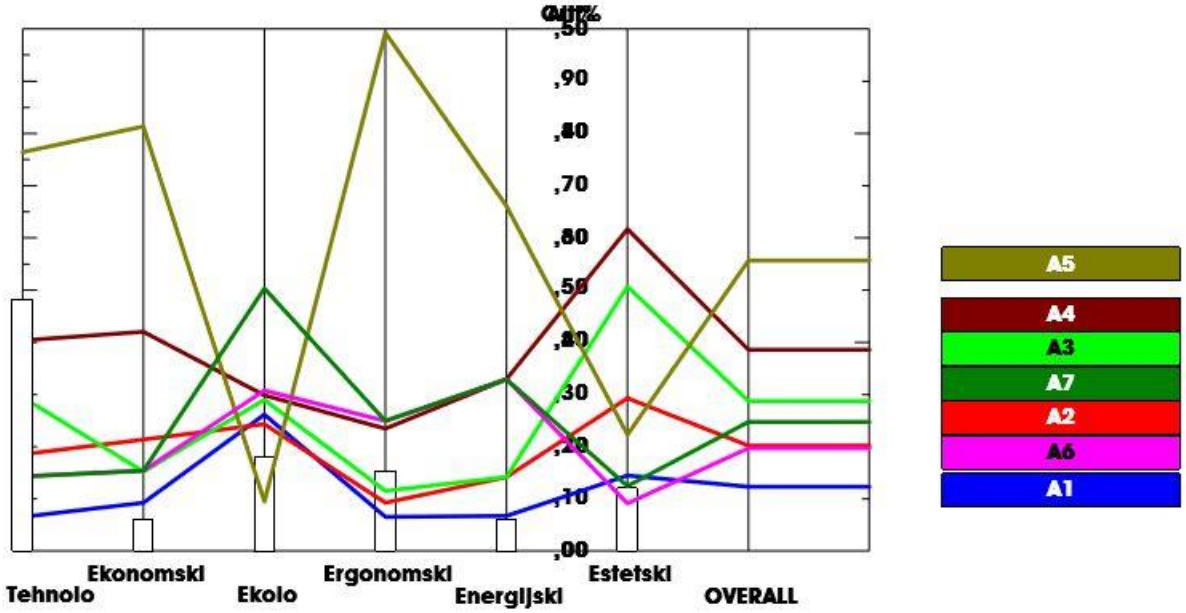

Slika 5.8 Analiza osjetljivosti za odabir optimalnog sustava pridobivanja drva

Provedeno ispitivanje imalo je za cilj testiranje i izradu višekriterijskog modela za usporedbu i ocjenu (rangiranje) postojećih sustava pridobivanja drva te donošenje odluke o najpogodnijim sustavima pridobivanja drva za konkretne uvjete pojedinih šumskih sastojina (radilišta). U tu su svrhu definirane pojedine alternative (sustavi), utvrđeni su kriteriji za njihovu ocjenu, izrađen je odgovarajući anketni upitnik, te analizirani odgovori ispitnika (primjenom AHP metode – programski paket Expert Choice), čime je ispunjen istraživački zadatak.

U razvoju višekriterijskog modela i njegovoj primjeni u oblikovanju šumskih radova, odabiru optimalnog sustava pridobivanja drva i sl., mnogostruki se kriteriji ne mogu promatrati odvojeno jedni od drugih. Naime, ekološkim, socijalnim, estetskim, rekreativnim i drugim kriterijima se pridaje sve veća važnost. Istovremeno raste potreba za što učinkovitijim obavljanjem šumskih radova te smanjenjem njihovog štetnog utjecaja na zdravlje i radnu sposobnost radnika. Neophodno je dakle, pronaći mehanizme (načine) koji će u najboljoj mjeri ispuniti navedene uvjete i osigurati održivi razvoj šuma i šumarstva. Primjena višekriterijskog odlučivanja (AHP metode) u odlučivanju u šumarstvu jedan je od mogućih načina dostizanja postavljenih ciljeva gospodarenja šumama.

Nedostatak je u tome što uključivanjem većeg broja kriterija, potrebni upitnici i analize postaju presloženi i prezahtjevni, te je neophodno utvrditi manji broj doista ključnih kriterija. Isto je dijelom pokazalo i ovo istraživanje.

Nalazi istraživanja i rezultati provedenih upitnika šumarskim stručnjacima mogu poslužiti kao potpora u donošenju odluka i tako posredno djelovati na primjenu određenih sustava pridobivanja drva. Time je zadaća istraživanja ostvarena, a oblikovani višekriterijski pristup model koji može ponuditi objektivne podloge za odlučivanje o najprikladnijim tehnologijama i sredstvima rada na brojnim različitim radilištima u hrvatskom šumarstvu.

Literatura

Ananda, J., G. Herath, 2003: The use of Analytic Hierarchy Process to incorporate stakeholder preferences into regional forest planning. Forest Policy and Economics 5(1): 13–26.

Diaz-Balteiro, L., C. Romero, 2008: Making forestry decisions with multiple criteria – a review and an assessment. Forest ecology and management 255(8-9): 3222–3241.

Field, D. B. 1973: Goal programming for forest management. Forest Science 19(2): 125–135.

Kangas, J., 1992: Multiple-use planning of forest resources by using analytic hierarchy process. Scan. J. For. Res. 7: 259–268.

Mendoza, G. A., W. Sprouse 1989: Forest planning and decision making under fuzzy environments: an overview and illustrations. For. sci. 35: 481–502.

Murray, D. M., K. Gadow 1991: Prioritizing mountain catchment areas. J. environ. manage. 32: 357–366.

Saty, T. L., 1977: A scaling method for priorities in hierarhical structures. J.mathemat.psych. 15: 234–281.

Saty, T. L., 1980: The analytical hierarchy process. McGraw-Hill, New York.

Šegotić, K., M. Šporčić, I., Martinić, 2003: The choice of a working method in forest stand thinning. SOR '03 Proceedings – The 7th International Symposium on Operational Research in Slovenia, Podčetrtek, Slovenia, September 24–26, 2003., p. 153–159.

Šegotić, K., M. Šporčić, I., Martinić, 2007: Ranking of the mechanisation working units in the forestry of Croatia. SOR '07, Proceedings of the 9th International Symposium on Operational Research, Nova Gorica, Slovenia, September 26–28, 2007., p. 247–251.

Wolfslehner, B., H. Vacik, M. J. Lexer, 2005: Application of the analytic network process in multi-criteria analysis of sustainable forest management. Forest Ecology and Management 207(1-2): 157–170.

Prilog 5.1
Ispitivanje za potrebe stručnoga projekta
„Optimizacija sustava pridobivanja drva i šumske prometne infrastrukture na strateško-taktičkoj razini planiranja“

Šumarski fakultet Sveučilišta u Zagrebu
Zavod za šumarske tehnike i tehnologije
Zagreb, 27. 03. 2018.

Zamolba i obavijest šumarskim stručnjacima (ispitanicima)

Poštovani,

Molimo Vas da za potrebe stručnoga projekta “Optimizacija sustava pridobivanja drva i šumske prometne infrastrukture na strateško-taktičkoj razini planiranja” financiranog iz sredstava naknade za korištenje općekorisnih funkcija šuma (Ministarstvo poljoprivrede RH) ispunite priloženi anketni upitnik.

Za ispitivanje ste odabrani kao sudionici prezentacije projekta održane 18. 07. 2017. godine na istraživačkome poligonu u Upravi šuma Podružnici Bjelovar (šumarija Bjelovar, GJ Bjelovarska Bilogora, odsjek 14b i 14c).

Cilj anketnog upitnika “Odabir sustava pridobivanja drva AHP metodom” je testiranje i izrada višekriterijskog modela za usporedbu i ocjenu (rangiranje) postojećih sustava pridobivanja drva te donošenje odluke o najpogodnijim sustavima pridobivanja drva za konkretne uvjete pojedinih šumskih sastojina (radilišta).

Ispitivanja i rezultati upitnika ne mogu neposredno djelovati na primjenu određenog sustava pridobivanja drva. No, zadaća istraživanja je razviti model koji može ponuditi objektivne podloge za odlučivanje o najprikladnijim tehnologijama i sredstvima rada na brojnim različitim radilištima u hrvatskom šumarstvu. Bez Vašega sudjelovanja navedenu zadaću nije moguće ostvariti.

Najtoplije zahvaljujemo na tome što ste prihvatili provedbu ispitivanja i odlučili popuniti upitnik te na taj način pomogli u provedbi projekta i izradi višekriterijskog modela za odabir sustava pridobivanja drva!

UPUTE I POJAŠNJENJA ZA ISPUNJAVANJE UPITNIKA

Za konkretnu sastojinu/radilište ispitanici ocjenjuju pogodnost primjene pojedinih sustava pridobivanja drva s obzirom na više različitih kriterija.

Definirani sustavi pridobivanja drva (alternative) koje se uspoređuju su:

Red. br.	Opis*
A1.	Sjekač i adaptirani poljoprivredni traktor (APT)
A2.	Sjekač i skider s vitlom
A3.	Sjekač i traktorska ekipaža
A4.	Sjekač i forvarder
A5.	Harvester i forvarder
A6.	Sjekač i vučena žičara
A7.	Sjekač i kamionska žičara

* Značajke i opis definiranih sustava pridobivanja drva detaljnije su prikazani u Prilogu 1 ovoga upitnika.

Pretpostavljeni kriteriji i parametri za ocjenu alternativa su:

Kriteriji	***Podkriteriji****
• Tehnološko-biološki:	– Struktura doznačenog drva
	– Prometnost i prohodnost terena
	– Primarna i sekundarna otvorenost
• Ekonomski:	– Proizvodnost
	– Ekonomičnost
• Ekološki:	– Oštećenje staništa (tlo, voda)
	– Oštećenje sastojine (dubeća stabla, pomladak)
	– Onečišćenje i zagađenje okoliša
• Ergonomski:	– Fizičko opterećenje radnika
	– Radni okoliš (buka, vibracije, ozljede…)
• Energijski:	– Potrošnja goriva, maziva, rezervnih dijelova
• Estetski:	– Krajobraz i socijalna funkcija šume

Metoda za ocjenu pogodnosti definiranih sustava pridobivanja drva je Analitički hijerarhijski proces (AHP) - za donošenje prijedloga odluke i odabir sustava pridobivanja drva provodi se usporedba u parovima. Usporedba pod/kriterija i alternativa se obavlja pomoću Saaty-eve skale, na način da se iskazuje relativna važnost jednog pod/kriterija naspram onoga s kojim se uspoređuje, odnosno relativna preferencija jedne alternative (sustava pridobivanja drva) u odnosu na onu s kojom se uspoređuje.

Saatyy-eva skala za određivanje relativnih važnosti tj. preferencija:

Ocjena prioriteta	Opisna ocjena prioriteta	Objašnjenje
1	Jednaki prioritet	Dvije aktivnosti/opcije jednako doprinose cilju.
3	Umjereni prioritet	Na osnovi iskustva i procjene, daje se mala prednost jednoj aktivnosti/opciji.
5	Jaki prioritet	Na osnovi iskustva i procjene, daje se jaka prednost jednoj aktivnosti/opciji.
7	Vrlo jaki prioritet	Jedna aktivnost/opcija se strogo favorizira u odnosu na drugu i njezina dominacija dokazana je u praksi.
9	Apsolutni prioritet	Na najvećoj mogućoj razini dokazana je prednost jedne aktivnosti/opcije u odnosu na drugu.

∗ *Međuvrijednosti na Saaty-evoj skali (2, 4, 6, 8) predstavljaju kompromis između odgovarajućih susjednih vrijednosnih procjena.*

* Podkriterije dodatno opisuju sljedeći čimbenici tj. pokazatelji:
Struktura doznačenog drva – *dimenzije stabala, vrsta, sječna gustoća, srednje kubno stablo, veličina sječine, br. dozn. stabala pa ha.*
Prometnost i prohodnost terena – *nagib terena, površinske prepreke, nosivost podloge, prohodnost terena*
Primarna i sekundarna otvorenost šuma – *srednja udaljenost privlačenja, mreža sekundarnih šumskih prometnica*
Proizvodnost – *dnevni učinak*
Ekonomičnost – *troškovi proizvodnje*
Oštećenje staništa (tlo, voda) – *gaženje i sabijanje tla, ugrožavanje vodotokova*
Oštećenje sastojine (dubeća stabla, pomladak) – *oštećivanje preostalih stabala, uništavanje pomladka*
Onečišćenje i zagađenje okoliša – *emisije štetnih plinova, izljevanje goriva i maziva, ugrožavanje zaštićenih biljnih i životinjskih vrsta*
Fizičko opterećenje radnika – *frekvencija pulsa i potrošnja energije pri radu*
Radni okoliš – *utjecaj buke, vibracija, plinova, brojnost i težina ozljeda/profesionalnih oboljenja*
Potrošnja goriva, maziva, rezervnih dijelova – *utrošak goriva i maziva, rezervnih i potrošnih dijelova/materijala*
Krajobraz i socijalna funkcija šume – *utjecaj na krajolik te rekreativnu, turističku i zdravstvenu funkciju šume.*

Opis sastojine/radilišta:

UŠP Bjelovar, šumarija Bjelovar, GJ Bjelovarska Bilogora,

Odsjek 14b – mješovita sastojina običnog graba (84 %), obične bukve, hrasta lužnjaka, crne johe i hrasta kitnjaka; površina: 18,28 ha; starost: 79 godina; uređajni razred: sjemenjače običnog graba; drvna zaliha: 5.330 m^3 (291,58 m^3/ha); propisani intenzitet proreda u prvom polurazdoblju: 11,67 %; Označeno: 1.782 stabla (731,24 m^3); sječna gustoća: 98 stabala/ha (40 m^3/ha); srednji promjer označenih stabala: 21,7 cm; planirana srednja udaljenost primarnog transporta: 250 m.

Odsjek 14c – mješovita sastojinu obične bukve (50 %), običnog graba (44 %), hrasta kitnjaka i hrasta lužnjaka; površina: 9,07 ha; starost: 79 godina; uređajni razred: sjemenjače obične bukve; ophodnja: 100 godina; drvna zaliha: 3.681 m^3 (405,84 m^3/ha); propisani intenzitet proreda u prvom polurazdoblju: 11,08 %; označeno: 559 stabla (446,3 m^3); sječna gustoća: 62 stabla/ha (49 m^3/ha); srednji promjer označenih stabala: 26,4 cm; planirana srednja udaljenost primarnog transporta: 550 m.

ANKETNI UPITNIK

Odabir sustava pridobivanja drva AHP metodom

Upitnik se satoji od tri dijela. U prvom dijelu se usporedbom u parovima iskazuje relativna važnost tj. prioritet postavljenih kriterija. U drugome se dijelu unutar svakoga kriterija iskazuje relativna važnost pojedinih podkriterija. U trećemu se dijelu usporedbom u parovima iskazuje relativna važnost (preferencija) definiranih sustava pridobivanja drva s obzirom na svaki od postavljenih podkriterija.

Molimo Vas da u usporedbi svakoga para označite samo jedan odgovor tj. polje (☒) !

I. Usporedba u parovima – Kriteriji:

KRITERIJI

	9	7	5	3	1	3	5	7	9	
Tehnološko-biološki	☐	☐	☐	☐	☐	☐	☐	☐	☐	Ekonomski
Tehnološko-biološki	☐	☐	☐	☐	☐	☐	☐	☐	☐	Ekološki
Tehnološko-biološki	☐	☐	☐	☐	☐	☐	☐	☐	☐	Ergonomski
Tehnološko-biološki	☐	☐	☐	☐	☐	☐	☐	☐	☐	Energijski
Tehnološko-biološki	☐	☐	☐	☐	☐	☐	☐	☐	☐	Estetski
Ekonomski	☐	☐	☐	☐	☐	☐	☐	☐	☐	Ekološki
Ekonomski	☐	☐	☐	☐	☐	☐	☐	☐	☐	Ergonomski
Ekonomski	☐	☐	☐	☐	☐	☐	☐	☐	☐	Energijski
Ekonomski	☐	☐	☐	☐	☐	☐	☐	☐	☐	Estetski
Ekološki	☐	☐	☐	☐	☐	☐	☐	☐	☐	Ergonomski
Ekološki	☐	☐	☐	☐	☐	☐	☐	☐	☐	Energijski
Ekološki	☐	☐	☐	☐	☐	☐	☐	☐	☐	Estetski
Ergonomski	☐	☐	☐	☐	☐	☐	☐	☐	☐	Energijski
Ergonomski	☐	☐	☐	☐	☐	☐	☐	☐	☐	Estetski
Energijski	☐	☐	☐	☐	☐	☐	☐	☐	☐	Estetski

II. Usporedba u parovima – Podkriteriji (s obzirom na kriterij kojem pripadaju)**:**

TEHNOLOŠKO-BIOLOŠKI

	9	7	5	3	1	3	5	7	9	
Struktura doznačenog drva	☐	☐	☐	☐	☐	☐	☐	☐	☐	Prometnost i prohodnost terena
Struktura doznačenog drva	☐	☐	☐	☐	☐	☐	☐	☐	☐	Primarna i sekundarna otvorenost
Prometnost i prohodnost terena	☐	☐	☐	☐	☐	☐	☐	☐	☐	Primarna i sekundarna otvorenost

EKONOMSKI

	9	7	5	3	1	3	5	7	9	
Proizvodnost	☐	☐	☐	☐	☐	☐	☐	☐	☐	Ekonomičnost

EKOLOŠKI

	9	7	5	3	1	3	5	7	9	
Oštećenje staništa (tlo, voda)	☐	☐	☐	☐	☐	☐	☐	☐	☐	Oštećenje sastojine (dub. stabla...)
Oštećenje staništa (tlo, voda)	☐	☐	☐	☐	☐	☐	☐	☐	☐	Onečišćenje i zagađenje okoliša
Oštećenje sastojine (dub. stabla...)	☐	☐	☐	☐	☐	☐	☐	☐	☐	Onečišćenje i zagađenje okoliša

ERGONOMSKI

	9	7	5	3	1	3	5	7	9	
Fizičko opterećenje radnika	☐	☐	☐	☐	☐	☐	☐	☐	☐	Radni okoliš (buka, vibracije…)

III. Usporedba u parovima – Alternative (s obzirom na pojedini podkriterij)**:**

STRUKTURA DOZNAČENOG DRVA

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

PROMETNOST I PROHODNOST TERENA

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

PRIMARNA I SEKUNDARNA OTVORENOST

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara

Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

PROIZVODNOST

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

EKONOMIČNOST

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder

Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

OŠTEĆENJE STANIŠTA (TLO, VODA)

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

OŠTEĆENJE SASTOJINE (DUBEĆA STABLA, POMLADAK)

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder

Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

ONEČIŠĆENJE I ZAGAĐENJE OKOLIŠA

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

FIZIČKO OPTEREĆENJE RADNIKA

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara

Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

RADNI OKOLIŠ (BUKA, VIBRACIJE, OZLJEDE…)

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

POTROŠNJA GORIVA, MAZIVA, REZERVNIH DIJELOVA

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža

Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

KRAJOBRAZ I SOCIJALNA FUNKCIJA ŠUME

	9	7	5	3	1	3	5	7	9	
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i skider s vitlom
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i APT	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i traktorska ekipaža
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i skider s vitlom	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i traktorska ekipaža	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Harvester i forvarder
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Sjekač i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i vučena žičara
Harvester i forvarder	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara
Sjekač i vučena žičara	☐	☐	☐	☐	☐	☐	☐	☐	☐	Sjekač i kamionska žičara

Prilog: Definirani sustavi pridobivanja drva

Sustavi pridobivanja drva / Osnovne značajke sustava pridobivanja drva	Sjekač – APT	Sjekač – Skider s vitlom	Sjekač – Traktor. ekipaža	Sjekač – Forvarder	Harvester – Forvarder	Sjekač – Vučena žičara	Sjekač – Kamion. žičara
Način kretanja drva	vuča drva jednim krajem oslonjenim o tlo		izvoženje drva na kotaču vozila			iznošenje drva ovješenog o kolica (nosivo uže)	
Način prihvata drva	vučnim užem vitla		uže vitla + hidra. dizalica	hidrauličnom dizalicom		podiznim / vučnim užem	podiznim užem
Pogodna metoda izradbe drva	(polu)deblovna		sortimentna			prilagodba ovisno o značajkama stabala i žičare	
Mjesto izradbe (dorade) drva	pomoćno stovarište		mjesto sječe stabla (kod panja)		kraj sekund. prometnice	ovisno o metodi izradbe drva	
Potreba za prostranim stovarištima	velika		mala			velika	
Potreba za pomoćnim radnikom	za prerezivačem na pom. stovarištu i kopčašem (osim u skupnome radu)			nema je		ovisno o metodi izradbe drva	
Prilagodljivost skupnome radu	velika			mala	velika		
Razina osposobljenosti radnika	mala do osrednja		velika		vrlo velika	osrednja do velika	vrlo velika
Optimalna udaljenost privlačenja, m	100 m	200 m	400 m			< 400 m**	< 800 m**
Najveća udaljenost privlačenja, m	200 m	300 m	800 m			** ovisno o najvećoj duljini nosivoga uža	
Uzdužni nagib terena, %	± 15 (20) %	± 35 %	± 15 %	± 30 %		bez ograničenja	
Osjetljivost na bočni nagib terena	vrlo velika	osrednja do velika	vrlo velika	velika		bez ograničenja	
Prikladnost pridob. tankih stabala	vrlo velika		osrednja do velika	velika, pri sakupljenom drvu uz sek. prometnicu		osrednja do velika	
Prikladnost pridob. debelih stabala	osrednja	velika*	osrednja	vrlo velika	velika (*BHD* < 40 cm)	osrednja do velika	
Prilagodljivost niskim sječ. gustoćama	vrlo velika			osrednja do velika		mala	
Prikladnost za male sječine	velika			osrednja		mala	
Mogućnost oštećenja šumskog tla	vrlo velika pri ograničenoj nosivosti tla					ne postoji pri potpunoj odignutosti drva od tla	
Mogućnost oštećenja dubećih stabala	velika		mala			osrednja	
Tipično područje pogodnosti primjene sustava pridobivanja drva	prorede šuma nizinskog i brežuljkastog područja	sve vrste prihoda bez obzira na područje šuma*	prorede šuma nizinskog i brežuljkastog područja	kas. prorede i oplod. sječe nizin. i brežulj. šuma	kulture četinjača i brzorastućih listača	prorede šuma brežuljkastog i brdskog područja	oplodne i preborne sječe brdskih te gorskih šuma
Tipični oblici mreže sekundarnih šumskih prometnica Traktorske vlake – negrađene sekund. prometnice, prosječeni i/ili obilježeni dijelovi za šumska vozila prometnoga terena (uzdužnoga nagiba <20(25) %) Traktorski putovi – građene sek. prometnice uzdužnoga nagiba <20(25) %, na terenima neprometnim za šumska vozila	Raspored »riblja kost« 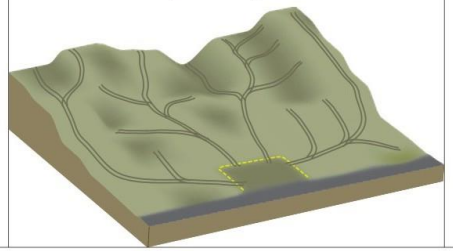		Paralelan (usporedan) raspored 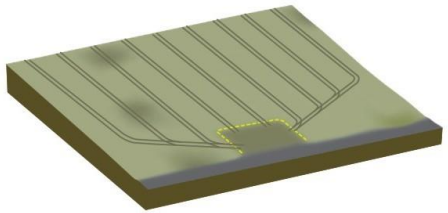			Nema zahijeva za sekundarnom šumskom infrastrukturom. Na prostorni položaj i raspored trasa žičare pojedine sječine, presudan utjecaj ima položaj šumske ceste, odnosno terenske i sastojinske prilike. Doznaka se stabala provodi nakon određivanja položaja žičnih linija. Dimenzije doznačenih stabala, određivat će metodu izradbe drva, kojom će se iznošeni teret prilagođavati nosivosti žičare.	

* odabir skidera (laki, srednje teški, teški) zasnovan je na vrsti prihoda, odnosno dimenzijama doznačenih stabala; promjenom metode izradbe drva prilagođuje se količina drva u teretu mogućnostima skidera

Prema: Poršinsky, T., 2008: Sustavi pridobivanja drva. Predavanje iz kolegija »Pridobivanje drva I«, Šumarski fakultet Sveučilišta u Zagrebu, 1–20.

6. Glavni pokus – GJ »Bjelovarska Bilogora«, odsjeci 14b i 14c – Primjena strojne sječe i izrade u proredi bjelogoričnih sastojina

Terenski je dio istraživanja primjene strojne sječe i izrade u proredi bjelogoričnih sastojina proveden u odsjecima 14b i 14c gospodarske jedinice »Bjelovarska Bilogora« kojom gospodari šumarija Bjelovar, Uprava šuma podružnica Bjelovar trgovačkog društva »Hrvatske šume« d.o.o. Zagreb (slika 6.1).

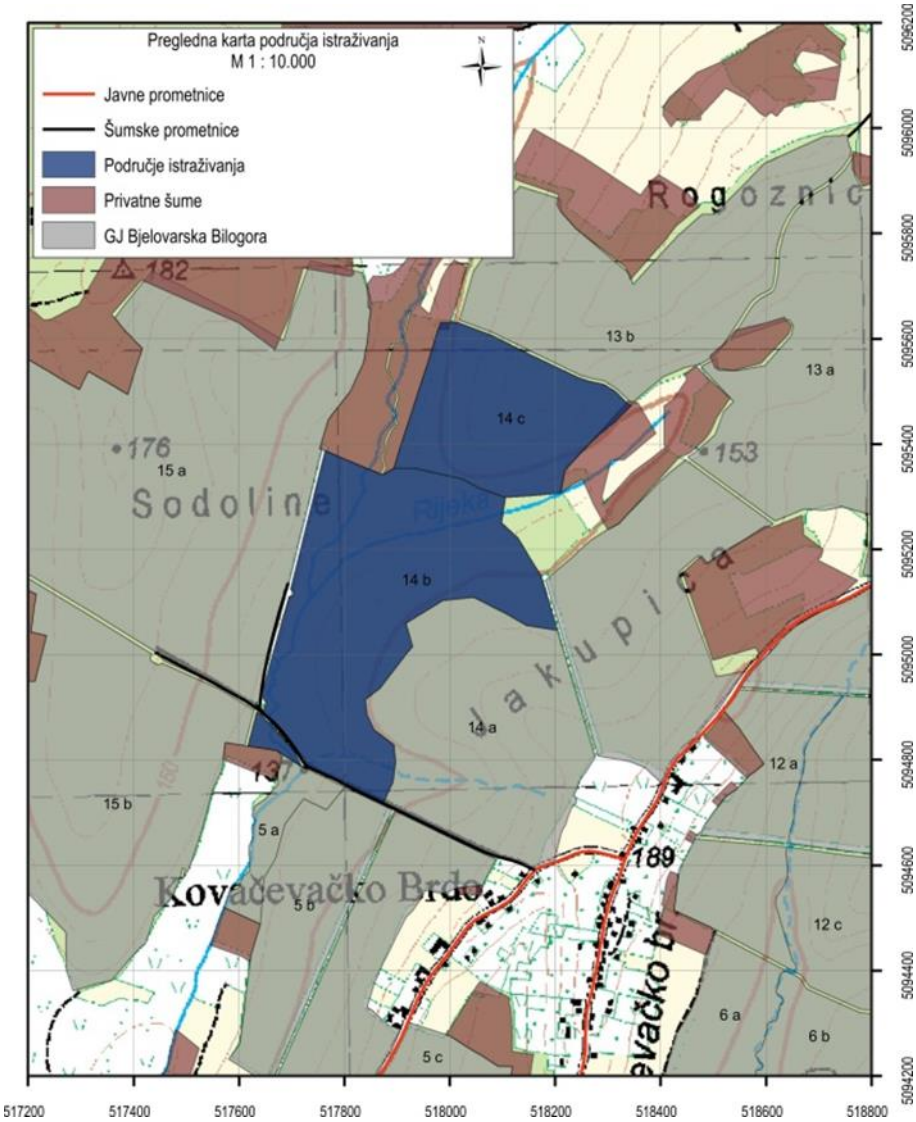

Slika 6.1 Pokusne plohe glavnoga istraživanja

Pripremni su radovi provedeni tijekom ljeta i jeseni 2016. godine, a uključivali su obilježavanje vlaka u sječini, nužnih za nesmetan rad harvestera i forvardera. S obzirom na nužnost doznake pojedinih stabala na trasama vlaka bilo je nužno obaviti i korekciju doznake stabala s ciljem omogućivanja kretnosti strojeva i dohvata stabala harvesterskom glavom (»harvesterske pruge« odgovarajućeg razmaka i prostornog rasporeda – slika 6.2).

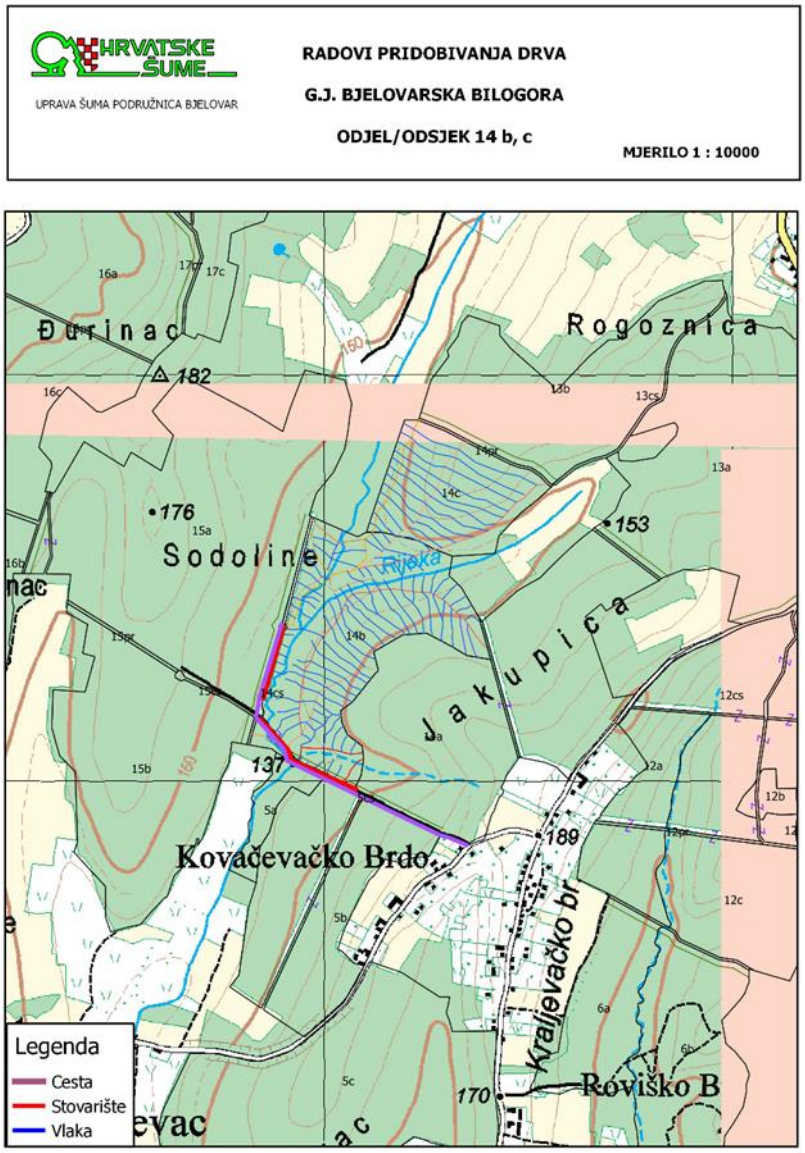

Slika 6.2. Šumska prometna infrastruktura mjesta istraživanja

Prema podacima osnove gospodarenja iz 2013. godine, odsjek 14b je površine 18,28 ha, uređajnog razreda običnog graba starosti 79 godina na II bonitetu. Propisana ophodnja iznosi 70 godina. Odsjek se nalazi na nadmorskoj visini 100 m, nagiba 3–9 %, ekspozicija je zapadna. Tlo je lesivirano i na njemu se razvila fitocenoza šume lužnjaka i običnog graba s bukvom. Sklop je potpun, a obrast iznosi 1,23. Drvna zaliha iznosi 291,58 m^3/ha, odnosno 5330 m^3 u odsjeku, od čega 18,16 m^3/ha čini hrast lužnjak, 3,72 m^3/ha hrast kitnjak, 17,34 m^3/ha obična bukva, 243,71 m^3/ha obični grab, 0,33 m^3/ha OTB i 8,32 m^3/ha crna joha. Broj stabala iznosi 784 po ha dok temeljnica iznosi 28,88 m^2/ha. Srednje plošno stablo je promjera 21,60 cm, dok je godišnji tečajni prirast 7,49 m^3/ha, odnosno 137 m^3 u odsjeku. Prema propisu osnove gospodarenja za prvo polurazdoblje treba obaviti proredu intenzitetom 11,67 %, odnosno 34,03 m^3/ha. Propisana je sječa 32 m^3/ha običnog graba i 2,02 m^3/ha obične bukve.

Prilikom doznake za ručno-strojnu sječu i izradu ukupno je doznačeno 1.455 stabala ukupnog obujma 741,81 m^3. Naknadno je doznakom stabala na vlakama i korekcijom prethodne doznake dostignut broj od 1.782 doznačenih stabla za strojnu sječu ukupnog obujma 731,24 m^3. Distribucija doznačenih stabala i doznačenog obujma po debljinskim stupnjevima i vrstama drveća obrađena je i prikazana u histogramskom obliku (slika 6.3).

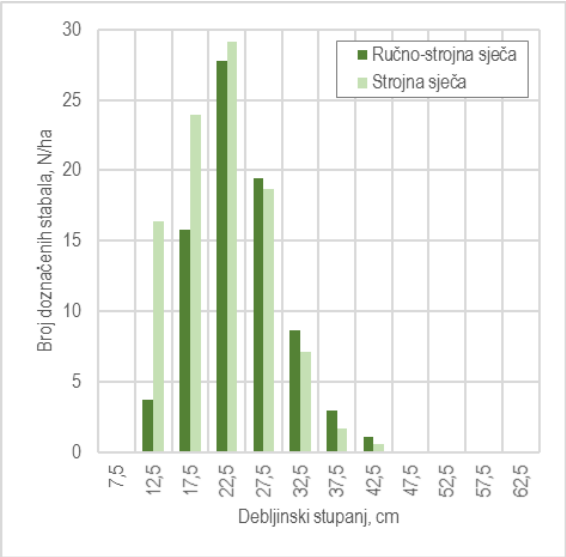

Slika 6.3 a) Distribucija doznačenih stabala po debljinskim stupnjevima za odsjek 14b

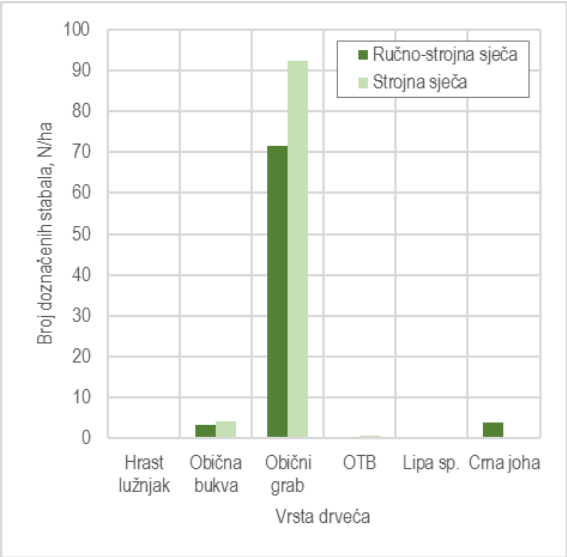

Slika 6.3 b) Distribucija doznačenih stabala po vrstama drveća za odsjek 14b

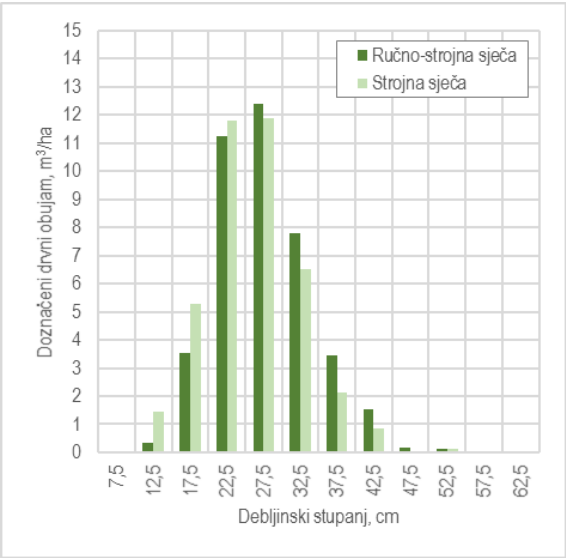

Slika 6.3 c) Distribucija doznačenog obujma po debljinskim stupnjevima za odsjek 14b

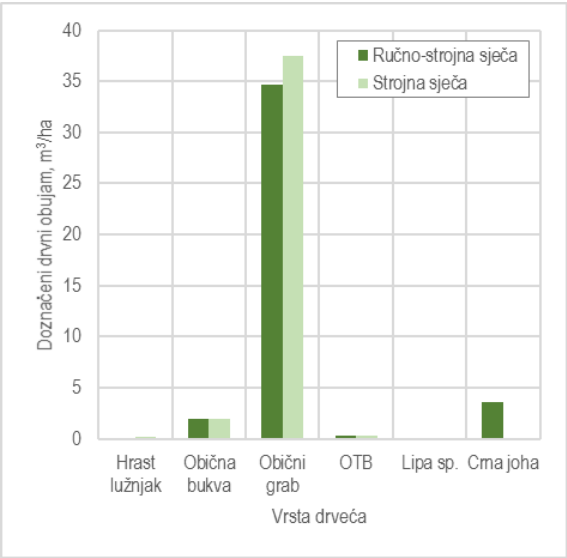

Slika 6.3 d) Distribucija doznačenog obujma po vrstama drveća za odsjek 14b

Odsjek 14c je površine 9,07 ha, uređajnog razreda bukve starosti 79 godina na I bonitetu. Propisana ophodnja iznosi 100 godina. Odsjek 14 c se nalazi na nadmorskoj visini 150–175 m, prosječni nagib iznosi 3–9 %, a ekspozicija je jugo-zapadna. Tlo je lesivirano, a fitocenzu predstavlja submontanska bukova šuma s trepavičastim šašem. Sklop je potpun, dok obrast iznosi 1,06. Drvna zaliha iznosi 405,84 m^3/ha, odnosno 3681 m^3 u odsjeku, od toga hrasta lužnjaka 7,94 m^3/ha, hrasta kitnjaka 16,54 m^3/ha, obične bukve 201,76 m^3/ha i običnog graba 179,60 m^3/ha. Broj stabala je 540 po ha, a temeljnica iznosi 30,98 m^2. Srednje plošno stablo je promjera 30,98 cm, dok je godišnji tečajni prirast 9,70 m^3/ha odnosno 88 m^3 u odsjeku. Prema propisu osnove gospodarenja za prvo polurazdoblje treba obaviti proredu intenzitetom 11,08 %, odnosno 44,98 m^3/ha; od toga obične bukve 19,96 m^3/ha, a običnog graba 25,03 m^3/ha.

Prilikom doznake za ručno-strojnu sječu i izradu ukupno su doznačena 423 stabala ukupnog obujma 407,02 m^3. Naknadno je doznakom stabala na vlakama i korekcijom prethodne doznake dostignut broj od 559 doznačenih stabla za strojnu sječu ukupnog obujma 446,3 m^3. Distribucija

označenih stabala i označenog obujma po debljinskim stupnjevima i vrstama drveća obrađena je i prikazana u histogramskom obliku (slika 6.4).

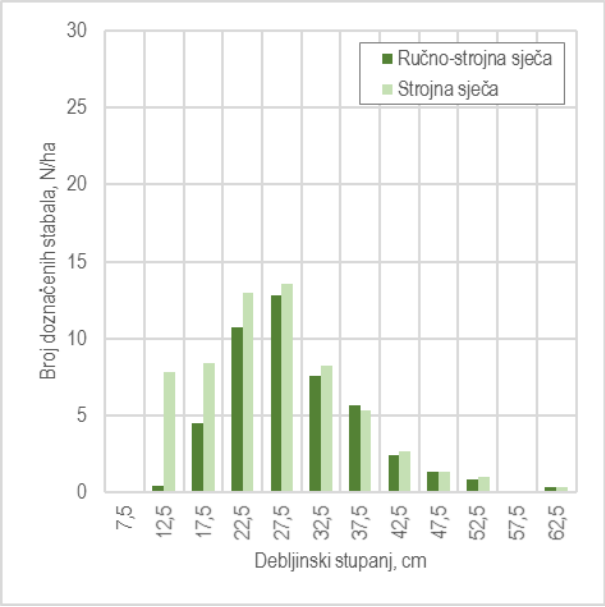

Slika 6.4 a) Distribucija označenih stabala po debljinskim stupnjevima za odsjek 14c

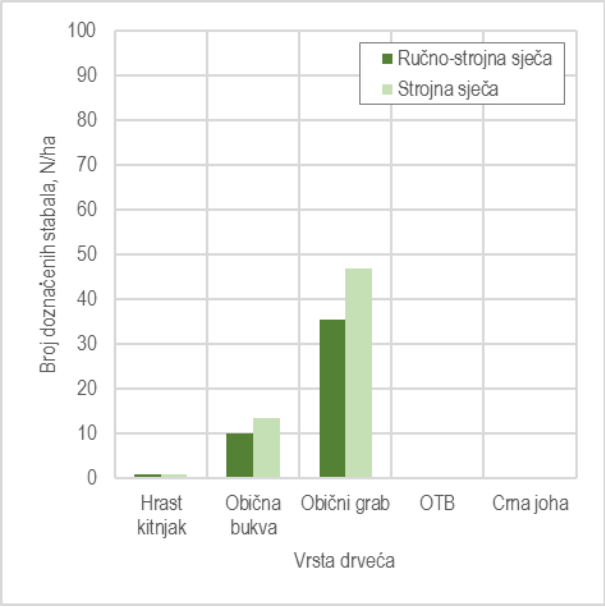

Slika 6.4 b) Distribucija označenih stabala po vrstama drveća za odsjek 14c

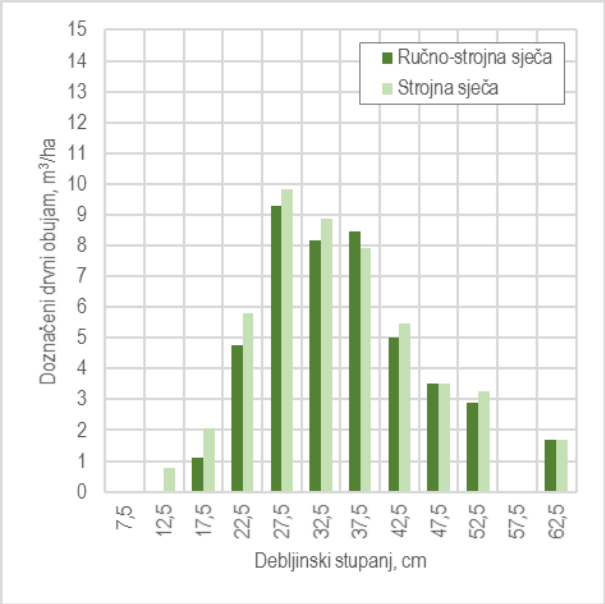

Slika 6.4 c) Distribucija označenog obujma po debljinskim stupnjevima za odsjek 14c

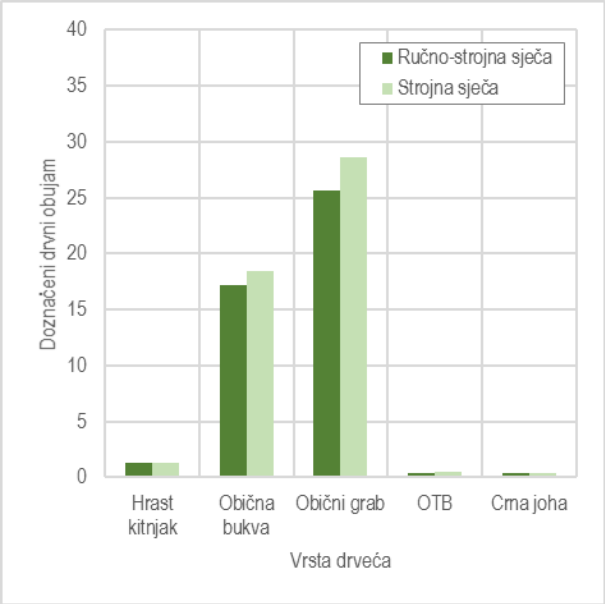

Slika 6.4 d) Distribucija označenog obujma po vrstama drveća za odsjek 14c

Sječa staba i izrada drvnih sortimenata obavljena je jednozahvatnim harvesterom Timberjack 1470D, a izvoženje izrađenih drvnih sortimanata obavljeno je forvarderom Timberjack 1710D.

Jednozahvatni harvester Timberjack 1470D šesterokotačno je vozilo (6 WD) s bogi sustavom na prednjoj osovini, njegova namjena je kretanje po bespuću te sječa i izrada drvnih sortimenata. Predstavnik je kategorije velikih harvestera širokog raspona primjene. Duljina harvestera Timberjack 1470D iznosi 7700 mm, visina mu je 3830 mm. Širina harvestera iznosi 3000 mm, dok mu je masa 18.800 kg. Timberjack 1470D pokreće motor John Deere JD6081 HTJ 04, 6-cilindrični, turbo diesel motor sa prednabijanjem. Maksimalna snaga motora je 180 kW pri brzini vrtnje od 1200–2000 min^{-1}. Maksimalni zakretni moment je 1250 NM pri brzini vrtnje motora od

1400 min^{-1}. Transmisija je kod istraživanog harvestera hidrostatsko-mehanička sa sporim i brzim hodom koji omogućuje promjenu brzine kretanja vozila bez prekida toka snage prema kotačima. Najveća obodna sila vozila je 190 kN, brzina kretanja po bespuću 7 km/ha, a putna brzina iznosi 24 km/h. Prednje gume su dimenzija 650x26,5, a stražnje 700x34. Harvester Timberjack 1470D koristi paralelnu hidrauličku dizalicu model TJ 200 H 97 na kojoj je ugrađena sječna glava. Deklarirani podizni moment je 178 kNm, a zakretni moment je 43,6 kNm. Doseg dizalice iznosi 10 m, dok je kut zakretanja 220°. Kontrola sustava kod havestera Timberjack 1470D (Total Machine Control) upravlja pogonskim motorom, transmisijom, radom dizalice i stabilnošću vozila. Računalni sustav (Timberjack 300) kontrolira rad sječne glave, izmjeru drvnih sortimenata, trupljenje debala (izradu sortimenata zadanih dimezija) te pohranjivanje podataka o izrađenoj oblovini koji se mogu ispisati ili pohraniti na računalo. Kabina je lagana, komforna i pregledna i izrađena u skladu s propisanim međunarodnim normama ISO (ROPS, POPS, OPS, BC). Harvester Timberjack 1470D je opremljen sječnom glavom Timberjack 758. Najveći sječni promjer iznosi 65 cm. Masa sječne glave s rotatorom iznosi 1080 kg. Posmak stabla kroz sječnu glavu ostvaruju četiri čelična valjka, sa silom u rasponu od 22 do 27 kN, uz posmičnu brzinu 0–4,7 m/s. Kresanje grana obavljaju tri pokretna te jedan fiksni nož. Vodilica lančane pile je dugačka 75 cm, a brzina kretanja lanca iznosi 40 m/s.

Slika 6.5. Harvester Timberjack 1470D

Slika 6.6. Sječna glava Timberjack 758

Forvarder Timberjack 1710D, osmerokotačno je vozilo (8 WD) s bogi sustavom na prednjoj i stražnjoj osovini. Ovaj tip forvardera pripada kategoriji teških forvardera, mase preko 14 tona. Njegova namjena je prvenstveno izvoženje drva prilikom čistih sječa (u kulturama četinjača) te za izvoženje drva prilikom oplodnih sječa (u sastojinama listača). Iako njegova primjena u prorednim sječama nije isključujuća, prilikom izvoženja drva iz prorednih sječina ograničavajući čimbenik su prvenstveno njegove dimenzije. Duljina Timberjacka 1710D je 10.900 mm, dok je njegova širina 3050 mm. Visina forvardera do vrha dizalice je 3900 mm, a njegova masa ovisi o stupnju opremljenosti i može iznositi od 18.500 do 19.500 kg. Timberjack 1710D pokreće pogonski agregat John Deere 6081H, 6-cilindrični, turbo diesel motor snage 160 kW (215 KS) pri brzini vrtnje od 2100 min^{-1}. Maksimalni zakretni moment iznosi 1090 Nm pri brzini vrtnje od 1400 min^{-1}. Transmisija forvardera Timberjack 1710D je hidrostatsko-mehanička sa po dvije brzine naprijed i nazad, a najveća pitna brzina je 23 km/h, dok najveća obodna sila na kotačima iznosi 200 kN. Dimenzije prednjih i stražnjih guma su identične i iznose 750x26,5. Timberjack 1710D je opremljen hidrauličnom dizalicom Boom CF885 na kojoj se nalazi hvatalo. Maksimalni dohvat dizalice je 8500 mm. Deklarirani podizni moment je 151 kNm, dok je zakretni moment 41 kNm. Nosivost forvardera iznosi 17.000 kg.

Slika 6.7 Forvarder Timberjack 1710D

Slika 6.8 Izvoženje drvnih sortimenata

Sječa stabala se izvodila na način da se harvesterskom glavom obuhvatilo deblo dubećeg stabla (što je moguće bliže tlu) nakon toga se izvodilo potpiljivanje te pad stabla. Nakon sječe slijedi izrada oborenog stabla, i to na način da se tehnička oblovina izrađivala sukladno propisanim normama, odnosno duljine su bile određene razredima kakvoće. Višemetarsko prostorno drvo je izrađivano na standardne duljine od 4 m. Izrađene drvne sortimente harvester je slagao pored »harvesterske pruge« sa koje je obavljao sječu i izradu, dok je ostatak neizrađene krošnje (sitnu granjevinu odlagao pod kotače.

Izvoženje forvarderom odvijalo se po prethodno obilježenim postojećim vlakama te »harvesterskim prugama«. Tehnička oblovina i višemetarsko prostorno drvo odvajani su prilikom utovara u odvojene tovare/turnuse.

Slika 6.9 Tovar višemetarskog prostornog drva

Slika 6.10 Tovar tehničke oblovine

Za pomoćno stovarište korištena je šumska cesta na kraju koje je bila okretaljka koja je služila za okretanje kamiona koji su odvozili drvo s pomoćnog stovarišta, ali je također služila kao i mjesto za parkiranje strojeva na kraju radnog dana. Drvni sortimenti odlagani su s obje strane pomoćnog stovarišta, i to višemetarsko prostorno drvo s jedne strane, a tehnička oblovina (furnirski i pilanski trupci) s druge strane. Osim odvajanja drva na višemetarsko prostorno drvo i tehničku oblovinu na pomoćnom stovarištu nije vršeno dodatno odvajanje drva npr. prema vrstama drveća. Pomoćno stovarište se protezalo na duljini od 120 m iz razloga što se primanje drvnih sortimenata

također odvijalo na pomoćnom stovarištu te je tehnička oblovina bila razvučena s jedne strane pomoćnog stovarišta i na taj način je poslovođi bila olakšana izmjera tehničke oblovine te njeno zaprimanje. Višemetarsko prostorno drvo je za razliku od tehničke oblovine bilo uhrpano te je na taj način prostor pomoćnog stovarišta bio najbolje iskorišten. Otprema drvnih sortimenata vršila se gotovo svakodnevno, osobito višemetarskog prostornog drva koje je voženo kamionskim skupovima, ali i traktorom s poluprikolicom opremljenom dizalicom. Zadnjega dana snimanja formairano je novo pomoćno stovarište u duljini od 30 m, također uz šumsku cestu, radi smanjenja udaljenosti izvoženja drvnih sortimenata iz 14b odsjeka.

6.1 Ekonomski pokazatelji

Proizvodnost skupnoga rada harvestera i forvardera u istraživanim sječinama istraživana je metodama studija rada i vremena. Studij rada kao znanstvena osnova organizacije rada i organizacije proizvodnje polazi od čovjeka i njegova rada te analize čovjek – radno mjesto – radna okolina. Zadatak je studija rada da znanstvenim metodama te logičkim, cjelovitim i sustavnim analizama dođe do optimalno oblikovanog načina rada te realnog vremena izrade, odnosno objektivno izračunane norme (Taboršak 1987). Studijem vremena utvrđuje se tehnička norma vremena, odnosno vrijeme koje je potrebno za izradu proizvoda u cjelini kao i za pojedine faze izrade. Istraživanjem se utvrđuje realno potrebno vrijeme izrade koje služi za izračunavanje norme čiji je cilj organizacijski i humano optimalno oblikovati rad.

Za usporedbu pogodnosti uporabe nekog sredstva rada u različitim eksploatacijskim uvjetima ili pri obavljanju rada različitim metodama u sličnim eksploatacijskim uvjetima dovoljno je usporediti proizvodnost rada, iskazanu u jednakim jedinicama. No, za usporedbu pogodnosti uporabe različitih sredstava rada u istim eksploatacijskim uvjetima nužno je osim proizvodnosti poznavati i odnosne troškove rada. Za jedinicu mjere koristi se jedinični trošak rada iskazan po jedinici proizvoda, a računa se kao količnik troška rada iskazanoga po jedinici vremena i proizvodnosti rada iskazane po istoj jedinici vremena (najčešće osmosatni radni dan ili radni sat). Za komparativne troškovne analize u pridobivanju drva najbolje je koristiti direktni trošak strojnoga rada (eng. machine rate), koji se sastoji od fiksnih i varijabilnih troškova stroja te troškova radnika.

Snimanje utroška vremena pojedinih radnih zahvata obavljeno je upotrebom tableta Alcatel plus 10 s instaliranim softverskim paketom za provođenje studija rada i vremena, komercijalnog naziva UmtPlus proizvođača Laubrass. Softver UmtPlus je i prije korišten pri snimanju utroška vremena radnih zahvata različitih strojeva koji se koriste u šumarstvu (Mudri 2012, Sever 2013).

Sever (2013) kao osnovne prednosti korištenja softvera UmtPlus prilikom snimanja utroška vremena pojedinih radnih zahvata navodi manju mogućnost pogreške prilikom mjerenja te pojednostavljeno bilježenje podataka. Podaci se ne moraju bilježiti na snimačkom listu i kasnije ručno unositi u program za obradu rezultata, već se oni automatski spremaju u memoriju softvera. Snimljene podatke je zatim moguće prebaciti na osobno računalo pomoću softvera UMT Manager iz kojeg ih je moguće brzo i jednostavno eksportirati u Microsoft Excel gdje se vrši daljnja obrada. Upravo su pozitivna iskustva i prednosti korištenja softvera UmtPlus, naspram u prošlosti korištene povratne metode kronometrije i snimanja utroška vremena pojedinog radnog zahvata kronometrom bili razlog korištenja softvera UmtPlus prilikom provedenog istraživanja.

U oba odsjeka istraživanju su prethodili detaljni pripremni radovi. Prije snimanja radnog procesa harvestera bilo je potrebno obilježiti doznačena stabla za sječu i to na način, da su stabla koja su služila kao uzorak za utvrđivanje izrađenog neto obujma bila obilježena rednim brojevima, koji su na stabla bili napisani s dvije nasuprotne strane, a njihov prsni promjer je bio evidentiran na terenski obrazac poradi daljnje obrade podataka. Obilježavanje stabala korištenih samo za izračun proizvodnosti obavljeno je na način da je za svako stablo izmjeren prsni promjer te napisan na stablo, također obavezno s dvije nasuprotne strane, kako bi bio vidljiv bez obzira s koje strane harvester prilazi stablu. Pri snimanju forvardera pripremni radovi su obuhvaćali izmjeru i obilježavanje duljina vlaka. Duljina je bila izmjerena mjernom vrpcom duljine 50 m, te je na svakih

50 m na najbliže nedoznačeno stablo ljepljivom trakom i sprejom obilježena udaljenost segmenata vlake rastućih po 50 m.

Za osnovnu jedinicu praćenja radnoga procesa odabrano je kod sječe i izrade stablo, a kod primarnoga transporta turnus izvoženja (Vusić 2013). Učinkovitost strojne sječe i izrade harvesterom utvrđena je naknadnom analizom radnog procesa (po stablima poznatog prsnog promjera) koji je snimljen digitalnom kamerom. Pri snimanju harvestera korištena je digitalna kamera postavljena na kabinu harvestera. Ovakav način snimanja odabran je iz razloga što je opasno i propisima zaštite na radu zabranjeno biti u blizini harvestera prilikom njegova rada, a što je neophodno da bi se na direktan način evidentirali utrošci vremena za pojedine radne zahvata. Također istraživani je harvester bio jednozahvatni te kod njega pojedini radni zahvati traju vrlo kratko i iziskuju veliku koncentraciju osobe koja snima te njegove brze reflekse. Kako bi se utvrdio utrošak vremena pojedinog radnog zahvata, snimljene je video zapise bilo potrebno analizirati pomoću softvera UmtPlus, u kojemu su prethodno bili definirani radni zahvati harvestera. Svaki radni zahvat ima svoj početak i kraj. Početak jednog radnog zahvata ujedno je završetak prethodnog radnog zahvata, a taj trenutak u kojemu dolazi do promjene radnog zahvata nazivamo fiksažna točka. Fiksažne točke moraju biti definirane prije početka snimanja, kako bi bilo moguće prepoznati kada počinje novi, a završava prethodni radni zahvat, odnosno prekid rada. Prilikom snimanja utvrđeni su sljedeći radni zahvati harvestera koji su obuhvaćali efektivni rad harvestera:

- **Vožnja do sječine:** odvija se prilikom ulaska harvestera u sječinu. Obuhvaća vrijeme od kada je harvestere krenuo s pomoćnog stovarišta, pa do zauzimanja položaja za sječu prvog stabla tog radnog dana.
- **Vožnja do pomoćnog stovarišta:** odvija se prilikom izlaska iz sječine, odnosno obuhvaća vrijeme od sječe i izrade posljednjeg stabla tog radnog dana pa do dolaska na pomoćno stovarište.
- **Premještanje harvestera:** predstavlja radni zahvat za vrijeme kojega se harvester kreće od prethodno posječenog i izrađenog stabla ka slijedećem stablu. Započinje nakon izrade krošnje prethodnog stabla i traje do početka zauzimanja položaja za sječu slijedećeg stabla.
- **Zauzimanje položaja:** nastupa nakon što je harvester završio s premještanjem i traje dok hatvesterska glava ne obuhvati doznačeno stablo.
- **Sječa:** je radni zahvat za vrijeme kojega se odvija prerezivanje debla te pad stabla na tlo. Početak radnog zahvata je nakon što je stablo obuhvaćeno harvesterskom glavom i traje do pada stabla na tlo ili do zaustave ukoliko se stablo prilikom pada naslonilo na okolna stabla.
- **Pomicanje:** radni je zahvat za vrijeme kojega operater hidrauličnom dizalicom zaustavljeno stablo povlači na tlo. Traje nakon sječe, pa sve dok stablo ne padne na tlo.
- **Izrada:** obuhvaća izradu debla i krošnje.
- **Izrada debla:** radni zahvat koji obuhvaća trupljenje debla. Započinje nakon pada stabla na tlo pa do izrade krošnje, odnosno pomicanja harvesterske glave do prve žive grane na stablu ili do rašlji.
- **Izrada krošnje:** je radni zahvat za vrijeme kojega se vrši kresanje grana i trupljenje preostalog drva koje se može izraditi iz krošnje. Započinje nakon trupljenja debla i traje do kraja izrade stabla.
- **Uhrpavanje:** pojavljuje se povremeno i najčešće nastupa nakon izrade krošnje, a podrazumijeva uhrpavanje izrađenih sortimenata ili sitne granjevine koja ostaje nakon izrade.

Slika 6.11. Detalji s terenskog istraživanja proizvodnosti harvestera i forvardera

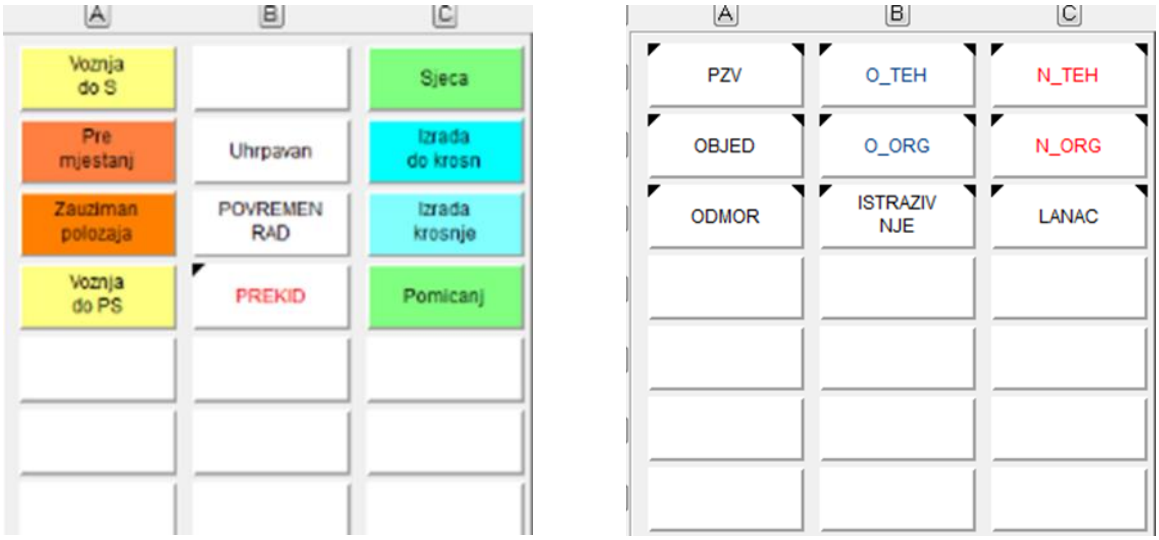

Slika 6.12 Sučelje softvera UmtPlus za analizu snimaka rada harvestera (lijeovo – radni zahvati; desno – prekidi)

Za stabla poznatih prsnih promjera koja su služila kao uzorak, neto obujam je izmjeren i evidentiran sukladno »Hrvatskim normama proizvoda iskorištavanja šuma« (HRN). Na uzorku stabala u oba odsjeka uspoređena je točnost mjerenja i evidencije izrađenih drvnih sortimenata računalnim sustavom harvestera te stupanj dorade sortimenata prilikom izrade.

Slika 6.13 Izmjera izrađenih sortimenata i određivanje stupnja dorade

Učinkovitost izvoženja oblog drva forvarderom praćena je terenskim računalom s pripadajućim računalnim algoritmom konstruiranim pomoću UmtPlus programskog paketa. Snimanje utrošaka vremena pojedinih radnih zahvata forvardera obavljeno je neposredno na terenu, sa sigurne udaljenosti i uz korištenje zaštitne opreme (zaštitna kaciga i reflektirajući prsluk) kako bi snimatelj bio uočljiv operateru forvardera. Pri snimanju korišten je terensko računalo s prethodno instaliranim softverom UmtPlus.

Prije snimanja definirane su fiksažne točke, odnosno pojedini radni zahvati:

- **Vožnja neopterećenog forvardera po pomoćnom stovarištu:** ovaj radni zahvat odvija se na pomoćnom stovarištu, odnosno na izgrađenoj šumskoj cesti uz koju je formirano pomoćno stovarište. Početak vožnje je nakon istovara posljednjeg sortimenta iz tovara i traje do ulaska forvardera u sječinu.
- **Vožnja neopterećenog forvardera po sječini:** započinje nakon ulaska forvardera u sječinu, a završava zaustavljanjem vozila na mjestu utovara drvnih sortimenata.
- **Utovar:** nakon zaustavljanja vozila započinje utovar drvnih sortimenata, koji traje dok se ne napuni tovarni prostor forvardera ili dok se ne utovare svi sortimenti u dohvatu hidraulične dizalice.
- **Pomicanje po sječini:** radni zahvat koji predstavlja premještanje forvardera do slijedećeg složaja drvnih sortimenata. Odvija se nakon utovara svih sortimenata u dohvatu hidraulične dizalice pa do premještanja do slijedećeg složaja drvnih sortimenata.
- **Vožnja opterećenog forvardera po sječini:** radni zahvat koji započinje nakon što se napunio tovarni prostor forvardera i obuhvaća vožnju po sječini do pomoćnog stovarišta.
- **Vožnja opterećenog forvardera po pomoćnom stovarištu:** dolaskom prednjih kotača forvardera na pomoćno stovarište započinje ovaj radni zahvat, a završava dolaskom do mjesta istovara, odnosno početkom istovara.
- **Istovar:** istovar drvnih sortimenata započinje nakon zaustavljanja forvardera na pomoćnom stovarištu i traje sve dok se ne istovari posljednji sortiment u tovaru.
- **Pomicanje po pomoćnom stovarištu:** pomicanje forvardera po pomoćnom stovarištu se odvija ukoliko se cijeli tovar ne istovaruje na jedno mjesto, već se forvarder pomiče kako bi istovario ostatak tovara. Ovaj radni zahvat je izražen kod istovara tehničke oblovine koja se razvlači po pomoćnom stovarištu. Počinje početkom pomicanja forvardera i traje ponovnog početka istovara.
- **Uhrpavanje/razvrstavanje:** radni zahvat koji se ne pojavljuje redovno, a podrazumijeva uhrpavanje sortimenata na pomoćnom stovarištu ili razdvajanje tehničke oblovine i višemetarskog prostornog drva, ako se nalaze na istom složaju u sječini.

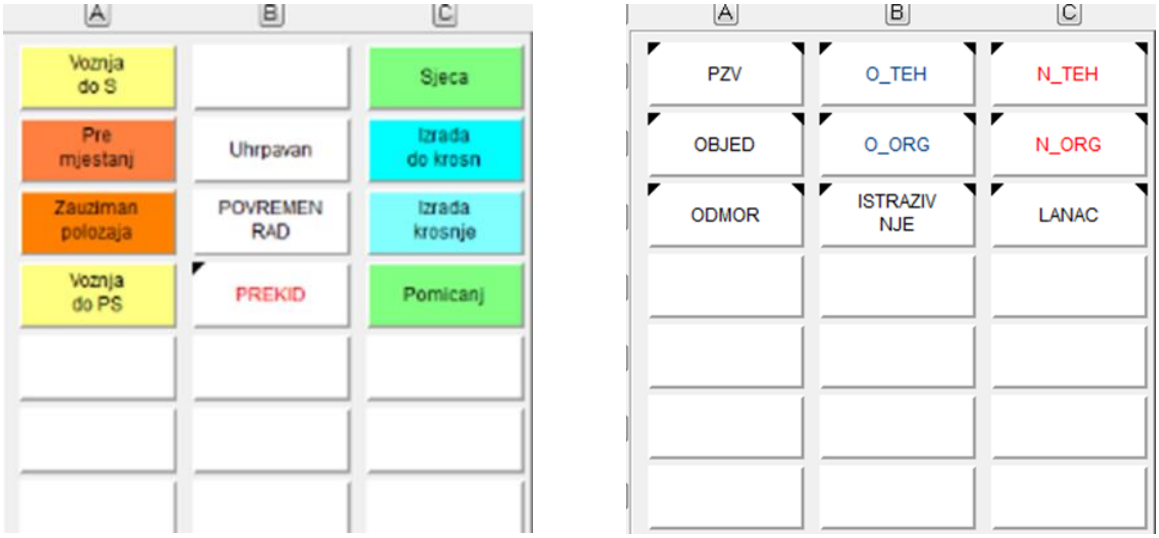

Slika 6.14 Sučelje softvera UmtPlus za snimanje raada forvardera (lijevo – radni zahvati; desno – prekidi)

Trajanje je pojedinih radnih zahvata analizirano je matematičko-statističkim metodama u ovisnosti o glavnim utjecajnim čimbenicima s ciljem konstruiranja matematičkih modela za izračun proizvodnosti harvestera, odnosno forvardera.

Tijekom istraživanja mehaniziranoga sustava pridobivanja drva sortimentnom metodom, u istraživanim je odsjecima ukupno posječeno, izrađeno i na pomoćno stovarište izvezeno 1020,89 m^3 drvnih sortimenata; od toga 26,73 % tehničke oblovine (272,89 m^3) i 73,27 % višemetarskog prostornog drva (748,00 m^3).

Od ukupno snimljenoga vremena rada harvestera na efektivno vrijeme otpada 68,83 %, dok je udio općeg vremena 31,17 %. Prosječni utrošak vremena vožnje harvestera od pomoćnog stovarišta do sječine iznosio je 5,52 minute, dok je prosječni utrošak vremena vožnje od sječine do pomoćnog stovarišta iznosio 5,94 minute po radnome danu. Za radni zahvat zauzimanje položaja prosječno je utrošeno 0,08 minuta po stablu. Za sječu stabala prosječno je utrošeno 0,25 minuta po stablu. Izrada debla prosječno iznosi 0,27 minuta po stablu, a na radni zahvat izrade krošnje prosječno je utrošeno 0,86 minuta po stablu. Na premještanje je prosječno utrošeno 0,56 minuta po stablu. Prosječni utrošak vremena za pomicanje stabala iznosi 0,04 minute po stablu. Na uhrpavanje je prosječno utrošeno 0,10 minuta po stablu.

Prsni promjeri posječenih i izrađenih stabala prilikom istraživanja kretali su se u rasponu od minimalno 10 cm do maksimalno 52 cm.

Faktor dodatnog vremena utvrđen je u iznosu 1,33 i njegova visoka vrijednost je posljedica korištenja harvestera starijeg godišta, odnosno smanjene tehničke ispravnosti harvestera. Posebno su pri analizi izdvojeni prekidi nastali uslijed pucanja ili pada lanca s vodilice (6,39 % općih vremena). Česti prekidi nastali uslijed pucanja i ispadanja lanca posljedica su prevelike brzine kojom vodilica izlazi iz harvesterske glave. Taj je problem tijekom istraživanja riješen na način da je brzina kojom vodilica izlazi iz harvesterske glave smanjenja dok je brzina kretanja lanca ostala ista.

Efektivna vrijemena sječe i izrade (izrada debla, izrada krošnje) promatrana su kao varijabilna vremena u odnosu na prsni promjer stabla (slike 6.15, 6.16 i 6.17). Kao što je vidljivo i na priloženim slikama, na izradu krošnje je utrošeno značajno više vremena negoli na izradu debla. Prilikom izrade stabla do krošnje harvester ne mora kresati grane, već samo vrši trupljenje. Najveći utrošak vremena izrade krošnje primijećen je kod onih stabla koja su imala rašlje.

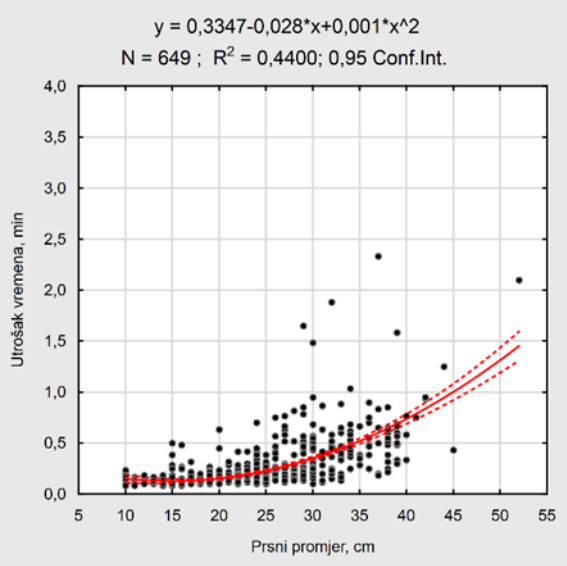

Slika 6.15 Ovisnost utroška vremena sječe o prsnom promjeru stabala

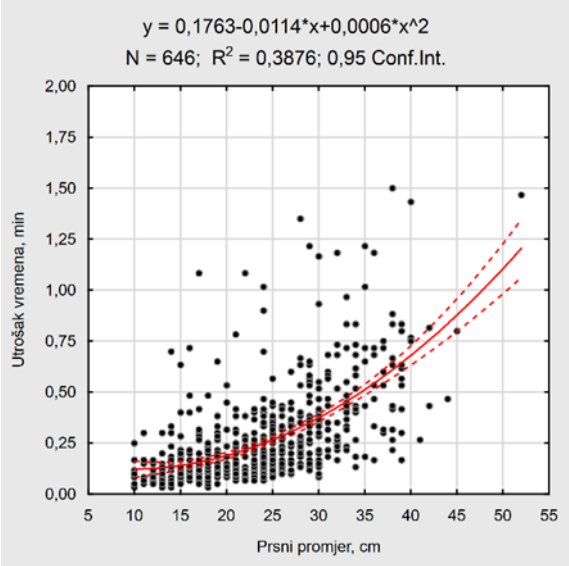

Slika 6.16. Ovisnost utroška vremena izrade debla o prsnom promjeru stabla

S obzirom da je računalna evidencija obujma krošnje bila evidentno nepouzdana zbog istovremene izrade (i mjerenja) više komada višemetarskog prostornog drva u jednom zahvatu za transformaciju proizvodnosti iskazanu brojem stabala u proizvodnost iskazanu neto obujmom bilo je nužno konstruirati pouzdan matematički algoritam za izračun ovisnosti neto obujma o prsnom promjeru posječenoga stabla. U navedenu je svrhu uzorkovano 94 stabla. Raspon prsnih promjera kretao se od 11 do 38 cm. Neto obujam kretao se u rasponu od minimalno 0,031 m^3 do maksimalno 2,123 m^3, dok je prosječni neto obujam stabla iznosio 0,518 m^3 (slika 6.18).

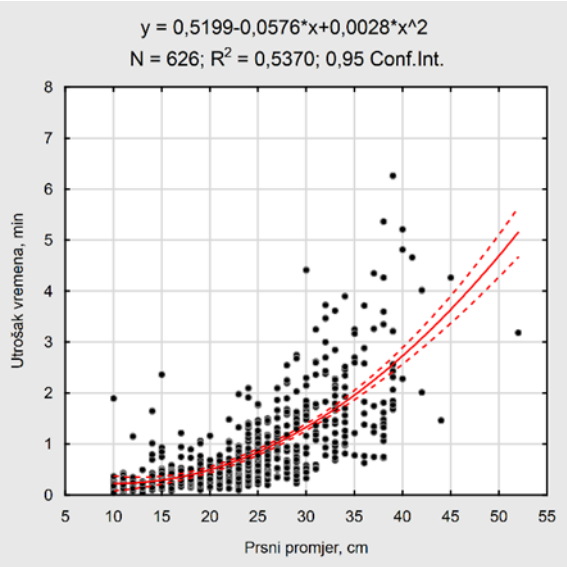

Slika 6.17 Ovisnost utroška vremena izrade krošnje o prsnom promjeru stabala

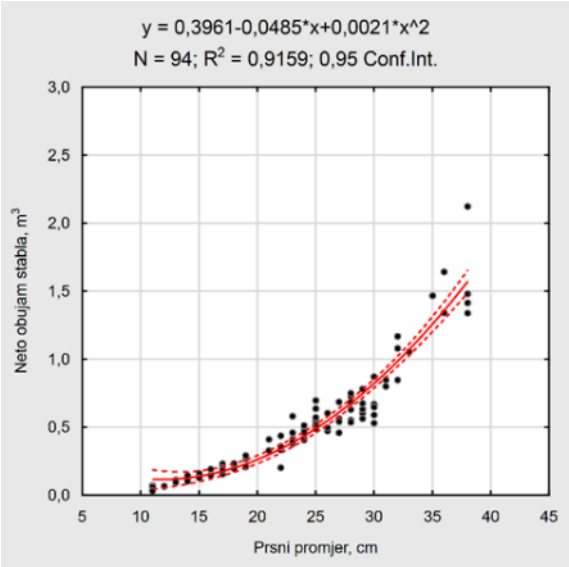

Slika 6.18 Ovisnost neto obujma stabla o prsnom promjeru stabla

Proizvodnost je harvestera izračunata na temelju matematičke jednadžbe za izračun proizvodnosti sječe i izradbe (1) u koju je uvršten faktor dodatnog vremena (f_d), utrošak fiksnog efektivnog vremena (t_F) koji je obuhvaćao prosječne vrijednosti utroška vremena za slijedeće radne zahvate: zauzimanje položaja (t_{ZP} = 0,08 min/stablo), pomicanje (t_{PO} = 0,04 min/stablo), premještanje harvestera (t_{PR} = 0,56 min/stablo), uhrpavanje (t_{UH} = 0,10 min/stablo), vožnja do sječine (t_{VS} =

0,04 min/stablo) i vožnja do pomoćnog stovarišta (t_{VPS} = 0,04 min/stablo). Na mjesto varijabilnih efektivnih vremena (t_V) uvrštene su regresijske jednadžbe za sječu (slika 6.15), izradu debla (slika 6.16) i izradu krošnje (slika 6.17).

$$P_h = \frac{60}{f_d \times (t_F + t_V)} [\frac{stablo}{h}] \dots (1)$$

$$P_h = \frac{60}{f_d \times (t_{ZP} + t_{PO} + t_{PR} + t_{UH} + t_{VS} + t_{PS} + t_S + t_{ID} + t_{IK})} \left[\frac{stablo}{h}\right]$$

Matematičkim modelom (1) moguće je izračunati proizvodnost strojne sječe i izrade (P_h) iskazanu brojem stabala po radnom satu. Množenjem izračunate proizvodnosti neto obujmom prosječnog stabla (slika 6.18) proizvodnost se može iskazati neto obujmom.

Harvesterom je moguće posjeći veći broj stabala nižeg debljinskog stupnja. S povećanjem prsnog promjera stabla potreban je veći utrošak vremena sječe i izrade što dovodi do smanjenja broja posječenih i izrađenih stabala. Proizvodnost harvestera se kretala od 33 stabla po satu za debljinski stupanj 12,5 cm do 8 stabala za debljinski stupanj 42,5 cm (slika 6.19). No, djelovanjem zakona obujma komada u jednom je satu moguće posjeći i izraditi 3,9 m^3 neto obujma oblog drva iz stabala prsnog promjera 12,5 cm do 16,8 m^3 neto obujma oblog drva iz stabala prsnog promjera 42,5 cm (slika 6.20).

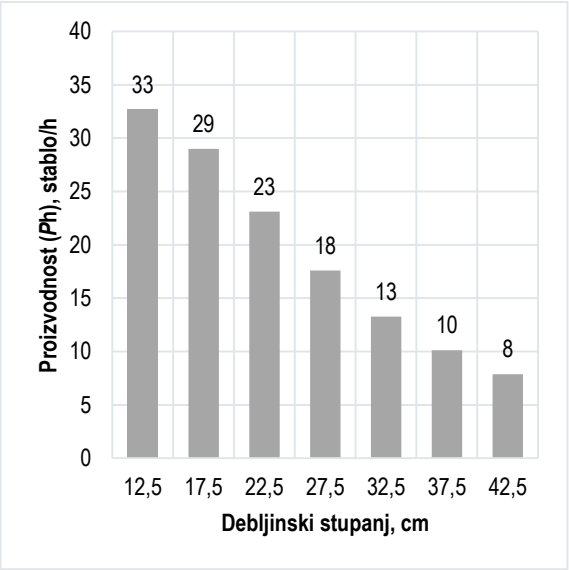

Slika 6.19 Proizvodnost strojne sječe i izrade iskazana brojem stabala po satu

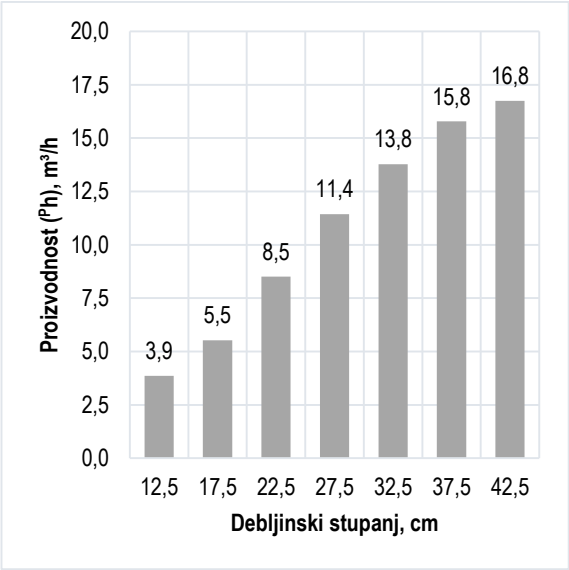

Slika 6.20 Proizvodnost strojne sječe i izrade iskazana neto obujmom po satu

Za izračun jediničnih troškova strojne sječe i izrade upotrjebljen je kalkulativni trošak u iznosu od 905,85 kn/h, koji je utvrđen prijašnjim istraživanjima strojne sječe i izrade (Vusić 2013). U ovisnosti o porastu proizvodnosti jedinični troškovi padaju od 235,07 kn/m^3 za debljinski stupanj 12,5 cm do 54,08 kn/m^3 za debljinski stupanj 42,5 cm.

Tijekom istraživanja rada forvardera utvrđena je prosječna brzina kretanja neopterećenog forvardera po pomoćnom stovarištu od 2,33 km/h, odnosno 2,74 km/h u sječini. Prosječna ostvarena brzina prilikom vožnje opterećenog forvardera po sječini iznosila je 2,60 km/h, odnosno 1,98 km/h po pomoćnom stovarištu.

U strukturi ukupno snimljenih vremena efektivna vremena čine 74,30 %, dok opće vrijeme čini 25,70 % ukupno snimljenog vremena izvoženja drvnih sortimenata forvarderom. U strukturi općih vremena najzastupljeniji su opravdani tehnički prekidi sa 27,48 % i objed sa 36,62 %. Razlog leži u korištenju stroja starijeg godišta što dovodi do čestih kvarova, osobito pucanje uljnih vodova.

Korigiranjem općih vremena objeda i pripremno završnog vremena te izbacivanjem prekida radi istraživanja izračunat je faktor dodatnog vremena 1,26.

Prosječna udaljenost vožnje neopterećenog forvardera po pomoćnom stovarištu iznosi 69,63 m ± 95,17 m, s prosječnim utroškom vremena od 1,80 minuta po turnusu. Prosječna udaljenost vožnje opterećenog forvardera po pomoćnom stovarištu iznosi 33,78 m ± 26,43 m, uz prosječni utrošak vremena od 1,02 minute po turnusu. Prosječna udaljenost vožnje neopterećenog forvardera po sječini iznosi 352,93m ± 204,84 m, uz prosječno vrijeme trajanja vožnje od 7,73 minute po turnusu. Opterećen forvarder je vožnjom po sječini prolazio prosječnu udaljenost od 253,41 m ± 188,96 m, dok je utrošak vremena opterećenog forvardera po sječini iznosio 5,85 minuta po turnusu. Vidljiva je razlika u prosječnim udaljenostima kod vožnje opterećenog i neopterećenog forvardera po sječini koja je uzrokovana kretanjem vozila po različitim izvoznim pravcima, ali i uslijed pomicanja forvardera prilikom utovara drvnih sortimenata. Na taj način forvarder je veće udaljenosti prolazio kada je bio neopterećen. Razlika u prosječnim udaljenostima vožnje neopterećenog i opterećenog forvardera po pomoćnom stovarištu je nastala prvenstveno prilikom istovara tehničke oblovine, koja je bila razvrstavana i »razvučena« po pomoćnom stovarištu, te je na taj način na kraju istovara udaljenost koju je neopterećen forvarder prolazio bila veća od udaljenosti vožnje opterećenog forvardera.

Obradom snimljenih podataka regresijskom analizom utvrđeni su utrošci vremena kretanja neopterećenog i opterećenog forvardera po pomoćnom stovarištu i sječini u zavisnosti o udaljenosti vožnje (slika 6.21, 6.22, 6.23, 6.24).

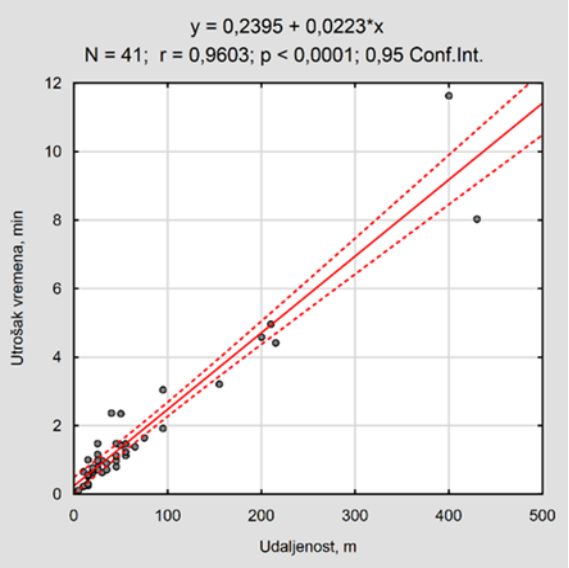

Slika 6.21 Ovisnost utroška vremena vožnje neopterećenog forvardera po pomoćnom stovarištu o udaljenosti vožnje

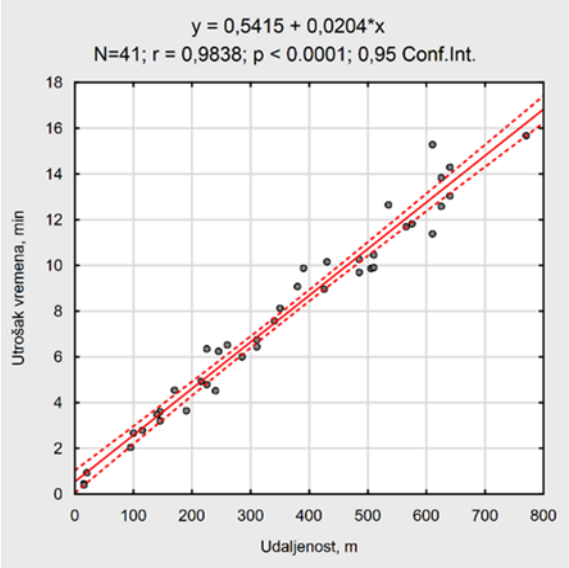

Slika 6.22 Ovisnost utroška vremena vožnje neopterećenog forvardera po sječini o udaljenosti vožnje

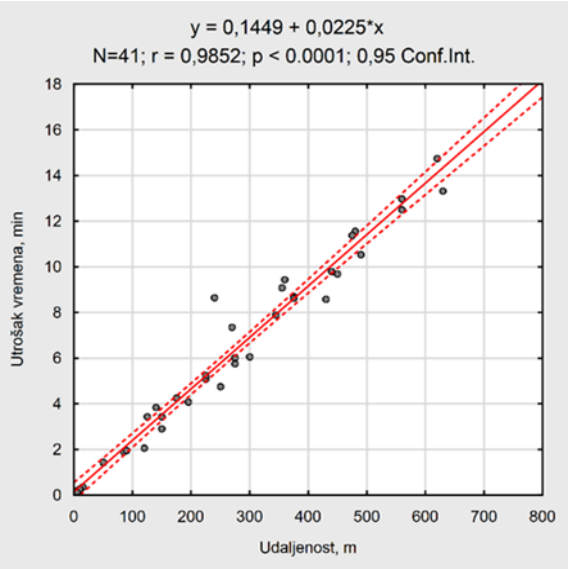

Slika 6.23 Ovisnost utroška vremena vožnje opterećenog forvardera po sječini o udaljenosti vožnje

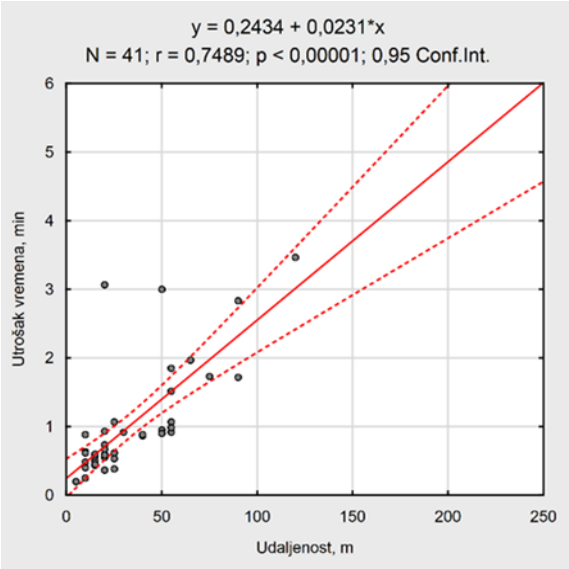

Slika 6.24 Ovisnost utroška vremena vožnje opterećenog forvardera po pomoćnom stovarištu o udaljenosti vožnje

Forvarderom je odvojeno transportirana tehnička oblovina i višemetarsko prostorno drvo. Za utovar tehničke oblovine prosječno je utrošeno 19,01 minuta, a prosječan broj komada u tovaru iznosio je 42 ± 11. Prosječno vrijeme utovara višemetarskog prostornog drva iznosilo je 24,50 minuta, dok je u tovaru prosječno bilo 105 ± 22 komada. Manji utrošak vremena za utovar tehničke oblovine, proizlazi iz većih dimenzija tehničke oblovine, odnosno s manjim brojem komada moguće je prije natovariti puni tovar forvardera. Također, povećanjem broja komada tehničke oblovine u tovaru znatno raste i utrošak vremena utovara, dok je to kod višemetarskog prostornog drva manje izraženo, što je vidljivo po nagibima pravaca izjednačenja (slika 6.25). Usporedbom pravaca izjednačenja za isti broj komada vidljivo je da za utovar višemetarskog prostornog drva treba utrošiti znatno manje vremena što je posljedica uhrpavanja višemetarskog prostorno drva u sječini prilikom izrade harvesterom. Prosječna udaljenost pomicanja po sječini pri utovaru (do sljedećeg mjesta utovara) iznosila je 18 m, a prosječni ukupni utrošak vremena za pomicanje pri utovaru iznosio je 19,16 minuta po turnusu.

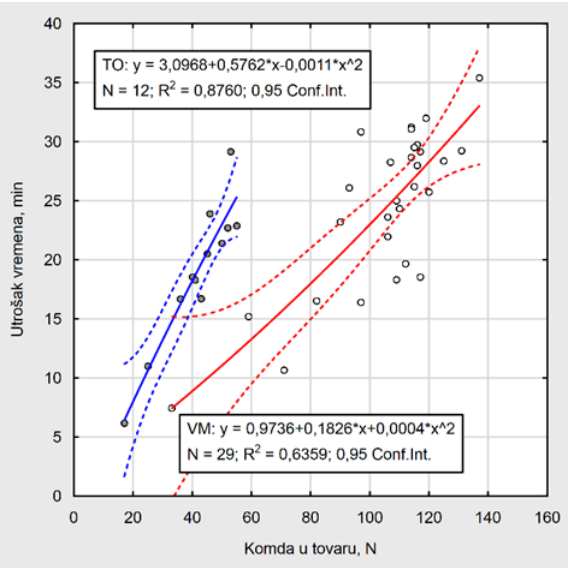

Slika 6.25 Ovisnost utroška vremena utovara o broju komada u tovaru

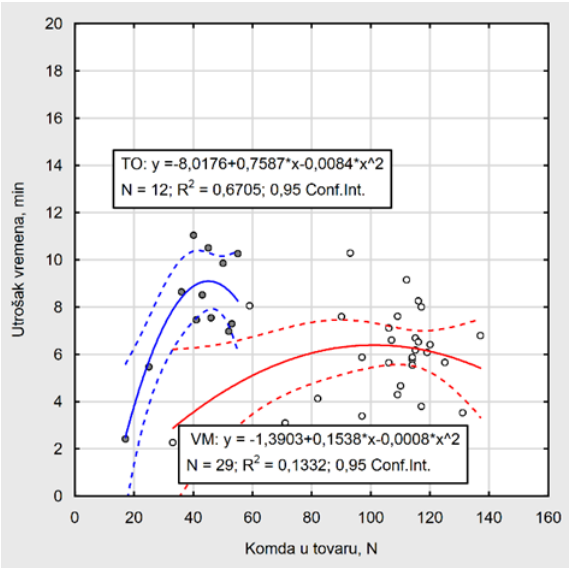

Slika 6.26 Ovisnost utroška vremena istovara o broju komada u tovaru

Istovar drvnih sortimenata se odvijao na pomoćnom stovarištu koje se je nalazilo s obje strane šumske ceste. Tehnička oblovina je u cilju omogućavanja preuzimanja bila »razvučena« s jedne strane pomoćnog stovarišta, dok je višemetarsko prostorno drvo bilo uhrpano sa suprotne strane. Prosječno vrijeme istovara tehničke oblovine trajalo je 8,01 minutu, a prosječan broj komada u tovaru je iznosio 42 ± 11. Za istovar višemetarskog prostornog drva čiji je tovar prosječno brojio 105 ± 22 komada, prosječno je utrošeno 6,04 minuta. Manji utrošak vremena istovara višemetarskog prostornog drva u odnosu na tehničku oblovinu rezultat je mogućnosti da se hidrauličkim hvatalom forvardera zahvati veći broj komada, te se samim tima istovar ubrzava. Također višemetarsko prostorno drvo je bilo uhrpavano na jedan složaj, pa nije bilo potrebno često pomicati forvarder prilikom istovara, a često je cijeli tovar istovaren samo s jednim pomicanjem. S druge strane, sortimenti tehničke oblovine su većih dimenzija i prilikom njihova istovara bilo je potrebno razvući ih po pomoćnom stovarištu kako bi ih poslovođa mogao preuzeti. Shodno tome prilikom istovara tehničke oblovine forvarder je morao obaviti nekoliko pomicanje kako bi istovario cijeli tovar. Prosječni utrošak vremena pomicanja forvardera po pomoćnom stovarištu iznosio je 0,31 minutu po turnusu, dok je prosječna udaljenost pomicanja iznosila 6 m.

Kada se usporedi prosječno vrijeme utovara s prijašnjim istraživanjima (Stankić 2010) istog tipa forvardera, ali prilikom izvažanja drvnih sortimenata u glavnom prihodu (dovršnom sijeku) gdje se vrijeme utovara na više sječina kretalo u rasponu od 9,64 minute po turnusu do 14,43 minute po turnusu, može se zaključiti da je manji utrošak vremena utovara drvnih sortimenata u sječinama glavnog prihoda rezultat većih obujma sortimenata koji se izrađuju prilikom sječa glavnog prihoda te je na taj način moguće brže utovariti puni tovar forvardera. S druge strane utrošci vremena istovara prilikom izvoženja oblovine u glavnom prihodu kreću se u rasponu od 6,00 minuta po turnusu do 7,93 minute po turnusu što nije bitno različito od utrošaka vremena istovara dobivenih ovim istraživanjem.

Za svaki odsjek izmjeren je po jedan prosječni tovar tehničke oblovine i višemetarskog prostornog drva. Obujam tovara višemetarskog prostornog drva iznosio je 12,83 m^3 po turnusu, dok je obujam tovar tehničke oblovine iznosio 14,16 m^3 po turnusu. Prosječni tovar izračunat ke kao ponderirani prosjek s obzirom na strukturu planskog neto obujma u dva istraživana odsjeka i iznosio je 13,28 m^3.

Izračun proizvodnosti forvardera obavljen je na temelju matematičke jednadžbe (2). U jednadžbu je uvršten faktor dodatnog vremena (f_d); utrošak fiksnog efektivnog vremena (t_F) obuhvaćao je utroške vremena za vožnju neopterećenog forvardera po pomoćnom stovarištu (t_{VPS_N} = 1,80 minuta/turnus), vožnje opterećenog forvardera po pomoćnom stovarištu (t_{VPS_O} = 1,02 minuta/turnus), utovara (t_U = 22,90 minuta/turnus), istovara (t_I = 6,61 minuta/turnusu), pomicanja po sječini (t_{P_S} = 19,16 minuta/turnus), uhrpavanja/razvrstavanja (t_{UH} = 0,26 minuta/turnus) i utrošak vremena pomicanja po pomoćnom stovarištu (t_{P_PS} = 0,31 minuta/turnus). Utrošak varijabilnih vremena (t_V) vožnje neopterećenog i opterećenog forvardera po sječini iskazan je pripadajućim regresijskim jednadžbama (slika 6.22 i 6.23).

Na temelju konstruiranog matematičkog modela može se izračunati proizvodnost izvoženja forvarderom (P_h) iskazna brojem mogućih turnusa izvoženja u radnom satu za različite srednje udaljenosti izvoženja (slika 6.27). Množenje broja mogućih turnusa s prosječnim obujmom tovara (13,28 m^3) proizvodnost se može iskazati neto obujmom (slika 6.28).

$$P_h = \frac{60}{f_d \times (t_F + t_V)} [\frac{turnus}{h}] \dots . (2)$$

$$P_h = \frac{60}{f_d \times (t_{VPS_N} + t_{VPS_O} + t_U + t_I + t_{P_S} + t_{UH} + t_{P_PS} + t_{VS_N} + t_{VS_O})} \left[\frac{turnus}{h}\right]$$

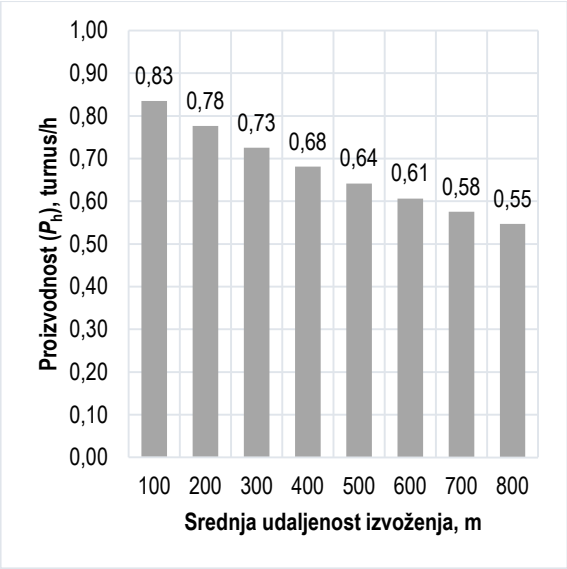

Slika 6.27 Proizvodnost forvardera iskazana brojem turnusa po satu

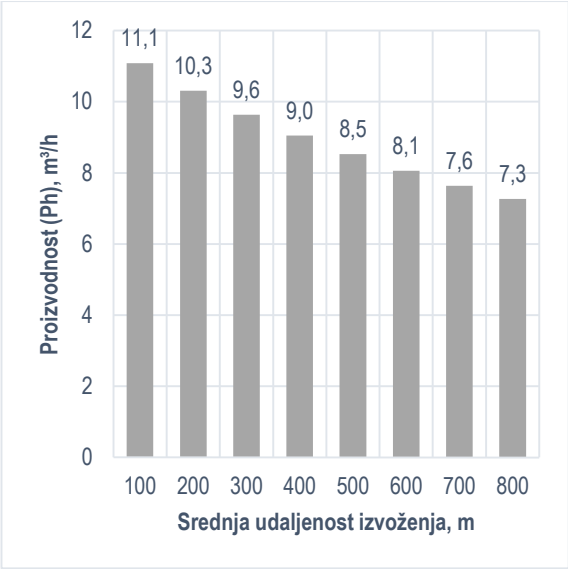

Slika 6.28 Ovisnost utroška vremena istovara o broju komada u tovaru

Povećanjem udaljenosti izvoženja drvnih sortimenata iz sječine do pomoćnog stovarišta dolazi do smanjenja proizvodnosti. Smanjenje proizvodnosti se očituje u smanjenju broja turnusa po satu koji za srednju udaljenost od 100 metara iznosi 0,83 turnusa, dok za srednju udaljenost od 800 m iznosi svega 0,55 turnusa. Usporedno sa smanjenjem broja turnusa dolazi i do smanjenja količine izvezenog drva koja za srednju udaljenost od 100 m iznosi 11,1 m^3 po satu, dok za srednju udaljenost od 800 m iznosi 7,3 m^3 po satu (slika 6.28).

Za izračun jediničnih troškova izvoženja drvnih sortimenata korišten je kalkulativni trošak u iznosu od 555,55 kn/h utvrđen u prijašnjim istraživanjima proizvodnosti forvardera (Vusić 2013). Povećanjem proizvodnosti forvardera dolazi do smanjenja jediničnog troška sa 76,48 kn/m^3 za srednju udaljenost izvoženja 800 m do 50,10 kn/m^3 za srednju udaljenost izvoženja 100 m.

Usporedba troškova ručno-strojne i strojne sječe i izrade izvršena je za svaki odsjek zasebno i to na temelju podataka iz plana sječa za oba odsjeka. Proizvodnosti su izračunate na temelju srednjeg promjera doznačenog stabla, za odsjek 14b on iznosi 21,7 cm, dok srednji promjer doznačenog stabla za odsjek 14c iznosi 26,4 cm. Proizvodnost harvestera izračunata je na temelju matematičkog modela (1), dok je proizvodnost ručno – strojne sječe očitana iz »Normativa Faze I i Faze II za plan sječa 2017. godine«. Za izračun jediničnih troškova korišteni su kalkulativni troškovi za ručno – strojnu i strojnu sječu utvrđeni prijašnjim istraživanjima (Vusić 2013).

Tablica 6.1 Usporedba proizvodnosti i jediničnih troškova ručno - strojne i strojne sječe i izrade

Sredstvo rad		Motorna pila	Harvester		
Radni sati godišnje, h/god		1544	1125	2000	3000
Trošak strojnog rada, kn/h		86,61	905,85	614,41	489,52
Proizvodnost, m^3/h	14 b	1,27	8,01	8,01	8,01
	14 c	1,88	10,84	10,84	10,84
Jedinični trošak, kn/m^3	14 b	68,20	113,09	76,71	61,11
	14 c	46,07	83,57	56,68	45,16

Unatoč znatno većoj proizvodnosti (m^3/h) harvester zbog visokog troška strojnog rada u odnosu na ručno – strojnu sječu i izradu postaje povoljniji tek pri godišnjem iskorištenju od oko 3000 sati.

Usporedba proizvodnosti i jediničnih troškova primarnog transporta za oba sredstva rada izvršena je za svaki odsjek zasebno. Podaci o srednjim planskim udaljenostima privlačenje i podaci o

proizvodnosti skidera Ecotrac 55V očitani su iz »Normativa Faze I i Faze II za plan sječa 2017. godine«. Srednja planska udaljenost privlačenja za odsjek 14 b iznosi 250 + 100 m, dok je planirani dnevni učinak privlačenja drvnih sortimenata skiderom bez kopčaša 19,82 m^3. Planirani dnevni učinak privlačenja drvnih sortimenata u odsjeku 14 c korištenjem skidera bez kopčaša je 18,95 m^3, dok je srednja planska udaljenost privlačenja 550 + 100 m. Proizvodnost forvardera izračunata je na temelju matematičkog modela (2), planskih udaljenosti primarnog transporta po sječini i istraživanjem utvrđenih udaljenosti transporta po pomoćnom stovarištu. Za izračun jediničnih troškova korišteni su kalkulativni troškovi za privlačenje drva skiderom bez kopčaša i izvoženje drva forvarderom utvrđeni prijašnjim istraživanjima (Vusić 2013).

Tablica 6.2 Usporedba proizvodnosti i jediničnih troškova privlačenja drva skiderom i zvoženja drva forvarderom

Sredstvo rad		Skider Ecotrac 55V	Forvarder Timberjack 1710D
Radni sati godišnje, h/god		1400	1480
Trošak strojnog rada, kn/h		166,67	555,50
Proizvodnost, m^3/h	14 b	2,48	9,63
	14 c	2,37	8,05
Jedinični trošak, kn/m^3	14 b	67,21	57,68
	14 c	70,32	69,01

Temeljem usporedbe jediničnih troškova (tablica 9) može se zaključiti da je u odsjeku 14b povoljnije izvoziti drvo forvarderom nego privlačiti ga skiderom. U odsjeku 14c, također je povoljnije izvoziti drvo forvarderom, iako razlika jediničnih troškova naspram privlačenja drva skiderom nije velika.

Rezultati troškovne pogodnosti sintetizirani su na razini sustava pridobivanja drva i prikazani u grafičkom obliku (slika 6.29) s naglaskom na godišnje iskorištenje harvestera (slika 6.30).

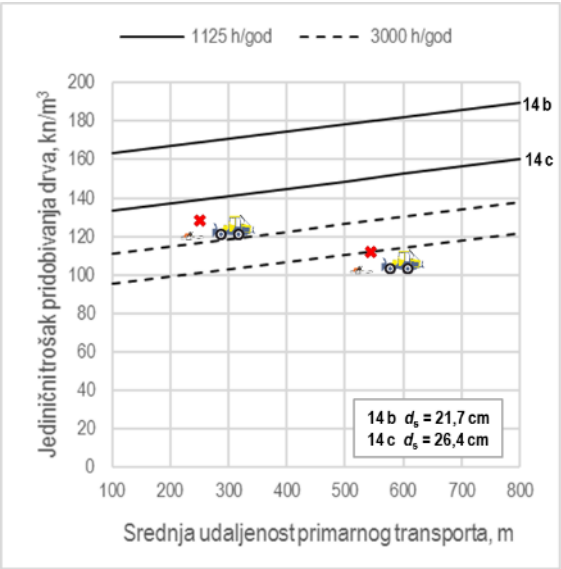

Slika 6.29. Usporedba jediničnih troškova sustava s obzirom na godišnje iskorištenje harvestera

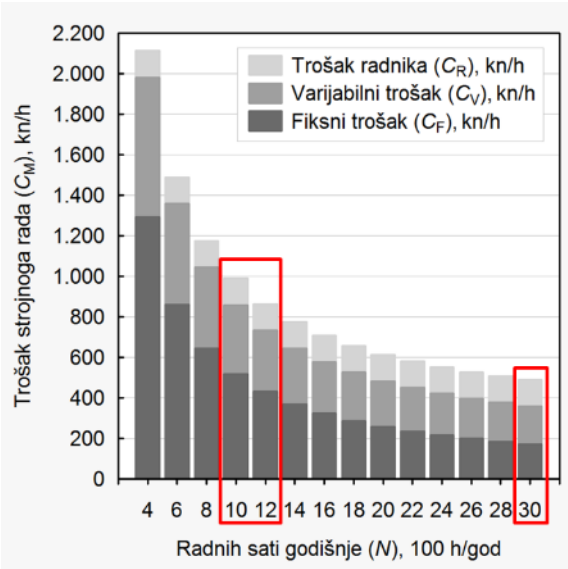

Slika 6.30. Utjecaj godišnjeg iskorištenja harvestera na jedinični trošak strojne sječe i izrade

6.1.1 Mjerenje i značajke izrađenih drvnih sortimenata

Moderni harvesteri opremljeni su tehničkim komponentama i računalnim programima čijom se primjenom osim za osnovnu namjenu upravljanja radom stroja i pomoći pri postupcima sječe i izrade drva može bitno unaprijediti cjelokupni logistički sustav. Bitna komponenta logističkog

sustava je i pravodobna i točna informacija o količini, kakvoći i lokaciji izrađenih drvnih sortimenata. Prilikom izrade drvnih sortimenata koriste se matematički algoritmi koji na temelju izmjerenih dimenzija oblog drva sugeriraju operateru optimalno mjesto trupljenja. Neposredno mjerenje se obavlja putem mehaničkih sastavnica, a obrada, prikaz i evidencija rezultata mjerenja obavlja se računalno. Mjerena duljina provodi se pomoću impulsnog uređaja, koji je pričvršćen na mjerni zupčanik koji se nalazi u harvesterskoj glavi i njegova jedina namjena je izmjera duljina izrađenog drva. Izmjera duljine se mjeri s točnošću na cm (Sladek i Neruda 2007). Promjer može biti izmjeren na dva načina: putem položaja noževa za kresanje grana i odgovarajuće kinematike ili položaja valjaka i odgovarajuće kinematike. U oba ova slučaja podaci o promjeru su određeni kontaktom koji je ostvaren s deblom (Hohmann 2017). Izmjera promjera oblovine pomoću senzora koji su postavljeni na noževe kojima se krešu grane uglavnom se obavlja na način da se promjer mjeri za svaki cm duljine te se određuje srednji promjer za svaku sekciju duljine 10 cm; tako se promjer debla na svaki metar duljine određuje na temelju 11 mjerenja (Sladek i Neruda 2007). Izmjera promjera debala kod harvestera vrši se s točnošću na mm.

Iako je izmjera izrađenog drva pomoću harvestera mnogo jednostavnija i brža u odnosu na ručni način izmjere obujma drva, uporabom harvesterske tehnologije za izmjeru drva nastaju tri ključna problema, a to su: točnost same izmjere, pouzdanost evidencije te način obilježavanja sortimenata.

Istražujući točnost izmjere harvesterom Hohmann i dr. (2017) su usporedili točnost ručne metode mjerenja i mjerenje harvesterom koristeći tehniku uranjanja u vodu temeljenu na poznatom Arhimedovom principu. Rezultati ukazuju da je volumen drva izmjeren harvesterom u prosjeku za 0,45 % manji od stvarnog volumena. Odstupanja su u intervalima od 2,08 % do -3,60 %. Iz dobivenih rezultata se može zaključiti da je mjerni sustav harvestera dovoljno točan. Volumen drva koji je izmjeren ručnim načinom izmjere (izmjera promjera promjerkom i izmjera duljina mjernom vrpcom) te određivanja volumena pomoću Huberove formule u prosjeku je 7,53 % manji od stvarnog volumena. Odstupanja u izmjeri ovdje su se kretala u intervalima od -3,05 % do -12,73 %.

Razlog zbog kojeg je mjerenje harvesterom točnije u odnosu na mjerenje ručnim načinom leži u činjenici da se harvesterom promjer mjeri na više kraćih sekcija na deblu, dok se kod ručnog načina mjeri samo jedan promjer (na sredini debla). Navedeni rezultati potvrđuju rezultate koje su objavili Dvořák i dr. (2016) ukazujući da je točnost mjerenja harvesterom u prosjeku 4,7 % veća u odnosu na mjerenje klasičnim ručnim načinom. Također još jedan od razloga za točnije mjerenje harvesterom je i izmjera promjera u milimetrima, dok se ručnim načinom promjer mjeri u centimetrima i zaokružuje na nižu vrijednost. U oba slučaja ispitivane su samo metode mjerenja s korom, dok odbitak kore nije proveden. Može se zaključiti da se izmjerom promjera na više sekcija na deblu bolje prati geometrija debla i rezultat navedenog je točniji izračun obujma.

Iako rezultati ukazuju da je harvesterom moguće točnije i preciznije izmjeriti stvarni obujam postavlja se pitanje obračuna količina i izračuna prodajne cijena ako je kao propisani način izmjere određeno ručno mjerenje.

U cilju postizanja točnosti iznimno preciznih rezultata izmjere obujma drva harvesterom nužna je redovna kalibracija mjernih uređaja harvestera prema propisanim specifikacijama. Primjera radi u Finskoj je propisano da odstupanje obujma oblog drva izmjerenog harvesterom može biti unutar ±4 % od stvarnog obujma drva, dok se na godišnjoj razini postiže točnost od ±2 % (Gingras 1995). Slične rezultate o točnosti izmjere obujma drva harvesterom potvrđuju i istraživanja provedena u Britaniji (British Forestry Commission). Istraživanje provedeno u Irskoj 2001. godine pokazuje da razina točnosti izmjere obujma za čiste sječe iznosi 6,7 % dok je razina točnosti prilikom proreda 5,3 % (Nieuwenhuis i Dooley 2006). Miklašēvičs (2017a) navodi da su u Latviji zakonom dozvoljena odstupanja unutar ±5 % od stvarnog obujma za furnirsku oblovinu breze, ±3 % za ostalu tehničku oblovinu i ±10 % za drvo za celulozu i drvo za ogrjev. Osim toga, zahtjevi za točnošću izmjere oblog drva harvesterom propisuju da odstupanja izmjerenog obujma mogu biti unutar granice od ±3 % od stvarnog obujma i najmanje 80 % svih izmjerenih promjera mora biti unutar granice odstupanja ± 6 mm (Miklašēvičs 2017a). Nieuwenhuis i Dooley (2006) iznose

da su u irskom šumarstvu dozvoljena odstupanja izmjere oblog drva harvesterom u odnosu na klasičnu izmjeru (promjerkom i mjernom vrpcom) do 5 % za tehničku oblovinu i do 7 % za celulozno drvo, a ako odstupanja prelaze dozvoljene granice nužno je provesti kalibraciju mjernog uređaja harvestera.

Kalibracija se obavlja na način da se nakon izrađenih 7 do 8 drvnih sortimenata iz računala harvestera pribave podatci o dimenzijama predmetnih sortimenata i zatim se pristupa ručnoj izmjeri te se obavlja usporedba. Za ručnu izmjeru procedura je propisana od strane proizvođača harvestera. Svaki sortiment se počevši od debljeg kraja podjeli na sekcije duljine 1 m i na polovini svake sekcije se mjere dva unakrsna promjera tako da se promjeri mjere na 0,5 m, 1,5 m, itd. Na posljednjoj sekciji svakog sortimenta, ako je kraći od 1 m promjeri se mjere na sredini stvarne duljine. Ako se na mjestu gdje se mjeri promjer nalaze kvrge mjesto izmjere se pomiče kako bi izmjereni promjer bio reprezentativan. Obujam se izračunava za svaku sekciju zasebno na temelju duljine i srednje vrijednosti izmjerenih dvaju promjera. Zbrojem obujama svih sekcija jednog drvnog sortimenta računa se stvarni obujam drvnog sortimenta. Navedenim načinom izmjere nastoji se oponašati mjerenje harvesterom koji obujam pojedinog drvnog sortimenta izračunava na temelju obujama više manjih sekcija (interval izmjere obično bude 5 do 10 cm). Nakon ručne izmjere u računalo harvestera se upisuju ručno izmjerene duljine i izračunati obujmi svakog sortimenta kako bi se mjerni sustav kalibrirao i na temelju provedene kalibracije iskazivao što točnije podatke o obujmu izrađenog drva.

S obzirom na mogućnosti koje harvesterska tehnologija pruža u pogledu izmjere izrađenih drvnih sortimenata logična je želja za što većom integracijom prikupljenih podataka u cjelokupni logistički sustav. Möller i Sondell (2003) predlažu plaćanje drva na temelju izmjere drva harvesterom čime bi se ubrzala transakcija, poboljšala kontrola toka pridobivanja drva i povećala učinkovitost prijema drva u pilanama. No, Hohmann i dr. (2017) navode da su njemačkom šumarstvu, samo instalirani opto-elektronični mjerni uređaji na ulazu u pilane validni za komercijalne transakcije. Mjerna tehnologija inkorporirana u mjernom sistemu harvestera koristi se samo za utvrđivanje referentnih vrijednosti duljina. Iako je mjerna tehnologija harvestera prilično napredna, ona se ne smatra pouzdanom u Njemačkoj i nizu drugih europskih zemalja, kao što je primjerice Češka. Posebno, zakonski zahtjevi ne dopuštaju korištenje mjernog sustava harvestera u svrhu naplate drva. Pravna osnova u Njemačkoj, s učinkom od 1. siječnja 2015. godine koja regulira način izmjere drva je Zakon o mjerenju i umjeravanju (kalibraciji) i Pravilnik o mjerenju i umjeravanju (kalibraciji). Zbog jednog pravnog ograničenja onemogućeno je korištenje harvestera za mjerenje drva, a navedeni se odnosi na činjenicu da takvi sustavi nisu »zatvoreni«, odnosno da su dopuštene intervencije, kao što su prilagodbe komponenta mjerenja (vrsta drva ili okolišnih uvjeta). Dok je takva prilagodba neophodna kako bi se prilagodio mjerni sustav pri promjeni uvjeta rada, treba propisati zakonske odredbe da bi se spriječilo neovlašteno miješanje, odnosno intervencije bilo kakve vrste u mjernom sustavu harvestera. Primjerice, Hohmann i dr. (2017) istražujući točnost izmjere obujma u slučaju izmjere promjera debla pomoću posmičnih valjaka koji služe za pomicanje debala kroz harvestersku glavu, odnosno ovisnost obujma o promjeni tlaka kojim valjci pritišću deblo utvrđuju da se povećanjem tlaka kojim valjci pritišću deblo povećava i razlika u obujmu jer su valjci dublje utisnuti u koru i izmjereni promjer debla je manji, a sukladnom tome i izmjereni obujam je manji. Drugi autori pak navode primjere u kojima se rezultati harvesterskih mjerenja koriste u komercijalnim transakcijama. Nieuwenhuis i Dooley (2006) navode kako je izmjera drva harvesterom prilikom komercijalnih transakcija dopuštena u Irskoj i u Skandinavskim zemljama. Miklašēvičs (2017b) navodi da je u Latviji pruhvatljiva izmjera drva harvesterom, ali posebno ističe nužnost kalibracije mjernog uređaja harvestera kako bi samo mjerenje bilo u skladu sa zakonskim regulativama koje definiraju dopuštenja odstupanja prilikom izmjere. Isti autor navodi da su za provjeru točnosti izmjere oblog drva harvesterom nadležni neovisni revizori koji nekoliko puta godišnje provjeravaju točnost izmjere svakog harvestera, odnosno provjeravaju da li su odstupanja izmjerenog volumena unutar odstupanja propisanih zakonom.

Poseban izazov pri uvođenju i zakonskom reguliranju korištenja podataka mjerenja harvesterom u Republici Hrvatskoj predstavlja postojeći način prodaje drva. Naime, označavanje svakog

pojedinog sortimenta (izuzev onih u kategoriji prostornoga drva) i utvrđivanje njegove kakvoće, nužno je u slučajevima kada se obavlja komadna prodaja vrjednijih sortimenata ili prodaja određene količine drvnih sortimenata poznatog obujma, kakvoće i u konačnici ukupne cijene; odnosno u svim onim slučajevima u kojima se ne prodaje ukupna količina izrađenih sortimenata (pojedine kakvoće) proizvedena u određenoj sječini (podatak koji dostupan iz računalnog ispisa harvesterskog mjerenja). Osim toga, sukladno propisanom načinu (NN 17/2015, NN 57/2017), obilježavanje se izrađenih drvnih sortimenata u Republici Hrvatskoj obavezno obavlja prije njihovog stavljanja u transport i to režijskim čekićem, a za sve drvne sortimente izuzev onih u kategoriji prostornoga drva i identifikacijskom pločicom ili rednim brojem koji služi kao poveznica s propisanim podacima (vrsta drva, dužina i srednji promjer sortimenta, drvni obujam, mjesto obilježavanja i osoba koja je izvršila obilježavanje). Navedena propisnost, s obzirom na proizvodnost i uobičajeni način rada harvestera (uhrpavanje izrađenih drvnih sortimenata u cilju optimizacije proizvodnosti izvoženja forvarderom) može predstavljati značajni organizacijski izazove prilikom preuzimanje drvnih sortimenata posebice u sječinama povoljnije sortimentne strukture (manjeg udjela prostornoga drva) u kojma se prikrajanje tehničke oblovine obavlja po principu »buck-to-quality«. No, već niz godina poznati su napredni načini označavanja drvnih sortimenata uporabom RFID (Radio Frequency ID) tehnologije (Picchi i dr. 2015). Na navedeni način drvni sortimenti se obilježavaju čipom sa pripadajućim informacijama iz harvesterskog računalnog programa (koje mogu zadovoljavati i zahtjeve naše trenutne propisnosti). Gjerdrum (2009) navodi jediničnu cijenu koja se kreće do jednog eura za jedan čip uvećanu za dodatne troškove uvođenja novoga sustava identifikacije drvnih sortimenata.

Rezultati istraživanja provedenoga u okviru ovoga Projekta ukazuju na značajne razlike između obujama drvnih sortimenata utvrđenih na propisani način prilikom preuzimanja i podataka preuzetih iz računalne evidencije harvestera.

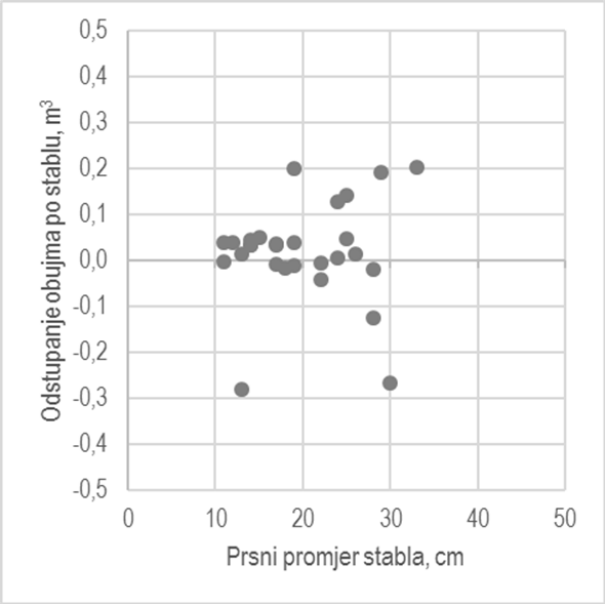

Slika 6.31 Odstupanje obujma po stablu (m^3) u 14b odsjeku (preuzeto – evidencija harvestera)

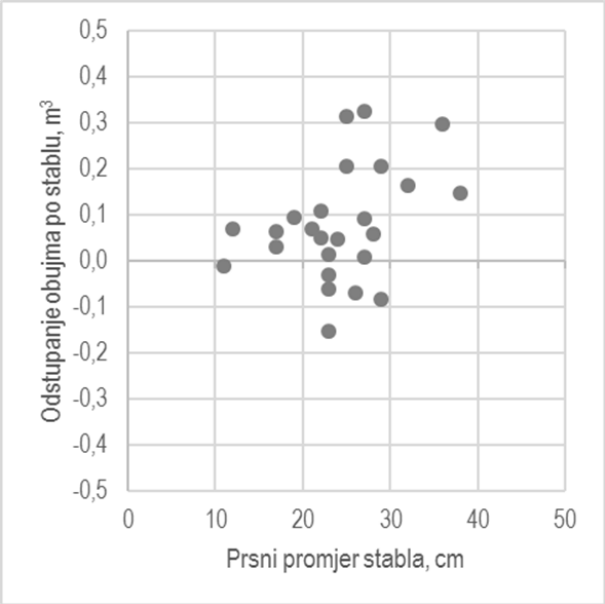

Slika 6.32 Odstupanje obujma po stablu (m^3) u 14c odsjeku (preuzeto – evidencija harvestera)

Odstupanja na razini stabla ukazuju da računalna evidencija harvestera u većini slučajeva iskazuje manji obujam u oba promatrana odsjeka (slika 6.31 i slika 6.32). Većina razlika iskazanih u postotnim iznosima nalazi se u rasponu ±20 %, uz značajan broj odstupanja (uglavnom pozitivnih) i izvan navedenog raspona (slika 6.33 i slika 6.34).

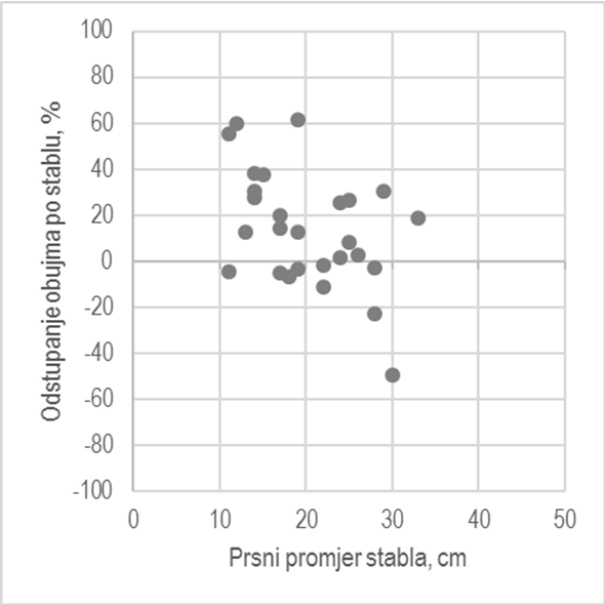

Slika 6.33 Odstupanje obujma po stablu (%) u 14b odsjeku (preuzeto – evidencija harvestera)

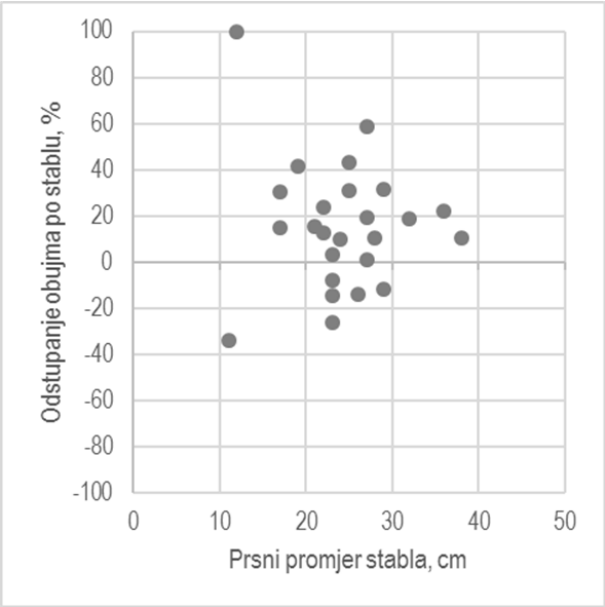

Slika 6.34 Odstupanje obujma po stablu (%) u 14c odsjeku (preuzeto – evidencija harvestera)

Tek detaljnije analize odstupanja, provedene na razini pojedinih sortimenata (slika 6.35 i slika 6.36), ukazuju i na razloge relativno velikih odstupanja na razini stabala uzorka. Evidentno je da glavnina razlika nastaje pri mjerenju drvnih sortimenata izrađenih iz krošnje.

Analiza postotnih razlika u dva istraživana odsjeka (slika 6.37 i slika 6.38), uz potrebu redovite kalibracije mjernih uređaja harvestera (normalno distribuirana odstupanja), jasno identificira dva uzroka nastanaka razlika prilikom mjerenja drvnih sortimenata izrađenih iz krošnje:

- neevidentiranje izrađenih sortimenata (pozitivna postotna razlika 100 %) koja prvenstveno nastaje prilikom evidencije obujma sortimenata čija je stvarna duljina manja od nominalne;
- evidentiranje većeg obujma izrađenih drvnih sortimenata (negativna razlika) istovremenom izradom više komada oblog drva u jednom zahvatu (mjerenje većeg promjera uz istovremeni izostanak jednog ili više komada u evidenciji – što djelomično sudjeluje i pri stvaranju pozitivnih razlika navedenih pod prethodnom točkom).

Zanimljivo je primijetiti da odstupanja na razini harvesterom evidentiranih sortimenta imaju mahom negativni predznak; dakle da harvestersko mjerenje rezultira većim obujmom negoli propisani način mjerenja (što potvrđuje rezultate prethodnih mjerenja), a da je suprotan predznak na razini stabla prvenstveno rezultat izostanka evidentiranja velikog broja sortimenata čija je duljina manja od nominalne.

Evidentiranje sortimenata čija je duljina manja od nominalne stvar je prilagodbe postavki računalnoga sustava harvestera i ne bi trebala predstavljati prepreku u ostvarivanju točnosti (i pouzdanosti) računalne evidencije. Glavnina odstupanja koja pokazuju trend normalne distribucije moguće je anulirati pravovremenom kalibracijom mjernoga sustava i njenom redovitom provjerom. Poseban problem prilikom mjerenja dimenzija drvnih sortimenata i posljedično evidencije njihova obujma predstavlja način izrade drvnih sortimenata iz krošnje istovremenim trupljenjem dva ili više komada obloga drva. Navedeni način rada predstavlja modifikaciju karakterističnu prvenstveno za rad u sječinama listača s ciljem povećanja ostvarive proizvodnosti, ali nedvojbeno rezultira netočnom izmjerom izrađenih sortimenata. Ostali razlozi netočnoga mjerenja leže također u morfološkom obliku izrađivanih bjelogoročnih stabala i posljedično nemogućnosti potpunog kresanja grana i izradi rašlji u jednome zahvatu.

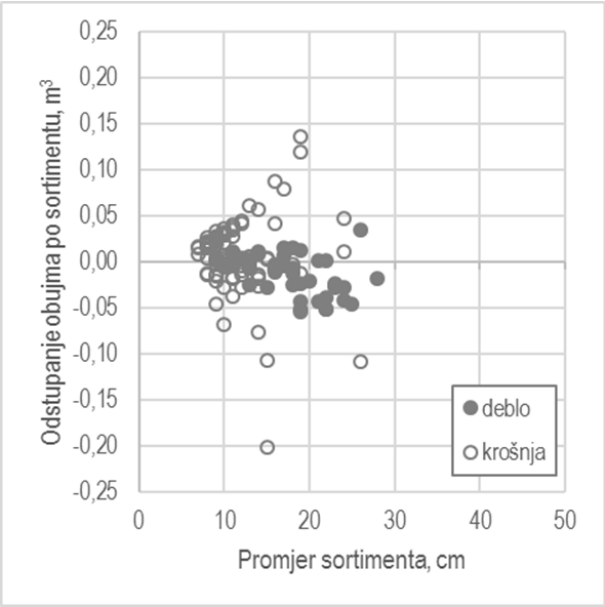

Slika 6.35 Odstupanje obujma po sortimentu (m^3) u 14b odsjeku (preuzeto – evidencija harvestera)

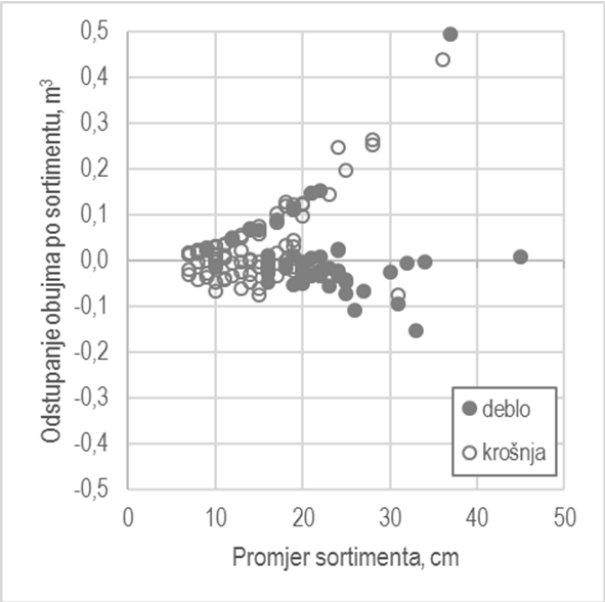

Slika 6.36 Odstupanje obujma po sortimentu (m^3) u 14c odsjeku (preuzeto – evidencija harvestera)

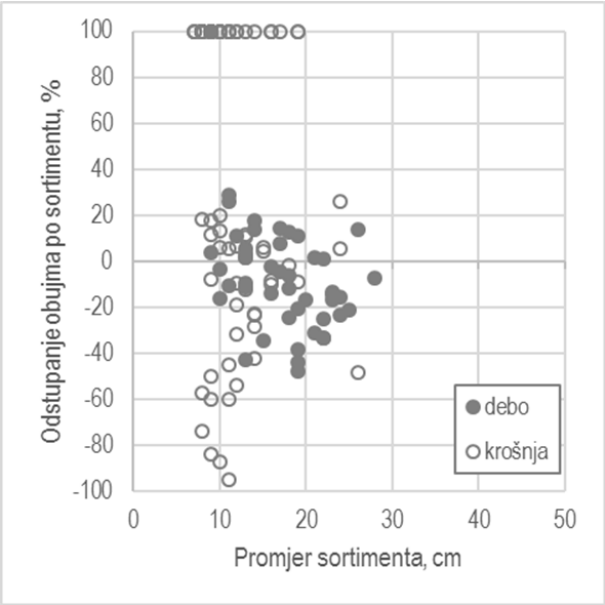

Slika 6.37 Odstupanje obujma po sortimentu (%) u 14b odsjeku (preuzeto – evidencija harvestera)

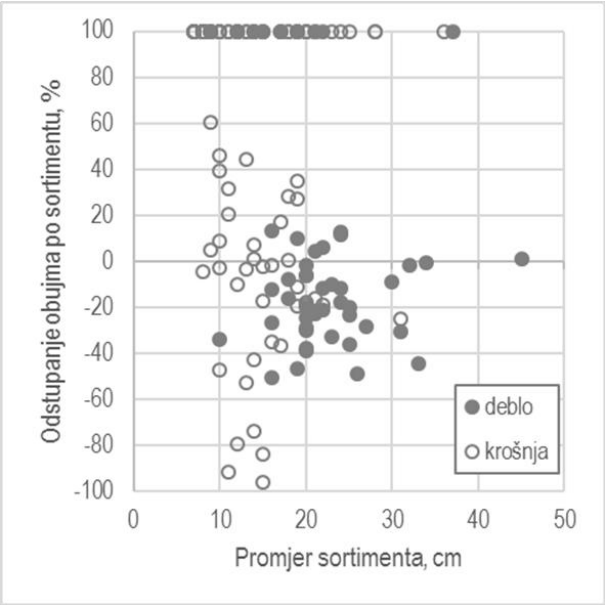

Slika 6.38 Odstupanje obujma po sortimentu (%) u 14c odsjeku (preuzeto – evidencija harvestera)

Prethodno navedene posebnosti pri izradi bjelogoričnih stabala rezultirale su potrebom dorade drvnih sortimenata; odnosno neizostavno bi rezultirale potrebom dorade da su dimenzije posječenih stabala uvjetovale pojavnost tehničkih sortimenata i u krošnji.

Potreba dorade iskazana brojem stabala ukazuje da se na oko 5 % komada u odsjeku 14b, odnosno na oko čak 25 % komada u odsjeku 14c može očekivati potreba dorade sortimenata (slika 6.39 i slika 6.40). No rezultati iskazani obujmom, svode navedene podatke u značajno manje iznose, ipak ukazujući da se na stablima većih dimenzija (odsjek 14c) može očekivati navedene probleme na razini 19 % izrađene količine drvnih sortimenata (prvenstveno kao posljedica pojavnosti grana/rašlji većih dimenzija, a opet nedovoljno velikih da bi se proizvodnost harvestera žrtvovala njihovim pojedinačnim zahvaćanjem i izradom).

Slika 6.39 Potreba dorade drvnih sortimenata u 14b odsjeku (broj komada)

Slika 6.40 Potreba dorade drvnih sortimenata u 14c odsjeku (broj komada)

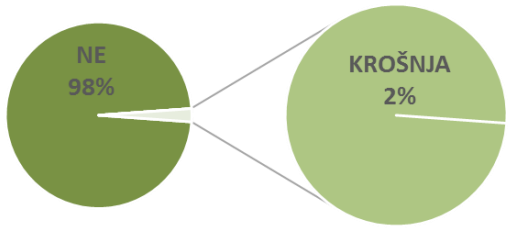

Slika 6.41 Potreba dorade drvnih sortimenata u 14b odsjeku (obujam)

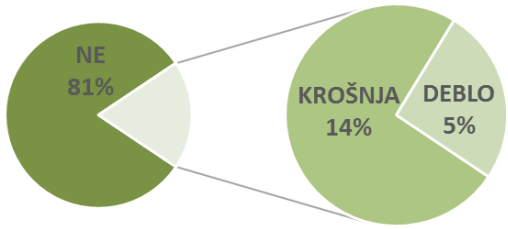

Slika 6.42 Potreba dorade drvnih sortimenata u 14c odsjeku (obujam)

Literatura

British Forestry Commission, 2005: Technical Development Branch, Report Nos. 2/95, 7/95 and 9/95. HMSO Publications Centre, London.

Dvořák, J., P. Natov, J. Kašpar, G. Szewczyk, M., Kormanek, 2016: Comparison of Standing Timber Sorting with Bucking by Harvesters. In: From Theory to Practice: Challenges for Forest Engineering; Proceeding and Abstracts of the 49th Symposium on Forest Mechanization, Warsaw University of Life Sciences, Warsaw, Poland, September 4 - 7, pp. 13-18.

Gingras, J-F, 1995: Recent Developments in Chip Cleaning and Cut-To-Length Harvesting Technologies in Finland. Forest Engineering Research Institute of Canada (FERIC) Eastern Division, Internal Report: IR-1995-06-01.

Gjerdrum, P., 2009: RFID tags applied for tracing timber in the forest products chain. pp. 1–6.

Hohmann. F., A. Ligocki. L. Frerichs., 2017: Harvester measuring system for trunk volume determination: comparasion with real trunk volume and applicability in the forest industry. Bulletin of the Transilvania University of Braşov 10(59): 27–33

Miklašēvičs, Z., 2017a: The Impact of Harvester Calibration on the Accuracy of Birch Veneer Logs Measurements by Measuring Diameter in Short Intervals Using Electronic 3d Systems. Proceedings of the 11th International Scientific and Practical Conference. III: 217–221.

Miklašēvičs, Z., 2017b: The analysis of coniferous logs top diameter measurement accuracy using harvester and 3D systems. Bulletin of the Transilvania University of Braşov 10(59): 35–42.

Möller J., J. Sondell, 2000: Customer driven assortments call for better diameter measuring: Improvements possible in the forests. In: Resultat – SkogForsk 15 (4). The Forest Research Inst. of Sweden, Uppsala, Sweden, pp. 1–4.

Mudri, I., 2012: Proizvodnost skidera Ecotrac 120V pri privlačenju drvnih sortimenata poludeblovnom metodom na području Šumarije Ivanec. Diplomski rad, Šumarski fakultet Sveučilišta u Zagrebu, 1–27.

Nieuwenhuis, M., T. Dooley, 2006: The Effect of Calibration on the Accuracy of Harvester Measurements. International Journal of Forest Engineering 17 (2): 25–33.

Picchi, G., M. Kühmaier, J. D. D. Marques, 2015: Survival Test of RFID UHF Tags in Timber Harvesting Operations. Croatian Journal of Forest Engineering 36(2): 165–174.

Pravilnik o doznaci stabala, obilježavanju drvnih sortimenata, popratnici i šumskom redu. NN 17/2015, NN 57/2017

Sever, N., 2013: Proizvodnost skidera Ecotrac 55V pri privlačenju oblog drva u dovršnom sijeku hrasta lužnjaka na području Šumarije Vrbovec. Diplomski rad, Šumarski fakultet Sveučilišta u Zagrebu, 1–30.

Sladek, P., J. Neruda, 2007: Analysis of Volume Differences in Measuring Timber in Forestry and Wood Industry. In: Austro 2007/FORMEC´07: Meeting the Needs of Tomorrows´ Forests – New Developments in Forest Engineering, October 7 – 11, 2007, Vienna and Heilegenkreuz – Austria, p. 1-11.

Stankić, I., 2010: Višekriterijsko planiranje izvoženja drva forvarderima iz nizinskih šuma Hrvatske. Disertacija, Šumarski fakultet Sveučilišta u Zagrebu, 1–123.

Taboršak, D., 1987: Studij rada. Str. 1–214, Zagreb, Tehnička knjiga.

Vusić, D., 2013: Pogodnost sustava pridobivanja drvne biomase u smrekovoj šumskoj kulturi. Disertacija, Šumarski fakultet Sveučilišta u Zagrebu, 1–174.

6.2 Energijski pokazatelji

Istraživani harvester i forvarder bili su opremljeni mobilnom jedinicom MOBILISIS WiGo W130C za daljinsko praćenje rada vozila. FMS se sastoji od hardverskih i softverskih komponenti koje omogućuju dvosmjernu komunikaciju između vozača i korisničkog (logističkog) centra. Osnovne komponente FMS-a prikazane su na slici 6.44. Na osnovu podataka koje prikuplja mobilna jedinica te koji se spremaju na server, korisnik (vlasnik vozila/voznog parka) može donositi odluke o izboru optimalne rute za prijevoz drva, može kontinuirano pratiti rad vozila, izdavati digitalne radne naloge. Osnovna komponenta svakog FMS sustava je mobilna jedinica koja, osim za određivanje položaja vozila, ima mogućnost preko različitih senzora prikupljati i slati krajnjem korisniku različite podatke o radu vozila. U kabinu je dodatno ugrađen tablet uređaj sa svrhom mjerenja vibracija koje se javljaju na stroju prilikom njegova rada.

Slika 6.43 Ugradnja mjernih uređaja

Svi podaci koji se prikupljaju pomoću mobilne jedinice i dodatnih senzora se putem GSM (GPRS) prijenosa podataka šalju na internet i spremaju na server. Na osnovu prikupljenih podataka formiraju se izvještaji do kojih korisnik dolazi preko računalnog sučelja (slika 6.45). Za računalno sučelje nije potrebna instalacija, svi podaci su vidljivi na web stranici s koje je omogućen pristup standardnim izvještajima o praćenju vozila, administracija lokacija / vozača / korisnika, izvještaji potrošnje goriva, izvještaji putanja, putni računi, greške itd. Svi podaci su zaštićeni lozinkom. Izvještaji krajnjem korisniku služe kao osnova za analizu učinaka, potrošnje goriva te kretanja vozila. Ukoliko se vozilo koje se prati ne nalazi u području GSM signala podaci se spremaju u internu memoriju mobilne jedinice, te se prilikom ulaska vozila u područje GSM signala šalju na server. Korištenjem FMS sustava korisnik ima mogućnost praćenja vozila u realnom vremenu.

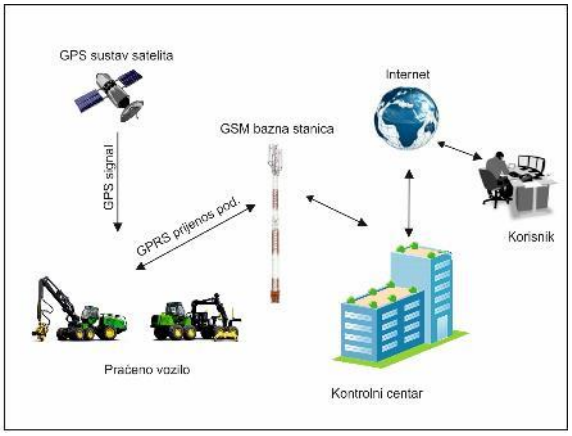

Slika 6.44 Osnovne komponente sustava za daljinsko praćenje vozila (FMS-a)

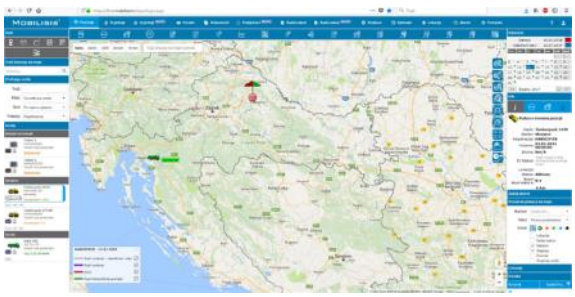

Slika 6.45 Mobilisis korisničko web sučelje

Za mjerenje razine goriva u spremniku korištena je sonda LLS-20160, koja služi za određivanje potrošnje goriva. To je kapacitivni senzor bez pokretnih dijelova. Ima digitalni izlaz (RS485 sučelje). Elektroničke komponente senzora su uronjene u elastično kućište koje osigurava

maksimalnu zaštitu za okolinu (IP66). Ima robusno aluminijsko kućište. Senzor je prilagodljiv na visinu spremnika, odnosno može biti odrezan na bilo koju dužinu sa automatskom kalibracijom.

U svrhu ovog istraživanja pomoću sustava daljinskog praćenja sa istraživanih strojeva korišteni su podaci o potrošnji goriva, njihova pozicija, odnosno putanja kretanja po sječini, rad hidraulične pumpe i aktivnost hidraulične dizalice. Svi navedeni parametri generiraju se iz baze podataka preko web aplikacije u tabličnom prikazu (MS Excel) gdje su svi parametri tablično prikazani u ovisnosti o vremenskoj bazi.

Potrošnja goriva istraživanih strojeva mjerena je pomoću kapacitivne sonde ugrađene u spremnik goriva, a podaci o potrošnji/razini goriva u spremniku stroja su se prenosili do centralnog servera pomoću FMS sustava, odnosno GPS/GPRS vezom. Preko web aplikacije FMS sustav automatski generira potrošnju strojeva u litrama, odnosno u litrama po radnom satu stroja za odabrani radni dan.

Dnevna i satna potrošnja goriva preuzeta je iz generiranog izvješća preko web aplikacije Mobilisis FMS sustava. Po pogonskome satu harvesterom je utrošeno od 15,7 l/h do 22,9 l/h; prosječno 19,04 l/h ± 2,15 l/h, odnosno 1,9 l/m^3.

Potrošnja goriva istraživanog forvardera za radne dane kada je radio na izvoženju drvnih sortimenata iskazana je u tablici 5. Potrošnja goriva iskazana je na tri različita načina, tj. po radnom danu, radnom satu i turnusu izvoženja. Po pogonskome satu forvarderom je utrošeno od 8,1 l/h do 10,4 l/h; prosječno 8,83 l/h ± 0,54 l/h, odnosno 0,9 l/m^3.

Jedinična potrošnja goriva po turnusu izvoženja kretala se od 6,63 l/turnus do 13,65 l/turnus. Najmanja jedinična potrošnja postignuta je u danima kada se izvoženje obavljalo sa manjih udaljenosti.

Tablica 6.3 Prikaz potrošnje goriva forvardera Timberjack 1710D

Datum	Potrošnja goriva		
	l/dan	l/h	l/turnus
5.7.2017	30,8	8,7	10,27
6.7.2017	72,5	8,9	12,08
7.7.2017	54,6	9,1	13,65
10.7.2017	56,7	8,5	11,34
11.7.2017	52,5	8,2	7,50
12.7.2017	81,5	8,6	10,19
13.7.2017	76,2	9,1	12,70
14.7.2017	84,6	9	12,09
15.7.2017	42,4	8,8	10,60
17.7.2017	66,2	9	13,24
18.7.2017	95	9	13,57
19.7.2017	40,9	8,6	10,23
20.7.2017	82,2	8,4	7,47
21.7.2017	66,3	8,1	6,63
24.7.2017	35	10,4	11,67

Rezultati energijske pogodnosti istraživanoga sustava prikazani su u radu: Pandur, Z., A. Đuka, I. Papa, M. Bačić, D. Janeš, D. Vusić, 2018: Energy efficiency of mechanized thinning in broadleaf stand. »Natural resources, green technology and sustainable development/3-GREEN2018«, Zagreb, Croatia, 116–120.

6.3 Ergonomski pokazatelji

6.3.1 Sigurnost na radu i profesionalne bolesti kod mehanizirane sječe i izrade drva

U većini zemalja radovi u šumarstvu su jedni od najopasnijih zanimanja s velikim ljudskim i financijskim gubitcima, a šumarska profesija spada u najopasnija zanimanja u proizvodnji (ILO 1981, Bentley i dr. 2005, Potočnik i dr. 2009, Lindroos i Burström 2010). Sječa i izrada drva, s mehanizacijom ili bez nje, fizički je zahtjevna, osobito na terenima većih poprečnih nagiba jer je povezana s velikim rizikom od nastanka ozljeda. Evidencije ozljeđivanja ukazuju na podatak da su aktivnosti pri sječi i izradi drva odgovorne za 65-80 % svih nesreća u sektoru šumarstva (Efthymiou 2008). Na rizik od nastanka ozljede ne utječe samo razina mehaniziranosti radova u šumarstvu i izloženost radnika ovisno o radnom mjestu, već i drugi čimbenici imaju znatan utjecaj. U okviru dostupnih istraživanja i izloženih rezultata uočeno je da razlika u segmentu radne snage ima značajan utjecaj na rizik od ozljeđivanja. Profesionalni šumski radnici zaposleni na neodređeno vrijeme od strane šumskog poduzeća znatno manje se ozljeđuju od poljoprivrednika, samozaposlenih radnika i radnika sjekača zaposlenih kod privatnih izvoditelja. U Austriji, poljoprivrednici koji sezonski izvode radove pridobivanja drva imaju dvostruko više nesreća na milijun kubičnih metara etata u odnosu na profesionalne radnike (Sozialversicherung der Bauern 1990), a u Švedskoj čak četiri puta više. U Švicarskoj, radnici zaposleni u državnim šumama imaju upola manje nesreća u odnosu na radnike zaposlene kod privatnih izvođača, posebice tamo gdje su radnici zaposleni samo sezonski i čine migracijsku radnu snagu (Wettmann 1992).

Većina pokazatelja koji se odnosi na pitanja sigurnost i zdravlje, vezano za operatere šumarske mehanizacije, rezultat su studija provedenih na području Novog Zelanda, Sjeverne Amerike i nordijskih zemalja. Zajedničko iskustvo navedenih zemalja je da se prevalencija nesreća smanjuje s povećanjem udjela šumske mehanizacije te smanjenja udjela manualnog i manualno-strojnog rada. U prilog navedenom, u nordijskim zemljama od kraja 70-ih godina prošlog stoljeća pa nadalje, razina rizika smanjila se s razine zanimanja najviše sklonog nesrećama na razinu zanimanja s prosječnom razinom rizika (u 2011. bilo je 11 nesreća s više od tri dana odsutnosti na milijun radnih sati, a prosječna vrijednost svih zanimanja bila je 13,2 nesreće na milijun sati rada) (FAII 2011, Klun i Medved 2007). Stopa ozljeda sa smrtnim ishodom u Švedskoj i Finskoj činila je 0,03 smrtna slučaja/10 milijuna m^3 posječenog i izrađenog drva u prosjeku (podatak se odnosi na profesionalne šumske radnike u periodu 2000-2004). U Njemačkoj odgovarajući pokazatelj ima vrijednost 0,16, u Austriji 0,83, a u Švicarskoj 1,00 (Klun i Medved 2007). Usporedba rizika od nastanka ozljeda između tradicionalnih operacija pridobivanja drva (sjekač + skider) i potpuno mehaniziranih radova pridobivanja drva, u okviru istraživanja provedenog u Kanadi, rezultiralo je tri puta većom stopom ozljeđivanja kod tradicionalnih operacija pridobivanja drva (ILO 1991). Slično istraživanje u Švedskoj rezultiralo je četiri puta većim rizikom od ozljeđivanja kod manualno-strojnog rada u odnosu na strojni rad kod sječe i izrade drva (ILO 1991). Navedeno potvrđuju istraživanja u SAD-u (Lefort i dr. 2003) i Švedskoj (Axelsson 1998) gdje je također stopa ozljeđivanja četiri puta veća kod sjekača u odnosu na operatere šumske mehanizacije. Dodatno, istraživanje provedeno u Kanadi ističe još značajniju razliku u stopi ozljeđivanja, čak sedam puta, kada se promatra iz aspekta ostvarenog etata (ILO 1991).

Detaljnija analiza nesreća u sektoru šumarstva pokazala je da su radovi na sječi i izradi drva daleko opasniji od drugih šumskih radova (ILO 1991). Navedeno je osobito istaknuto kod manualno-strojne sječe i izrade drva gdje je obaranje stabla te prerezivanja debla i ostalih segmenata stabla prepoznato kao aktivnost kod kojih se sjekači najčešće ozljeđuju (ILO 2012). S druge strane, operateri šumske mehanizacije dobro su zaštićeni u kabinama radnog stroja (forvardera, harvestera), što je rezultiralo značajnim padom rizika od nastanka ozljeda. Operateri harvestera dožive manje od 15 % ozljeda koje dožive šumski radnici sjekači za istu količinu posječenog i izrađenog etata. Istraživanja u Švedskoj pokazala su da operateri harvestera iskuse

samo jednu četvrtinu nesreća profesionalnog šumskog radnika sjekača (ILO 2012). Stopa ozljeda kod rada harvestera u pravilu je niska, iako rizik od ozljeđivanja raste kada šumski radnik sjekač radi paralelno sa harvesterom. Radne aktivnosti održavanja harvestera su opasne: popravci su uvijek pod visokim radnim opterećenjem; postoji velika opasnost od pokliznuća i pada, neugodan i nefiziološki radni položaja, podizanje teških tereta, kontakt s hidrauličkim uljima i vrućim uljima pod pritiskom i sl. (ILO 2012). Sukladno navedenom, kod mehanizirane sječe i izrade drva prva potencijalna opasnost, koja je uzrok većine nesreća, odnosi se na ozljede koje rezultiraju popravcima i održavanjem sredstva rada na samom radilištu. U prošlom desetljeću šumska mehanizacija postala je sve pouzdanija što je uzročno-posljedično rezultiralo s manjim brojem popravaka, a samim time i ozljeda na radu. Druga potencijalna opasnost koja uzrokuje znatan udio nesreća na radu kod mehanizirane sječe i izrade drva je penjanje i silaženje iz kabine sredstva rada (forvardera, harvestera i sl.). Vrlo često operater sredstva rad iskoči iz kabine na neravan teren i/ ili sklisko tlo (npr. blato, snijeg, razbacane grane i sl.) što u konačnici može rezultirati lakšom ili težom ozljedom na radu.

Backström i Åberg (1998) u Švedskoj istražili su ozljeđivanje operatera tijekom rada sa šumskom mehanizacijom, a u okviru rezultata uzroka ozljeđivanja istaknuli su 5 slijedećih kategorija:

- ozljede uzrokovane montiranjem i/ili spuštanjem šumskog stroja bile su zastupljene s 21 %, a broj izgubljenih dana izražen kroz vrijednost medijane bio je 7;
- ozljede uzrokovane radom / održavanjem stroja stojeći na istom bile su zastupljene s 20 %, a broj izgubljenih dana izražen kroz vrijednost medijane bio je 49;
- ozljede uzrokovane iznenadnim i neočekivanim kretanjem određenog dijela stroja (kod radova održavanja dok stroj radi) bile su zastupljene s 8 %, a broj izgubljenih dana izražen kroz vrijednost medijane bio je 54,5;
- ozljede uzrokovane gubljenjem dijela stroja ili alata (koji je pao i pogodio operatera) bile su zastupljene s 8 %, a broj izgubljenih dana izražen kroz vrijednost medijane bio je 34;
- ozljede uzrokovane prevrtanjem, sudarom i/ili zalijetanjem stroja bile su zastupljene s 11 %, a broj izgubljenih dana izražen kroz vrijednost medijane bio je 43.

Iako je stopa ozljeđivanja zbog primjene mehaniziranog rada smanjena, još uvijek se smatra da je navedeni pokazatelj previsok (Lewark 2005). U prilog tom idu rezultati istraživanja Backströma i Åberga (1998) koji su pokazali da je broj nesreća tijekom strojnog rada u Švedskoj na istoj razini već nekoliko godina, a ta se razina podudara s razinom ostale industrijske proizvodnje.

Uvođenje visoko mehaniziranih sustava pridobivanja drva (harvestera, forvardera) dovelo je do promjena u vrsti i stupnju naprezanja kojemu su radnici izloženi u usporedbi s konvencijalnom metodom rada (sjekač + motorna pila + skider). Ergonomske studije u šumarstvu sve veći naglasak stavljaju na operatere šumske mehanizacije iz razloga što mehaniziranost povećava rizik od mišićno-koštanih ozljeda tj. kratkih ponavljajućih ciklusa i pokreta ruke (ponavljajućih pokreta sa i bez primjene sile) što može rezultirati razvojem profesionalne bolesti. Druga, negativna, strana mehaniziranosti radova u šumarstvu je javljanje novih zdravstvenih rizika u vidu bolova u vratu te naprezanja i deformacije ramena kod operatera (ILO 2012). Rezultati istraživanja ukazuju da mišićno-koštani poremećaji uzrokuju više bolovanja nego nesreća. Erikson (1995) navodi da je među 603 šumska radnika bilo 25 ozljeda što je rezultiralo sa 255 dana bolovanja, dok je kod 10 registriranih mišićno-koštanih poremećaja zabilježeno 1 253 dana bolovanja. Također, godišnje se u Švedskoj i Finskoj registrira oko 20 profesionalnih bolesti na 10.000 radnika, a najčešće su to gubitak sluha, koštano-mišićne bolesti i kožne bolesti (zbog hidrauličkih ulja, goriva, itd.) (FIOH 2012).

Gröger i Lewark (2002) izvještavaju da su operateri šumske mehanizacije znatno više izloženi statičkom, nego dinamičkom opterećenju. Sjedeći radni stav u stroju može dovesti do povećanog pritiska na vrat, ramena i mišiće leđa. Tipični simptomi za operatera su problemi s ramenima-rukama, koji su posljedica nelagodnog radnog držanja i napora potrebnog za ulazak u kabinu stroja. Löfroth i Pettersson (1982) utvrdili su indikaciju rastućeg problema vezanog za pritužbe o bolovima u vratu i ruci kod švedskih operatera mehanizacije. Oni su procijenili da je oko 75 % uzorkovanih ispitanika imalo barem neke pritužbe tijekom razdoblja od dvije godine, a 20 – 30 % imalo je probleme koji su doveli do savjetovanja s liječnikom i / ili nesposobnosti vezane za normalan rad. Jonsson i suradnici (1983) objavili su istraživanje provedeno na 241 operateru mehanizacije (stopa odgovora 88 %). Rezultati su pokazali da je 56 % ispitanika imalo prigovor na bolove u vratu, a 50 % pritužbe na bolove u ramenima tijekom prethodnih 12 mjeseci. Lidén i Pontén (1985) utvrdili su da je 50 % od 110 uzorkovanih operatera šumske mehanizacije imalo prigovor vezan za bolove u vratu / ramenu. Naprezanje, a samim time pojava nelagode i bolova, u šaci, ruci, vratu i ramenima također može biti prouzročeno cikličkim ponavljanjem istih pokreta (RSI - Repetitive Strain Injury). Važno je istaknuti da operateri šumske mehanizacije nordijskih zemalja rade s vrlo malim naprezanjem u mišićima, koristeći mini-džojstike, sjede na ergonomskim sjedalima s naslonima za ruke. Međutim, ozljede i profesionalne bolesti zbog cikličkog ponavljanja istih pokreta (RSI) još uvijek čine veliki problem iz aspekta sigurnosti i zaštite zdravlja radnika. Istraživanja pokazuju da se između 50 i 80 % operatera mehanizacije žali na bolove u vratu ili ramenima. Ove brojke često su teško usporedive jer se ozljeda i/ili profesionalna bolest postupno razvija tijekom dugog vremenskog razdoblja (ILO 2012). Iako su operateri šumske mehanizacije manje izloženi buci te vibracijama koje se prenose na šake i ruke u odnosu na rukovatelje motornom pilom, oni su više izloženi vibracijama koje se prenose na cijelo tijelo što može biti potencijalni uzrok degenerativnih promjena kralježnice (Lewark 2005).

Psihološko opterećenje ima veću ulogu od fizičkog opterećenja na zdravlje i radni učinak kod operatera šumske mehanizacije. Brojni kompleksi pokreti potrebni za rad sa šumskim strojem (harvesterom) zahtijevaju visok stupanj koncentracije, visoki stupanj pažnje i kontinuiranu spremnost za prilagođavanje radne brzine stroja. Stres, naprezanje, monotonija i izolacija su uobičajene sastavnice povezane s ovakvom vrstom radnog mjesta (Lewark 2005). Schmid-Vielgut (1986) bio je među prvima koji je opisao kako su operateri šumske mehanizacije izloženi povećanom psihološkom opterećenju (stres) u kombinaciji s umorom, a u odnosu na rukovatelje motornom pilom. Dugoročno, navedeni štetni učinci na zdravlje dovode do slabljenja imunološkog sustava s istodobnim povećanjem osjetljivosti prema fizičkim i psihičkim bolestima koje rezultiraju depresijom. Gellerstedt (1997) je izvijestio o postavljenim ograničenjima vezanim za produktivnost zbog psihološkog opterećenja operatera stroja. Navedene aktivnosti rezultiraju povećanjem stresa, umora i napora tijekom smjene. Također, među operaterima javljaju se problemi s vratom i ramenima. Loša vidljivost, neskladni pokreti, nefiziološki stav tijela tijekom rada te uvijanje i okretanje glave kumulativno doprinose navedenom stanju. Na uzorku norveških šumskih radnika Hagen i sur. (1998) utvrdili su da je povećanje poremećaja donjeg (lumbosakralnog) dijela leđa kod operatera mehanizacije usko povezano s povećanjem psiholoških zahtjeva.

Jedna od nedovoljno istraženih modernih profesionalnih bolesti kod operatera tehnološki vrlo napredne šumske mehanizacije je sindrom kompjuterskog vida. Isti predstavlja privremeno stanje uzrokovano dugim neprekinutim periodima gledanja u zaslon računala. Neki simptomi sindroma računalnog vida su glavobolja, zamagljen vid, bol u vratu, umor, zamor očiju, suhe i nadražene oči te problemi u ponovnom fokusiranju pogleda. Ti simptomi mogu biti pogoršani neprimjerenim osvjetljenjem (tj. vrlo svijetlim ili bliještećim rasvjetnim tijelima iznad glave tj. rad na otvorenom u kabini stroja) ili kretanjem zraka ispred očiju (npr. izravan dotok zraka klimatizirajućeg sustava stroja). Sindrom kompjuterskog vida uzrokovan je smanjenom učestalosti treptanja za vrijeme

dugotrajnog rada na računalu (gledanja u zaslon radnog stroja). Normalna učestalost treptanja je 16 do 20 puta na minutu. Istraživanja su pokazala da se učestalost treptanja smanjuje na 6 do 8 treptaja po minuti za ljude koji rade za kompjuterom. To isušuje oči. Također, napor uložen u fokusiranje pogleda dugi niz sati, opterećuje cilijarne mišiće oka. To izaziva simptome astenopije i uzrokuje osjećaj umora u oku nakon dugog rada. Neki pacijenti ne mogu fokusirati predmete koji su im blizu ni nakon kraćeg vremena. To se najčešće javlja kod ljudi između tridesete i četrdesete godine života, što vodi smanjenju sposobnosti očnih akomodativnih mehanizama fokusiranja.

Radovi u šumarstvu, osobito radovi u procesu pridobivanja drva, idu u red fizički najzahtjevnijih radova među različitim gospodarskim djelatnostima. Pri tom se posebno misli na opterećenja kojima su radnici izloženi: energijska potrošnja, terenski i vremenski uvjeti rada, učestalost i težina povreda na radu, izloženost pri djelovanju vibracije, buke, plinova i ostalih štetnih čimbenika radnog okoliša. Osim što su fizički naporni radovi visoko rizični za zdravlje radnika, velika je vjerojatnost da će se šumski radnici u svom radnom vijeku jednom ili više puta ozlijediti ili oboljeti od profesionalne bolesti. Shodno navedenom, u ocjeni i analizi razine sigurnosti u pojedinoj djelatnosti koristi se više različitih pokazatelja, no dva najvažnija indeksa koja se koriste u prikazivanju nesreća, a prihvaćeni su od strane Međunarodne organizacije rada (ILO), su indeks frekvencije i indeks težine. Osim navedena dva pokazatelja, kao specifični pokazatelji razine sigurnosti u šumarskoj djelatnosti koristi se još: broj povreda na 1.000 zaposlenih, broj povreda na milijun m^3 etata te količina etata na jednu povredu.

U okviru poduzeća HŠ d.o.o. Zagreb ozljede na radu evidentiraju se i prate prema postojećim zakonskim propisima. Prilikom svake ozljede radnika, čiji je poslodavac HŠ d.o.o. Zagreb, provode se propisani postupci prijave, uviđaja, izvješćivanja i sl. Svaka od 16 Uprava šuma u sklopu poduzeća HŠ d.o.o. Zagreb zadužena je za godišnje izvješće svojih radnika vezanih za povređivanje, uzrok povrede te ostale podatke. Osnovni uvjet unapređivanja sigurnosti i zdravlja radnika u šumarstvu, osobito radnika uključenih u direktnu proizvodnju, je posjedovanje svih relevantnih informacija koje su potrebne za razumijevanje, tumačenje i preveniranje detektiranih problema.

Broj povreda u pojedinoj organizacijskoj cjelini ide u red ključnih pokazatelja sigurnosti. Najčešće se iskazuje u apsolutnom iznosu kao godišnji broj povreda te kao relativni pokazatelj brojnosti povreda po ukupnom broju radnika (svi proizvodni i neproizvodni radnici) te po broju proizvodnih radnika iz razloga što velik udio režijskih zaposlenika može stvoriti krivu predodžbu o broju ozljeda. Proizvodni radnici su kritična kategorija i broj ozljeda ne treba povezivati s ukupnim brojem zaposlenih, već s onom skupinom na koju se odnose. Temeljem provedene deskriptivne analize (slika 6.46 i 6.47) možemo vidjeti da se broj zaposlenih u HŠ d.o.o. svake godine smanjuje, a broj ozljeda od 2013. godine poprima uzlazni trend. S druge strane, u sklopu UŠP Bjelovar (slika 6.46 i 6.47) trend smanjenja broja zaposlenih manje je izražen nego na razini poduzeća, a broj ozljeda godišnje ne pokazuje značajne ekstreme u promatranom periodu.

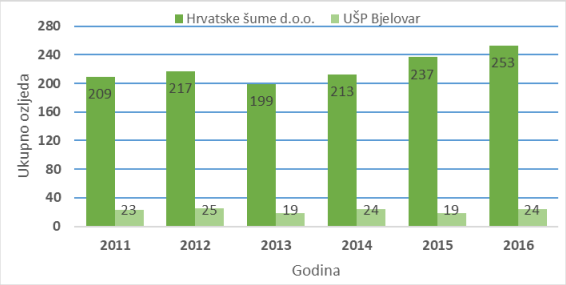

Slika 6.46 Trend kretanja ozljeda na radu u HŠ d.o.o. te UŠP Bjelovar

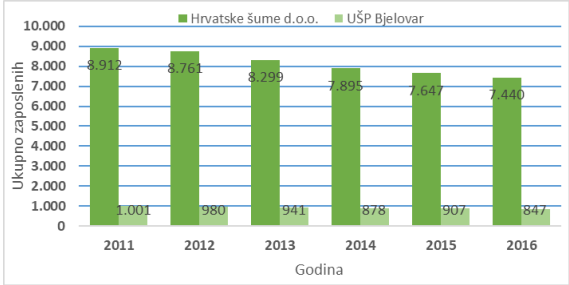

Slika 6.47 Trend kretanja broja zaposlenih u HŠ d.o.o. te UŠP Bjelovar

Prvi značajan pokazatelj **indeks učestalosti** (slika 6.48) predstavlja vrlo objektivan način utvrđivanja frekventnosti ozljeđivanja jer polazi od nepobitne činjenice da ozljede nastaju ovisno o riziku i efektivnom radnom vremenu. Efektivno radno vrijeme (EV) je definirano kao ukupan broj radnih sati provedenih na radu, bilo po vremenu ili učinku. Važno je istaknuti da u efektivno radno vrijeme ne ulaze sati zbog: (a) prekida rada, (b) godišnjih odmora ili blagdana, (c) stručnog obrazovanja, (d) bolovanja te (e) neopravdanih izostanaka. Indeks učestalosti prikazuje broj nesreća na milijun radnih sati.

Sukladno dobivenim pokazateljima na slici 6.47 vidljivo je da, u odnosu na HŠ d.o.o. kao sustav, UŠP Bjelovar u promatranom razdoblju bilježi manji broj nesreća na milijun radnih sati. Unutar šestogodišnjeg razdoblja (slika 6.48) HŠ d.o.o. u prosijeku imaju 17 ozljeda na milijun radnih sati godišnje, dok UŠP Bjelovar ima 15,5 ozljeda na milijun radnih sati godišnje.

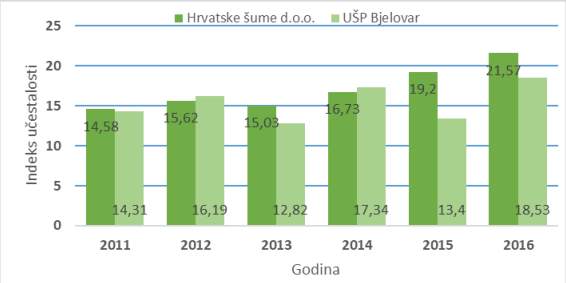

Slika 6.48 Trend kretanja indeksa učestalosti u HŠ d.o.o. te UŠP Bjelovar

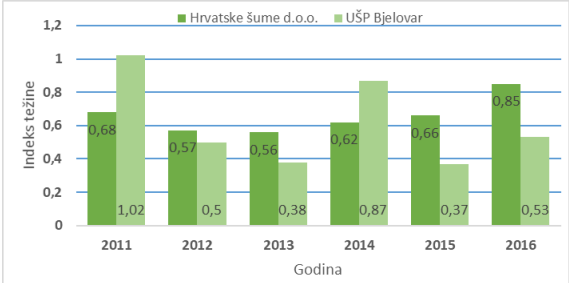

Slika 6.49 Trend kretanja indeksa težine u HŠ d.o.o. te UŠP Bjelovar

Drugi značajan pokazatelj **indeks težine** (slika 6.49) predstavlja broj izgubljenih radnih dana zbog nesreća na tisuću radnih sati. Navedenim indeksom se pokušava, putem gubitaka u radnom vremenu zbog povreda na radu, izraziti ekonomska tj. financijska dimenzija štete ili troška što ga ima poslovni sustav uslijed povrede radnika. Navedeno je značajno jer indeks učestalosti sam po sebi ne ukazuje na težinu (ozbiljnost) posljedica ozljeđivanja. Iz slikovnog prikaza 6.49, za promatrano razdoblje, vidljivo je da UŠP Bjelovar ima 2011. i 2014. značajno veći broj izgubljenih radnih dana u odnosu na poduzeće HŠ, dok je kod preostale četiri godine vrijednost navedenog pokazatelja manja.

Pokazatelj vezan za broj ozljeda na 1.000 zaposlenih (slika 6.50) ističe značajno odstupanje između UŠP Bjelovar i HŠ d.o.o. tek 2015. i 2016. godine (u prosjeku godišnje 8 ozljeda više na razini poduzeća HŠ u odnosu na UŠP Bjelovar). Unutar šestogodišnjeg razdoblja (slika 6.50) HŠ d.o.o. u prosijeku imaju 27,36 ozljeda na 1000 zaposlenih godišnje, dok UŠP Bjelovar ima 24,22 ozljeda na 1.000 zaposlenih.

Zakonitost nalaže da rizik od povreda u nekoj organizacijskoj jedinici raste s obujmom radne zadaće po pojedinom izvršitelju posla. Sukladno prethodno navedenom, specifični pokazatelji razine sigurnosti pri šumskom radu uzimaju u odnos broj povreda i obujma posla koji se u šumarstvu iskazuje kroz radnu zadaću godišnje sječe (etata) u m^3. Kod usporedbe razine zaštite na radu mogu se primijeniti dva specifična pokazatelja (a) izrađeni m^3 drva (etata) po 1 povredi te (b) broj povreda na izrađenih 1.000.000 m^3.

Pokazatelj izrađenih m^3 drva po jednoj povredi nedvojbeno ide u prilog UŠP Bjelovar (slika 6.51). Unutar šestogodišnjeg razdoblja (slika 6.51) HŠ d.o.o. u prosijeku izrađuje 22.629 m^3 po ozljedi godišnje, dok UŠP Bjelovar izrađuje 30.895 m^3 po ozljedi godišnje.

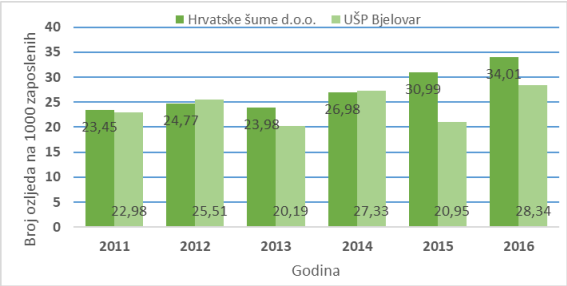

Slika 6.50. Trend kretanja broja ozljeda na 1000 zaposlenih u HŠ d.o.o. te UŠP Bjelovar

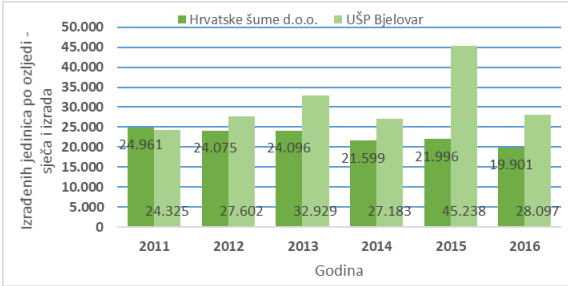

Slika 6.51 Trend kretanja izrađenih m^3 po ozljedi u HŠ d.o.o. te UŠP Bjelovar

Detaljnija analiza kretanja broja ozljeda kod radova pridobivanja drva na području UŠP Bjelovar, za radni proces sječe i izrade te privlačenja, prikazana je na slici 6.52.

Unutar promatranog razdoblja (slika 6.52) vidljivo je da je rizik od nastanka ozljede na radovima sječe i izrade mnogostruko veći u odnosu na radove privlačenja drva. U okviru promatranog razdoblja (slika 6.52) UŠP Bjelovar je u prosijeku godišnje imala 12,3 ozljeda na radovima sječe i izrade te 2,3 ozljeda na radovima privlačenja drva, čime je potvrđena prisutnost višestrukog rizika kod ručno-strojnog rada.

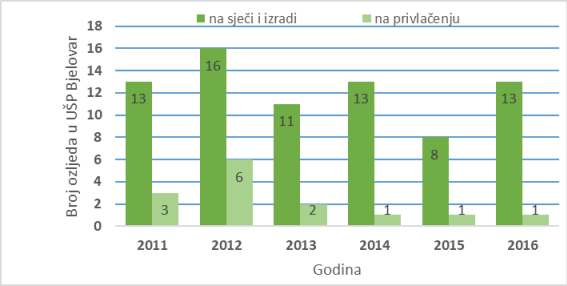

Slika 6.52 Trend kretanja broja ozljeda u UŠP Bjelovar kod faze I. i II.

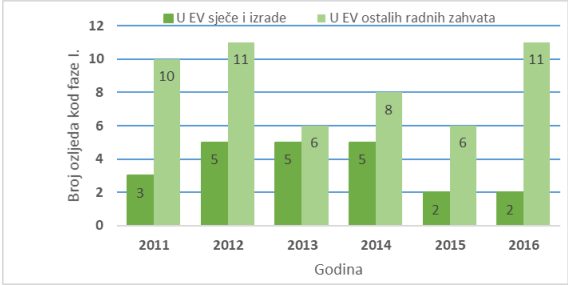

Slika 6.53 Trend kretanja broja ozljeda u UŠP Bjelovar kod faze I. spram radnih zahvata

Analiza strukture povređivanja po radnim zahvatima kod radova pridobivanja drva na području UŠP Bjelovar, za radni proces sječe i izrade te privlačenja, prikazana je na slici 6.53 i 6.54. Kod radnog procesa sječe i izrade drva (slika 6.53), u promatranom razdoblju, vidljivo je da se značajniji broj ozljeda događa u efektivnom radu kod ostalih radnih zahvata (u prosijeku godišnje 8,6 ozljeda) npr. uganuća kod kretanja radnika zbog klizavosti i zakrčenosti hodne površine, pad grane na radnika i sl. S druge strane, kod čistog efektivnog rada kada je motorna pila u pogonu u prosjeku je zabilježeno 3,6 ozljeda godišnje. Slična situacija povređivanja po radnim zahvatima prisutna je i kod privlačenja drva (slika 6.54) gdje je kod čistog efektivnog rada sa strojem (puna i/ili prazna vožnja) broj ozljeda u prosjeku 0,5 godišnje dok je u efektivnom radu kod ostalih radnih zahvata na privlačenja broj ozljeda u prosjeku 1,8 godišnje.

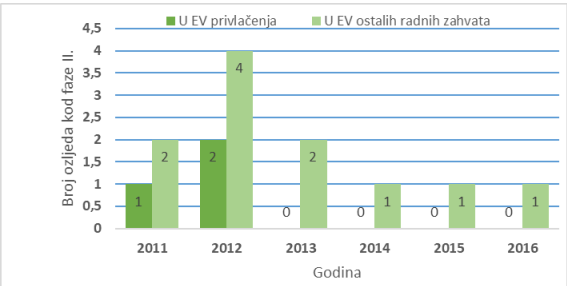

Slika 6.54 Trend kretanja broja ozljeda u UŠP Bjelovar kod faze II. spram radnih zahvata

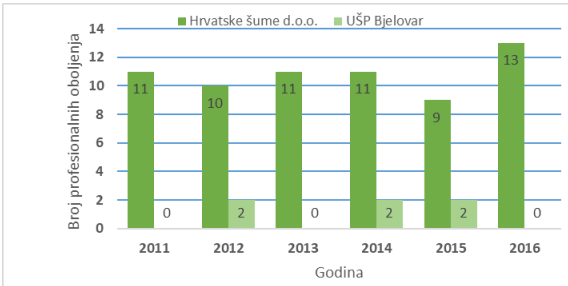

Slika 6.55 Trend kretanja broja profesionalnih oboljenja u HŠ d.o.o. te UŠP Bjelovar

Profesionalne bolesti su najčešće uzrokovane jednim uzročnim čimbenikom radnog mjesta, a težina bolesti odgovara razini i duljini izloženosti, pa se profesionalne bolesti u pravilu pojavljuju nakon višegodišnje izloženosti štetnostima i naporima. Analizom trenda pojavnosti profesionalnih bolesti za promatrano razdoblje (slika 6.55) vidljivo je da se na razini poduzeća HŠ d.o.o. Zagreb u prosijeku evidentira 10,8 profesionalnih oboljenja godišnje, dok na razini UŠP Bjelovar evidentirana je u prosijeku 1 profesionalna bolest godišnje.

Literatura

Axelsson, S. A., 1998: The mechanisation of logging in Sweden and its effect on occupational safety and health. J Forest Eng 9(2): 25–31.

Backström, T., E. Åberg, 1998: Olycksfall. in: Winkel, J., Attebrant, M., Wikström, B.-O. (ed.) Konsensusrapporter rörande kunskapsläget om arbetsmiljön i skogsmaskiner. Arbete och Hälsa 10: 42–46.

Bentley, T., R. Parker, L., Ashby, 2005: Understanding felling safety in the New Zealand forest industry. Appl. Ergonomics 36: 165–175.

Efthymiou, P. N., 2008: Wood Harvesting. Aristotle University of Thessaloniki, Thessaloniki.

Erikson, G., 1995: Belastningsskador bland maskinförare i skogen. Fakta- och åtgärdskatalog. (RSI in forest-machine operators in Scandinavia) Redogörelse 4. Skogforsk: Uppsala.

Federation of Accident Insurance Institutions (FAII), 2011: Accidents at work sustained by wage earners, by professional category. Finland, 2011.

Finnish Institute of Occupational Health (FIOH), 2012: Työperäisten sairauksien rekisteri (Register of the occupational disease; in Finnish).

Gellerstedt, S., 1997: Mechanised cleaning of young forests: The strain on the operator. International Journal of Industrial Ergonomics 20: 137–143.

Gröger, V., S. Lewark, 2002: Der arbeitende Mensch in Wald. Schriftenreihe der Bundesanstalt für Arbeitsschutz und Arbeitsmedizin, Fb 970. Dortmund, Berlin & Dresden.

Hagen, K. B., P. Magnus, K. Vetlesen, 1998: Neck/shoulder and low-back disorders in the forest industry: Relationship to work tasks and perceived psychosocial job stress. Ergonomics 41(10): 1510–1518.

International Labour Organisation (ILO), 1981: Occupational Safety and Health problems in the Timber Industry. Geneva, Switzerland.

International Labour Organization (ILO), 1991: Occupational Safety and Health in Forestry. Report II, Forestry and Wood Industries Committee, Second Session. Geneva: ILO.

International Labour Organization (ILO), 2012: Encyclopedia on Occupational Health and Safety – Foutrhe Edition. Part X: Industries Based on Biological Resources. Chapter 68 – Forestry. (Izvor: http://www.ilocis.org/documents/chpt68e.htm)

Jonsson, B., C. Brulin, B. E. Ericson, C. Hammar, 1983: Besvär från rörelseorganen bland skogsmaskinförare. (Musculoskeletal complaints in forestry machine operators.) Undersökningsrapport 1983(13). Arbetarskyddsstyrelsen.

Klun, J., M. Medved, 2007: Fatal accidents in forestry in some European countries. Croatian Journal of Forest Engineering 28(1): 55–62.

Lefort, A. J., C. P. de Hoop, , J. C. Pine, 2003: Characteristics of injuries in the logging industry of Louisiana, USA: 1986 to 1998. Int J For Eng 14: 75–89.

Lewark, S., 2005: Scientific reviews of ergonomic situation in mechanized forest operations. Institutionen för skogens produkter och marknader, str. 185.

Lidén, E., B. Pontén, 1985: Belastningsbesvär och arbetsväxling hos skogsmaskinförare. (Neck/shoulder complaints and job rotation of forest machine operators) Uppsatser och resultat 45. Sveriges lantbruksuniversitet, Institutionen för skogsteknik: Garpenberg.

Lindroos, O., L. Burström, 2010: Accident rates and types among selfemployed private forest owners", Acc. Anal. Prev. 42: 1729–1735.

Löfroth, C., B. Pettersson, 1982: Neck, arm and upper-back disorders in logging machine drivers: Description of the problem and proposals for preventive measures. Forskningsstiftelsen Skogsarbeten: Stockholm.

Potočnik, I., T. Pentek, A. Poje, 2009: Severity Analysis of Accidents in Forest Operations, Croat. J. of Forest Eng. 30(2): 171–184.

Schmid-Vielgut, B., 1986: Streß statt Schwerarbeit. Forst und Holz 41(21): 576–580.

Sozialversicherung der Bauern, 1990: Extracts from official Austrian statistics submitted to the ILO (unpublished).

Wettman, O., 1992: Securité au travail dans l'exploitation forestière en Suisse. In FAO/ECE/ILO Proceedings of Seminar on the Future of the Forestry Workforce, edited by FAO/ECE/ILO. Corvallis, OR: Oregon State University Press.

6.3.2 Fizičko opterećenje i energetska potrošnja

Ocjena fizičkog opterećenja rada operatera harvestere i šumskog radnika sjekača provođena je pomoću »ErgoFellow 3.0« softvera. U okviru navedenog softvera primjenjena su dva ergonomska alata: OWAS (engl. *Ovako Working Posture Analysing System*) i REBA (engl. *Rapid Entire Body Assessment*). OWAS metoda omogućuje procjenu stupnja statičkog opterećenja radnika na radnom mjestu analizirajući njihovo držanje, identificirajući četiri radna položaja za leđa, tri za ruke, sedam za noge i tri kategorije za težinu predmetnog tereta (Schilden 1989). Svaki od navedenih čimbenika ima atributnu vrijednost koda. Tehnika klasificira kombinacije navedene četiri kategorije prema stupnju njihovog utjecaja na mišićno-skeletni sustav za sve kombinacije položaja tijela radnika. Prema OWAS metodi, stupnjevi procjene štetnosti postojećih kombinacija držanja i opterećenja grupirani su u četiri kategorije djelovanja koje ukazuju na hitnost intervencije na radnom mjestu (Mattila i Vilkki 2003, Kee i Karwowski 2007).

- **Kategorija djelovanja 1:** normalni i prirodni položaji bez štetnog djelovanja na mišićno-skeletni sustav - nisu potrebne mjere;
- **Kategorija djelovanja 2:** blago štetna držanja - korektivne mjere potrebne u skoroj budućnosti;
- **Kategorija djelovanja 3**: primjetno štetno držanje - moraju se poduzeti korektivne mjere što je prije moguće;
- **Kategorija djelovanja 4:** izuzetno štetno držanje - odmah je potrebno poduzeti korektivne mjere za poboljšanje.

REBA metoda je posturalna sustavna analiza osjetljiva na mišićno-skeletne rizik kod različite vrste radnih zahvata, posebno za procjenu radnih položaja koji se nalaze u zdravstvenoj te drugim uslužnim djelatnostima (Hignett i McAtamney 2000). Osnovna ideja REBA metode je da se procijeni položaj pojedinih segmenata tijela, a rezultati položaja tijela radnika se povećavaju kad zabilježeni položaj segmenta tijela odstupa od neutralnog položaja. Sustav klasifikacije držanja

temelji se na dijagramu dijelova tijela, a uključuje gornji dio ruke, donji dio ruke, zglob, trup te vrat i noge. Skupina A uključuje trup, vrat i noge, dok skupina B uključuje gornje i donje ruke i zapešća. navedene skupine se kombiniraju u jednu od 144 moguće kombinacije držanja koje se pretvaraju u jedinstveni kod položaja tijela (Takala i dr. 2010). Metoda odražava opseg vanjskih opterećenja, mišićne aktivnosti uzrokovane statičkim, dinamičkim, brzim promjenama ili nestabilnim položajima, te efekt spajanja istih. Dobiveni rezultati su sažeti kako bi dobili jedan rezultat za svako promatranje (Takala i dr. 2010). Navedena metoda pruža pet kategorija djelovanja za procjenu razine korektivnih aktivnosti.

- **Kategorija djelovanja 0**: korektivna akcija, uključujući daljnju procjenu, nije potrebna;
- **Kategorija djelovanja 1**: korektivna akcija, uključujući daljnju procjenu, može biti potrebna;
- **Kategorija djelovanja 2**: korektivna akcija, uključujući daljnju procjenu, potrebna u skoroj budućnosti;
- **Kategorija djelovanja 3**: korektivna akcija, uključujući daljnju procjenu, potrebna što je prije moguće;
- **Kategorija djelovanja 4**: korektivna akcija, uključujući daljnju procjenu, potrebna je odmah.

OWAS metoda klasificira opterećenje položaja tijela za hitnost korektivnih akcija u četiri kategorije djelovanja. Dok REBA metoda grupe opterećenja položaja tijela svrstava u pet akcijskih kategorija, koje imaju malo drugačije značenje od kategorija djelovanja u okviru OWAS metode. Da bi se omogućila usporedba REBA i OWAS metode, razine rizika REBA metode prema Kee i Karwowskom (2007) regrupirane su na četiri razine uzimajući u obzir značenje kategorija djelovanja za obje tehnike.

Tablica 6.4 Regrupirani stupnjevi rizika za REBA metodu

Regrupirana kategorija djelovanja	Originalna kategorija djelovanja	Značenje
1	0	Normalan položaj
2	1 i 2	Nisko rizičan položaj
3	3	Srednje rizičan položaj
4	4	Visoko rizičan položaj

Detalji terenskog istraživanja tj. rada operatera harvestera i motorne pile lančanice zabilježeni su pomoću video kamere. Kod terenskog rada operatera harvestera snimljeno je 9 h i 29 minuta efektivnog vremena strojne sječe i izrade drva, dok je kod terenskog rada šumskog radnika sjekača snimljeno 45 minuta efektivnog vremena ručno-strojne sječe i izrade drva. Položaji tijela izdvojeni su iz radnih snimaka snimljenih video kamerom sukladno metodi trenutačnih opažanja. Kod strojne sječe i izrade s harvesterom definirani interval opažanja iznosi 6 min, što ukupno čini 88 uzorkovanih radnih položaja tijela operatera tijekom efektivnog rada. S druge strane, kod ručno-strojne sječe i izrade drva definirani interval opažanja iznosi 0,5 min, što ukupno čini 87 uzorkovanih radnih položaja tijela šumskog radnika sjekača. Svi uzorkovani položaji tijela ocijenjeni su pomoću »ErgoFellow 3.0« softvera kroz dvije navedene tehnike promatranja: OWAS i REBA metode, što u konačnici rezultira s dva položajna opterećenja tijela operatera po svakoj primijenjenoj tehnologiji rada.

Ergonomski aspekt istraživanja obuhvaćao je utvrđivanje energetskog opterećenja šumskih radnika putem mjerenja frekvencije pulsa tijekom radnoga dana. Za procjenu energetskog opterećenja šumskih radnika, odnosno za utvrđivanje njihove energetske potrošnje pri radu uobičajeno se koriste metode zasnovane na mjerenju pulsa (Vondra 1995, Martinić 1993). Zbog svoje praktičnosti i jednostavnog terenskog mjerenja one su vrlo prikladne za istraživanja u šumarstvu. Mogućnosti i opravdanost primjene metode počiva na vezi između frekvencije pulsa i energetske potrebe koju je nužno zadovoljiti pri dinamičkom radu. Svaka intenzivna aktivnost i

psiho-fizičko opterećenje koje izaziva šumski rad dovodi do povećanja energetske potrebe radnikova organizma. Narasla energetska potreba se zadovoljava pojačanim radom srca, tj. povećanim udarnim obujmom srca (količina krvi koja se izbacuje u krvotok pri svakoj kontrakciji) i povećanom frekvencijom pulsa (broj kontrakcija/otkucaja srca u jedinici vremena, obično jedna minuta). Na taj se način u organizmu s krvi dostavlja veća količina hranjivih tvari i kisika potrebnoga za oslobađanje energije neophodne za obavljanje rada, tj. zadovoljavanje nastale energetske potrebe. Znači, s porastom energetske potrebe raste i rad srca, odnosno frekvencija pulsa.

Na temelju izmjerene frekvencije pulsa pri pojedinoj vrsti rada, moguće je prema priznatim klasifikacijama (Ronay 1975, Kaminsky 1971) razvrstati određene vrste radova po kategorijama težine, odnosno opterećenja koje izazivaju.

Tablica 6.5 Kategorizacija opterećenja pri šumskom radu

Ronay (1975)		Kaminsky (1971)	
OPTEREĆENOST	Frekvencija srca, min^{-1}	TEŽINA RADA	Energ. potrošnja, MJ/8 h
Bez opterećenja	oko 70		
Mala	75 - 95	Laki rad	1,23 - 2,51
Srednja	96 - 115	Teški rad	do 6,30
Umjerena	116 - 130	Najteži rad	do 10,47
Velika	131 - 150		
Vrlo velika	iznad 150	Sportski maksimum	od 11 do 41,90

Pomoću izmjerene frekvencije pulsa također je moguće, pomoću poznatih modela (1), izračunati potrošnju kisika i energije pri radu (Vondra 1995). Napominje se da je fiziološka jedinica za rad i energiju litra kisika (1 LO_2), te da se pri potrošnji 1 LO_2 u organizmu oslobađa energija u prosječnoj količini od 5 Kcal (kalorijski ekvivalent kisika).

$$Q_{EP} = 14{,}42 - 0{,}4268\, f_{FS} + 0{,}003914\, f_{FS}^2 \qquad (1)$$

Q_{EP} – energijska potrošnja, $kJ \cdot min^{-1}$; f_{FS} – frekvencija srca, min^{-1}

Ograničenje navedenih metoda je u tome što uz radno opterećenje na frekvenciju pulsa utječu i životna dob, zdravstveno stanje, tjelesna težina, pušenje, unutrašnji doživljaji, psihičko stanje i sl. Ipak, smatra se da i pred tih ograničenja, prosječna, skupna razina pulsa u radnome danu daje vrlo koristan i dovoljno pouzdan podatak o radnom opterećenju radnika.

Za mjerenje frekvencije pulsa u provedenim je istraživanjima korišten uređaj Garmin Fenix 3HR (slika 6.56).

Slika 6.56 GPS uređaj i Heart Rate Monitor Garmin Fenix 3HR

Slika 6.57 Provedba snimanja na terenu

Garmin Fenix 3HR je visokoprecizan multisport sat sa senzorom za otkucaje srca na zapešću. Sat sadrži brojne funkcije za praćenje i procjenu izvedbe različitih aktivnosti na otvorenome. Opremljen je barometarskim visinomjerom, elektroničkim 3-osnim kompasom i GPS prijemnikom

koji automatski kalibrira ove senzore radi što točnijih podataka. Sveobuhvatnim funkcijama navigacije i praćenja Fenix 3HR bilježi GPS zapis traga i stvara trag kretanja.

Uređaj je opremljen je Elevate tehnologijom mjerenja pulsa na zapešću što omogućuje praćenje pulsa bez potrebe nošenja monitora pulsa na prsima. Pritom je uz praćenje rezultata za vrijeme rada, moguće pratiti dnevne aktivnosti uz praćenje pulsa 24 sata dnevno te dobiti točnije podatke o potrošnji energije tijekom dana. Fiziološka mjerenja koja prate rad također mogu dati procjenu sljedećih parametara:

- Naprezanje – oscilacije pulsa pokazuju ukupnu razinu stresa
- Stanje performansi – uspoređuje trenutačnu kondiciju s prosječnom kondicijom
- Laktatni prag – procjenjuje točku u kojoj se mišići brzo umaraju

Dodatne funkcijama koje daju informacije o stanju fizičke spreme i kondiciji uključuju maksimalni primitak kisika (VO2), utrošak kalorija, savjetnik za oporavak i sl.

Snimanjima provedenim uz primjenu opisane metode i uređaja Garmin Fenix 3HR obuhvaćene su tri vrste šumarskih radova, odnosno tri šumska radnika – operater harvestera, operater forvardera i šumski radnik sjekač. Radnici su prethodno mjerenju pulsa upoznati sa snimanjem te su za svakog radnika zabilježeni osnovni osobni podaci (starost, visina, težina, puls u mirovanju, zdravstveno stanje i dr.). Tijekom snimanja zasebno su praćene dionice efektivnoga rada radnika i dodatnoga vremena pri radu (odmori, zastoji, fiziološke potrebe i sl.). Na razini cjelokupnoga snimanja, odnosno za svaku pojedinačnu dionicu pritom su posebno bilježeni sljedeći parametri: 1) trajanje dionice/snimanja, 2) prosječna frekvencija pulsa, 3) maksimalna frekvencija pulsa.

Kod terenskog rada operatera harvestera ukupno je snimljeno je 17 h i 25 minuta rada, odnosno 11 h i 33 minuta efektivnog rada i 05 h i 52 minuta dodatnog vremena. Kod terenskog rada operatera forvardera ukupno je snimljeno je 16 h i 33 minuta rada (12 h i 24 minuta efektivnog rada i 04 h i 09 minuta dodatnog vremena). Kod terenskog rada šumskog radnika sjekača ukupno je snimljeno je 06 h i 07 minuta rada (03 h i 52 minute efektivnog rada i 02 h i 15 minuta dodatnog vremena).

Za daljnju obradu i analizu podataka svi su snimljeni zapisi pomoću aplikacije Garmin Connect IQ preneseni na posebnu on-line platformu, odnosno bazu koju omogućava detaljnije analiziranje, kategoriziranje i statistiku podataka.

Šumski radovi, osobito radovi na pridobivanju drva, svrstavaju se među najteže od svih ljudskih djelatnosti. Pri tom se misli na opterećenja kojima su radnici izloženi pri radu u promjenljivim terenskim i vremenskim uvjetima. Takav rad obilježavaju visoka energijska potrošnja, učestale povrede, izloženost djelovanju vibracija, buke, plinova, prašine i ostalih štetnosti. Kod velikog broja šumskih radova, bez obzira na značajan stupanj mehaniziranosti, upravo ljudski organizam predstavlja osnovni izvor radne energije.

Za procjenu fizičkog opterećenja šumarskih radnika, zbog svoje praktičnosti, vrlo često primjenjuju se metode temeljene na mjerenju pulsa. Mnogi autori ergonomskih istraživanja drže da prosječna razina pulsa u radnome danu daje koristan podatak o radnom opterećenju.

Poznato je da postoji ovisnost utroška kisika i pulsa. Pri fizičkom radu veća se opskrba mišića krvlju postiže bržim radom srca (većim pulsom) i povećanjem srčanoga obujma. Povećanje pulsa pri dinamičnom radu odvija se po određenoj zakonitosti, ovisno o težini posla. Nakon rada puls postupno pada, to sporije što je obavljeni rad bio naporniji. Na puls, uz radno opterećenje, utječu životna dob, zdravstveno stanje, tjelesna težina, psihičko stanje te osobito unutrašnji doživljaji – stres, strah, radost.

Odnos između fizičkog opterećenja pri nekom radu i utrošenog kisika za isti rad je čvrsto ovisan i linearno proporcionalan. Jednako je tako pri čistom fizičkom radu i odnos frekvencije srca i potrošnje kisika čvrsto linearan. Uvažavajući takav odnos potrošnju kisika je jednostavno izračunati iz frekvencije srca (pulsa). Utrošak kisika pri radu mjerilo je teškoće (težine) rada, jer je odnos između obavljenog fizičkog rada i uporabljenoga kisika linearan. Taj odnos koji je kod

svakog čovjeka drugačiji definira fizička sposobnost čovjeka. Potrošnja kisika također je jedan od standardnih pokazatelja fizičkog opterećenja te se često koristi u ocjenjivanju teškoće rada (tablica 6.6).

Tablica 6.6 Potrošnja kisika pri radu (prema Hollman & Andersen)

	Mirovanje	Rad			
		Laki rad	Srednje teški rad	Teški rad	Najveće opterećenje
Potrošnja kisika, L/min (muški)	0,29	> 0,81	> 1,26	> 2,15	3,20

Za ocjenu fizičkog opterećenja rukovatelja šumske mehanizacije na radovima pridobivanja drva primijenjena je metoda mjerenja frekvencije srca (pulsa) koje je provedeno na uzorkovanim ispitanicima pomoću uređaja Garmin Fenix 3HR (dalje: Garmin 3HR). U postupku odabira ispitanika terenskog mjerenja korišten je namjerni (kvotni) uzorak koji je rezultat osobnog prosuđivanja barem u jednom dijelu postupka izbora jedinica uzorka. Kvotni uzorak je najvažniji u skupini uzoraka koji se zasnivaju na teoriji slučajnosti, a bira se postupkom u kojemu je osigurano da različite podskupine osnovnog skupa budu zastupljene u uzorku prema njihovim važnim značajkama upravo na način kako to istraživač odredi. Prije terenskog mjerenja za svakog ispitanika određeni su slijedeći parametri: spol, visina (u cm), tjelesna masa (u kg), frekvencija srca u odmaranju (FS_o) i maksimalna teorijska frekvencija srca ($FSmax_t$). Frekvencija srca u odmaranju utvrdila se individualnim brojanjem otkucaja srca u trajanju od 1 minute (a) ujutro nakon buđenja ili (b) na mjestu mjerenja poslije 20 minuta bez aktivnosti (mirovanje). Maksimalna teorijska frekvencija srca izračunala se po formuli FSmaxt = 210 – (0,65 x godine života). Tako određeni osobni parametri činili su tzv. ulazni profil ispitanika koji je prije početka terenskog mjerenja, za svakog ispitanika, unesen u memoriju Garmin 3HR.

Ispitanike u istraživanju fizičkog opterećenja (tablica 6.7) činili su operater harvestera i forvardera (djelatnici privatnog poduzeća Forest – obrt za šumarske usluge trgovinu i prijevoz) te šumski radnik sjekač (djelatnik poduzeća HŠ d.o.o. UŠP Bjelovar). Terenska mjerenja i prikupljanje podataka fizičkog opterećenja provedeno je tijekom mjeseca lipnja, srpnja i rujna 2017. godine.

Tablica 6.7 Prosječne vrijednosti kvotnog uzorka ispitanika
RS = radno sredstvo; D_g = dob u godinama; H = visina u centimetrima; TM = tjelesna masa u kilogramima, FS_o = frekvencija srca u odmaranju; $FSmax_t$ = maksimalna teorijska frekvencija srca

RS	D_g	H	TM	FS_o	$FSmax_t$
Operater harvestera	26	175	103	68	193
Operater forvardera	33	180	90	74	189
Operater motorne pile	40	180	92	62	184

Kod strojne sječe i izrade frekvencija srca tijekom rada operatera harvestera mjerena je dva dana te je ukupno snimljeno 1045 minuta utroška vremena. Rad operatera forvardera tj. mjerenje frekvencije srca također je provedeno kroz dva radna dana te je ukupno snimljeno 993 minute utroška vremena. Kod ručno strojne sječe frekvencija srca tijekom rada šumskog radnika sjekača mjerena je jedan dan, a ukupno je snimljeno 367 minuta utroška vremena. Analiza izmjerenih frekvencije srca kod uzorkovanih ispitanika provedena je na razini efektivnog i dodatnog vremena (tablica 6.8)

Izmjerene vrijednosti prosječne frekvencije srca kod efektivnog, ali i kod dodatnog, vremena rada vidljivo se razlikuju (tablica 8) između ručno-strojnog i strojnog rada kod radova pridobivanja drva. Sukladno dobivenim vrijednostima prosječne frekvencije srca, radno opterećenje izraženo kroz energetsku potrošnju i potrošnju kisika također rezultira vidljivom razlikom u vrijednostima između ručno-strojnog i strojnog rada (tablica 6.8). Kod efektivnog rada šumski radnik sjekač ima najveću prosječnu zabilježenu frekvenciju srca (tablica 6.8).

S druge strane, prosječna zabilježena frekvencija srca tijekom dodatnog vremena zamjetno je veća kod strojnog rada (operatera harvestera i forvardera) nego kod ručno-strojnog rada (tablica 6.8). Razlog navedenog je što u sklopu dodatnog vremena kod strojnog rada značajan udio imaju radni zahvati koji iziskuju intenzivnije fizičko naprezanje kao npr. namještanje lanca na vodilici harvesterske glave, čišćenje hladnjaka na harvesteru tokom rada, zamjena hidrauličnih crijeva na harvesteru ili forvarderu, popravak kompjutera na harvesterskoj glavi i dr.

Tablica 6.8 Deskriptivna statistika frekvencije srca i radnog opterećenja uzorkovanih operatera šumske mehanizacije kod efektivnog i dodatnog vremena rada
RS = radno sredstvo; FS = prosječna frekvencija srca; FSmax = maksimalna frekvencija srca; EP = energetska potrošnja; VO_2 = potrošnja kisika

RS	EFEKTIVNO VRIJEME (EV)			
	[1]FS_{EV}	[1]$FS\ max_{EV}$	EP (KJ/min)	VO_2 (l/min)
Operater harvestera	87	109	7,12	0,92
Operater forvardera	91	124	8,03	1,01
Operater motorne pile	105	127	13,06	1,39
	DODATNO VRIJEME (DV)			
	FS_{DV}	$FS\ max_{DV}$	EP (KJ/min)	VO_2 (l/min)
Operater harvestera	98	121	10,39	1,20
Operater forvardera	97	120	10,02	1,18
Operater motorne pile	90	123	17,84	0,97

[1]Zaokružene vrijednosti na puni broj

Radi podrobnijeg uvida u problematiku radnog opterećenja detaljnija analiza obuhvatila je (a) ispitivanje razlika prosječne frekvencije srca, energetske potrošnje i potrošnje kisika spram strukture radnog vremena (EV - DV) te (b) ispitivanje razlika prosječne frekvencije srca, energetske potrošnje i potrošnje kisika, kod efektivnog vremena i dodatnog vremena, spram tri sredstva rada. Testiranje statističke značajnosti razlika aritmetičkih sredina prosječne frekvencije srca, energetske potrošnje i potrošnje kisika između efektivnog i dodatnog vremena provedeno je pomoću T-testa (tablica 6.9).

T-test je pokazao postojanje signifikantne razlike kod prosječne frekvencije srca, energetske potrošnje i potrošnje kisika između efektivnog i dodatnog vremena za sve tri vrste radova, odnosno tri šumska radnika – operater harvestera, operater forvardera i šumskog radnika sjekača (tablica 6.9).

Tablica 6.9 Ispitivanje značajnosti razlike izmjerenih vrijednosti pomoću T-testa
RS = radno sredstvo; H = harvester; F = forvarder; MP= motorna pila; M = aritmetička sredina; t = t vrijednost; df = stupnjevi slobode; p = razina značajnosti

Varijable	RS	M_{EV}	M_{DV}	t	df	p
Prosječna frekvencija srca (1/min)	H	87,437	98,058	4,883	31	0,000**
	F	90,888	97,200	2,710	17	0,015*
	MP	104,846	89,538	-4,197	24	0,000**
Energetska potrošnja (KJ/min)	H	7,119	10,393	4,812	31	0,000**
	F	8,032	10,020	2,635	17	0,017*
	MP	13,064	7,841	-3,948	24	0,000**
Potrošnja kisika (l/min)	H	0,916	1,204	4,883	31	0,000**
	F	1,010	1,181	2,710	17	0,015*
	MP	1,388	0,973	-4,197	24	0,000**

* Razlika je značajna na razini 0,05; ** razlika je značajna na razini 0,01

Dodatno, u sklopu formirane baze podataka tj. efektivnog i dodatnog vremena testirane su razlike između srednjih vrijednosti frekvencije srca, energetske potrošnje i potrošnje kisika spram opisne varijable koju čine tri vrste rada (rad pomoću harvestera, forvardera i motorne pile). Homogenost varijanci između grupa podataka testirana je *Leveneovim testom* (p>0,05), a na osnovi razine

značajnosti testa daljnje ispitivanje razlika definiranih varijabli provedeno je pomoću paramatarskih i/ili neparametarskih tehnika.

U okviru efektivnog vremena rada prosječna frekvencija srca kod tri vrste radova pokazala je statistički značaj F (2, 35)= 22,82; p= 0,01 (tablica 5). Naknadno provedena usporedba pomoću Turkeyevog HSD testa pokazala je da se srednja vrijednost frekvencije srca kod šumskog radnika sjekača (M=104,85; SD=10,08) značajno razlikuje od vrijednosti frekvencije srca kod operatera harvestera (M=87,44; SD= 5,06) i operatera forvardera (M=90,89; SD=4,51). Srednja vrijednost frekvencije srca operatera harvestera tokom efektivnog vremena rada nije pokazala statistički značajnu razliku u odnosu na vrijednost frekvencije srca operatera forvardera. Također, u okviru dodatnog vremena rada prosječna frekvencija srca kod tri vrste radova pokazala je statistički značaj F (2, 37)= 5,63; p= 0,01 (tablica 10). Naknadno provedena usporedba pomoću Turkeyevog HSD testa pokazala je da se srednja vrijednost frekvencije srca kod šumskog radnika sjekača (M=89,54; SD=8,44) značajno razlikuje od vrijednosti frekvencije srca kod operatera harvestera (M=98,06; SD=7,18) i operatera forvardera (M=97,20; SD=5,51). Srednja vrijednost frekvencije srca operatera harvestera tokom dodatnog vremena rada nije pokazala statistički značajnu razliku u odnosu na vrijednost frekvencije srca operatera forvardera.

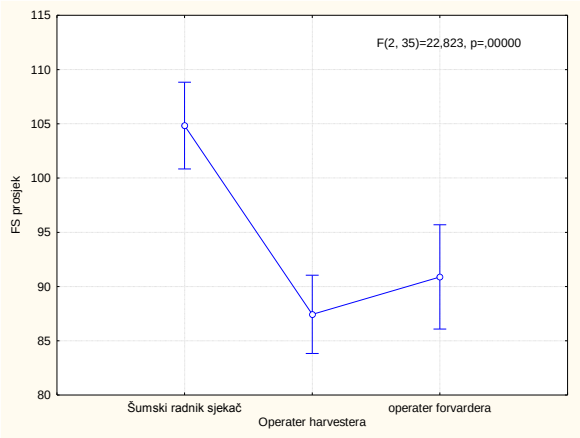

Slika 6.58 Srednja vrijednost FS tijekom EV spram tri sredstva rada

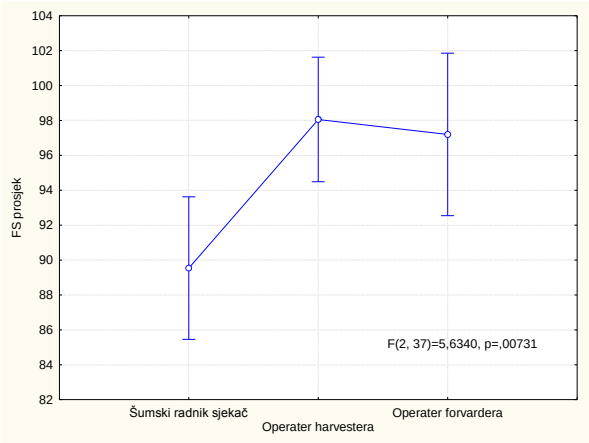

Slika 6.59 Srednja vrijednost FS tijekom DV spram tri sredstva rada

Energetska potrošnja i potrošnja kisika izračunata na temelju izmjerene prosječne frekvencije srca, također je logičnim slijedom, u okviru efektivnog i dodatnog vremena rada pokazao statistički značaj (tablica 6.10).

Tablica 6.10. Ispitivanje razlika varijabli spram tri vrste rada
VS = vremenska struktura; N = broj radnih zahvata; F = F omjer; df = stupnjevi slobode; p = razina značajnosti

Varijable	VS	N	F	df	p
Prosječna frekvencija srca (1/min)	EV	38	22,82	2	0,000**
	DV	40	5,634	2	0,007**
Energetska potrošnja (KJ/min)	EV	38	19,57	2	0,000**
	DV	40	5,026	2	0,012*
Potrošnja kisika (l/min)	EV	38	22,82	2	0,000**
	DV	40	5,634	2	0,007**

* Razlika je značajna na razini 0,05; ** razlika je značajna na razini 0,01

Literatura

Hignett. S., L. McAtamney, 2000: Rapid Entire Body Assessment (REBA). Appl Ergon. 31: 201–5.

Kaminsky, G., 1960: Arbeitsphysiologische Grundlagen für die Gestaltung der Fostarbeit, Reinbek bei Hamburg.

Kee, D., W. A. Karwowski, 2007: comparison of three observational techniques for assessing postural loads in industry. International Journal of Occupational Safety and Ergonomics 13(1): 3–14.

Martinić, I., 1993: Fizičko opterećenje radnika pri radu uređajem za bušenje Stihl BT 308 i motornim čistaćem Stihl FS 360. Meh. Šumar. (18)4: 179–190.

Mattila, M., M. Vilkki, 2003: Occupational Ergonomics: Principles of Work Design. CRC Press. Chapter 26, OWAS methods, 2003, 13 str.

Ronay, E., 1975: Ergonomia. Učebne texty, VŠLD Zvolen.

Takala, E. P., I. Pehkonen, M. Forsman, G. Å. Hansson, S. E. Mathiassen, W. P. Neumann, G. Sjogaard, K. B. Veiersted, R. H. Westgaard, J. Winkel, 2010: Systematic evaluation of observational methods assessing biomechanical exposures at work. Scand J Work Environ Health. 36(1): 3–24.

Vondra, V., 1995: Work standards and exertion of forestry worker. Meh. šumar. 20(4): 189–196.

6.3.3 Ergonomska analiza i ocjena radnih uvjeta

S tehnološkim i društvenim razvojem tijekom vremena događaju se i promjene unutar domene sigurnosti na radu i zaštite zdravlja u sektoru šumarstva. Radnici u šumarstvu izloženi su fizičkim, fiziološkim i okolišnim čimbenicima koji rezultiraju različitim oboljenjima, osobito povezanim s mišićnim, skeletnim, živčanim i vaskularnim sustavom te oštećenjem sluha. S razvojem strojne sječe i izrade, rad se iz vanjskog radnog okoliša preseljava u kabinu sredstva rada čime se smanjuje fizička težina rada i izloženost većini čimbenika rizika unutar radnog okoliša. S druge strane, kod strojne sječe i izrade drva javljaju se nove vrste ozljeda i oboljenja, kao npr. sindrom ponavljajućih pokreta (Axelsson i Pontén 1990) koji je rezultat mišićno-skeletnog poremećaja, te novi kognitivni čimbenici rizika koji su sve prisutniji. Stoga, tradicionalnu ergonomsku paradigmu »manje je bolje« treba zamijeniti sa »više može biti bolje« jer smanjena tjelesna aktivnost također ima štetne utjecaje na zdravlje operatera (Straker i Mathiassen 2009).

Mišićno-skeletni poremećaji (MSP) te kumulativni poremećaji vrata i gornjih udova uzrokovani poslom (WRULD) najčešće se javljaju zbog stalnih ponavljanja istih pokreta, uporabe vibrirajućih sredstava rada kroz duži vremenski period te neergonomskog položaja tijela tokom rad. U šumarskoj praksi nalaze se svi uvjeti koji šumskog radnika sjekača izlažu oboljenju od MSP-a: teški terenski uvjeti (niske temperature, sklizak i neravan teren), težak fizički rad i neergonomski položaj tijela (rukovanje teretom, zgrbljena i savinuta leđa), opasni alati i strojevi poput motorne pile. S druge strane, posljedice relativno sigurnog rada s harvesterom i forvarderom očituju se kroz poremećaje mišićno-skeletnog (MSP) i živčanog sustava. Bolovi kod operatera harvestera najčešće se javljaju u području vrata, donjeg dijela leđa te ramena (Hanse i Winkel 2008, Rehn i dr., 2009, Silva i dr., 2014). Pojava MSP-a kod strojne sječe i izrade uvelike ovisi o organizaciji rada (Østensvik i dr. 2008).

Sukladno prethodno spomenutom, ergonomska istraživanja često se provode sa svrhom evaluacije, klasifikacije i, ako je potrebno, implementacije korektivnih mjera vezanih za položaj tijela radnika tokom rada, a s ciljem pronalaska optimalnog načina uravnoteživanja dvije osnovne

komponente radnog sustava – ljudske sposobnost i radnih uvjeta. Stoga, ergonomska ocjena položaja tijela radnika tokom rada može pružiti vrijedne informacije s ciljem oblikovanja ili redizajna radnog mjesta i sredstva rada što u konačnici može pomoći u unapređenju radnih performansi radnika uz istovremeno ne prekoračivanje razine sigurnosti vezane za mišićno-skeletno opterećenje. U sklopu istraživanja, provedenog na području UŠP Bjelovar, vrednovanje ergonomskog aspekta rada operatera harvestera, forvardera i šumskog radnika sjekača provedeno je kroz ocjenu položaja tijela radnika tokom rada pomoću »ErgoFellow 3.0« softvera. U okviru navedenog softvera primijenjena su dva ergonomska alata: OWAS (engl. Ovako Working Posture Analysing System) i REBA (engl. Rapid Entire Body Assessment).

Detalji terenskog istraživanja tj. rada operatera harvestera, forvardera i motorne pile lančanice zabilježeni su pomoću video kamere. Kod terenskog rada operatera harvestera snimljeno je 9 h i 29 minuta efektivnog vremena strojne sječe i izrade drva, kod terenskog rada operatera forvardera 8 h i 29 minuta efektivnog vremena izvoženja drvne mase, a kod terenskog rada šumskog radnika sjekača 45 minuta efektivnog vremena ručno-strojne sječe i izrade drva. Položaji tijela izdvojeni su iz radnih snimaka snimljenih video kamerom sukladno metodi trenutačnih opažanja. Kod strojne sječe i izrade s harvesterom definirani interval opažanja iznosi 6 min, što ukupno čini 88 uzorkovanih radnih položaja tijela operatera tijekom efektivnog rada. Kod strojnog izvoženja drvne mase forvarderom definirani interval opažanja također iznosi 6 min, što ukupno čini 79 uzorkovanih radnih položaja tijela operatera tijekom efektivnog rada. S druge strane, kod ručno-strojne sječe i izrade drva definirani interval opažanja, zbog kratkoće video zapisa, iznosi 0,5 min, što ukupno čini 88 uzorkovanih radnih položaja tijela šumskog radnika sjekača. Svi uzorkovani položaji tijela ocijenjeni su pomoću »ErgoFellow 3.0« softvera kroz dvije navedene tehnike promatranja: OWAS i REBA metode, što u konačnici rezultira s dva položajna opterećenja tijela operatera po svakoj primijenjenoj tehnologiji rada. U tablici 6.11. prikazan je planirani i ostvareni broj uzorkovanih položaja tijela pri radu kod sva tri operatera.

Tablica 6.11 Struktura uzorkovanog položaja tijela pri radu kod sva tri operatera

Radno sredstvo	Radni položaj tijela		
	Definiran računski, N	Uzorkovan iz snimke, N	Izvršenja, %
Motorna pila	88	88	100
Harvester	88	84	95,45
Forvarder	79	76	96,20

Izvršena analiza radnog položaja tijela operatera tri sredstva rada spram kategorije djelovanja (slika 6.60 i 6.61) pokazala je da rad operatera motornom pilom zahtjevniji i višestruko rizičniji u odnosu na rad operatera hravestera ili forvardera.

Prema OWAS metodi (slika 6.60) kod operatera motornom pilom (N=88) u kategoriju normalnog položaja svrstano je 40,91 % uzorkovanih položaja tijela, dok je 37,50 % svrstano u kategoriju blago rizičnog položaja, a 20,45 % u kategoriju srednje rizičnog položaja i 1,14 % u kategoriju visoko rizičnog položaja. S druge strane, kod operatera harvestera (slika 6.60, N=84) 82,14 % uzorkovanih položaja tijela svrstano je u kategoriju normalnog položaja i 17,86 % u kategoriju blago rizičnog položaja tijela tokom rada. Kod operatera forvardera prema OWAS metodi (slika 6.60, N=76) 97,37 % uzorkovanih položaja tijela svrstano je u kategoriju normalnog položaja i 2,63 % u kategoriju blago rizičnog položaja tijela tokom efektivnog rada. Ocjena kategorije djelovanja položaja tijela prema REBA metodi (slika 6.61) za operatera motorne pile rezultiralo je sa 60,23 % uzorkovanih položaja tijela koji su svrstani u kategoriju blago rizičnog položaja, 21,59 % u kategoriju srednje rizičnog položaja i 18,18 % u kategoriju visoko rizičnog položaja. Kod operatera Harvestera (slika 6.61) 98,81 % uzorkovanih položaja tijela svrstano je u kategoriju blago rizičnog položaja i 1,19 % u kategoriju srednje rizičnog položaja tijela, dok su kod operatera forvardera svi uzorkovani položaji (100 %) svrstani u kategoriju blago rizičnog položaja tijela. Provedena usporedba dvije metode kategorizacije rizika iz aspekta radnog položaja tijela pokazuje

da REBA metoda daje oštrije rezultate u odnosu na OWAS metodu kod sva tri uzorkovana radna sredstva (slika 6.60 i 6.61).

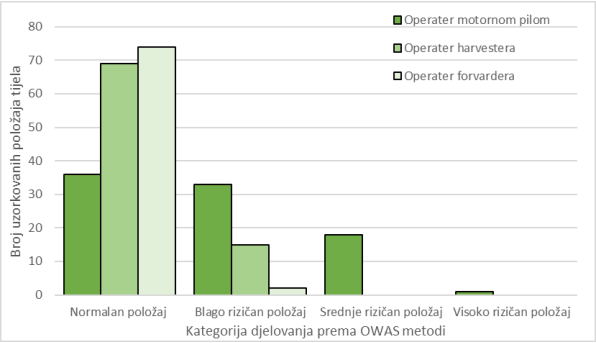

Slika 6.60 Broj uzorkovanih položaja tijela operatera prema OWAS metodi

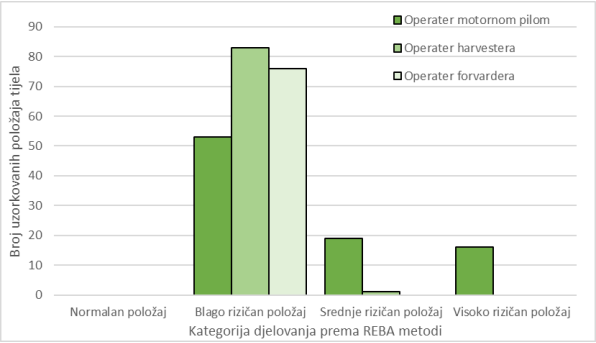

Slika 6.61 Broj uzorkovanih položaja tijela operatera prema REBA metodi

Detaljnija usporedba uzorkovanih položaja tijela operatera, prema OWAS i REBA metodi, za sva tri sredstva rada provedena je prema grupama radnih zahvata. Kod analize položaja tijela operatera motorne pile (slika 6.62 i 6.63) imali smo tri grupe radnih zahvata: elemente rušenja (N = 29; obuhvatili su čišćenje radnog okoliša, obradu žilišta, izradu zasjeka i završni rez), elemente izrade (N = 38; obuhvatili su kresanje, trupljenje, mjerenje i sl.) i ostale aktivnosti (N = 21; obuhvatili su utvrđivanje ili provjeru smjera rušenja, prijelaz ili odstupanje od stabla/debla te aktivnosti na kopčanju trupaca). Rezultati analize prema OWAS metodi (slika 6.62) pokazuju da je najveći udio srednje rizičnog položaja tijela (19,32 %) i visoko rizičnog položaja tijela (1,14 %) prisutan kod elemenata rušenja. Najveći udio blago rizičnog položaja tijela (26,14 %), prema OWAS metodi (slika 6.62), prisutan je kod elemenata izrade, a najveći udio normalnog položaja rada prisutan je kod ostalih aktivnosti. S druge strane, oštrija kategorizacija rizika radnog položaja prema REBA metodi (slika 6.63 pokazuje višestruko veći udio visoko rizičnog položaja tijela (17,05 %) kod elemenata rušenja, a nešto manji udio srednje rizičnog položaja tijela (11,36 %). Kod elemenata izrade kategorija blago rizičnog položaja tijela zastupljena je sa 31,82 %, dok je kategorija srednje rizičnog položaja tijela zastupljena sa 10,23 % (slika 6.63). Kod ostalih aktivnosti (slika 6.63) svi uzorkovani položaji tijela svrstani su u kategoriju blago rizičnog položaja.

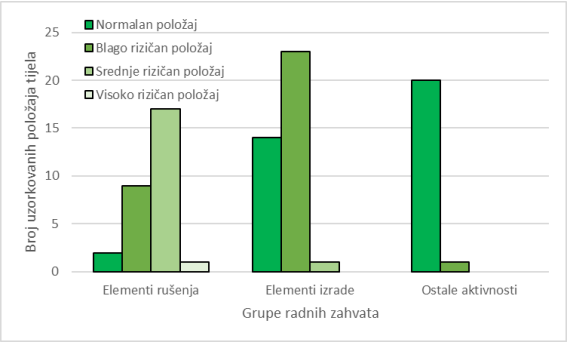

Slika 6.62 Broj uzorkovanih položaja tijela operatera motorne pile prema OWAS metodi

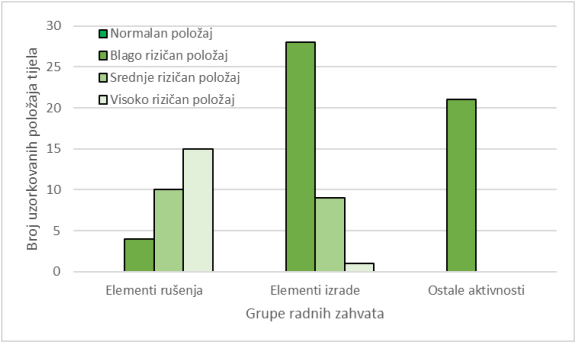

Slika 6.63 Broj uzorkovanih položaja tijela operatera motorne pile prema REBA metodi

Detaljnija analiza položaja tijela operatera harvestera (slika 6.64 i 6.65) provedena je unutar tri grupe radnih zahvata: rad s harvesterskom glavom (N = 56), vožnja naprijed/nazad (N = 23) i ostale aktivnosti (N = 5; obuhvatili su čišćenje hladnjaka, radni dogovor s kolegom preko mobitela i sl.). Rezultati analize prema OWAS metodi (slika 6.64) pokazuju da je najveći udio blago rizičnog položaja tijela (10,71 %) prisutan kod vožnje sredstva rada naprijed/nazad iz razloga što se

sjedište operater ne može okretat za 360 ° tj. tijekom vožnje unazad operater vozi u zamjetno fiziološki nepovoljnom radnom položaju. Kod aktivnosti rada s harvesterskom glavom (slika 6.64) normalan položaj tijela tokom rada zastupljen je s 63,10 %, a blago rizičan položaj rada s 3,57 %. Kod ostalih aktivnosti (slika 6.64) blago rizičan položaj tijela zastupljen je s 3,57 % iz razloga što su tu bile obuhvaćene aktivnosti čišćenja hladnjaka sredstva rada od lišća i sl. Kategorizacija rizika položaja tijela prema REBA metodi (slika 6.65) pokazala je oštrije rezultate kod sve tri grupe radnih operacija. Kategorija blago rizičnog položaja kod rada s harvesterskom glavom zastupljena je s 66,67 % (slika 6.65), a kod vožnje sredstva rada s 27,38 %. Kategorija srednje rizičnog položaja tijela operatera harvestera s udjelom od 1,19 % zastupljena je unutar ostalih aktivnosti.

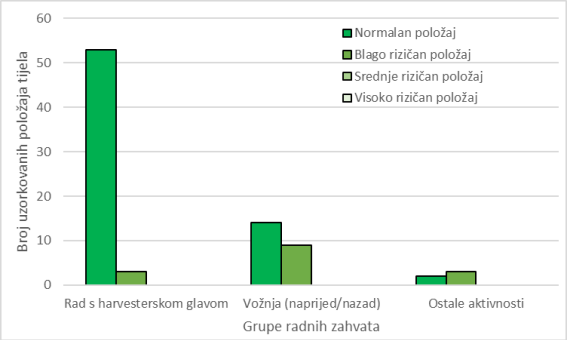

Slika 6.64 Broj uzorkovanih položaja tijela operatera harvestera prema OWAS metodi

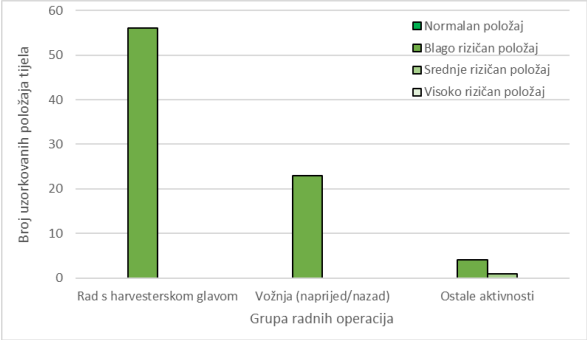

Slika 6.65 Broj uzorkovanih položaja tijela operatera harvestera prema REBA metodi

Analiza položaja tijela kod operatera forvardera (slika 6.66 i 6.67) provedena je unutar tri grupe radnih zahvata: rad sa dizalicom (N = 39), vožnja i/ili pomicanje naprijed/nazad (N = 36) te ostale aktivnosti (N = 1; zastoj na pomoćnom stovarištu zbog utovara kamiona). Rezultati analize prema OWAS metodi (slika 6.66) pokazuju da je jedini udio blago rizičnog položaja tijela (2,63 %) prisutan kod vožnje ili pomicanja sredstva rada naprijed/nazad iz razloga što operater sredstva rada kod kombinacije radnih zahvata utovara i pomicanja ne okreće sjedište. Kod grupe radnih zahvata rada s dizalicom (slika 6.66) normalan položaj tijela zastupljen je s 51,32 %, a kod vožnje ili pomicanja naprijed/nazad s 44,74 %. Kategorizacija rizika položaja tijela operatera forvardera prema REBA metodi (slika 6.67) pokazala je blago rizičan položaj tijela unutar sve tri grupe radnih operacija.

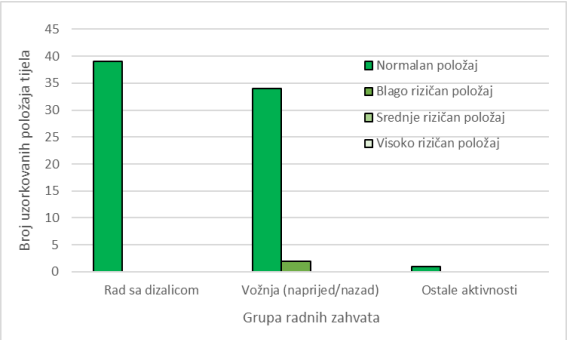

Slika 6.66 Broj uzorkovanih položaja tijela operatera forvardera prema OWAS metodi

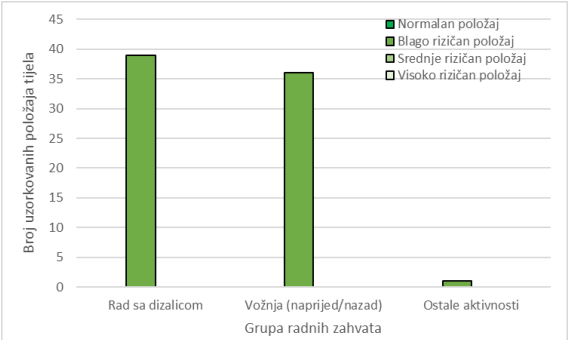

Slika 6.67 Broj uzorkovanih položaja tijela operatera forvardera prema REBA metodi

Literatura

Axelsson, S. A., B. Pontén, 1990: New ergonomic problems in mechanized logging operations. International Journal of Industrial Ergonomics 5(3): 267–273.

Hanse, J. J., J. Winkel, 2008: Work organisation constructs and ergonomic outcomes among European forest machine operators. Ergonomics 51(7): 968–981.

Østensvik, T., P. Nilsen, K. B. Veiersted, 2008: Muscle Activity Patterns in the Neck and Upper Extremities Among Machine Operators in Different Forest Vehicles. International Journal of Forest Engineering 19(2): 11–20.

Rehn, B., T. Nilsson, R. Lundström, M. Hagberg, L. Burström, 2009: Neck pain combined with arm pain among professional drivers of forest machines and the association with whole-body vibration exposure. Ergonomics 52(10): 1240–1247.

Silva, E. P., L. J. Minette, A. L. P.Sanches, A. P. Souza, F. L. Silva, S. C. T.Mafra, 2014: Prevalence of musculoskeletal symptoms in forest harvesting machine operators. Revista Arvore 38(4): 739–745.

Straker, L., S. E. Mathiassen, 2009: Increased physical work loads in modern work – A necessity for better health and performance? Ergonomics 52(10): 1215–1225.

6.4 Ekološki pokazatelji

6.4.1 Oštećivanje šumskog tla

Nosivost tla se procjenjuje mjerenjem njegove tvrdoće preko otpora prodiranju (penetraciji) koji tlo pruža utiskivanju metalnog stošca poznatih mjera. Pri tome se otpor prodiranja konusa mijenja s dubinom prodiranja u tlo zbog uslojenosti tla, sadržaja skeleta i isprepletenosti tla korijenjem. Krivulja prodirne značajke tla sadrži podatke o potrebnoj sili ili tlaku za utiskivanje konusa u tlo u ovisnosti o dubini prodiranja konusa.

Određivanje prodirnog otpora obavlja se mjernim uređajem tzv. penetrometrom, uz poznatu ploštinu osnovice konusa i mjerenu silu utiskivanja. U svrhu mjerenja prodirne značajke i određivanja nosivosti tla korišten je digitalni penetrometar Eijkelkamp Penetrologger (slika 6.68).

U praktičnoj primjeni koristi se standardizirana vrijednost mjerenja otpora prodiranja konusa (ASAE EP542 1999) na dubini tla od 15 cm, nazvana konusni indeks (CI). Ista norma preporuča korištenje konusnoga indeksa pri procjeni prohodnosti terena i kretnosti vozila te kao parametar koji se koristi u modelima vučnih značajki vozila, tzv. WES modelu (*Waterways Experimentation Station, US Army Corps of Engineering research*).

Usporedno sa mjerenjem prodirne značajke tla mjeren je i volumni sadržaj vlage u tlu sa digitalnim uređajem koji se zove ThetaProbe (Theta sonda). Theta sonda se priključuje na komunikacijski kanal penetrologera i prije svakog utiskivanja konusa u tlo, u tlo se utiskuje Theta sonda sa trnovima radi mjerenja vlage tla. Vlaga tla je mjerena na površini tla prilikom svakog mjerenja penetracijske značajke tla.

Osim nosivosti tla mjeren je i otpor tla na smicanje krilnom sondom (slika 6.69). Krilna sonda je najprimjenjiviji uređaj za mjerenje smične čvrstoće tla u terenskim uvjetima koji se sastoji od mjernog krila i mjerila zakretnog momenta. Mjerno krilo se utiskuje u tlo do željene dubine, a moment–metrom se bilježi zakretni moment potreban da se okrene krilo u trenutku savladavanja čvrstoće tla na smicanje. Krilnu sondu treba okretati konstantnom brzinom.

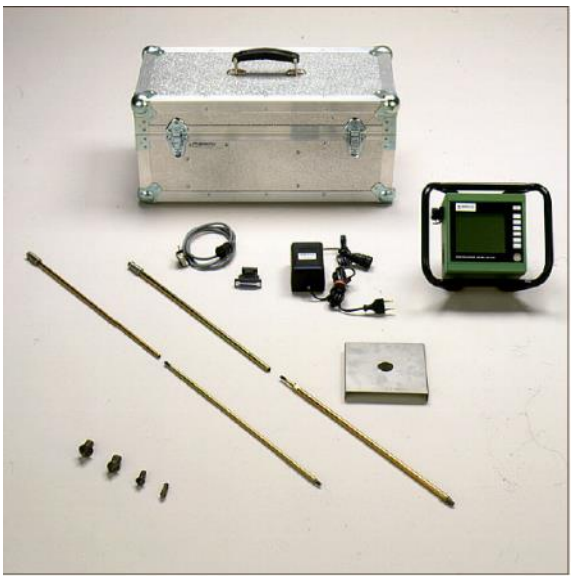

Slika 6.68 Digitalni konusni penetrometar Eijkelkamp Penetrologger

Slika 6.69 Krilna sonda

Na temelju mase uzoraka tla uzetih u narušenom (fizički izmjenjenom) stanju, laboratorijskim analizama mjere se i izračunavaju vodno – fizička svojstva tla. Svrha uzimanja ove vrste uzoraka na terenu je određivanje granulometrijskoga sastava tla te vrsta i tip tla. Laboratorijske (direktne) metode određivanja granulometrijskoga ili mehaničkoga sastava tla rade se u skladu sa normom ISO 11277 (2009), a obuhvaćaju sušenje uzorka, odvajanje skeleta, usitnjavanje i prosijavanje

tla preko sita s rupicama promjera 2 mm kako bi se odvojilo sitno tlo (sitnica). Određivanje granulometriskog sastava tla obavljeno je u Ekološko – pedološkom laboratoriju Šumarskog fakulteta u Zagrebu.

Utjecaj na šumsko tlo u postupcima strojne sječe i izrade stabala te primarnog transporta drva u većini slučajeva je toliko intenzivan da je nužno uspostaviti sustav upravljanja i kontrole rada vozila kao mjere opreza u svrhu zaštite tla. U svrhu zaštite tla nužna je dokumentacija u smislu snimanja broja prolazaka vozila po sastojini, ali i načina po kojem se vozilo kreće po sastojini. Pri tome se misli na to da li vozilo odnosno vozač prati smjernice organiziranog izvoženja drva sa ciljem zaštite tla i pomlatka ili se neorganizirano kreće po sastojini tražeći prostale drvne sortimente. Za snimanje položaja i putanja kretanja, te na temelju snimljenih koordinata izračuna duljine puta kretanja strojeva, korišteni su GPS uređaji ugrađeni u mobilne jedinice FMS–a.

Granulometrijski sastav tla

Uzorci tla u narušenm stanju uzeti na području istraživanih odsjeka obrađeni su u Ekološko – pedološkom laboratoriju, a dobiveni rezultati prikazani su u tablici 6.12.

Teksturna oznaka tla na temelju dobivenih odnosa veličine čestica tla istraživanih radilišta je praškasta ilovača prema FAO (2006) klasifikaciji.

Tablica 6.12 Granulometrijski sastav tla

Oznaka uzorka	Krupni pijesak (2–0,2 mm)	Sitni pijesak (0,2–0,063 mm)	Krupni prah (0,063–0,02 mm)	Sitni prah (0,02–0,002 mm)	Glina (< 0,002 mm)	Teksturna oznaka
14 b 1-1	0,16	4,05	48,97	31,10	15,72	Praškasta ilovača
14 b 1-2	0,16	5,16	48,45	30,72	15,51	Praškasta ilovača
14 b 1-3	0,18	4,13	49,23	30,93	15,53	Praškasta ilovača
14 b 2-1	1,32	5,93	54,23	26,84	11,67	Praškasta ilovača
14 b 2-2	1,00	6,15	53,78	27,14	11,94	Praškasta ilovača
14 b 2-3	1,15	6,59	53,51	27,15	11,61	Praškasta ilovača
14 b 3-1	1,85	4,58	51,62	27,74	14,21	Praškasta ilovača
14 b 3-2	1,81	5,06	50,82	27,77	14,54	Praškasta ilovača
14 b 3-3	1,92	5,21	51,36	27,24	14,27	Praškasta ilovača

Nosivost tla

Za nosivosti tla, odnosno konusnog indeksa tla – *CI* na dubini tla od 15 cm (norma ASAE EP542 1999), koristio se digitalni penetrometar *Eijkelkamp Penetrologger* sa konusom površine presjeka kružne baze 2 cm^2 i vršnim kutem od 30º. Usporedno sa mjerenjima nosivosti tla mjerena je i vlažnost tla sa sondom koja je sastavni dio penetrometra. Ukupno je napravljeno 60 mjerenja nosivosti i vlažnosti tla. Mjerenja su obavljena na negaženom i gaženom tlu unutar jedva vidljivih kolotraga.

Dobiveni rezultati (slika 6.70) pokazuju da prosječni konusni indeks – *CI* na istraživanom radilištu iznosi 1,71 MPa što znači da je tlo jako dobre nosivosti (iznad 0,5 MPa se smatra da tlo ima dobru nosivost). Razlog tako dobre nosivosti je upravo jako niska volumna vlažnost tla koja u je u prosjeku iznosila svega 7,8 %vol (slika 6.70) mjerena u njegovom površinskom dijelu.

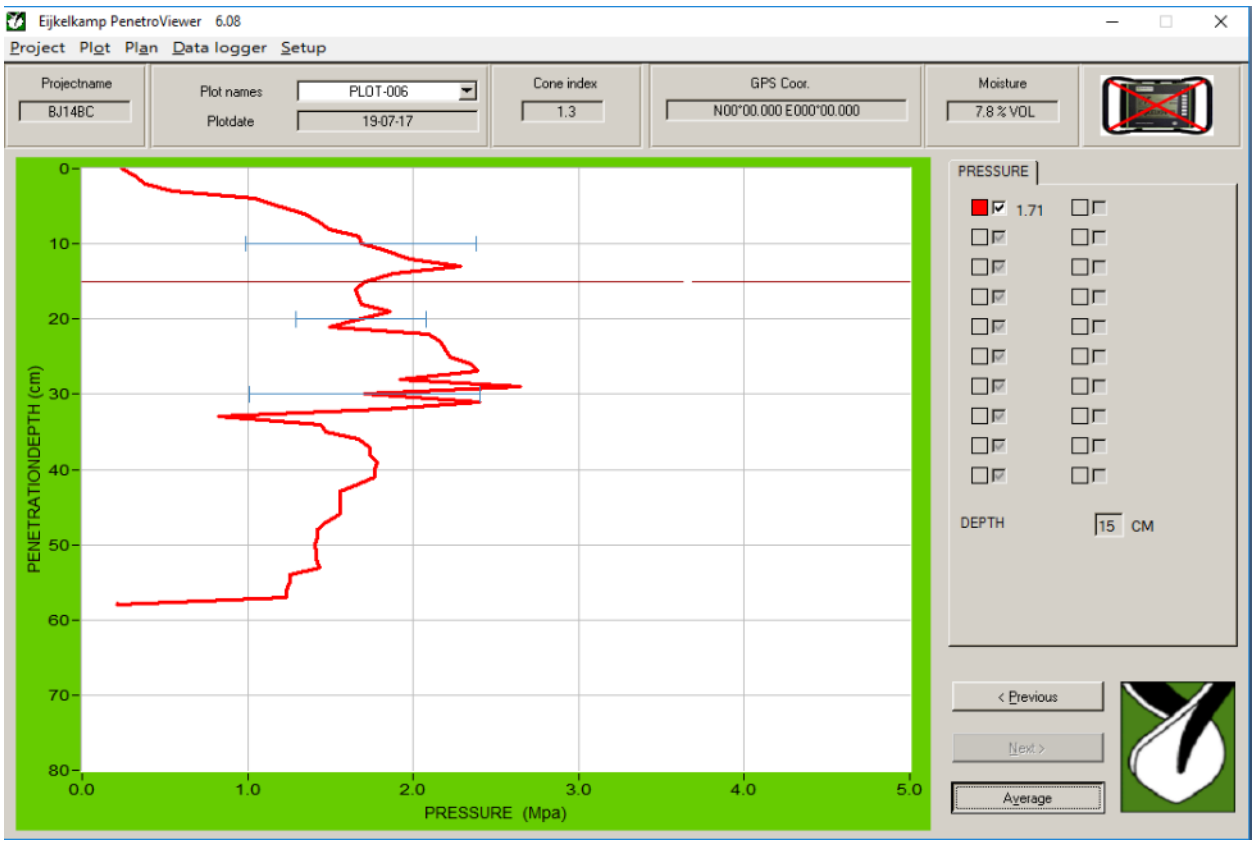

Slika 6.70 Rezultati mjerenja penetrometrom

6.4.2 Štete na dubećim stablima

Negativni su ekološki učinci zbog oštećivanja sastojina uporabom strojeva pri šumskim radovima predmet mnogobrojnih istraživanja, rasprava i različitih ocjenjivanja (Poršinsky i dr. 2004). Autori koji su proučavali navedenu problematiku suglasni su da ne postoji mogućnost obavljanja šumskih radova bez oštećivanja okoliša unatoč svim mjerama zaštite (Martinić 2000). Spinelli (1994) zaključuje da je obujam oštećenja u uskoj vezi s radnim sredstvima, kakvoćom organizacije rada, pogodnošću radnih metoda u konkretnim terenskim uvjetima te kakvoćom radne tehnike izvoditelja šumskih radova. Primjerice, kod privlačenja drva obujam oštećivanja raste s porastom dimenzija i snage strojeva, stupnjem mehaniziranosti rada i duljinama privlačene oblovine (Martinić 1991). Većina istraživača smatra da je broj mehanički oštećenih stabala dobar pokazatelj ukupnog oštećenja sastojine, a navedene se štete mogu razmjerno jednostavno i točno odrediti (Martinić 2000). Mehanička oštećenja stabla se najčešće klasificiraju kao izvaljeno i/ili polomljeno stablo, polomljene grane te oštećenja kore (nagnječena kora, oguljena kora). Dok izvala ili lom stabla kao posljedicu imaju doznaku stabala u kategoriji ad stabala i sječu istih tijekom redovitih radova pridobivanja drva u predmetnoj sječini, oštećenja kore dubećih stabala ostavljaju dugotrajne i ponekad neizvjesne posljedice po oštećena stabla i cijelu sastojinu. Naime, oštećenja kore predstavljaju otvore na stablu kroz koje je ono pristupačno zarazi uzročnicima truleži drva (Poršinsky i Ožura 2006), što može imati dalekosežne posljedice na kakvoću budućih drvnih sortimenata, ali i na stabilnost cijele sastojine. Pri tome, ozljede kore do 10 cm^2 površine, za razliku od većih ozljeda kod kojih se s povećanjem površine ozljede povećava i rizik od zaraze, u pravilu ne predstavljaju značajnu opasnost, jer stablo vrlo brzo kalusira nastalu ozljedu čime je smanjena mogućnost zaraze sporama gljiva (Meng 1978).

Istraživanja šteta na dubećim stablima u hrvatskom šumarstvu intenziviraju se devedesetih godina prošloga stoljeća, u trenutku kada uvođenjem modernih sredstava rada za primarni transport drva i modifikacijom tradicionalnih metoda pridobivanja drva u cilju povećanja

proizvodnost rada postaje primjetan i trend porasta oštećivanja stabala. Nažalost, opsežna istraživanja koja provode Martinić (1990) i Vuletić (1996) nisu rezultirala uspostavom referentnih vrijednosti prihvatljivih razina oštećivanja dubećih stabala, a rezultati stranih autora ograničene su primjene u našim uvjetima (prvenstveno s obzirom na istraživane vrste). Sustavni pristup vrednovanja razine oštećivanja dubećih stabala, čiji izostanak i danas predstavlja ozbiljan izazov šumarskoj struci, u narednim će godinama očekivanim značajnijim korištenjem mehaniziranih sustava pridobivanja drva postati nužan preduvjet za pravilan odabir sječina u kojima je strojna sječa i izrada poželjna alternativa postojećem načinu rada. Do tog trenutka, okvirnu predodžbu o razini oštećenja dubećih stabala pružaju nam samo rezultati pojedinih znanstvenih istraživanja.

Ivanek (1976) utvrđuje da privlačenje konjskom spregom uzrokuje oštećenje na 15 % stabala, privlačenje oblog drva adaptiranim traktorom 15,9 %, a privlačenje zglobnim traktorom 14,5 %. Doležal (1984) utvrđuje da ozljede na pridanku i deblu imaju za posljedicu smanjenje novčane vrijednosti sortimenata i do 20 %. Južinić (1984) u bukovim sastojinama starosti 30 – 60 godina utvrđuje oštećenja na 9,4 % stabla pri sortimentnoj metodi rada, te 22,8 % pri deblovnoj metodi rada. Krznar i dr. (1989) utvrđuju da tijekom provođenja šumsko-uzgojnog zahvata prorede dolazi do ozljede na 18 % stabala. Ozlijede ploštine 1–500 cm^2 zastupljene su na 58 – 89 % ozlijeđenih stabala, a ozljeda u obliku oguljene kore na 95 % stabala nalazila se na prvom metru debla.

Martinić (1990) provodi istraživanje u gospodarskoj jedinici »Novigradska planina«, u mješovitoj sastojini hrasta, bukve i graba starosti 47 godina. Drvna zaliha iznosi 155 m^3/ha, a broj stabala 750 kom/ha. U sastojini se nalaze traktorske vlake, a srednja udaljenost privlačenja iznosi 350 m. Prilikom istraživanja postavljene su 24 plohe koje čine približno 10 % površine istraživanog odjela. Obzirom na ukupni opseg oštećenja, nakon provedenih radova utvrđene su štete na 8,16 % stabala. Promatrajući uzrok oštećenja, utvrđeno je da su radovi na privlačenju drva najčešći uzrok oštećivanja stabala i da je 53,17% svih oštećenja uzrokovano sredstvom privlačenja ili vučenim tovarom. Oštećenja prilikom sječe i izrade odnosila su se na veliki broj zaustava prilikom obaranja, što je uzrokovalo lomljenje grana ili cijelih stabala. Prema vrsti oštećenja, u provedenoj analizi, utvrđeno je da najveće učešće zauzima oštećenje u obliku oguljene kore s 48 %, zatim zgnječena kora 37 %, lom-izvala 13 % i lom grana 2 %. Budući da su traktori prilikom formiranja tovara silazili s traktorskih vlaka, značajna oštećenja nastala su na 61,46 % stabala zbog privlačenja izvan vlaka u sastojini. Prema mjestu oštećenja na stablu, najveću zastupljenost ima oštećenje žilišta s 71,46 %, a preostalih 19 % otpada na deblo, krošnju i korijen. Daljnjom analizom došlo se do zaključka da je broj polomljenih grana značajno veći pri izvođenju radova na sječi i izradi stabala, a da je udio stabala s oguljenom korom veći kod privlačenja drva. S gledišta gospodarske važnosti prilikom privlačenja drva, oštećivana su korisna stabla, a kod sječe, gospodarski nevažna stabla. S obzirom na posljedice oštećivanja, utvrđeno je da oštećenja prilikom sječe imaju značajno veće posljedice nego oštećenja pri privlačenju. Utvrđeno je da pri sječi čak 20,3 % oštećenih stabala ima za posljedicu vrlo teško oštećenje.

Krpan i dr. (1993) provode istraživanje u nizinskim sastojinama. Tijekom faze privlačenja drva traktorima došlo je do ozljeda na 38,5 % preostalih stabala u sastojini. Utvrđen je gubitak volumnog prirasta dominantnog sloja za 4,7 % godišnje u odnosu na neozlijeđena stabla. Prema mjestu ozljede većina ih se nalazi na deblu (58 %), a do visine od 1,5 m iznad tla nalazi se 76 %. S obzirom na veličinu ozlijede, 74 % ozljeda ima ploštinu veću od 500 cm^2. Na pojedinom oštećenom stablu u prosjeku se nalazi 1,5 ozljeda.

Vondra i Bogojević (1994) prilikom prorede stare sastojine kitnjaka i bukve, tijekom izvođenja radova obaranja stabala utvrđuju pojavnost ozljeda na 45 % stabala, odnosno 33 teško ozlijeđena stabla po hektaru. Prilikom radova na privlačenju drva utvrđeno je da 88 % svih ozljeda dolazi pri vuči tereta.

Vuletić (1996) provodi istraživanja u sastojinama hrasta lužnjaka s ciljem utvrđivanja na koji način ozljeda, ovisno o vrsti, mjestu i veličini, utječe na kakvoću drva te kakvi i koliki gubitci se mogu očekivati i što se na temelju saznanja o posljedicama ozljeđivanja može očekivati u budućnosti. Postotni udio ozlijeđenih stabala između pojedinih pokusnih ploha je vrlo varijabilan i kreće se u rasponu od 27,6 – 66,7 %, dok je na razini svih ozlijeđenih i neozlijeđenih stabala 46,6 %. S

obzirom na mjesto ozlijede najviše su oštećena debla sa 37,6 %, zatim korijen 34,3 % i pridanak s 28,1 %. Prema veličini ozljede najzastupljenije su one do 500 cm^2 (65,8 %), zatim od 501 – 1000 cm^2 (21,7 %), te iznad 1001 cm^2 (12,5 %). Tijekom daljnje razrade podataka utvrđeno je da 40 % ozljeda pripada u grupu ozbiljnih oštećenja (površine iznad 500 cm^2). Takve ozljede značajno utječu na daljnji razvoj stabla u fiziološkom pogledu, ali uzrokuju i ekonomske gubitke radi smanjenja kvalitete sortimenta.

Poršinsky i dr. (2004) istražuju oštećenja dubećih stabala tvrdih listača pri sječi i izradi drva harvesterom u sječini starosti 80 godina, drvne zalihe 323 m^3/ha na 449 stabla/ha te utvrđuju ukupno oštećenih 29,5 stabala/ha (odnosno 6,4 % preostalih stabala nakon sječe).

Poršinsky i Ožura (2006) pri istraživanju oštećivanja dubećih stabala pri izvoženju drva forvarderom u sječini hrasta lužnjaka starosti 99 godina, drvne zalihe 398 m^3/ha na 183 stabla/ha utvrđuju intenzitet štete u iznosu 2,5 stabla/ha, odnosno svega 1,5 % preostalih stabala nakon sječe.

Prethodno proučena literatura predstavljala je osnovu pri planiranju pokusa tijekom provođenja istraživanja šteta na dubećim stablima nakon primjene mehaniziranog sustava pridobivanja drva u istraživanim 14b i 14c odsjeku.

Prva je izmjera s ciljem utvrđivanja šteta na dubećim stablima provedena neposredno nakon provođenja radova sječe i izrade harvesterom te izvoženja forvarderom na primjernim prugama na kojima su doznačena i obrojčana stabla predstavljala uzorak za utvrđivanje ovisnosti neto obujma stabla o prsnom promjeru stabla. Primarni je cilj ovih istraživanja bio utvrditi uzrok oštećenja, odnosno udio stabala oštećenih pri sječi i izradi stabala harvesterom te stabala oštećenih prilikom izvoženja drvnih sortimenata forvarderom.

Nakon završetka istraživanja proizvodnosti mehaniziranog sustava, tijekom ovog izvještajnog razdoblja provedena su detaljnija istraživanja šteta na preostalim dubećim stablima na četiri primjerne pruge širine 10 m postavljene na međusobnoj udaljenosti 50 m pod azimutom od 45° na način da presijecaju prosječene »harvesterske pruge« i obuhvate približno 10 % površine odsjeka 14b i 14c.

Terenska izmjera šteta na dubećim stablima sastojala se od izmjere prsnih promjera svih neoštećenih i oštećenih stabala prisutnih na primjernim prugama te evidencije lokacije stabla (sastojina, uz »harvestersku prugu«, uz glavnu vlaku), vrste oštećenja (izvaljeno i/ili polomljeno stablo, polomljene grane, nagnječena kora, oguljena kora) te mjesta (deblo, pridanak, žilište, korijen) i veličine oštećenja kore (površine pravokutnika). Prikupljanje podataka o sastojini, utvrđivanje, klasifikacija i evidentiranje oštećenja na terenu te sadržaj i struktura snimačkih listova bazirani su na konceptu koji predlažu Tomanić et al. (1989), uvažavajući posebnosti istraživanoga sustava pridobivanja drva.

Podaci su terenskih izmjera sistematizirani i obrađeni s ciljem iskaza odnosa oštećenih i neoštećenih stabala te njihovih lokacija unutar sječine. Oguljenja kore kao najzastupljenija vrsta oštećenja detaljno su analizirana i prikazana s obzirom na mjesto i veličinu oštećenja.

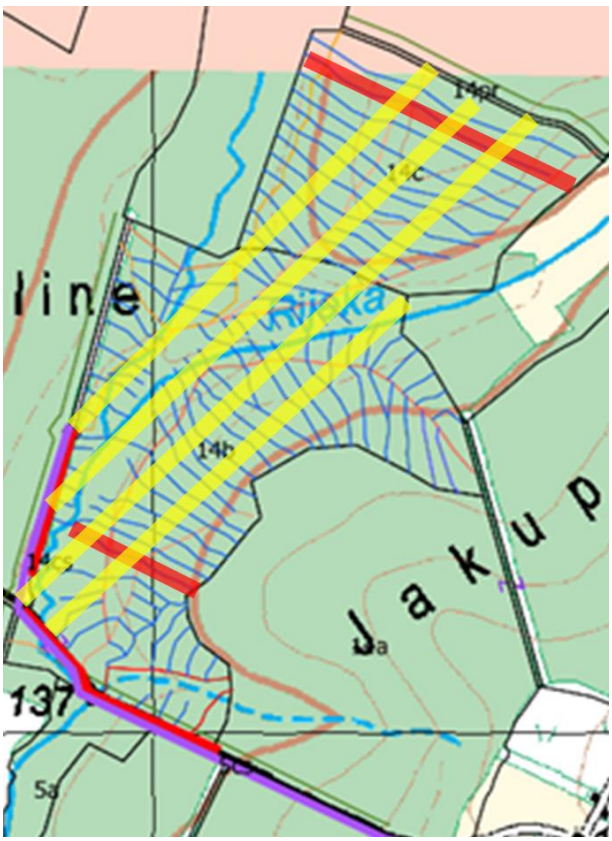

Slika 6.71 Primjerene pruge na kojima su mjerene štete na preostalim dubećim stablima

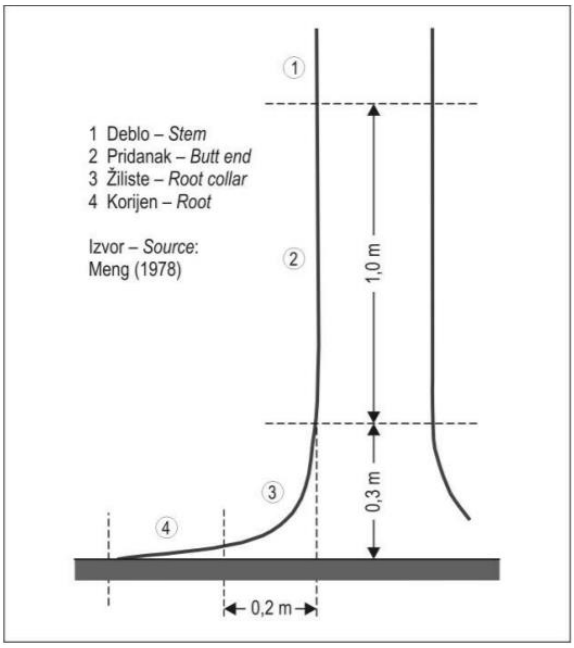

Slika 6.72 Razredba mjesta oštećenja kore (Prema Poršinsky i Ožura 2006)

Slika 6.73 Obilježavanje šteta s ciljem utvrđivanja uzroka oštećenja

Slika 6.74 Izmjera dimenzija oštećenja

U 14b odsjeku prilikom sječe i izrade stabala harvesterom oštećen je jednak broj stabala kao i prilikom izvoženja drvnih sortimenata forvarderom (slika 6.75), dok je u odsjeku 14c 10 % više stabla oštećeno prilikom sječe i izrade negoli prilikom izvoženja (slika 6.76).

Rezultati uzroka oštećivanja ukazuju na činjenicu da je interakcija dimenzija strojeva te dimenzija doznačenih stabala te broja i prostornog rasporeda doznačenih i preostalih stabala odlučujuća za nastanak šteta na preostalim dubećim stablima u odsjeku 14b. U odsjeku 14c relativno veće dimenzije doznačenih stabla uzrokovale su i veću pojavnost šteta uzrokovanih prilikom sječe i izrade negoli prilikom izvoženja. Navedeno je, unatoč povoljnijoj prohodnosti u odsjeku 14c, (uz

različit ukupan broj preostalih stabala) vjerojatni uzrok povećanom udjelu oštećenih stabla u odsjeku 14c u usporedbi s odsjekom 14b (slika 6.77 i slika 6.78).

Slika 6.75 Uzrok oštećenja u odsjeku 14b (H – harvester; F – forvarder)

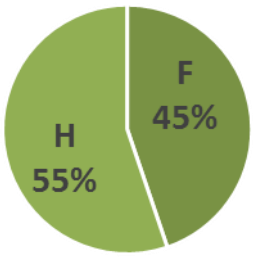

Slika 6.76 Uzrok oštećenja u odsjeku 14c (H – harvester; F – forvarder)

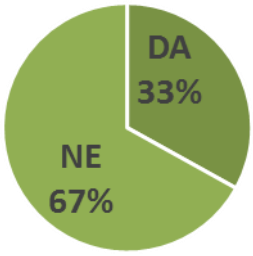

Slika 6.77 Udio oštećenih stabala u odsjeku 14b

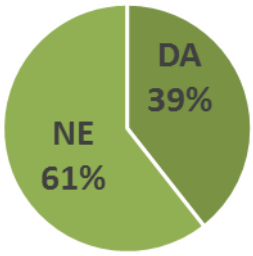

Slika 6.78 Udio oštećenih stabala u odsjeku 14c

Sječa i izrada stabala većih dimenzija debla i krošnji (u 14c odsjeku) uzrokovala je i pomak pojavnosti mjesta oguljenja kore sa primarno žilišta (slika 6.79) u 14b odsjeku (kao posljedice povlačenja stabala po tlu prilikom izrade harvesterom i ograničenog prostora između preostalih stabala) na pridanak i deblo (slika 6.80) u 14c odsjeku (kao posljedice obaranja stabala većih dimenzija).

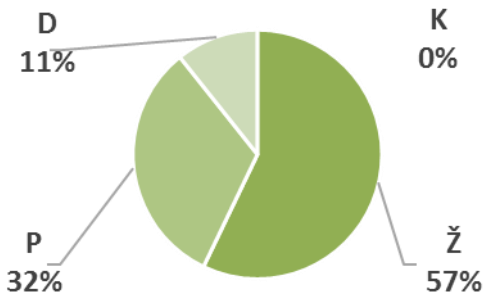

Slika 6.79 Mjesto oštećenja pri radu harvestera u odsjeku 14b (K – korijen, Ž – žilište, P – pridanak, D – deblo)

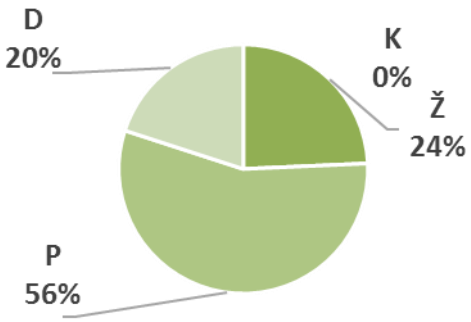

Slika 6.80 Mjesto oštećenja pri radu harvestera u odsjeku 14c (K – korijen, Ž – žilište, P – pridanak, D – deblo)

Razlike u mjestima oguljenja kore pri radu forvardera pokazuju znatno manju varijabilnost između istraživanih odsjeka (slika 6.81 i slika 6.82) i logično ukazuju da se oštećenja mogu očekivati primarno u zoni ispod 1,30 m kao posljedica prometovanja vozila (ali i zahvata izrađenih drvnih sortimenata prilikom utovara).

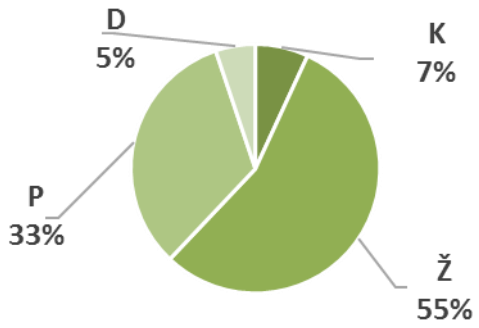

Slika 6.81 Mjesto oštećenja pri radu forvardera u odsjeku 14b (K – korijen, Ž – žilište, P – pridanak, D – deblo)

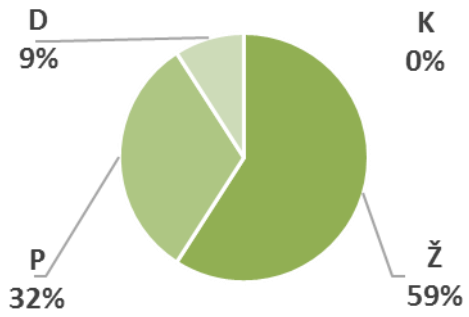

Slika 6.82 Mjesto oštećenja pri radu forvardera u odsjeku 14c (K – korijen, Ž – žilište, P – pridanak, D – deblo)

Dimenzije sječenih stabala su i vjerojatni uzrok različitoj distribuciji lokacija oštećenja. Naime, prilikom obaranja i izrade stabala većih promjera i visina, u odsjeku 14c, oštećenja su mogla intenzivnije zahvatiti veći dio sastojine koja se nalazi između posječenih »harvesterskih pruga« (slika 6.84 i slika 6.83). Prilikom analize lokacije neoštećenih stabala nisu uočene veće razlike između istraživanih odsjeka (slika 6.85 i slika 6.86).

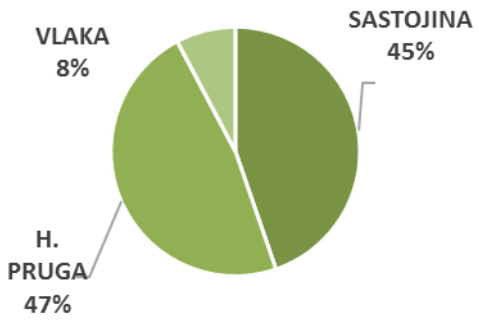

Slika 6.83 Lokacija oštećenih stabala u odsjeku 14b

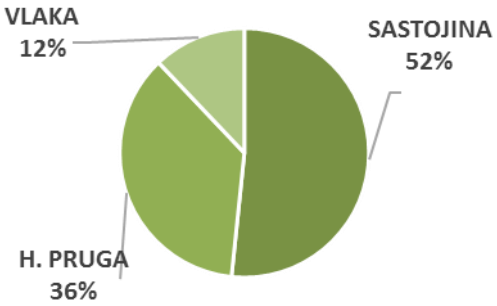

Slika 6.84 Lokacija oštećenih stabala u odsjeku 14c

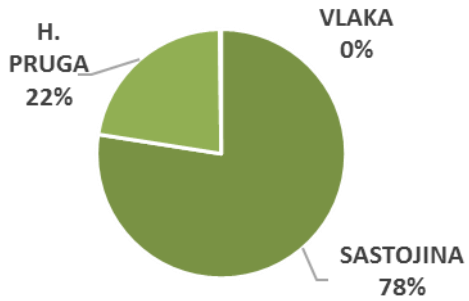

Slika 6.85 Lokacija neoštećenih stabala u odsjeku 14b

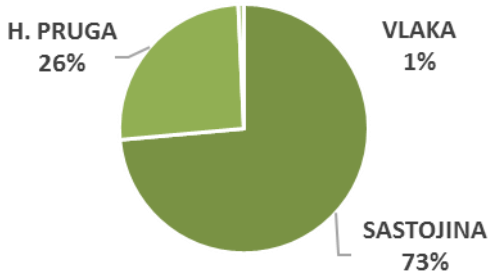

Slika 6.86 Lokacija neoštećenih stabala u odsjeku 14c

Površine pojedinih oguljenja kore (slika 6.87) i oguljenja kore po stablu (slika 6.89) s obzirom na mjesto nastanka oštećenja u odsjeku 14b ukazuju da se 75 % oguljenja kore na deblu, pridanku i žilištu nalaze u kategoriji ispod 100 cm^2 (odnosno 200 cm^2). U istoj se kategoriji nalazi 50 % oguljenja kore na korijenu.

U odsjeku 14c (slika 6.88 i slika 6.90), površine oguljenja debla i pridanka su značajno veća (kao posljedica sječe stabla i utovara drvnih sortimenata većih dimenzija), no još uvijek 50 % oštećenja na navedenim mjestima spada u kategoriju ispod 100 cm^2 (odnosno 200 cm^2).

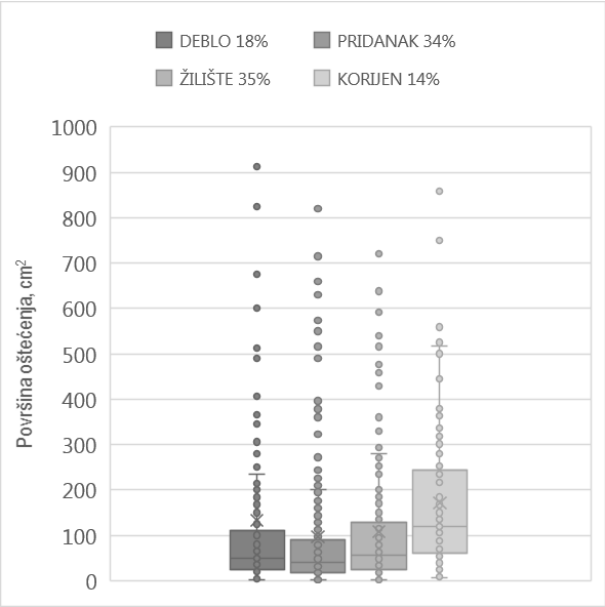

Slika 6.87 Površina oguljene kore (po oštećenju) u odsjeku 14b

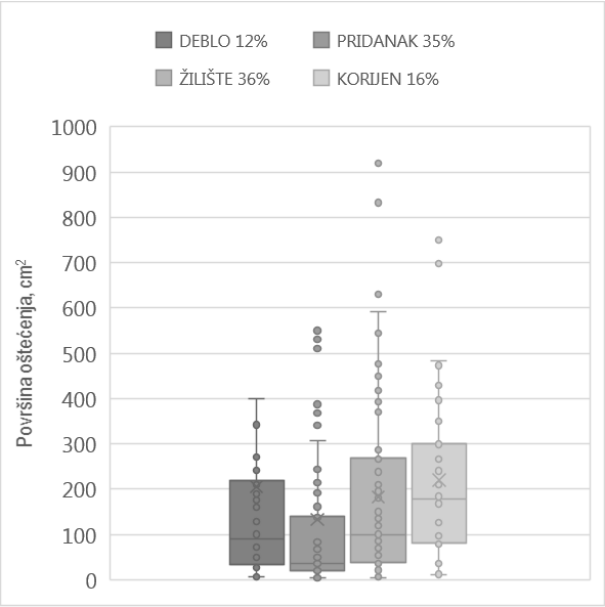

Slika 6.88 Površina oguljene kore (po oštećenju) u odsjeku 14c

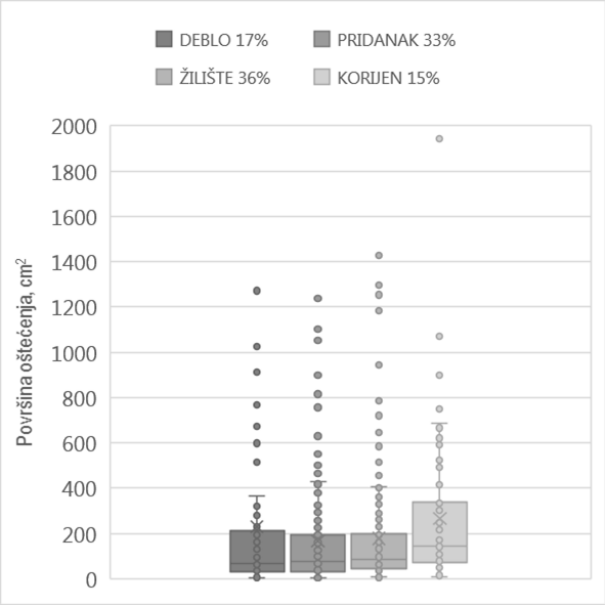

Slika 6.89 Površina oguljene kore (po stablu) u odsjeku 14b

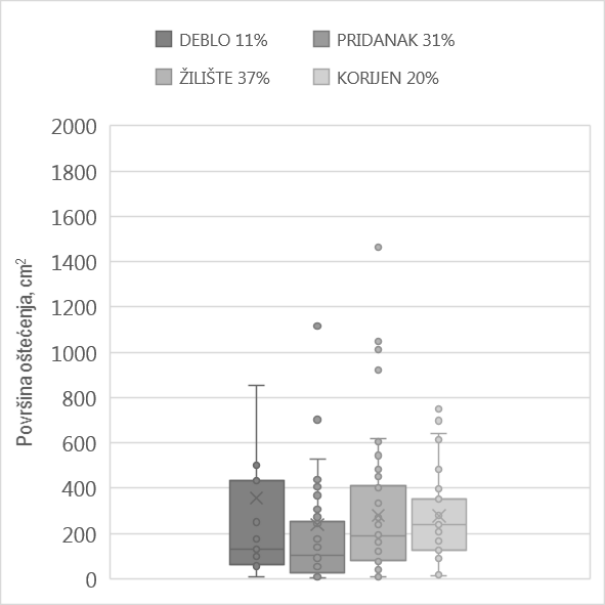

Slika 6.90 Površina oguljene kore (po stablu) u odsjeku 14c

Prilikom tumačenja rezultata ovog i prethodnih istraživanja nužno je imati na umu da općeprihvaćeni način iskazivanja oštećenih stabala u postotnom odnosu spram svih preostalih stabala u sastojini nakon radova pridobivanja drva posjeduje značajnih prednosti (prvenstveno pruža uvid u izglede održavanja neporemećene strukture sastojine te omogućuje matematičku usporedbu rezultata istraživanja provedenih u raznolikim sastojinskim uvjetima), no i jedan bitan nedostatak; uvelike ovisi o ukupnom broju preostalih stabala. Naime, sastojine u kojima raste veći broj stabala po jedinici površine imaju veći izgled za postizanjem većih apsolutnih iznosa broja oštećenih stabala (posebice prilikom uporabe mehaniziranih sustava pridobivanja drva, odnosno strojeva većih dimenzija koji se kreću i izvan mreže sekundarnih šumskih prometnice) koji pak u odnosu s ukupnim brojem preostalih stabala mogu rezultirati manjim relativnim brojem oštećenih stabala (iskazanih postotkom) prilikom usporedbe sa rezultatima istraživanja provedenim u drugačijim sastojinskim uvjetima.

U cilju smanjena šteta na dubećim stablima nužna je kontinuirana edukacija operatera šumskih strojeva o osjetljivosti šumkoga ekosustava na posljedice izvođenja radova prodobivanja drva kao i na moguće smanjenje ekonomske vrijednosti preostalih stabla u satojini. S obzirom na očekivano povećanje primjene harvestera u hrvatskom šumarstvu preporuča se ciljano školovanje operatera harvestera u okviru obrazovnog sustava.

Literatura

Doležal, B., 1984: Štete u šumi izazvane primenom mehanizacije. Dokumentacija za tehniku i tehnologiju u šumarstvu, 47, Beograd.

Ivanek, F., 1976: Vrednotenje poškodb pri spravilu lesa v gozovih na Pohorju, Institut za gozdno in lesno gospodarstvo pri Bioteničkoj fakulteti, 194, Ljubljana.

Južinić, B., 1984: Poškodbe pri sečnji in sravilu lesa v bukovih drogovnjakih. Diplomski rad. Biotehnička fakulteta v Ljubljani, 1–75.

Krznar, A., D. Gajdek, S. Dolenec, 1989: Problematika vrednovanja šteta i neki rezultati. Radovi 80: 139–161.

Krpan, A. P. B., S. Petreš, Ž. Ivanović, 1993.: Neke fizičke štete u sastojini, posljedice i zaštita. Glasnik za šumske pokuse 4: 271–280.

Martinić , I., 1991: Oštećenje sastojine pri obaranju stabla, izradi i privlačenju drva. Šumarski list 115 (1-2): 33–47.

Martinić , I., 1991: Oštećenje sastojine pri obaranju stabla, izradi i privlačenju drva. Šumarski list 115 (1-2): 33–47.

Martinić , I., 2000: Koliko smo blizu ekološki prihvatljivoj uporabi mehanizacije u šumarstvu?

Šumarski list 124 (1-2): 3–13.

Poršinsky, T., A. P. B. Krpan, I. Stankić, 2004: Djelotvornost strojne sječe i izrade u sastojinama tvrdih i mekih listača - 4. dio: Okolišna pogodnost strojne sječe u prirodnim sastojinama. Šumarski list 128 (11-12): 655–669.

Poršinsky, T., M. Ožura, 2006: Oštećivanje dubećih stabala pri izvoženju drva forvarderom. Nova mehanizacija šumarstva 27: 41–49.

Spinelli , R., 1994: Environment impact of logging by farm tractors. Interactive seminar and workshop »Soil, tree, machines interaction«, Feldafing, Germany, 1–10.

Tomanić, S., V., Vondra, I., Martinić, 1989: Oštećivanje sastojine pri šumskim radovima. Mehanizacija šumarstva 14(3-4): 65–72.

Vondra, V., S. Bogojević, 1994: Prinos znanja o uporabi srednjeg skidera Ecotrac V organizacijskim i ekonomskim pokazateljima rada. Mehanizacija šumarstva 19(4): 247–258.

Vuletić, D., 1996: Ekonomski gubici na vrijednosti drva hrasta lužnjaka (*Quercus robur* L.) kao posljedica ozljeđivanja stabala. Magistarski rad. Šumarski fakultet u Zagrebu, 1–89.

Martinić , I., 1990: Interakcije metoda rada, radnih uvjeta i proizvodnosti rada pri sječi i izradi drva u proredama sastojina. Magistarski rad. Šumarski fakultet u Zagrebu, 1–100.

6.4.2.1 Visina panjeva

Visina je panjeva definirana u Pravilniku o doznaci stabala, obilježavanju drvnih sortimenata, popratnici i šumskom redu (NN 17/2015, NN 57/2017). Članak 26. Stavak 2. propisuje da: »Visina

panjeva u sastojinama nakon sječe i izrade u nizinskim predjelima ne smije prelaziti jednu četvrtinu prsnog promjera odnosno jednu trećinu prsnog promjera na nagnutim terenima«. Osim ispravnog izvođenja zasjeka prilikom ručno-strojnog obaranja stabla motornim pilama lančanicama dva su osnovna razloga propisivanja visine panjeva; omogućavanje kretnosti strojeva (ne samo zbog radova pridobivanja drva već prvenstveno zbog radova zaštite šuma te ostalim radovima obnove i njege šuma koji se obavljaju strojno) i adekvatno iskorištenje raspoložive nadzemne biomase stabala (što veće iskorištenje najvrjednijeg dijela deblovine – pridanka).

Visina panjeva nakon strojne sječe harvesterom rezultat je interakcije morfoloških karakteristika stabala (razvedenosti žilišta debla), konfiguracije terena i tehničkih značajki harvesterske glave. Visina reza prilikom obaranja stabla ponajprije ovisi o minimalnoj visini reza koju je moguće postići kada se harvesterska glava položi na tlo prilikom obuhvaćanja stabla, ali uvelike ovisi i o mogućnosti sigurnog obuhvata debla harvesterskom glavom u navedenom položaju. Obaranje stabla većih dimenzija i razvedenijeg žilišta u određenim je slučajevima izrazito zahtjevno, osobito ako je podrezivanje zbog duljine vodilice nužno obaviti s dvije strane (slika 6.91) s obzirom da harvesterskom glavom nije moguće izvesti obradu žilišta.

Slika 6.91 Prihvatljiva visina panja nakon strojne sječe

Slika 6.92 Neprihvatljiva visina panja nakon strojne sječe

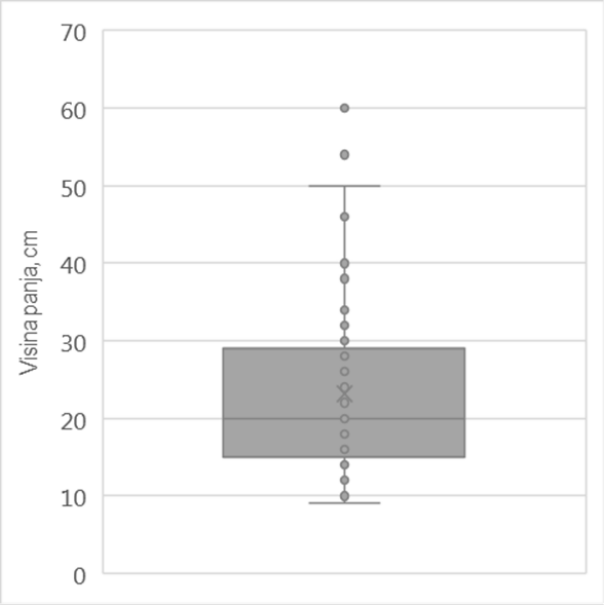

Slika 6.93 Visine panjeva nakon strojne sječe u 14b odsjeku

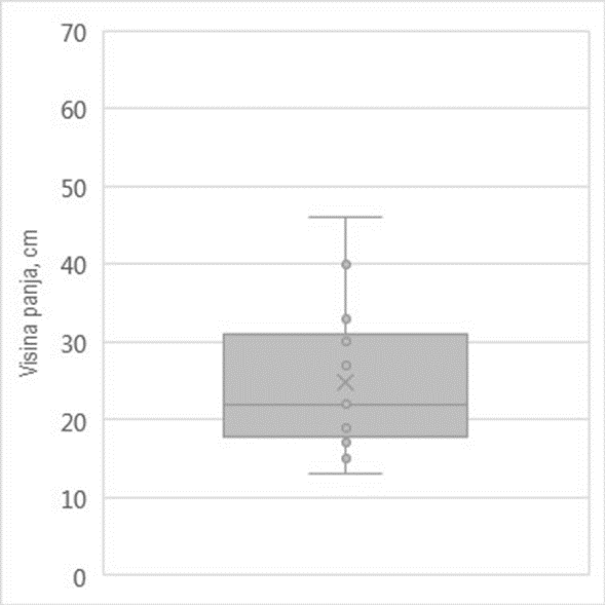

Slika 6.94 Visine panjeva nakon strojne sječe u 14c odsjeku

Prosječne su visine panjeva nakon strojne sječe u istraživanim odsjecima iznosile značajno više negoli propisne (slika 6.93 i slika 6.94), približno razini srednjih prsnih promjera doznačenih stabala (za 14b Ds = 21,7 cm; za 14c Ds = 26,4 cm).

Evidentna je nemogućnost dostizanja propisanih vrijednosti posebice za stabla manjih prsnih promjera (zbog tehničkih značajki harvesterske glave). Stablima relativno većih dimenzija (kod kojih je visina panjeva rezultat izvođenja strojnog obaranja stabala na siguran način) moguće je neposredno nakon sječe strojno podrezati panjeve i time omogućiti prohodnost sječine, ali na uštrb proizvodnosti harvestera istovremeno smanjujući iskorištenje raspoloživog drvnog obujma.

Literatura

Pravilnik o doznaci stabala, obilježavanju drvnih sortimenata, popratnici i šumskom redu. NN 17/2015, NN 57/2017

7. Diseminacija rezultata Projekta

Tijekom trajanja Projekta članovi istraživačke skupine poduzeli su niz aktivnostu u cilju diseminacije rezultata Projekta:

1) Prijavljene su dvije teme predavanja u okviru Programa stručnoga usavršavanja članova Hrvatske komore inženjera šumarstva i drvne tehnologije za 2018. godinu.

- Prof. dr. sc. Tomislav Poršinsky: Kriteriji određivanja gustoće primarne šumske prometne infrastrukture
- doc. dr. sc. Dinko Vusić: Mehanizirani sustavi pridobivanja drva

Navedena je predavanja Odbor za stručno usavršavanje HKIŠDT uvrstio u program Stručnog usavršavanja članova HKIŠDT za 2018. godinu (prihvaćen 13. ožujka 2018. godine). Do sada su predavanja održana na području UŠP Karlovac (17. travnja 2018. godine), UŠP Buzet (25. travnja 2018. godine) i UŠP Bjelovar (7. svibnja 2018. godine).

2) Članovi istraživačke skupine pripremili su deset znanstvenih radova s rezultatima istraživanja koja su bila (su)financirana ovim Projektom:

- Bačić, M., M. Šušnjar, Z. Pandur, M. Šporčić, M. Landekić, 2018: Physical Workload while Working with Hedging Bill and Battery Cutter in Tending of Pedunculate Oak. 7th International Ergonomics Conference ERGONOMICS 2018 – Emphasis on Wellbeing, Zadar, Croatia, 59–64.
- Đuka, A., D. Vusić, D. Horvat, M. Šušnjar, Z. Pandur, I. Papa, 2017: LCA Studies in Forestry – Stagnation or Progress? Croatian journal of forest engineering 38 (2): 311–326.
- Đuka, A., T. Pentek, T. Poršinsky, D. Janeš, M. Starčević, I. Papa, 2017: Otvorenost gospodarske jedinice Belevine, NPŠO Zalesina, i prijedlog daljnjega otvaranja. Nova mehanzacija šumarstva 38(1): 15–32.
- Janeš, D., T. Poršinsky, T. Pentek, Ž. Tomašić, I. Papa. A. Đuka, 2018: Terrain classification for timber harvesting and forest accessibility. FORMEC 2018 – Improved Forest Mechanisation: mobilizing natural resources and preventing wildfires, Madrid, Spain, str. 2.
- Landekić, M., M. Šporčić, I. Martinić, M. Bakarić, 2018: Ocjena radnog položaja tijela šumskog radnika sjekača. VII. međunarodni stručno-znanstveni skup ZAŠTITA NA RADU I ZAŠTITA ZDRAVLJA, Zadar, Hrvatska, str. 6.
- Landekić, M., M. Šporčić, I. Martinić, M. Šušnjar, Z. Pandur, M. Bačić: 2018: Evaluation and Comparison of Forest Machinery Operators' Cardiovascular Workload. FORMEC 2018 – Improved Forest Mechanisation: mobilizing natural resources and preventing wildfires, Madrid, Spain, str. 9.
- Pandur, Z., A. Đuka, I. Papa, M. Bačić, D. Janeš, D. Vusić, 2018: Energy efficiency of mechanized thinning in broadleaf stand. »Natural resources, green technology and sustainable development/3-GREEN2018«, Zagreb, Croatia, 116–120.
- Papa, I., T. Pentek, D. Janeš, T. Šerić, D. Vusić, A. Đuka, 2017: Usporedba podataka prikupljenih različitim metodama terenske izmjere pri rekonstrukciji šumske ceste. Nova mehanzacija šumarstva 38(1): 1–14.
- Poršinsky, T., A. Đuka, I. Papa, Z. Bumber, D. Janeš, Ž. Tomašić, T. Pentek, 2017: Kriteriji određivanja gustoće primarne šumske prometne infrastrukture – Primjeri najčešćih slučajeva. Šumarski list: znanstveno-stručno i staleško glasilo Hrvatskoga šumarskog društva 141 (11–12): 593–608.
- Vusić, D., M. Plantak, I. Papa, A. Đuka, T. Pentek, T. Poršinsky, 2018: Analysing the Efficiency of Mechanised Thinning in Broadleaf Stands. FORMEC 2018 – Improved Forest

Mechanisation: mobilizing natural resources and preventing wildfires, Madrid, Spain, str. 9.

Rezultati prezentirani u navedenim radovima, ako i nisu posebno navedeni u ovom Izvješću, predstavljaju sastavni dio ovoga Izvješća.

3) Tijekom provođenja glavnog pokusa, dana 18. srpnja 2017. godine organizirana je terenska demonstracija primjene mehaniziranog sustava pridobivanja drva u proredi bjelogodričnih sastojina za šumarske stručnjake koji se bave problematikom pridobivanja drva. Članovi istraživačkog tima prezentirali su osnovne značajke primjene navedenoga sustava, primjenjene metode istraživanja i dosadašnje rezultate 5E pokazatelja. Nakon prezentacije uslijedila je stručna rasprava.

Slika 7.1 Terenska demonstracija primjene istraživanog sustava

4) Rezultati Projekta u obliku Polugodišnjih izvješća i pripadajućih Priloga, kao i ovo Završno izvješće dostupni su na mrežnim stranicama Šumarskog fakulteta.
http://okfs-optimizacija.sumfak.hr

U Zagrebu, 26. srpnja 2018. godine

Voditelj projekta:

doc. dr. sc. Dinko Vusić