

Utjecaj selektivne aplikacije s ultrazvučnim senzorima na zanošenje i depozit tekućine u nasadu višnje

Impact of selective application with ultrasonic sensors on drift and liquid deposit in the cherry orchard

Petrović, D., Jurišić, M., Plaščak, I., Duvnjak, V., Marković, M., Banaj, A., Tadić, V.

Poljoprivreda/Agriculture

ISSN: 1848-8080 (Online)

ISSN: 1330-7142 (Print)

<http://dx.doi.org/10.18047/poljo.25.1.13>



Fakultet agrobiotehničkih znanosti Osijek, Poljoprivredni institut Osijek

Faculty of Agrobiotechnical Sciences Osijek, Agricultural Institute Osijek

UTJECAJ SELEKTIVNE APLIKACIJE S ULTRAZVUČNIM SENZORIMA NA ZANOŠENJE I DEPOZIT TEKUĆINE U NASADU VIŠNJE

Petrović, D.⁽¹⁾, Jurišić, M.⁽¹⁾, Plaščak, I.⁽¹⁾, Duvnjak, V.⁽²⁾, Marković, M.⁽¹⁾, Banaj, A.⁽¹⁾, Tadić, V.⁽¹⁾

Izvorni znanstveni članak

Original scientific paper

SAŽETAK

U radu je prikazan utjecaj dvaju različitih sustava raspršivanja (klasičnoga i senzorskog) pomoću raspršivača Tifone Vento 1500, s različito podešenim tehničkim čimbenicima raspršivanja, na zemljišno i zračno zanošenje tekećine te depozit u krošnji. Istraživanje je obavljeno prema ISO normi 22866:2005 u nasadu višnje. Analizom varijance ispitan je utjecaj norme raspršivanja kao čimbenik A (A_1 - 250 l ha⁻¹; A_2 - 200 l ha⁻¹), tip mlaznica kao čimbenik B (B_1 - Lechler TR 8002C; B_2 - Lechler ITR 8002C) i brzina zračne struje ventilatora kao čimbenik C (C_1 - 18 m s⁻¹; C_2 - 12 m s⁻¹). Raspršivanje je obavljeno sa 4-postotnom otopinom organske boje Tartrazine, a filter-papirićima je prikupljena zanesena tekećina. Optimalizacijom tehničkih čimbenika raspršivanja ostvaruje se maksimalno smanjenje od 36,59% za zemljišno zanošenje te 75,05% za zračno zanošenje na 5 m udaljenosti od tretiranoga reda. Eksploatacijom ultrazvučnoga senzorskog sustava za selektivnu aplikaciju zemljišno zanošenje smanjuje se za 43,35%. U ovome slučaju zračno zanošenje na 5 m udaljenosti od tretiranoga reda smanjuje se za 66,57% te 79,61% na udaljenosti od 10 m. Maksimalno reduciranje zračnoga zanošenja na 10 m ostvareno je uporabom ITR mlaznica analizirajući oba sustava raspršivanja. Eksploatacija ultrazvučnoga senzorskog sustava nije negativno utjecala na depozit u krošnji jer iz dobivenih rezultata nije zabilježena značajna razlika između dvaju sustava raspršivanja (0,5%). Opremanje konvencionalnih raspršivača naprednim sustavima za selektivnu aplikaciju značajno doprinosi preciznosti nanošenja sredstva za zaštitu bilja, a time i smanjenju negativnoga utjecaja na okoliš.

Ključne riječi: senzori, selektivna aplikacija, zanošenje tekećine, norma raspršivanja, brzina zraka, raspršivač, mlaznice

UVOD

Primjenom moderne poljoprivredne tehnike s uporabom raznih senzorskih sustava i optimalno podešenih tehničkih čimbenika raspršivanja (norma raspršivanja, tip mlaznice, brzina zračne struje i brzina gibanja stroja) mogu se ostvariti rezultati koji zadovoljavaju biološke, eksploatacijske i ekonomske aspekte zaštite bilja. Loša raspodjela škropiva može smanjiti učinkovitost raspršivanja i povećati opasnost od onečišćenja okoliša (Verduyck i sur., 1999.). Uporaba tehnologije za smanjenje zanošenja tekećine izvan ciljanoga prostora zaštite bilja temelji se na proučavanju i unaprjeđenju

kvalitete raspršivanja. Dezintegraciju mlaza s obzirom na konstrukciju mlaznice proučavaju Czaczek (2012.), Vallet i Tinet (2013.) te Fritz i sur. (2014.). Zande i sur. (2014.) istražuju mogućnost prilagodbe brzine zračne struje prema stadiju razvoja biljke. Reduciranjem brzine

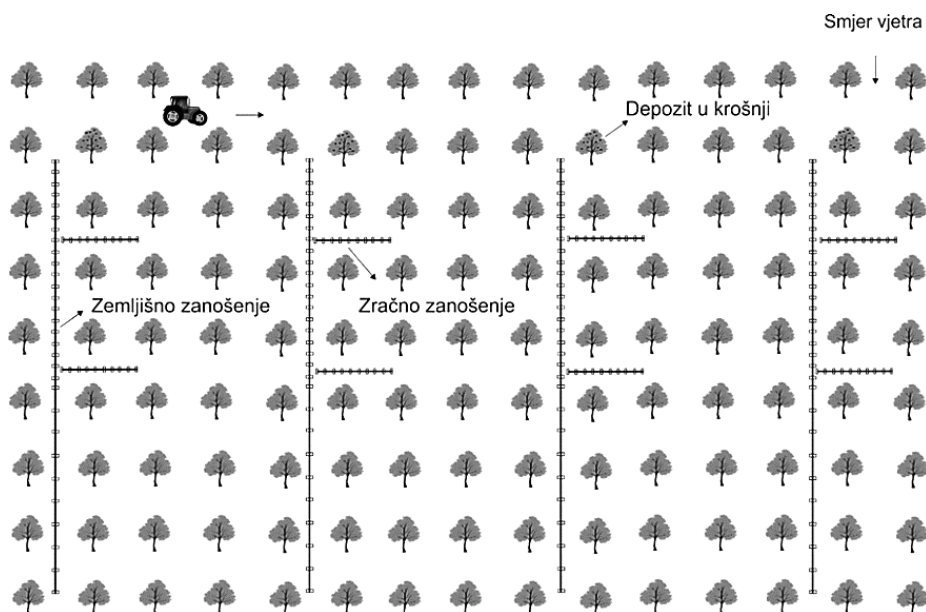
(1) Dr. sc. Davor Petrović, viši stručni suradnik; prof. dr. sc. Mladen Jurišić, doc. dr. sc. Ivan Plaščak, doc. dr. sc. Monika Marković, Anamarija Banaj, mag. ing. agr., doc. dr. sc. Vjekoslav Tadić (vtadic@fazos.hr) - Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet agrobiotehničkih znanosti Osijek, Vladimira Preloga 1, 31000 Osijek, Hrvatska, (2) Dr. sc. Vinko Duvnjak, znanstveni savjetnik, Poljoprivredni institut Osijek, Južno predgrađe 17, 31000 Osijek, Hrvatska

zračne struje ventilatora ostvareno je značajno smanjenje zračnoga zanošenja tekućine (25-77%) u fenološkoj fazi mirovanja biljke. Brzinu zračne struje s različitim čimbenicima podešavanja (položaj lopatica ventilatora i broj okretaja pogonskoga vratila) istražuju Tadić i sur. (2014.) te Banaj i sur. (2016.). Miranda-Fuentes i sur. (2015.) navode da brzina zračne struje utječe na depozit unutar krošnje, s povećanjem gubitaka tekućine izvan ciljanoga objekta raspršivanja (Salcedo i sur., 2015.). Smanjenjem depozita u srednjem dijelu krošnje povećava se mogućnost ponovne pojave štetočinja (Farooq i Salyani, 2002.; Cross i sur., 2003.; Salyani i sur., 2006.; Zhu i sur., 2006.; Celen i sur., 2009.). Za učinkovitu i sigurnu primjenu zaštitnih sredstava razvija se nekoliko metoda aplikacije: raspršivači s reciklirajućim sustavom, uporaba GIS-a i razvoj tzv. „pametnih“ raspršivača s promjenljivom normom raspršivanja. Kao dio suvremene tehnologije, GIS značajno doprinosi učinkovitijoj zaštiti bilja (Jurišić i sur., 2015.). Potreba za smanjenjem onečišćenja okoliša i inputa u poljoprivrednoj proizvodnji dovodi do proučavanja metode održive uporabe pesticida u trajnim nasadima pomoću njihove selektivne aplikacije. Llorens i sur. (2013.) navode da se ugradnjom elektronskih dijelova na konvencionalne raspršivače značajno unaprjeđuje tehnika raspršivanja i smanjuje zanošenje tekućine. Unaprjeđenje konvencionalnih raspršivača senzorskim sustavom osmišljeno je zbog ostvarenja uštede pesticida i smanjenja onečišćenja okoliša (Solanelles i sur., 2006.; Jeon i sur., 2012.). Primjenu ultrazvučnih senzora za prepoznavanje krošnje u realnome vremenu istražuju sljedeći znanstvenici: Solanelles i sur., 2006.; Stajanko i sur., 2012.; Gamarra-

Diezma i sur., 2015. Glavna prednost ove vrste senzora jest robusna izvedba koja smanjuje negativan utjecaj nepovoljne radne okoline (vlaga, vibracije, prljavština, temperatura, magla) i njihova relativno niska cijena s obzirom na druge elektroničke sklopove koji se koriste u iste svrhe (Stajanko i sur., 2012.). Cilj istraživanja jest utvrđivanje utjecaja glavnih tehničkih čimbenika raspršivanja (norme raspršivanja, tipa mlaznice i brzine zračne struje) eksploatacijom raspršivača *Tifone Vento 1500*, s dva različita sustava raspršivanja (selektivno i konvencionalno), na zemljišno i zračno zanošenje te depozit tekućine u krošnji. Pomoću navedenoga cilja znanstvenim će metodama i statističkom obradom rezultata istraživanja biti izveden zaključak o opravdanosti korištenja senzorskoga sustava i optimalizacije tehničkih čimbenika raspršivanja.

MATERIJAL I METODE

Istraživanje je obavljeno u četverogodišnjem nasadu višnje u vlasništvu rasadnika *Karolina* (Osijek, Osječko-baranjska županija, Hrvatska) u svibnju 2017. godine. Geografski položaj nasada je 45°31'17.5"SZŠ i 18°46'39.6"IZD. Uzgojni je oblik u ispitivanome nasadu popravljena piramida sa stablom visine 80 cm. Razmak između biljaka iznosi 6 x 3,5 m (razmak između redova x razmak između voćaka). Prosječna visina nasada je 2,57 m, a prosječna dimenzija krošnje 1,76 m x 1,96 m. Istraživanje je postavljeno prema *ISO normi 22866:2005*, koja propisuje točne postupke provedbe istraživanja i determinacije zanošenja depozita tekućine. Filter-papirići postavljeni su prema shemi koju prikazuje Slika 1.



Slika 1. Shema postavljanja istraživanja.

Figure 1. Research set-up scheme.

U istraživanju je ispitivana uporaba ultrazvučnoga senzorskog sustava za selektivnu aplikaciju, koji je postavljen na raspršivač *Tifone Vento 1500* s različito podešenim tehničkim čimbenicima raspršivanja: normom raspršivanja, tipom mlaznice i brzinom zračne struje. Korišten sustav ultrazvučnih senzora tvrtke *Sick*, model *UM30-215111*, ima mogućnost detekcije objekta na udaljenosti od 0,6 do 6 m, a minimalna površina predmeta koji mogu detektirati je 0,02 m². Izrađeni su od nehrđajućega čelika i plastike, a na tijelu senzora postavljen je zaslon koji pokazuje očitane vrijednosti i udaljenost objekta. Brzina detekcije ciljanoga predmeta je 240 ms i označena je certifikatom *IP 67*. Navedeni senzori rade na 80 kHz, s rezolucijom od >0,18 mm.

Tehnički pregled raspršivača obavljen je prema Zakonu o održivoj uporabi pesticida (*NN 14/14*). Tijekom istraživanja praćeni su meteorološki uvjeti u nasadu s prijenosnom meteorološkom postajom *Hoobo*. Vučeni raspršivač *Tifone Vento 1500* opremljen je spremnikom tekućine obujma 1500 l. Mlaznice *Lechler TR 8002C* i *ITR 8002C* postavljene su polukružno na obodu usmjerenja. Ventilator se sastoji od osam lopatica, a promjer ventilatora iznosi 810 mm. Brzinu zračne struje moguće je podešavati promjenom radnoga položaja lopatica ventilatora. Raspršivač je agregatiran s traktorom *Torpedo 6006K*, sa snagom motora od 42 kW. Slika 2. prikazuje vučeni raspršivač *Tifone Vento 1500* i sustav senzora *Sick*.




Slika 2. Vučeni raspršivač *Tifone Vento 1500* i sustav senzora *Sick*.

Figure 2. Air assisted sprayer *Tifone Vento 1500* and *Sick* sensor system.

Metodom *TRV* (Slika 3) izračunat je obujam vegetacije u nasadu na određenome uzgojnom prostoru (Doruchowski i sur., 2012). *TRV* (engl. *tree row volume*) se izračunava prema izrazu (1), u kojem je *TRV* - obujam

nasada, m³ ha⁻¹; h_n - visina nasada, m; b_k - širina krošnje, m; b_r - širina reda, m.

$$TRV = \frac{h_n \cdot b_k \cdot 10\,000}{b_r} \text{ (m}^3 \text{ ha}^{-1}\text{)} \quad (1)$$



Slika 3. Određivanje obujma nasada (metoda *TRV*).

Figure 3. Determination of tree volume (*TRV* method)

Kao čimbenik A ispitana je norma raspršivanja. Primijenjena je optimalna norma raspršivanja A (250 l ha^{-1} , izračunata prema trenutnom stanju nasada i obujmu lisne mase), te norma raspršivanja A reducirana za 20% (200 l ha^{-1}). Kao drugi tehnički čimbenik promatran je utjecaj standardne mlaznice B (*Lechler TR 8002C*) i mlaznice sa smanjenim zanošenjem (*Lechler ITR 8002C*), kao čimbenik B_2 . Čimbenik C označuje utjecaj zračne struje na zanošenje tekućine. C je brzina zračne struje ventilatora izračunatu prema obujmu lisne mase (18 m s^{-1}), dok je brzina zračne struje od 12 m s^{-1} čimbenik C_2 . Za prikupljanje podataka o zanesenoj tekućini korišteni su filter-papirići, a kao bojilo tekućine korištena je organska boja *Tartrazine* u koncentraciji od 4%. Za određivanja koncentracije otopine isprane s filter-papirića korištena je spektrofotometrijska metoda (*Varian Cary 50 UV-Visible*). Za statističku analizu (analiza varijance i *LSD test*) rezultata istraživanja korišten je operativni softver *SAS Enterprise*

Guide ver. 7.15HF2 (SAS Institute 2017.) te *Exel 2016. Ink* za regresijsku analizu i korelaciju.

Izračunavanje depozita po jedinici površine obavljeno je pomoću izraza (2), kako to opisuju Stajanko i sur. (2012.), gdje je depozit tekućine na kolektoru ($\mu\text{g cm}^{-2}$), koncentracija boje kojom se obavlja aplikacija ($\mu\text{g ml}^{-1}$), w količina deionizirane vode (ml) i površina filter-papirića (cm^2).

$$M_d = \frac{T_{cl} \cdot w}{L_a} \quad (2)$$

REZULTATI I RASPRAVA

Vremenski uvjeti tijekom eksploatacije raspršivača *Tifone* s oba sustava raspršivanja prikazani su u Tablici 1.

Tablica 1. Meteorološki podatci.

Table 1. Meteorological data.

Konvencionalni sustav / Conventional spraying												
Tretman / Treatment	$A_1B_1C_1$	$A_1B_1C_2$	$A_1B_2C_1$	$A_1B_2C_2$	$A_2B_1C_1$	$A_2B_1C_2$	$A_2B_2C_1$	$A_2B_2C_2$	\bar{x}	σ	K.V. (%)	
T_z (°C)	19,4	19,6	19,6	20,1	23,4	23,1	24,8	24,6	21,8	2,4	10,9	
R_v (%)	70,6	70,1	69,9	65,5	55,2	55,6	50,4	50,2	60,9	1,0	14,8	
v_v (m s^{-1})	Min.	0,6	0,8	0,7	0,5	0,4	0,6	0,4	0,8	0,6	0,2	26,7
	Max.	0,9	1,2	0,8	0,9	0,8	1,1	0,9	1,2	1,0	0,2	17,1
	\bar{x}	0,8	1,0	0,8	0,7	0,6	0,9	0,7	1,0	0,8	0,2	19,1
Senzorski sustav / Sensor spraying												
T_z (°C)	19,2	19,4	19,2	20,3	23,1	22,8	24,1	25,1	21,7	2,4	11,1	
R_v (%)	70,5	70,1	70,1	65,8	55,6	55,9	49,8	49,9	60,9	9,1	15,0	
v_v (m s^{-1})	Min.	0,4	0,9	0,7	1,7	0,6	0,8	0,4	0,9	0,8	0,4	51,8
	Max.	1,1	1,2	0,7	0,8	0,8	1,2	1,3	1,5	1,1	0,3	26,2
	\bar{x}	0,8	1,1	0,7	1,3	0,7	1,0	0,9	1,2	0,9	0,2	23,1

T_z - temperatura zraka (°C); R_v - relativna vlažnost zraka (%); v_v - brzina vjetra (ms^{-1})

T_z - air temperature in the orchard; R_v - relative air humidity in the orchard; v_v - wind speed

Vremenski uvjeti tijekom istraživanja prikazani u Tablici 1 bili su u skladu s preporučenim vrijednostima (Tadić, 2013.): temperatura zraka manja od 22°C , relativna vlažnost veća od 60% i brzina vjetra manja od 3 m s^{-1} . Nuyttens i sur. (2005.) navode da su najznačajniji meteorološki uvjeti tijekom aplikacije temperatura zraka i brzina vjetra, te je poštivanjem preporučenih vrijednosti moguće značajno unaprijediti aplikaciju i smanjiti zanošenje tekućine. Važnost utjecaja brzine i smjera vjetra na zračno i zemljišno zanošenje tekućine analiziraju Grella i sur. (2017.). Temeljem dobivenih

rezultata utvrđuju 24% varijabilnosti zračnoga zanošenja tekućine promjenom smjera i povećanjem brzine vjetra veće od 3 m s^{-1} ($1,1\text{-}10,8 \text{ m s}^{-1}$). Radno je područje ultrazvučnih senzora za selektivnu aplikaciju korištenih u ovome istraživanju od -25 do $+70^\circ\text{C}$, te je u potpunosti otklonjen utjecaj temperature zraka na točnost očitavanja. Tablica 2. prikazuje opisnu statistiku za glavna svojstva istraživanja po pojedinim tretmanima, a iz nje se zamjećuje da su relativne mjere varijacije između ponavljanja (σ i *K.V.*) u iznosima do 10%.

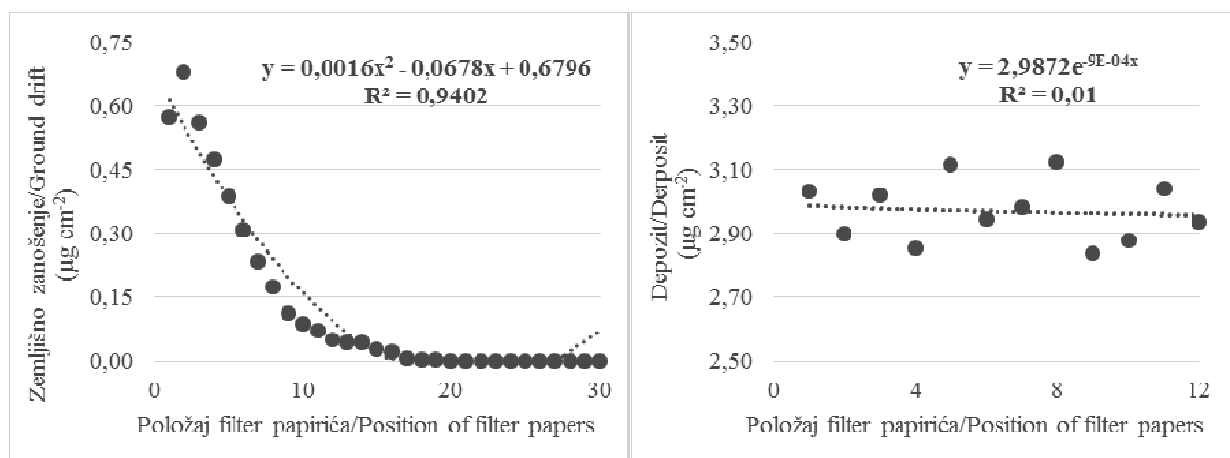
Tablica 2. Opisna statistika za glavna svojstva istraživanja.

Table 2. Descriptive statistics for the main properties of the research.

Tretman Treatment	Konvencionalni sustav / Conventional spraying											
	Zemljišno zanošenje Ground drift (g ha ⁻¹)			Depozit Deposit (g ha ⁻¹)			Zrač. zanošenje - 5 m Air drift - 5 m (g ha ⁻¹)			Zrač. zanošenje - 10 m Air drift - 10 m (g ha ⁻¹)		
	\bar{x}	σ	K.V. (%)	\bar{x}	σ	K.V. (%)	\bar{x}	σ	K.V. (%)	\bar{x}	σ	K.V. (%)
A ₁ B ₁ C ₁	15,95	0,13	0,77	295,42	7,57	0,94	25,27	0,70	0,57	10,29	1,38	1,14
A ₁ B ₁ C ₂	20,81	0,65	2,95	299,17	10,90	0,48	29,43	1,01	0,81	13,79	1,31	1,04
A ₁ B ₂ C ₁	23,05	0,91	4,21	297,00	13,98	0,90	15,36	1,29	1,04	0,00	2,70	2,20
A ₁ B ₂ C ₂	25,05	0,42	1,61	314,20	17,93	1,43	17,86	2,52	0,39	0,00	2,41	1,85
A ₂ B ₁ C ₁	9,98	0,38	3,60	281,10	5,95	0,50	16,29	6,48	5,49	9,29	8,95	7,69
A ₂ B ₁ C ₂	15,69	1,02	6,22	284,00	8,81	0,50	23,64	3,29	2,76	7,42	8,61	7,32
A ₂ B ₂ C ₁	13,95	0,31	2,12	285,80	7,88	0,88	7,14	2,14	1,78	0,00	4,35	3,85
A ₂ B ₂ C ₂	17,50	1,70	9,23	287,20	10,55	1,68	8,36	6,08	5,04	0,00	6,33	5,34
Tretman Treatment	Senzorski sustav / Sensor spraying											
	\bar{x}	σ	K.V. (%)	\bar{x}	σ	K.V. (%)	\bar{x}	σ	K.V. (%)	\bar{x}	σ	K.V. (%)
	A ₁ B ₁ C ₁	7,57	0,13	0,77	289,00	7,57	0,94	8,00	0,70	0,57	0,00	1,38
A ₁ B ₁ C ₂	10,90	0,65	2,95	299,30	10,90	0,48	13,93	1,01	0,81	5,79	1,31	1,04
A ₁ B ₂ C ₁	13,98	0,91	4,21	293,10	13,98	0,90	0,00	1,29	1,04	0,00	2,70	2,20
A ₁ B ₂ C ₂	17,93	0,42	1,61	309,80	17,93	1,43	6,92	2,52	0,39	0,00	2,41	1,85
A ₂ B ₁ C ₁	5,95	0,38	3,60	277,00	5,95	0,50	6,35	6,48	5,49	0,00	8,95	7,69
A ₂ B ₁ C ₂	8,81	1,02	6,22	280,00	8,81	0,50	11,29	3,29	2,76	2,29	8,61	7,32
A ₂ B ₂ C ₁	7,88	0,31	2,12	281,60	7,88	0,88	0,00	2,14	1,78	0,00	4,35	3,85
A ₂ B ₂ C ₂	10,55	1,70	9,23	282,10	10,55	1,68	2,86	6,08	5,04	0,00	6,33	5,34

Za glavna svojstva istraživanja (zemljišno zanošenje, depozit, zračno zanošenje na 5 i 10 m) provedena je regresijska analiza, a rezultati su prikazani u grafikonima 1. i 2. Udaljavanjem filter-papirića

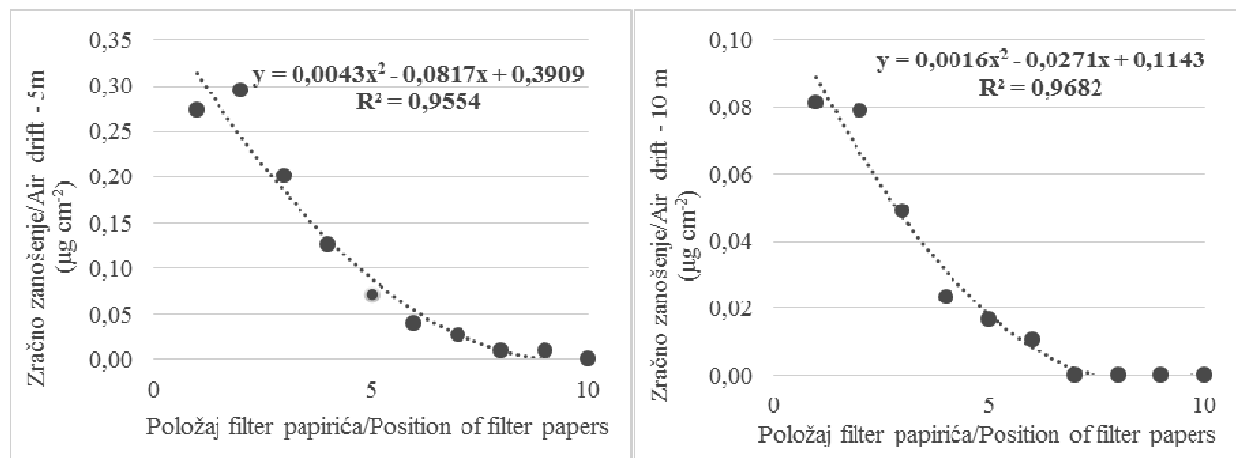
od tretiranoga reda statistički se značajno smanjuje zemljišno zanošenje ($r=0,81$, jaka korelacija/Pearson), dok kod depozita nema statistički značajnih interakcija ($r=0,098$).

**Grafikon 1. Regresijska analiza za zemljišno zanošenje (lijevo) i depozit (desno).**

Graph 1. Regression analysis for ground drift (left) and deposit (right).

Promatrajući zračno zanošenje, oba modela pokazuju visoki koeficijent determinacije (5 m: $R^2=0,95$;

10 m: $R^2=0,96$), sa statističkom značajnošću i jakim korelacijom/Pearson (5 m: $r=0,93$; 10 m: $r=0,90$).



Grafikon 2. Regresijska analiza za zračno zanošenja na 5 i 10 m.

Graph 2. Regression analysis for air drift at 5 and 10 m.

Analizu varijance za zemljišno i zračno zanošenje tekućine na 5 i 10 m udaljenosti od tretiranoga reda za

glavne tehničke čimbenike raspršivanja te njihove interakcije prikazuje Tablica 3.

Tablica 3. Analiza varijance za ispitivana svojstva istraživanja.

Table 3. Analysis of variance for the main properties of the research.

Konvencionalni sustav / Conventional spraying									
ANOVA		Zemljišno zanošenje Ground drift		Depozit Deposit		Zračno zanošenje – 5 m Air drift – 5 m		Zračno zanošenje – 10 m Air drift – 10 m	
		F-test	p	F-test	p	F-test	p	F-test	p
A	A ₁	640,28*	<,0001	3,31 n. s.	0,08	84,14*	<,0001	75,62*	<,0001
	A ₂								
B	B ₁	157,53*	<,0001	0,12 n. s.	0,73	178,45*	<,0001	187,70*	<,0001
	B ₂								
C	C ₁	241,41*	<,0001	1,37 n. s.	0,25	14,33*	0,0009	33,07*	<,0001
	C ₂								
AB		41,17*	<,0001	0,01 n. s.	0,93	0,00 n. s.	0,9645	75,62*	<,0001
AC		14,70 n. s.	0,0008	0,00 n. s.	0,99	0,13 n. s.	0,7248	1,26 n. s.	0,273
BC		5,29 n. s.	0,0304	0,02 n. s.	0,90	11,45 n. s.	0,025	33,07*	<,0001
ABC		5,29 n. s.	0,0304	0,02 n. s.	0,90	5,57 n. s.	0,0267	1,26 n. s.	0,273
Senzorski sustav / Sensor spraying									
ANOVA		Zemljišno zanošenje Ground drift		Depozit Deposit		Zračno zanošenje - 5 m Air drift - 5 m		Zračno zanošenje - 10 m Air drift - 10 m	
		F-test	p	F-test	p	F-test	p	F-test	p
A	A ₁	190,15*	<,0001	1,90 n. s.	0,18	46,57*	<,0001	35,48*	<,0001
	A ₂								
B	B ₁	171,98*	<,0001	0,29 n. s.	0,59	630,24*	<,0001	188,70*	<,0001
	B ₂								
C	C ₁	119,07*	<,0001	1,19 n. s.	0,29	320,93*	<,0001	188,70*	<,0001
	C ₂								
AB		65,39*	<,0001	0,05 n. s.	0,82	0,01 n. s.	0,90	35,48*	<,0001
AC		0,99 n. s.	0,33	0,02 n. s.	0,90	21,45*	0,0001	35,48*	<,0001
BC		0,38 n. s.	0,541	0,20 n. s.	0,66	1,49 n. s.	0,23	188,70*	<,0001
ABC		0,16 n. s.	0,697	0,00 n. s.	0,97	5,36*	0,03	35,48*	<,0001

$\alpha=0,05$; A - norma raspršivanja ($l\ ha^{-1}$), B - tip mlaznice, C - brzina zračne struje ($m\ s^{-1}$)

$\alpha=0,05$; A - spraying norm ($l\ ha^{-1}$), B - nozzle type, C - air flow rate ($m\ s^{-1}$)

Temeljem podataka iz Tablice 3. uočava se da glavni tehnički čimbenici istraživanja (norma raspršivanja, tip mlaznice i brzina zračne struje) kod oba sustava raspršivanja ostvaruju statistički značajan utjecaj na svojstvo zemljišnoga zanošenja. Statistička značajnost ostvarena je kod oba slučaja zračnoga zanošenja. Različito podešeni tehnički čimbenici raspršivanja, prema shemi istraživanja, ne ostvaruju statistički značajan utjecaj na svojstvo depozita. Pozitivan utjecaj zračno-injektorskih mlaznica na smanjenje zemljišnoga i zračnog zanošenja utvrđuju Grella i sur. (2017.). Na temelju dobivenih rezultata objašnjavaju varijabilnost u smislu smanjenja zanošenja tekućine od 51% zračno-injektorskim mlaznicama u odnosu na standardne mlaznice. Petrović i sur. (2018.) navode da se uporabom zračno-injektorskih mlaznica prilikom aplikacije u znatnoj mjeri smanjuje zračno zanošenje tekućine

u odnosu na standardne mlaznice. Prilagodba brzine zračne struje prema stadiju razvoja biljke s ciljem smanjenja zanošenja tekućine primjenjuju Zande i sur. (2014.). Smanjenje zanošenja na 5 m udaljenosti od zadnjega reda stabala u trajnome nasadu iznosilo je od 11 do 23% norme raspršivanja kod nasada u punoj lisnoj masi pri najvećoj brzini ventilatora. Prilagodbom izlazne brzine zraka u istome nasadu ostvareno je smanjenje zanošenja tekućine od 25 do 77%. Tablica 4 prikazuje rezultate testa $LSD_{0,05}$ za ispitivana svojstva depozita, zemljišnoga i zračnog zanošenja na 5 i 10 m udaljenosti od tretiranoga reda. Prema *ISO normi 22866:2005* uzorkovana površina za zemljišno zanošenje iznosi 1050 cm², za zračno zanošenje iznosi 350 cm², a za depozit tekućine u krošnji 420 cm². Srednje vrijednosti u tablicama predstavljaju ukupnu prikupljenu količinu tekućine na određenoj površini u μg .

Tablica 4. Test $LSD_{0,05}$ za glavne tehničke čimbenike raspršivanja.

Table 4. $LSD_{0,05}$ test for the main spraying factors.

Konvencionalni sustav / Conventional spraying									
Čimbenici raspršivanja Spraying factors		Zemljišno zanošenje Ground drift		Depozit Deposit		Zračno zanošenje - 5 m Air drift - 5 m		Zračno zanošenje - 10 m Air drift - 10 m	
		$LSD_{0,05}$	\bar{x}	$LSD_{0,05}$	\bar{x}	$LSD_{0,05}$	\bar{x}	$LSD_{0,05}$	\bar{x}
A	A ₁	222,63	25,55*	1 238,00	17,86 n. s.	76,94	16,90*	21,06	13,52 n. s.
	A ₂	144,25		1 220,13		48,50		13,31	
B	B ₁	202,88	36,01*	1 231,63	18,89 n. s.	82,81	13,17*	34,37	0,52*
	B ₂	164,00		1 228,75		42,63		0,00	
C	C ₁	207,50	34,42*	1 235,93	18,47 n. s.	69,38	19,32 n. s.	19,75	13,69 n. s.
	C ₂	159,38		1 224,87		56,06		14,63	
Senzorski sustav / Sensor spraying									
A	A ₁	127,69	27,61*	1 233,99	26,44 n. s.	24,94	12,11 n. s.	5,06	5,05 n. s.
	A ₂	88,53		1 214,75		17,94		2,00	
B	B ₁	130,71	25,71*	1 227,13	27,26 n. s.	34,31	7,83*	7,06	4,46*
	B ₂	82,88		1 229,96		8,56		0,00	
C	C ₁	126,53	27,60*	1 231,00	26,80 n. s.	30,62	10,33*	7,06	4,46*
	C ₂	87,31		1 215,74		12,25		0,00	

A - norma raspršivača (l ha⁻¹); B - tip mlaznice; C - brzina zračne struje (m s⁻¹)

A - spraying norm, (l ha⁻¹) B - nozzle type, C - air flow rate (m s⁻¹)

Testom $LSD_{0,05}$ ispitan je statistički značajan utjecaj unutar nezavisnih svojstva (glavnih tehničkih čimbenika raspršivanja) na zavisna svojstva istraživanja (zemljišno i zračno zanošenje, depozit). Tip mlaznice pokazuje statistički značajan utjecaj na sva svojstva zanošenja osim depozita, odnosno mlaznice *Lechler ITR 8002C* ostvaruju smanjeno zanošenje u svim slučajevima. Smanjenje brzine zračne struje povoljno je djelovalo na smanjenje zemljišnoga zanošenja kod oba sustava raspršivanja. Navedeni pozitivni utjecaj ostvaren je i kod zračnoga zano-

šenja pri korištenju senzora, dok je kod konvencionalnoga raspršivanja i depozita izostao. Smanjenje norme raspršivanja pozitivno je utjecalo na smanjenje zemljišnoga zanošenja i zračnoga zanošenja na 5 m bez korištenja senzora. Promjenom vrijednosti glavnih tehničkih čimbenika raspršivanja ostvareni se depozit tekućine u krošnji statistički značajno ne razlikuje kako kod konvencionalnoga, tako i kod senzorskoga sustava raspršivanja. Srednje vrijednosti u tablicama predstavljaju ukupnu prikupljenu količinu tekućine na određenoj površini u μg .

Tablica 5. Test $LSD_{0,05}$ za sustave raspršivanja korištenih u istraživanju.Table 5. $LSD_{0,05}$ test for spraying systems used in the research.

Sustav raspršivanja Spraying systems	Zemljišno zanošenje / Ground drift				Depozit / Deposit			
	\bar{x}	F-test	P	$LSD_{0,05}$	\bar{x}	F-test	p	$LSD_{0,05}$
Konvencionalni / Conventional	183,42	40,0	<,0001	23,45*	1 229,43	0,68	0,41	14,97 n. s.
Senzori / Sensors	109,24				1 223,27			
	Zračno zanošenje - 5 m Air drift - 5 m				Zračno zanošenje - 10 m Air drift - 10 m			
Konvencionalni / Conventional	64,12	62,39	<,0001	10,78*	17,22	14,74	0,0003	7,10*
Senzori / Sensors	21,43				3,51			

Tablica 5 prikazuje da su najmanje vrijednosti zemljišnoga i zračnog zanošenja tekućine ostvarene primjenom senzorskoga sustava raspršivanja. Testom $LSD_{0,05}$ utvrđeno je statistički značajno smanjenje zemljišnoga zanošenja tekućine uporabom senzorskoga sustava u odnosu na konvencionalni sustav ($LSD_{0,05}=23,45^*$). Za zračno zanošenje na 5 i 10 m također je utvrđeno statistički značajno smanjenje vrijednosti senzorskim načinom raspršivanja ($LSD_{0,05}=10,78^*$ i $LSD_{0,05}=7,10^*$). Depozit tekućine u krošnji nije se statistički značajno promijenio primjenom senzorskoga sustava u odnosu na konvencionalni sustav raspršivanja ($LSD_{0,05}=14,75$ n. s.). Vrlo slične rezultate ostvarili su Chen i sur. (2013.), koji su zabilježili smanjenje zemljišnoga zanošenja u voćnjaku jabuke od 68 pa sve do 90% primjenom varijabilne norme, dok je smanjenje zračnoga zanošenja iznosilo od 70 do 92%. Maghsoudi i sur. (2015.) prototipom raspršivača sa sustavom ultrazvučnih senzora za selektivnu aplikaciju također su ostvarili značajnu uštedu od 35,5% u odnosu na primijenjenu normu raspršivanja, bez značajne promjene kvalitete aplikacije. Usto, Solanelles i sur. (2006.) sustavom ultrazvučnih senzora u različitim nasadima (masliniku, nasadu kruške i jabuke) ostvarili su značajne uštede od 70, 28 i 39% u usporedbi s konvencionalnim načinom raspršivanja. Na slično smanjenje ukazuju Llorens i sur. (2011), pri čemu je ostvarena ušteda primijenjene norme raspršivanja slijedom selektivne aplikacije pomoću ultrazvučnih senzora radi određivanja veličine i oblika krošnje iznosila 58%. Smanjenje norme za više od 70% ostvarili su Jeon i sur. (2011.) te Jeon i Zhu (2012.), i to uporabom ultrazvučnih senzora u rasadniku. Koch i Weisser (2000.) ostvarili su smanjenje zanošenja tekućine od 50% uporabom elektivne aplikacije u voćnjaku višnje od fenološke faze cvjetanja do opadanja lišća.

ZAKLJUČAK

Prilagodba tehničkih čimbenika raspršivanja utjecala je na smanjenje zemljišnoga i zračnog zanošenja na 5 i 10 m udaljenosti od tretiranoga reda uporabom obaju sustava raspršivanja. Smanjenje zemljišnoga zanošenja iznosilo je od 19,16 do 36,59%, dok je smanjenje za zračno zanošenje na 5 m iznosilo od 19,19 do 75,05%. Maksimalno reduciranje zračnoga zanošenja od 100% na

10 m ostvareno je uporabom mlaznica *ITR* analizirajući oba sustava raspršivanja. Depozit tekućine u krošnji nije se statistički značajno mijenjao i nalazi se u rasponu od minimalnih 0,23 do maksimalnih 1,55%. Unaprijeđenjem konvencionalnoga raspršivača *Tifone* s ultrazvučnim senzorskim sustavom za selektivnu aplikaciju zemljišno je zanošenje smanjeno za 43,35%. U ovome slučaju zračno zanošenje na 5 m udaljenosti od tretiranoga reda smanjeno je za 66,57% te za 79,61% na udaljenosti od 10 m. Eksploatacija ultrazvučnoga senzorskoga sustava nije negativno utjecala na depozit u krošnji jer unutar dobivenih rezultata nije zabilježena značajna razlika između dvaju sustava raspršivanja. Prema zabilježenim rezultatima vremenskih uvjeta tijekom istraživanja utvrđeni su vrlo mali otkloni od onih idealnih. Opremanje konvencionalnih raspršivača naprednim sustavima za selektivnu aplikaciju značajno doprinosi preciznosti nanošenja sredstva za zaštitu bilja, a time i smanjenju negativnoga utjecaja na okoliš.

LITERATURA

- Banaj, A., Tadić, V., Petrović, D., Knežević, D., Banaj, Đ., & Duvnjak, V. (2016). Vertikalna raspodjela zračne struje kod raspršivača Agp 200 ENU i Tifone Vento 1500. *Proceedings of the 44th International Symposium on Agricultural Engineering "Actual Tasks on Agricultural Engineering"*, 167-175.
- Celen, I. H., Durgut, M. R., Avci, G. G., & Kilic, E. (2009). Effect of air assistance on deposition distribution on spraying by tunnel - type electrostatic sprayer. *African Journal of Agricultural Research*, 4(12): 1392-1397.
- Chen, Y. Zhu, H. Ozkan, H. E. Derksen, R. C. Krause, C. R. (2013). Spray drift and off-target loss reductions with a precision air-assisted sprayer. *Trans. ASABE*, 56(6), 1273-1281. <https://doi.org/10.13031/trans.56.10173>.
- Czacyk, Z. (2012). Influence of Air Flow Dynamics on Droplet Size in Condition of Air-assisted Sprayers. *Atomization and Sprays*, 22(4): 275-282. <https://doi.org/10.1615/AtomizSpr.v22.i4>.
- Cross, J. V., Walklate, P. J., Murray, R. A., & Richardson, G. M. (2003). Spray deposits and losses in different sized apple trees from an axial fan orchard sprayer. *Crop protection*, 25(2), 381-394. [https://doi.org/10.1016/S0261-2194\(02\)00192-8](https://doi.org/10.1016/S0261-2194(02)00192-8)

6. Doruchowski, G., Holownicki, R., Godyn, A., & Swiechowski, W. (2012). Calibration of orchard sprayers – the parameters and methods, *Fourth European Workshop on Standardised Procedure for the Inspection of sprayers, SPISE*, 4: 140-144.
7. Farooq, M., & Salyani, M. (2002). Spray Penetration into the Citrus Tree Canopy from Two Air - Carrier Sprayers, *ASAE Annual Conference and Trade Show*, 45(5), 1287-1293. <https://doi.org/10.13031/2013.11057>
8. Fritz, B. K., Hoffmann, W. C., Bagley, W. E., Kruger, G. R., Czaczyk, Z., & Henry, R. S. (2014). Measuring Droplet Size of Agricultural Spray Nozzles-measurement Distance and Airspeed Effects. *Atomization and Sprays*, 24(9), 747-760. <https://doi.org/10.1615/AtomizSpr.2014008424>
9. Gamarra-Diezma, J. L., Miranda-Fuentes, A., Llorens, J., Cuenca, A., Gregorio, L., Blanco-Roldán, G., & Rodríguez-Lizana, A. (2015). Testing Accuracy of Long-Range Ultrasonic Sensors for Olive Tree Canopy Measurements. *Sensors*, 15(2): 2902-2919. <https://doi.org/10.3390/s150202902>
10. Grella, G., Gallart, M., Marucco, P., Balsari, P., & Gil, E. (2017). Ground Deposition and Airborne Spray Drift Assessment in Vineyard and Orchard: The Influence of Environmental Variables and Sprayer Settings. *Sustainability*, 9(5), 728. 1-26. <https://doi.org/10.3390/su9050728>
11. ISO 22866 (2005). Equipment for crop protection-Methods for the field measurement of spray drift.
12. Jeon, H. Y., Zhu, H., Derksen, R. C., Ozkan, H. E., Krause, C. R., & Fox, R. D. (2011). Performance evaluation of a newly developed variable-rate sprayer for nursery liner applications. *Trans. ASABE*, 54(6), 1997-2007. <https://doi.org/10.13031/2013.40648>
13. Jeon, H. Y., & Zhu, H. (2012). Development of a variable-rate sprayer for nursery liner applications. *Trans. ASABE*, 55(1): 303-312. <https://doi.org/10.13031/2013.41240>
14. Jurišić, M., Šumanovac, L., Zimmer, D., & Barač, Ž. (2015). Tehnički i tehnološki aspekti pri zaštiti bilja u sustavu precizne poljoprivrede, *Poljoprivreda*, 21(1): 75-81. <http://doi.org/10.18047/poljo.21.1.12>
15. Koch, H., & Weisser, P. (2000). Sensor equipped orchard spraying-efficacy, savings and drift reduction. *Aspects of Applied Biology*, 57, 357-362.
16. Llorens, J., Gil, E., Llop, J., & Escola, A. (2011). Ultrasonic and LIDAR Sensors for Electronic Canopy Characterization in Vineyards: Advances to Improve Pesticide Application Methods. *Sensors*, 11(2), 2177-2194. <https://doi.org/10.3390/s110202177>
17. Llorens Calveras, J., Landers, A. J. & Larzelere, W. (2013). Precision application of pesticides in orchards - adjusting liquid flow. *NY Fruit Quarterly*, 21(4): 7-10.
18. Maghsoudi, H., Minaeia, S., Ghobadiana, B., & Masoudi, H. (2015). Ultrasonic sensing of pistachio canopy for low-volume precision spraying. *Computers and Electronics in Agriculture*, 112, 149-160. <https://doi.org/10.1016/j.compag.2014.12.015>
19. Miranda-Fuentes, A., Gamarra-Diezma, J. L., Blanco-Roldán, G. L., Cuenca, A., Llorens, J., Rodríguez-Lizana, A., ... & Gil-Ribes, J. A. (2015). Testing the influence of the air flow rate on spray deposit, coverage and losses to the ground in a super-intensive olive orchard in southern Spain. *SuproFruit 2015 - 13th Workshop on Spray Application in Fruit Growing*, *Julius-Kühn-Archiv*, 448, 17-18. <https://doi.org/10.5073/jka.2015.448.000>
20. Nuyttens, D., Sonck, B., de Schampheleire, V., Steurbaut, W., Baetens, K., Verboven, P., ... & Ramon, H. (2005). Spray drift as affected by meteorological conditions. *Communications in Agricultural and Applied Biological Sciences*, 70(4), 947-959.
21. Petrović, D., Banaj, Đ., Tadić, V., Knežević, D., & Banaj, A. (2018). Utjecaj tehničkih čimbenika raspršivanja na zemljišno i zračno zanošenje tekućine u nasadu višnje. 46. *Symposium "Actual Tasks on Agricultural Engineering"*, 213-222.
22. Salcedo, R., Garcera, C., Granell, R., Molto, E., & Chueca, P. (2015). Description of the airflow produced by an air-assisted sprayer during pesticide applications to citrus. *Spanish Journal of Agricultural Research*, 13(2), e0208. <http://doi.org/10.5424/sjar/2015132-6567>
23. Salyani, M., Sweeb, R.D., & Farooq, M., (2006). Comparison of string and ribbon samplers in orchard spray applications. *Transactions of the ASABE*, 49(6), 1705-1710. <https://doi.org/10.13031/2013.22287>
24. Solanelles, F., Escola, A., Planas, S., Rosell, J. R., Camp, F., & Gracia, F. (2006). An electronic control system for pesticide application proportional to the canopy width of tree crops. *Biosystems Engineering*, 95(4), 473-481. <https://doi.org/10.1016/j.biosystemseng.2006.08.004>
25. Štajnko, D., Berk, P., Lešnik, M., Jejčić, V., Lakota, M., Štrancar, A., ... & Rakun, J. (2012). Programmable ultrasonic sensing system for targeted spraying in orchards. *Sensors*, 12(11), 15500-15519. <https://doi.org/10.3390/s121115500>
26. Tadić, V. (2013). Utjecaj tehničkih čimbenika raspršivanja na pokrivenost lisne površine u trajnim nasadima. *Doktorska disertacija*, Poljoprivredni fakultet, Sveučilište Josipa Jurja Strossmayera, Osijek.
27. Tadić, V., Banaj, Đ., Petrović, D., Knežević, D., Lukinac Čačić, J., & Mendušić, I. (2014). Brzina i protok zraka s različitim tipovima raspršivača. *Agronomski glasnik*, 75(4): 181-196.
28. Vallet, A., & Tinet, C. (2013). Characteristics of droplets from single and twin jet air induction nozzles: a preliminary investigation. *Crop Protection*, 48, 63-68. <https://doi.org/10.1016/j.cropro.2013.02.010>
29. Vercruyssen, F., Steurbaut, W., Drieghe, S., & Dejonckheere, W. (1999). Off target ground deposits from spraying a semi-dwarf orchard. *Crop Protection*, 18(9): 565-570.
30. Zakon o održivoj uporabi pesticida (NN 14/14). Retrieved from <https://www.zakon.hr/z/703/Zakon-odr%C5%BEivoj-uporabi-pesticida>
31. Zande, J. C., Butler Ellis, M. C., Wenneker, M., Walklate, P. J., Kennedy, M. (2014). Spray drift and bystander risk from fruit crop spraying. *Aspects of Applied Biology*, 122: 177-186.
32. Zhu, H., Brazee, R. D., Derksen, R. C., Fox, R. D., Krause, C. R., Ozkan, H. E., & Losely, K. (2006). A specially designed air - assisted sprayer to improve spray penetration and air jet velocity distribution inside dense nursery crops, *Transactions of the ASABE*, 49(5): 1285-1294. <https://doi.org/10.13031/2013.22037>

IMPACT OF SELECTIVE APPLICATION WITH ULTRASONIC SENSORS ON DRIFT AND LIQUID DEPOSIT IN THE CHERRY ORCHARD

SUMMARY

In this research, the impact of two different spraying systems (classic and sensor with Tifone Vento 1500 air assisted sprayer) is shown on two types of drift (ground and air) and liquid deposit in the treetop. Technical spraying factors were set differently through the research according to treatments. The research was conducted according to ISO norm 22866 in a cherry orchard. With variance analysis, impact of spraying norm as factor A (A_1 - 250 l ha⁻¹; A_2 - 200 l ha⁻¹); nozzle type as factor B (B_1 - Lechler TR 8002C; B_2 - Lechler ITR 8002C) and air flow rate as factor C (C_1 - 18 m s⁻¹; C_2 - 12 m s⁻¹) was examined. Spraying was conducted with 4% dilution of tartazine organic dye, and drifted liquid was collected with filter papers. By optimizing the technical spraying factors, a maximum reduction of 36.59% for ground drift is achieved, as well as 75.05% for air drift at 5 m distance from the treated row. By exploiting the ultrasonic sensory system for selective application, ground drift was reduced by 43.35%. In this case the air drift at 5 m distance from the treated row was decreased by 66.57%, and 79.61% at a distance of 10 m. Maximum air drift reduction at 10 m was achieved by using an ITR nozzle for both spraying systems. The exploitation of ultrasonic sensory system did not have a negative effect on the deposit in the treetop, because no significant difference was found between these two spraying systems (0.5%). Equipping conventional sprayers with advanced systems for selective application greatly contributes to higher precision of pesticides application and with thereby reducing the negative impact on the environment.

Key words: sensors, selective application, liquid drift, spraying norm, air flow rate, air assisted sprayer, nozzles

(Primljeno 14. veljače 2019.; prihvaćeno 2. travnja 2019. - Received on February 14, 2019; accepted on April 2, 2019)