

IDENTIFIKACIJA OBMOČIJ VETROLOMA NA PODLAGI ČASOVNE VRSTE S PODATKI C-SAR

WINDTHROW IDENTIFICATION WITH C-SAR TIME SERIES

Alen Mangafić, Martin Puhar, Blaž Barborič

UDK: 528.8

Klasifikacija prispevka po COBISS.SI: 1.03

Prispelo: 14. 2. 2020

Sprejeto: 17. 8. 2020

DOI: 10.15292/geodetski-vestnik.2020.03.335-347

SHORT SCIENTIFIC ARTICLE

Received: 14. 2. 2020

Accepted: 17. 8. 2020

IZVLEČEK

V noči med 29. in 30. oktobrom 2018 je več gozdnih območij v Sloveniji in severni Italiji prizadel močan vetrolom. V članku predlagamo novo metodologijo za identifikacijo območij vetroloma. Predlagamo nova indeksa: PCA-CI za identificiranje območij večjih sprememb in PCA-WI za identificiranje območij vetroloma na podlagi časovne vrste podatkov C-SAR satelita Sentinel-1. V primerjavi z dosedanjimi študijami identificiranja vetrolomov predlagana metodologija ne odšteva kanalov dvopolnih in enopolnih kombinacij VH-VV, temveč predlaga nov pristop z multivariantno transformacijo zmanjševanja dimenzionalnosti časovnih vrst posameznih dvopolnih in enopolnih kombinacij v dveh obdobjih.

ABSTRACT

A strong windthrow affected many forests in Slovenia and northern Italy on the night of the 29th and the 30th of October, 2018. In this paper, we propose a new methodology for windthrow identification, comprising two new indexes, PCA-CI for evaluating change detection and PCA-WI for the identification of windthrows by analysing the time series of C-SAR Sentinel-1 data. The proposed methodology, unlike the previous studies on the identification of windthrows, does not subtract the values of dual and single polarised VH-VV data combinations, but proposes a new approach with a multivariate transformation of dimensionality reduction of the time series of the dual and single polarised data in two different time frames.

KLJUČNE BESEDE

vetrolom, časovna vrsta, SAR, C-SAR, radar, Sentinel-1, daljinsko zaznavanje

KEY WORDS

windthrow, time series, SAR, C-SAR, radar, Sentinel-1, remote sensing

1 UVOD

Problematiko vetroloma smo obravnavali v okviru projekta HARMO-DATA, ki je del programa Interreg V-A Italija-Slovenija 2014–2020. Eden izmed glavnih ciljev projekta je bil okrepitev zmogljivosti institucionalnega sodelovanja za učinkovito upravljanje prostora na čezmejnem območju. V projektu je sodelovalo šest partnerjev iz Slovenije (Geodetski inštitut Slovenije, Geodetska uprava RS in podjetje Igea d.o.o.), partnerja iz italijanske regije Furlanije - Julisce krajine (podjetje Insel in Univerza v Trstu) in regije Benečija (podjetje Terre). Del projekta HARMO-DATA je bil namenjen obravnavi podatkov, ki so na voljo prek platforme Copernicus. Glavni poudarek raziskave so možnosti uporabe teh podatkov pri različnih aktivnostih, povezanih z ukrepanjem ob ogroženosti zaradi naravnih nesreč in ob izrednih dogodkih na čezmejnem območju, med katere spada tudi močan vetrogom, ki je prizadel več gozdnih območij v Sloveniji in severni Italiji v noči med 29. in 30. oktobrom 2018. Ta ekstremni vremenski pojav je bil del širšega vremenskega dogajanja, ki so ga vremenoslovci poimenovali nevihta Adrian in se je začelo 28. oktobra 2018 z močno nevihto nad zahodnim delom Sredozemlja in končalo 3. novembra 2018 nad Islandijo (Météo-France, 2018; BBC, 2018). Nevihta je bila klasificirana kot orkan 3. kategorije po Saffir-Simpsonovi lestvici orkanov (od petih kategorij) in je v več državah povzročila zelo veliko gospodarsko škodo, ki je bila skupno ocenjena na 3,3 milijarde evrov. V Italiji je zahtevala enajst smrtnih žrtev, takrat je na primer tudi močno poplavilo Benetke. Podrobnejšo oceno škode, ki jo je povzročil vetrogom v okviru opisanega vremenskega dogajanja, je izdelal Zavod za gozdove Slovenije (ZGS). V njej je navedeno, da je bilo poškodovanih 280.000 kubičnih metrov drevja, pri čemer je bilo večji del (90 %) iglavcev. Najobsežnejše poškodbe so nastale na slovenjegraškem območju, v zgornji Mežiški dolini (Koprivna, slika 1), na območju Bohinja in Bleda ter na Postojnskem. Močneje poškodovanih je bilo 12.000 hektarjev površin, popolnoma ogolelih je bilo 164 hektarjev gozda, od tega 150 hektarjev na Koroškem. Škoda je bila ocenjena na 5,6 milijona evrov. ZGS je oceno izvedel za posamezne gozdne odseke na območjih, ki jih je prizadel vetrogom (ZGS, 2018a; Dnevnik, 2018; Koroške novice, 2018).



Slika 1: Zaradi vetroloma močno prizadeta Koprivna na Koroškem (levo) in Cal Visende v Benečiji (desno). Vira: Koroške novice, 2018; Italy Magazine, 2018.

2 TEORETIČNO IN TEHNOLOŠKO OZADJE

V nadaljevanju obravnavamo problematiko identifikacije območij vetroloma, ki smo jo izvedli z analizo časovnih vrst radarovih podatkov. Ozadje pojava, uporabljeni tehnologiji in pregled študijskih primerov so podrobneje opisani v podpoglajvih.

2.1 Vetrolomi

Naravne ujme pomenijo veliko težavo pri upravljanju z gozdovi in se mnogokrat prepletajo, na primer poplave s plazovi, usadi, obilnimi padavinami in vetrom (Preslica, 2019). V članku se osredotočamo na vetrolome, ki so v zadnjih letih vse pogosteja vrsta naravne ujme v Sloveniji. O vetrolomu govorimo, kadar močan veter poškoduje ali uniči drevesa v gozdu. Veter lahko drevesa izruva iz tal, odlomi pri panju ali pa prelomi debla. Te poškodbe so pogubne, saj drevesa običajno odmrejo takoj ali pa životarijo še nekaj let, preden dokončno odmrejo (Preslica, 2019). Vetrolomi so v slovenskih gozdovih relativno pogost pojav predvsem na območjih, kjer ni ustrezne drevesne sestave. Najpogosteje prizadenejo enomerne gozdove ene drevesne vrste. Pri tem so najbolj izpostavljeni umečno zasajeni smrekovi gozdovi. Vetrolomi so pogosti na grebenih, okoli vrhov, na zaobljenih hribih, gorskih sedlih in hrbitih. Glede na veter in gibanje najmočnejših sunkov je lahko drevje uničeno na obsežnih površinah ali pa v ozkih pasovih (Preslica, 2019). Z naravnimi ujmami v gozdovih Slovenije se strokovno ukvarjajo na Zavodu za gozdove Slovenije, kjer spremljajo posek gozda zaradi naravnih ujm.

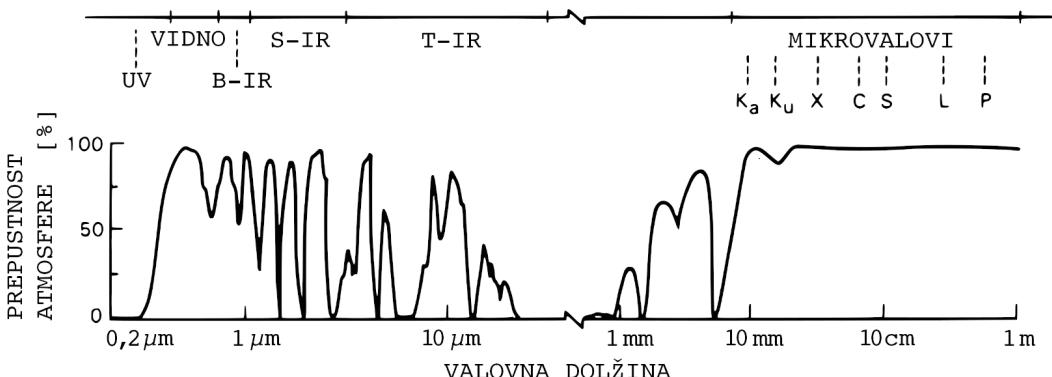
Najhujši vetrolom v zadnjih dvajsetih letih se je zgodil med 11. in 13. decembrom 2017 (Breznikar, 2018). Poškodbe gozdov, ki jih je takrat povzročil veter, so presegale do tedaj znane poškodbe zaradi vetrolomov tako po količini poškodovanega drevja kot po obsegu prizadete površine. Veter je močneje prizadel gozd na približno petini gozdnih površin v Sloveniji in poškodoval za 2,2 milijona m³ drevja (Breznikar, 2018). Najbolj so bili poškodovani gozdovi na Kočevskem, Notranjskem in Koroškem, močno poškodovana so bila tudi območja gozdov na Jezerskem, Solčavskem in v Dravski dolini. Poškodbe so bile prisotne tudi v drugih predelih Slovenije, še najmanj so bili poškodovani gozdovi na vzhodu države. Zaradi vetrolomov sicer izstopajo leta od 2003 do 2008. Nastajali so večinoma razpršeno po vsej Sloveniji, najhujše so bile poškodbe v letih 2006 in 2008. V letu 2006 je močan veter konec junija podrl 85.000 m³ lesne mase na Jelovici (160 hektarjev poškodovane površine). V neurjih poleti 2008 je bilo poškodovanih 20.000 hektarjev gozdov s 500.000 m³ lesne mase. Popolnoma uničenih je bilo približno 700 hektarjev gozda. Največje poškodbe so bile na območju prelaza Črnivec med Kamnikom in Gornjim Gradom. Sečna zaradi plazov in usadov je pri tem v primerjavi s sečnjo zaradi drugih naravnih ujm zanemarljiva (Jakša, 2009). Močan vetrolom je prizadel več gozdnih območij v Sloveniji in severni Italiji v noči med 28. oktobrom in 30. novembrom 2018.

2.2 Tehnologija SAR pri spremljanju površja

Senzorji, ki sestavljajo sisteme daljinskega zaznavanja, so lahko aktivni ali pasivni. Slednji za zajem podob potrebujejo zunanjji vir elektromagnetnega valovanja, ki osvetli predmet opazovanja. Vir elektromagnetnega valovanja za multispektralne senzorje je Sonce, kar pomeni, da z njimi lahko snemamo le podnevi, podobe pa se radiometrično med seboj razlikujejo tudi zaradi tega, ker so bile posnete ob različnih delih dneva in različnih razmerah v atmosferi. Dodatna velika omejitev pasivnih senzorjev je, da del spektra elektromagnetnega valovanja, v katerem delujejo, tj. valovne dolžine od vidne svetlobe do dolgovalovne infrardeče svetlobe, ne prodira skozi oblake in ni na območju atmosferskih oken s popolno prepustnostjo (slika 2). To pomeni, da obdobja oblačnosti še dodatno zmanjšujejo čas, v

katerem je mogoče uporabljati sisteme daljinskega zaznavanja s pasivnimi senzorji. Primeri aktivnih senzorjev so radarji, ki predmet opazovanja osvetlijo z elektromagnetnim valovanjem iz mikrovalovnega dela spektra. Mikrovalovi v primerjavi z vidno in infrardečo svetlobo prodirajo skozi oblake, meglice, prah in dež.

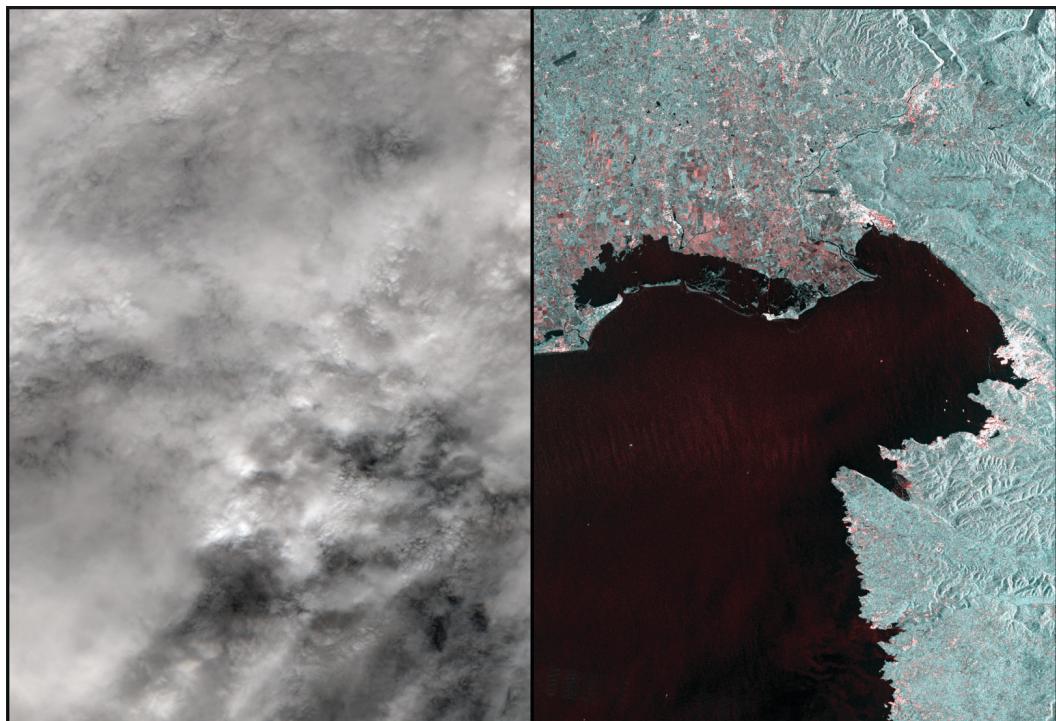
Radar z umetno odprtino (v nadaljevanju: SAR) je aktivni instrument bočnega pogleda, ki oddaja kratke mikrovalovne impulze z valovno dolžino od enega centimetra do enega metra in sprejema njihov odboj. Oddani impulzi so polarizirani vodoravno (H) in/ali navpično (V), sprejem odbitih impulzov je prav tako ločen na vertikalno in/ali horizontalno polarizacijo. Pri obdelavi posnetkov SAR uporabljam različne mere odbojnosti, kot so β , γ in σ . Med seboj se razlikujejo po ploskvi, ki se uporabi za normalizacijo vrednosti odbojev (Henderson et al., 1998; Ošir et al., 2006; Spoto et al., 2012). Radarji delujejo pri različnih valovnih dolžinah, pri katerih se je *de facto* uveljavila neuradna radarska referenčna nomenklatura, sestavljena iz pasov K_a, K_u, X, C, S, L in P (Henderson et al., 1998). Prepustnost atmosfere za različne valovne dolžine, od ultravijoličnega valovanja do mikrovalov, je prikazana na sliki 2. Podoba, pridobljena s SAR, je pravokotna rastrska podoba, katere vrednosti celic so kompleksna števila, iz katerih dobimo informacijo o amplitudi in fazi odbitega valovanja. Faza odbitega valovanja je odvisna od valovne dolžine radarskega sistema ter razdalje med oddajnikom radarskega valovanja in odbojnikom na Zemlji (Rojko, 2016). Amplituda odbitega valovanja je odvisna od geometričnih (na primer vpadnega kota, hrapavosti) in dielektričnih lastnosti odbojnega površja (Henderson et al., 1998).



Slika 2: Prepustnost atmosfere za različne valovne dolžine (NASA, 1989).

SAR omogoča zajem podatkov tako podnevi kot ponoči in v vseh atmosferskih razmerah. Spremljanje prostora s satelitskimi posnetki je najučinkovitejše, ko imamo na voljo časovne vrste podatkov. Časovne vrste multispektralnih podatkov omogočajo najrazličnejše analize, njihova slabost je, da imajo številne vrzeli, ki so posledica oblačnega vremena, to pa je v visokogorju še posebej pogosto. Stalno spremeljanje visokogorskih gozdov v alpskih državah je tako mogoče le z analizo radarskih časovnih vrst v kombinaciji z drugimi podatki (na primer multispektralnimi, hiperspektralnimi, lidarskimi in terenskimi). Prednost tehnologije SAR v primerjavi z multispektralnim snemanjem lahko vidimo na sliki 3, kjer sta prikazana izdelka obeh tehnologij, zajeta med nevihto 28. oktobra 2018.

Različne valovne dolžine imajo različno interakcijo s površjem. Ena izmed pomembnih razlik je razlika v globini prodiranja skozi vegetacijo. Zaradi tega je optimalna izbira instrumenta odvisna od raziskovalne študije. Valovi X-SAR (na primer TerraSAR-X) se odbijajo od vrha krošenj, medtem ko L-SAR (na primer ALOS – PALSAR) skoznje prodirajo (Cartus et al., 2012; Eineder et al., 2019). Kombinacija senzorjev X-SAR in L-SAR omogoča oceno prostornine biomase. Pomemben dejavnik pri izbiri instrumenta je tudi časovna ločljivost, saj goste časovne vrste omogočajo boljše spremeljanje sprememb v prostoru. Poleg tehničnih specifikacij je pomemben tudi finančni dejavnik, ki je velikokrat ključen pri izbiri vira podatkov. Za namene raziskave takšnih sprememb površja, kot je identifikacija vetroloma, bi bila optimalna, a glede na ponudnika storitev izredno draga, izbira senzorja X-SAR. Alternativa so prosto dostopni podatki, kot so podatki programa Evropske vesoljske agencije (ESA) za opazovanje Zemlje Copernicus. ESA ponuja brezplačne izdelke visoke časovne ločljivosti C-SAR konstelacije Sentinel-1. Specifikacije in podrobnosti konstelacije Sentinel-1 in njegovih izdelkov podrobnejše opisujemo v podpoglavlju 2.3.



Slika 3: Satelitski posnetki Sentinel-2 (levo) in Sentinel-1 (desno) površja severnega dela Jadrana med nevihto Adrian 28. oktobra 2018.

2.3 Sentinel-1

Sentinel-1 je Copernicusova konstelacija, sestavljena iz dveh satelitov (1A in 1B, za prihodnost sta navedana še 1C in 1D), ki sta opremljena z instrumentom tipa C-SAR in okrog Zemlje krožita na višini 693 kilometrov. Časovna ločljivost posameznega satelita je 12 dni, skupni obhodni čas pa znaša 6 dni. Frekvenca instrumentov je 5,405 GHz in zajemajo podatke v štirih načinih zajema. Copernicusove storitve ponujajo dostop do treh ravni obdelanosti: surovi podatki, SLC in GRD. Podatki SLC (angl. *single look*

complex) vsebujejo poševne razdalje ter podatke o fazi in amplitudi. Podatki GRD (angl. *ground range detected*) so zajeti, večkratno pogledani (angl. *multi-looked*) in projicirani na referenčni elipsoid WGS 84. Ločljivost prevzorčenih celic je 10×10 metrov, celice pa vsebujejo informacijo o amplitudi odbitega valovanja. Polarizaciji, uporabljeni pri oddaji in sprejemu signala, sta navpična (V) in vodoravna (H), torej imamo možnost kombiniranja V in H pri oddanem in sprejetem valovanju (enopolne in dvopolne kombinacije: VV, HH, VH, HV) (Torres et al., 2012; Rojko, 2016; Rossi, 2015; ESA, 2020). Kombinacije produktov in njihove transformacije se razlikujejo glede na tip raziskave. V naslednjem podoglavlju predstavljamo nekatere študijske primere uporabe radarskih časovnih vrst za namene spremeljanja gozdov.

2.4 Časovne vrste radarskih posnetkov

Obstajajo različni pristopi k analiziranju časovne spremembe pikslov. Odvisni so od dolžine niza časovne vrste in intervala med pridobljenimi podatki. Glede na študijske primere lahko ločimo analizo dosedanjih dogodkov (na primer iskanje maksimalne magnitude posameznega dogodka) ali napovedovalne analize prihodnjih trendov (na primer iskanje anomalij pri cikličnih dogodkih). Analize sprememb pikslov izvajamo s primerjanjem statističnih kazalcev vrednosti pikslov (na primer MVA – minimalne, maksimalne in srednje odbojne letne vrednosti; Quegan et al., 2000), njihove okolice ali objektov (na primer OBIA TWDTW; Belgiaj in Csillik, 2018). Spremembe lahko zaznavamo s statističnim modeliranjem (na primer uporabo regresijskega modela) ali kompleksnejšimi metodami strojnega učenja (na primer globokim učenjem GRU; Niculescu et al., 2018).

Obstaja več študijskih primerov, ki so pokazali učinkovitost radarskih časovnih vrst za spremeljanje gozdov. Quegan et al. (2000) so prikazali uporabnost polarizacije VH in njene binarne klasifikacije glede na razlike med dvopolnimi in enopolnimi kombinacijami. V študiji so ugotovili, da je na območju gozdov vrednost dvopolne kombinacije VH vedno nižja od 2 dB. Razlike v VH in VV so uporabljene v različnih študijah z namenom ovrednotenja biomase in njihovo vrednost lahko definiramo z različnimi transformacijami in algoritmi (na primer algoritmom BIOMASAR; Santoro et al., 2010). Primer študije, namenjene identifikaciji vetroloma, so izvedli Eriksson et al. (2012), kjer so pokazali, da je z visoko ločljivimi posnetki SAR mogoče identificirati vetrolome. Rüetschi et al. (2019) so v nadaljevanju raziskali uporabnost Sentinel-1 pri identifikaciji vetroloma. Njihova časovna vrsta je bila sestavljena iz razlik dvopolnih in enopolnih vrednosti mere odbojnosti γ zaporednih podatkov IW GRDH. Predlagali so indeks vetrolomov (WI):

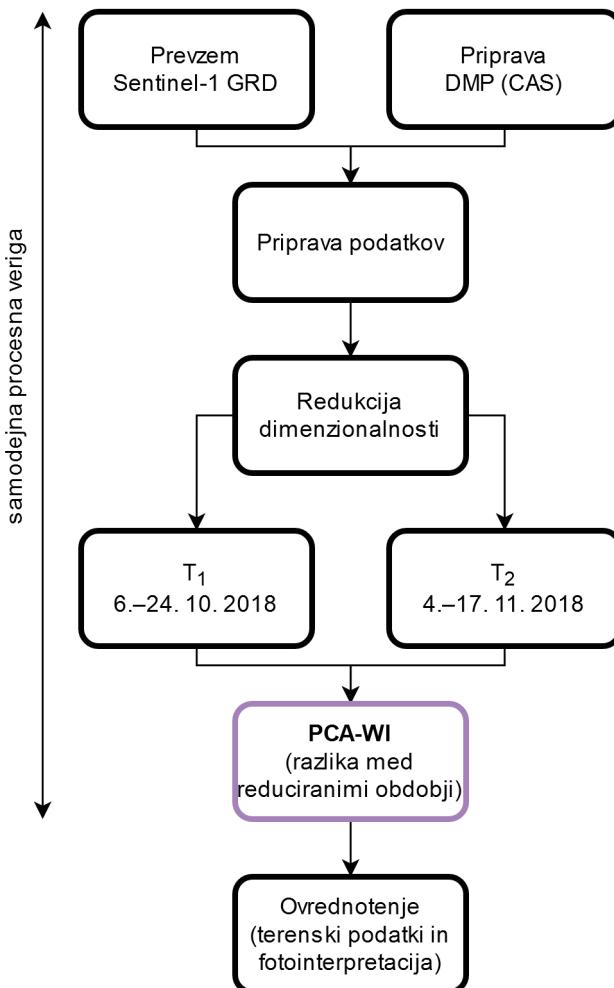
$$WI = (\gamma_{LRW,VV,T_2}^0 - \gamma_{LRW,VV,T_2}^0) + (\gamma_{LRW,VV,T_1}^0 - \gamma_{LRW,VV,T_1}^0),$$

kjer je γ_{LRW}^0 časovni kompozit vseh γ^0 odbojnosti časovne vrste, T_1 in T_2 pa predstavljata podatke pred vetrolomom in po njem. Pri terenskih podatkih so uporabljali digitalne modele površja ločljivosti 2 metra in 25 metrov, ki so jih z bilinearno interpolacijo prevzorčili na ločljivost 10 metrov. Njihova študija se je izkazala kot učinkovita za kartiranje vetrolomov, večjih od 0,5 hektarjev (85-odstotna natančnost). Povprečna vrednost WI na območjih vetroloma je bila enaka ali večja od 0,5 dB (Rüetschi et al., 2019). Težava glede uporabnosti njihove raziskave je, da je metoda zasnovana za časovno serijo, ki zahteva 5 posnetkov pred dogodkom in 10 posnetkov po njem. Pri Sentinel-1 to pomeni, da lahko z analizo WI posredujemo rezultate pristojni službi približno dva meseca po dogodku, kar je preveč časa za ustrezен odziv. V tem obdobju bi najverjetneje imeli na voljo že ustrezno pokritost z brezoblačnimi optičnimi

posnetki Sentinel-2, na podlagi katerih lahko tudi identificiramo vetrolome, tako z izračunom kot fotointerpretacijo (na primer AlpMon, 2018). V članku predlagamo pristop detekcije vetrolomov, s katerim nadgrajujemo metodologijo, ki jo predlagajo Rüetschi et al. (2019). Namen naše nadgradnje je pridobiti čim več informacij iz podatkov, ki so sestavljeni iz krajše časovne vrste, in torej skrajšati čas do pridobitve rezultatov, uporabnih za odločanje in izvajanje ukrepov. V našem primeru ponujamo indeks, ki je lahko uporaben za oceno poškodovanih območij in s katerim je mogoče zmanjšati obseg terenskih kontrol ter posledično skrajšati čas, v katerem pristojne službe izdelajo sanacijske načrte. Metodologijo in postopek izračuna opišemo v poglavju 3.

3 METODE

Identifikacijo območij vetroloma smo izvedli z analizo časovnih vrst radarovih podatkov. Diagram raziskovalnega načrta je prikazan na sliki 4.



Slika 4: Diagram raziskovalnega načrta.

Pri predlagani metodologiji identifikacije območij vetroloma se uporablajo do sedaj preverjeni vhodni podatki, in sicer razlike med VH in VV (Quegan et al., 2000; Eriksson et al., 2012; Rüetschi et al., 2019). Pri tem smo nadgradili pristop primerjave časovnih obdobjij, pri katerem kanalov dvopolnih in enopolnih kombinacij ne odštevamo, temveč z multivariantno transformacijo zmanjšujemo dimenzionalnost časovnih kombinacij VH-VV v dveh obdobjih.

3.1 Predlagana indeksa

Domnevamo, da so vrednosti pikslov VH in VV na območjih, na katerih se je topografija spremenila, bolj razprtene in torej manj korelirane. To pomeni tudi, da imajo območja večjih sprememb večje vrednosti po redukcijah dimenzionalnosti, kot je analiza glavnih komponent (angl. *principal component analysis*, PCA). PCA zmanjša korelacijo med posameznimi kovariatami tako, da transformira potencialno korelirano množico podatkov v množico linearne nekorelirane spremenljivke oziroma v glavne komponente. S transformacijo se odstranijo nadstevilni podatki ter zmanjša koreacija med posameznimi VH- in VV-kanali. Tako zagotovimo enodimenzionalni kompozit normaliziranih časovnih vrst dveh obdobjij, ki pojasnjuje večji del razpršenosti vhodnih podatkov oziroma ima največjo informacijsko gostoto (Hotelling, 1933; Oštir, 2006; Mesner, 2016).

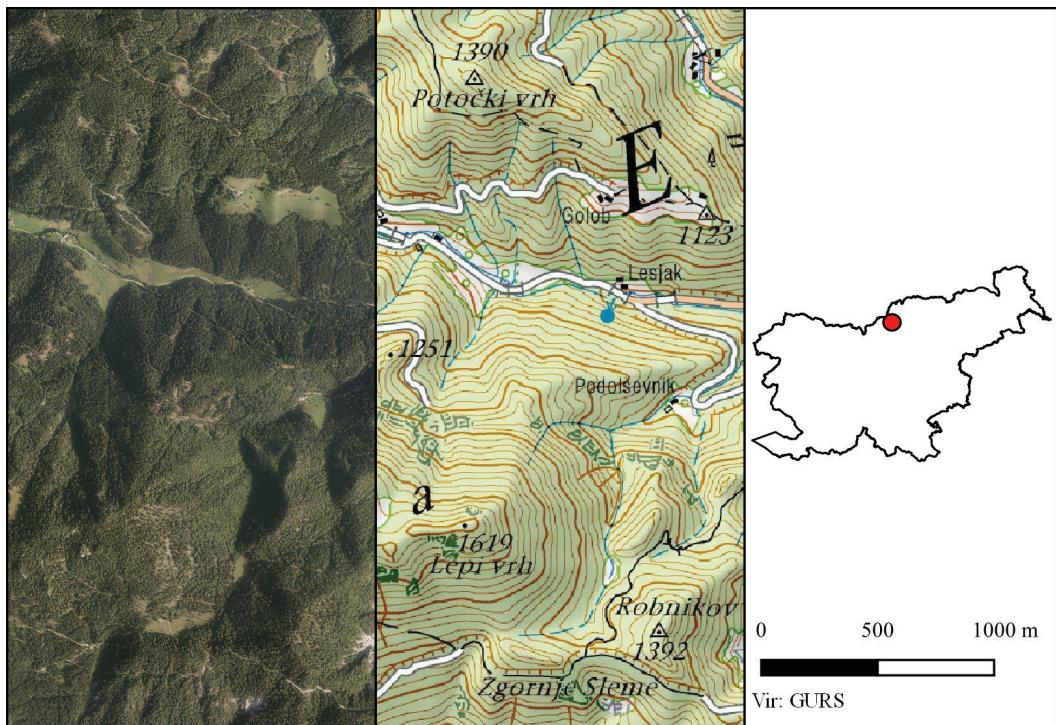
Predlagamo nova indeksa – PCA-CI (angl. *PCA change index*) in PCA-WI (angl. *PCA windthrow index*):

$$PCA-CI = PCA(PCA(\gamma_{VH,T_1}^0), PCA(\gamma_{VV,T_1}^0)) - PCA(PCA(\gamma_{VH,T_2}^0), PCA(\gamma_{VV,T_2}^0))Z, \quad (1)$$

$$PCA-WI_a = |PCA-CI| \quad (2)$$

$$PCA-WI_r = \frac{|PCA-CI| - \min|PCA-CI|}{\max|PCA-CI| - \min|PCA-CI|} \quad (3)$$

kjer je $PCA(x, y)$ prva normalizirana glavna komponenta (PCA-1). Vhodni vzorec smo, tako kot Rüetschi et al. (2019), razdelili na dva dela, T_1 in T_2 , ki predstavlja podatke pred vetrolomom in po njem. Glavno komponento najprej izračunamo posamezno za odboje γ^0 dvopolnih in enopolnih kombinacij, nato še za vsako časovno obdobje združenih PCA-1 posebej. PCA-CI predstavlja razlike vrednosti glavnih komponent enopolnih in dvopolnih kombinacij časovnih obdobjij pred dogodkom in po njem ter posledično prikazuje območja, ki so doživelja največjo spremembu med obdobjji. PCA-WI izračunamo kot absolutno vrednost PCA-CI, saj pri vetrolому domnevamo, da smer razpršenosti spremenljivke ni pomembna, v prvem koraku nas namreč ne zanima, ali je drevo izruvano ali prelomljeno, temveč le velikost spremembe. Zaloga vrednosti PCA-WI je med 0 in 1. PCA-WI_a je absolutni indeks in je primeren za primerjavo različnih dogodkov, ki imajo različne magnitude, lokacije in čase. PCA-WI_r je relativni indeks in je primeren za lažjo interpretacijo dogodka na specifičnem območju v specifičnem času, saj je rezultat normalizacije *Min-Max*. Normalizacijo izvajamo na podatkih, ki so inverzno maskirani (maskirana območja so na slikah 5, 6 in 7 označena s črno) ter vsebujejo informacije le na gozdnih sestojih. Časovna vrsta je sestavljena iz osmih posnetkov (naraščajoče in padajoče tirnice, od 6. do 24. oktobra 2018) pred dogodkom in šestih posnetkov (naraščajoče in padajoče, od 4. do 17. novembra 2018) po dogodku študijskega območja, prikazanega na sliki 5. Posnetkov iz 29. in 30. oktobra 2018 nismo upoštevali, ker ne vemo, za katero obdobje, T_1 ali T_2 , bi jih upoštevali. Proses obdelave podatkov opisujemo v nadaljevanju.



Slika 5: Študijsko območje.

3.2 Priprava vhodnih podatkov in vmesni rezultati

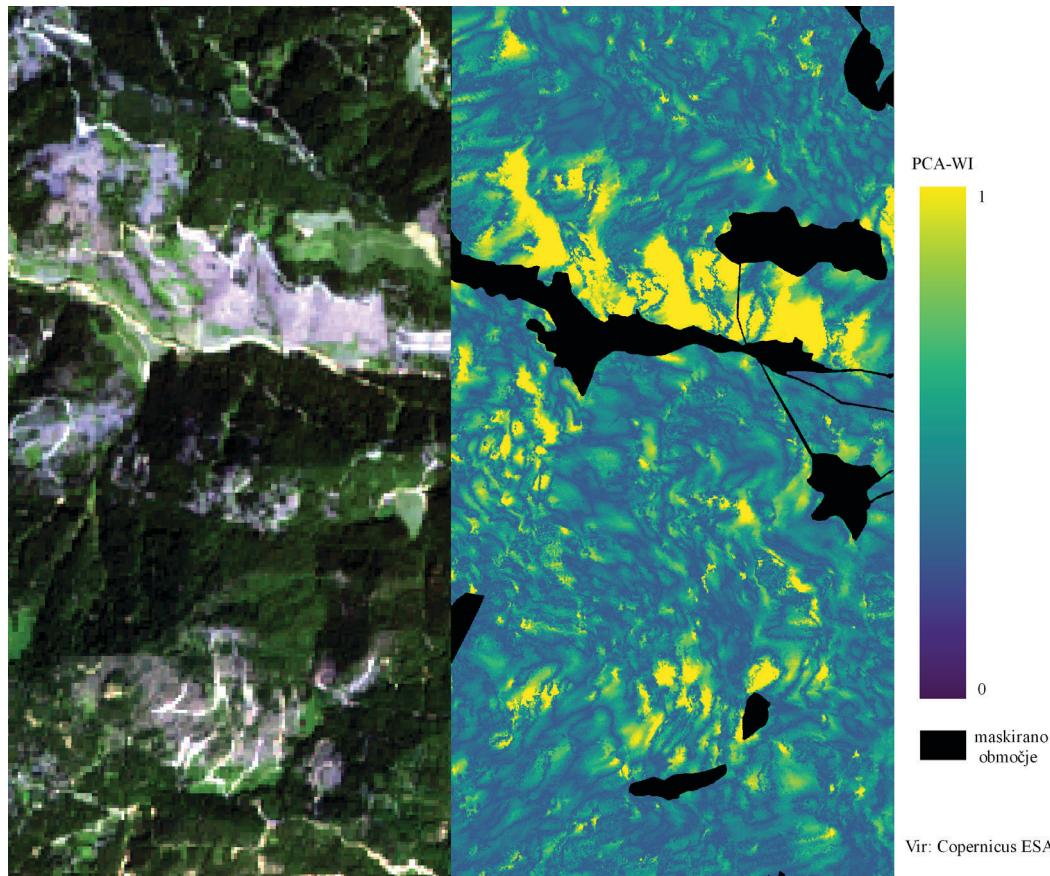
Podatke Sentinel-1 GRD smo obdelali po naslednji korakih:

1. posodabljanje s preciznimi tirnicami;
2. radiometrična kalibracija VH in VV v odboja γ^0 (Laur et al., 2004);
3. radiometrični terenski popravek odboja na podlagi digitalnega modela površja ločljivosti 1 m;
4. odstranjevanje pegastega šuma z uporabo »enkrat pogledanega« filtra Lee-Sigma s parametri: premično okno velikosti 7×7 , tarča velikosti 3×3 in vrednost $\sigma = 0,9$;
5. geometrični terenski popravek *Range-Doppler* z radiometrično normalizacijo na podlagi digitalnega modela površja ločljivosti 1 m;
6. transformacija iz linearnih vrednosti v decibele.

V nasprotju z raziskavami Quegan et al. (2000), Eriksson et al. (2012), Rüetschi et al. (2019) predlagamo enočasovno odstranjevanje šuma ter geometrični terenski popravek *Range-Doppler* (Logan, 1995). Odstranjevanje pegastega šuma z enočasovnim filtrom izvajamo, ker lahko večasovni filtri minimalne razlike v pikslih identificirajo kot šum in jih odstranijo (Mirelva et al., 2017). Dodatni geometrični popravek je potreben, ker študijsko območje stoji v visokogorju. V navedenih raziskavah so študijski primeri obravnavali ravninska območja, zato dodatni terenski popravki niso bili izvedeni.

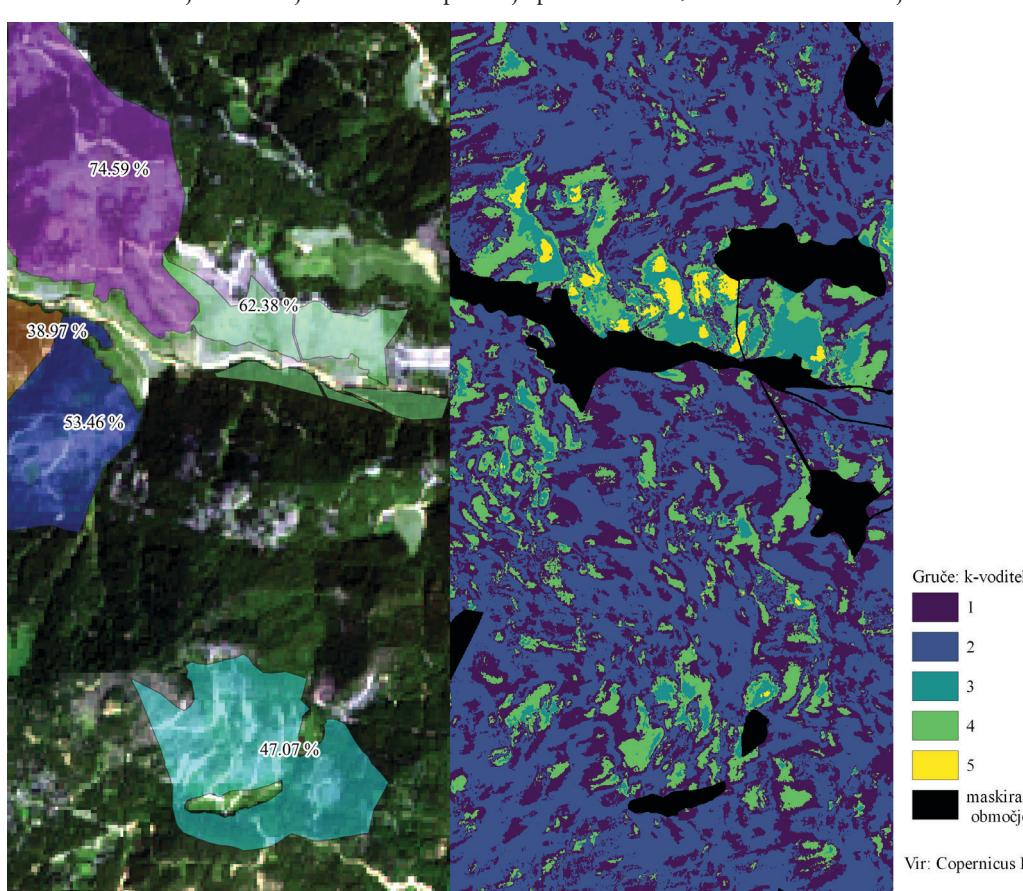
4 REZULTATI IN NJIHOVO OVREDNOTENJE

PCA-WI je rastrski sloj, ki vsebuje vrednosti o obsegu spremembe na območju. Rezultate smo najprej primerjali s prvim brezoblačnim posnetkom Sentinel-2 iz 30. junija 2019 (slika 6).



Slika 6: Primerjava posnetka Sentinel-2 in rastrskega sloja PCA-WI za študijsko območje s slike 5.

Pri fotointerpretaciji lahko opazimo, da so območja, ki so najbolj prizadeta z vetrolomom (slika 5 prikazuje stanje pred tem), skladna z najvišjimi vrednostmi indeksa PCA-WI_r. Vrednosti smo primerjali s podatki terenske kontrole ZGS, ki vsebujejo areale območij vetroloma s pripisanim odstotkom poškodovanih dreves. Vrednosti PCA-WI_r na območju smo primerjali z odstotkom poškodovanih dreves z uporabo Kendallovega (τ) in Pearsonovega korelacijskega koeficienta (ρ). Vrednost korelacijskega koeficiente τ je popolna (1), medtem ko je vrednost ρ 0,96. Kendallov korelacijski koeficient je primernejši za manjše vzorce od Pearsonovega (Bonnet et al., 2000). Na podlagi izračunanega lahko trdimo, da je skladnost terenskih kontrol z vrednostmi našega indeksa boljša od 0,96. V nadaljevanju smo še pregledali gruče najbolj poškodovanih območij. PCA-WI_r smo samodejno klasificirali z metodo gručenja k-voditeljev (angl. *k-means*, Rubin, 1967) v pet razredov. Izbrana je metoda k-voditeljev, ker PCA in k-voditelji izvajajo primerljivo objektno transformacijo, pri čemer k-voditelji izvajajo diskretno transformacijo, PCA pa zvezno (Ding in He, 2004). Na sliki 7 lahko vidimo, da gruče, ki predstavljajo najmočnejše spremembe



Slika 7: Primerjava terenskih kontrol ZGS (levo) in gruč PCA-WI.

5 SKLEP

Predlagana metoda obdelave časovnih vrst podatkov C-SAR s pridobivanjem indeksa PCA-WI se je izkazala kot izjemno koristna pri identifikaciji območij vetroloma, saj omogoča hitro ugotavljanje najbolj prizadetih območij. Tovrstni rezultati so lahko podlaga za optimizacijo operacij pristojnih služb. Na podlagi izjemno visoke korelacije s terenskimi podatki domnevamo, da PCA-WI omogoča izvajanje napovedi odstotka poškodovanih dreves. Ocene poškodovanih območij trenutno potekajo le s terenskimi analizami. S kombinacijo terenskih analiz in predstavljenih analiz podatkov daljinskega zaznavanja bi lahko zmanjšali stroške in pospešili izvedbo sanacijskih načrtov. Rezultati raziskave odpirajo nova vprašanja, kot je na primer preizkus uporabe PCA-WI-gruč, združenih z metodo k-voditeljev, kot objektov za strojno učenje

pikselskih ali objektnih klasifikatorjev (na primer z metodo podpornih vektorjev in naključnimi gozdovi). Tako bi lahko izračunali odstotke poškodovanih dreves na poljubnih arealih. Identifikacija območij vetroloma je bila izvedena z analizo podatkov, ki so bili na voljo 18 dni po dogodku. Zanimivo bi bilo izvesti študijo, s katero bi ocenili možnost identifikacije območij vetroloma v še krajšem času po dogodku in ovrednotili, kako se spreminja skladnost terensko ovrednotenih in izračunanih poškodb s spremembami površine raziskovanega areala, ter primerjali rezultate s tistimi, ki so bili pridobljeni z drugimi metodami.

ZAHVALA

Raziskovalno delo je bilo opravljeno v okviru projekta HARMO-DATA, ki je potekal v okviru programa Interreg V-A Italija-Slovenija 2014–2020.

Literatura in viri:

- AlpMon (2018). Satellite Earth Observation to highlight hot spots of damaged forest areas. E04Alps, The Alps from Space Workshop, 27–29 June 2018 Villa Blanka, Innsbruck, Austria.
- BBC (2018). Venice under water as deadly storms hit Italy. <https://www.bbc.com/news/world-europe-46029302>, pridobljeno 1. 2. 2020.
- Belgiu, M., Csillik, O. (2018). Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sensing of Environment*, 204, 509–523. DOI: <https://doi.org/10.1016/j.rse.2017.10.005>
- Breznikar, A. (2018). Ukrepi po vetrolomu v slovenskih gozdovih med 11. in 13. decembrom 2017. *Ujma*, 32, 86–93.
- Bonett, D. G., Wright, T. A. (2000). Sample size requirements for estimating pearson, kendall and spearman correlations. *Psychometrika*, 65, 23–28. DOI: <https://doi.org/10.1007/BF02294183>
- Cartus, O., Kellndorfer, J., Rombach, M., Walker, W. (2012). Mapping canopy height and growing stock volume using airborne lidar, ALOS PALSAR and Landsat ETM+. *Remote Sensing*, 4 (11), 3320–3345. DOI: <https://doi.org/10.3390/rs4113320>
- Ding, C., He, Y. (2004). K-means clustering via Principal Component Analysis. V: Proceedings of the Twenty-first International Conference on Machine Learning, 29. ICML '04. New York, NY, USA: ACM. DOI: <https://doi.org/10.1145/1015330.1015408>
- Dnevnik (2018). Nedavni vetrolom poškodoval 280.000 kubičnih metrov drevja. Dnevnik, Družba medijskih vsebin, d.d. <https://www.dnevnik.si/1042846274/slovenija/nedavni-vetrolom-poskodoval-280000-kubicnih-metrov-drevja>, pridobljeno 1. 2. 2020.
- Eineder, M., Roth, A., Moreira, A. (2019). Ten years of TerraSAR-X—Scientific Results. *MDPI*, 276–278.
- ESA (2020). Sentinel-1 SAR Technical Guide. <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-1-sar>, pridobljeno 13. 8. 2020.
- Eriksson, L. E. B., Fransson, J. E. S., Soja, M. J., Santoro, M. (2012). Backscatter signatures of wind-thrown forest in satellite SAR images. 2012 IEEE International Geoscience and Remote Sensing Symposium, 6435–6438. DOI: <https://doi.org/10.1109/IGARSS.2012.6352732>
- Fransson, J. E. S., Walter, F., Blennow, K., Gustavsson, A., Ulander, L. M. H. (2002). Detection of storm-damaged forested areas using airborne CARABAS-II VHF SAR image data. *IEEE Transactions on Geoscience and Remote Sensing*, 40 (10), 2170–2175. DOI: <https://doi.org/10.1109/TGRS.2002.804913>
- Fransson, J. E. S., Pantze, A., Eriksson, L. E. B., Soja, M. J., Santoro, M. (2010). Mapping of wind-thrown forests using satellite SAR images. 2010 IEEE International Geoscience and Remote Sensing Symposium, 1242–1245. DOI: <https://doi.org/10.1109/IGARSS.2010.5654183>
- Green, R. M. (1998). The sensitivity of SAR backscatter to forest windthrow gaps, *International Journal of Remote Sensing*, 19 (12), 2419–2425. DOI: <https://doi.org/10.1080/014311698214811>
- Henderson F. M., Lewis A. J. (1998). Principles and applications of imaging radar (Manual of Remote Sensing, Volume 2): Wiley, New York, 2–48.
- Hotelling, H. (1933). Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 24, 417–441 in 498–520. DOI: <https://doi.org/10.1037/h0071325>
- Italy magazine (2018). Storms in Italy's Dolomites raze centuries-old forests. <https://www.italymagazine.com/news/storms-italys-dolomites-rale-centuries-old-forests>, pridobljeno 1. 2. 2020.
- Jakša, J., Kolšek, M. (2009). Naravne ujme v slovenskih gozdovih. *Ujma*, 23, 72–81.
- Koroške novice (2018). Vetrolom v Koprivni, gasilci na delu že ves dan. Spletni medij Koroške novice. <https://www.koroskenovice.si/novice/foto-vetrolom-v-koprivni-gasilci-na-delu-ze-yes-dan/>, pridobljeno 1. 2. 2020.
- Künzer, C., Dech, S., Wagner, W. (ur.). (2015). Remote sensing time series: Revealing land surface dynamics. *Remote Sensing and Digital Image Processing*, Springer International Publishing Switzerland, 323–356. DOI: https://doi.org/10.1007/978-3-319-15967-6_16
- Laur, H., Bally, P., Meadows, P., Sanchez, J., Schaettler, B., Lopinto, E., Esteban, D. (2004). ERS SAR calibration: Derivation of α_0 in ERS SAR PRI products, ESA/ESRIN, ES-TN-RS-PM-HL09, Issue 2, Rev. 5f, November 2004.
- Logan, T. L. (1995). Terrain correction of synthetic aperture radar imagery using the Cray T3D. CUG 1995 Spring Proceedings, Alaska SAR Facility.
- Mesner, N. (2016). Analiza možnosti uporabe samodejne klasifikacije podobe za vzdrževanje prostorskih podatkovnih zbirk. Magistrsko delo. Univerza v Ljubljani,

- Fakulteta za gradbeništvo in geodezijo, 13–16.
- Météo-France (2018). Corse: Violente tempête le 29 octobre. <http://www.meteofrance.fr/actualites/67470814-corse-violente-tempete-le-29-octobre>, pridobljeno 1. 2. 2020.
- Mirelva, P. R., Nagasawa, R. (2017). Single and multi-temporal filtering comparison on synthetic aperture radar data for agriculture area classification. Proceedings of the International Conference on Imaging, Signal Processing and Communication, 72–75. DOI: <https://doi.org/10.1145/3132300.3132316>
- NASA (1989). SAR (Synthetic Aperture Radar). Earth observing system. Volume 2F: Instrument panel report. Earth Science and Application Division, NASA Headquarters, Washington DC.
- Niculescu, S., Ienco, D., Hangau, J. (2018). Application of deep learning of multi-temporal Sentinel-1 images for the classification of coastal vegetation zone of the Danube delta. ISPRS – International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII–3, 1311–1318. DOI: <https://doi.org/10.5194/isprs-archives-XLII-3-1311-2018>
- Oščir, K. (2006). Daljinsko zaznavanje. Ljubljana: Založba ZRC.
- Preslica (2019). Vetrolom. <https://www.gozd-les.com/upravljanje-gozdov/tezave-gozdom/ujme/vetrolom>, pridobljeno 1. 2. 2020.
- Rojko, I. (2016). Uporaba diferencialne radarske interferometrije za opazovanje premikov površja. Magistrsko delo. Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.
- Rossi, C. (2015). Decolla la space economy italiana. AirPress. <http://www.airpressonline.it/8562/decolla-la-space-economy-italiana/>, pridobljeno 1. 2. 2020.
- Rubin, J. (1967). Optimal classification into groups: An approach for solving the taxonomy problem. Journal of Theoretical Biology, 15, 103–144. DOI: [https://doi.org/10.1016/0022-5193\(67\)90046-X](https://doi.org/10.1016/0022-5193(67)90046-X)
- Rüetschi, M., Small, D., Waser, L. (2019). Rapid detection of windthrows using Sentinel-1 C-Band SAR data. Remote Sensing, 11 (2), 115. DOI: <https://doi.org/10.3390/rs11020115>
- Santoro, M., Beer, C., Cartus, O., Schmullius, C., Shvidenko, A., McCallum, I., Wegmueller, U., Wiesmann, A. (2010). The BIOMASAR algorithm: An approach for retrieval of forest growing stock volume using stacks of multi-temporal SAR data. Proceedings of ESA Living Planet Symposium, 28. junij–2. julij 2010.
- Small, D., Holec, F., Nuesch, D. (1995). Combination of ascending/descending ERS-1 InSAR data for calibration and validation. 1995 International Geoscience and Remote Sensing Symposium, IGARSS '95. Quantitative Remote Sensing for Science and Applications, 1, 553–555. DOI: <https://doi.org/10.1109/IGARSS.1995.520452>
- Spotò, F., Sy, O., Laberinti, P., Martimort, P., Fernandez, V., Colin, O., Hoersch, B., Meygret, A. (2012). Overview of Sentinel-2. 2012 IEEE International Geoscience and Remote Sensing Symposium, 1707–1710. DOI: <https://doi.org/10.1109/IGARSS.2012.6351195>
- Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B., Flouri, N., Brown, M., Traver, I. N., Deghaye, P., Duesmann, B., Rosich, B., Miranda, N., Bruno, C., L'Abbate, M., Croci, R., Pietropaolo, A., Huchler, M., in Rostan, F. (2012). GMES Sentinel-1 mission. Remote Sensing of Environment, The Sentinel Missions – New Opportunities for Science, 120, 9–24. DOI: <https://doi.org/10.1016/j.rse.2011.05.028>
- ZGS (2018a). Podrobnejša ocena obsega poškodb zaradi vetroloma v noči iz 29. na 30. oktober 2018 v slovenskih gozdovih in ukrepih. Zavod za gozdove Slovenije.
- ZGS (2018b). Načrt sanacije gozdov, poškodovanih v vetrolому od 11. do 13. decembra 2017. Osnutek načrta sanacije gozdov, poškodovanih v vetrolому, od 11. do 13. decembra 2017. Zavod za gozdove Slovenije.



Mangafić A., Puhar M., Barborič B. (2020). Identifikacija območij vetroloma na podlagi časovne vrste s podatki C-SAR. Geodetski vestnik, 64 (3), 335–347. DOI: <https://doi.org/10.15292/geodetski-vestnik.2020.03.335-347>

Alen Mangafić, mag. prost. načrt.
Geodetski inštitut Slovenije
Jamova cesta 2, SI-1000 Ljubljana
e-naslov: alen.mangafic@gis.si

Blaž Barborič, univ. dipl. geog.
Geodetski inštitut Slovenije
Jamova cesta 2, SI-1000 Ljubljana
e-naslov: blaz.barboric@gis.si

Martin Puhar
IGEA, d. o. o.
Podpeška cesta 1, SI-1351 Brezovica pri Ljubljani
e-naslov: martin.puhar@igea.si