

Obilježja tuče u sadašnjim i budućim klimatskim uvjetima na području Hrvatske

Jelić, Damjan

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Science / Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:217:757027>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-05-03**



Repository / Repozitorij:

[Repository of the Faculty of Science - University of Zagreb](#)





Sveučilište u Zagrebu

PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

Damjan Jelić

**OBILJEŽJA TUČE U SADAŠNJIM I
BUDUĆIM KLIMATSKIM UVJETIMA NA
PODRUČJU HRVATSKE**

DOKTORSKI RAD

Zagreb, 2022.



Sveučilište u Zagrebu

PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

Damjan Jelić

**OBILJEŽJA TUČE U SADAŠNJIM I
BUDUĆIM KLIMATSKIM UVJETIMA NA
PODRUČJU HRVATSKE**

DOKTORSKI RAD

Mentori: izv. prof. dr. sc. Maja Telišman Prtenjak
dr. sc. Ivan Güttler

Zagreb, 2022.



University of Zagreb

FACULTY OF SCIENCE
DEPARTMENT OF GEOPHYSICS

Damjan Jelić

HAIL CHARACTERISTICS IN PRESENT AND FUTURE CLIMATE OVER CROATIA

DOCTORAL DISSERTATION

Supervisors: Assoc Prof Maja Telišman Prtenjak
Ivan Güttler, PhD, Rsch Assoc

Zagreb, 2022.

Ova je doktorska disertacija izrađena na Geofizičkom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu pod vodstvom izv. prof. dr. sc. Maje Telišman Prtenjak i dr. sc. Ivana Güttlera, u sklopu Sveučilišnog poslijediplomskog doktorskog studija fizike, smjer geofizika.

Zahvala

Ovim doktorskim radom obilježen je kraj jednog od važnijih razdoblja mog života kroz koje su se oblikovali temelji mojih znanja, iskustava, ali i pravci razmišljanja te putanje daljnjeg djelovanja. Cijeli proces ne bi bio moguć bez velike podrške niza osoba i institucija koje su na sebi svojstven način doprinijele ostvarenju ovog iskoraka.

Stoga bih se, od srca želio zahvaliti izv. prof. dr. sc. Maji Telišman Prtenjak, mojoj prvoj mentorici, na ukazanom velikom povjerenju, podršci, kako onoj stručnoj, tako i moralnoj te razumijevanju i toleranciji. Uz to, iznimno sam zahvalan na svim iskustvima i odgovornostima koje mi je omogućila u ovom procesu, čime mi je postavila čvrste i široke temelje na kojima mogu nastaviti graditi svoju karijeru. Također, zahvaljujem se dr. sc. Ivanu Güttleru, svom drugom mentoru, na svesrdnom povjerenju, razgovorima, diskusijama, sugestijama i savjetima, te moralnoj podršci kroz ovaj proces, a posebno u njegovoj završnici.

Zahvalu upućujem i Sektoru za meteorološka motrenja i klimatološke podatke Državnog hidrometeorološkog zavoda koji ustrajno prikuplja meteorološka mjerenja i opažanja bez kojih ovaj rad ne bi bilo moguće napraviti. Ovom zahvalom bih posebno izdvojio Damira Mlineka koji mi je spremno stajao na raspolaganju za sva tehnička pitanja, zahtjeve za podatke, kao i pomoć oko pristupa pojedinim arhivama. Također, hvala načelnici Sektora Dubravki Rasol na povjerenju i dozvoli da koristim pisanu arhivu kako bih došao do podataka. Hvala i tvrtci Ubimet GmbH na ustupanju mjerenja iz LINET baze podataka o munjama. U radnji su također korišteni podatci reanalize ERA5 i klimatskih simulacija iz inicijative EURO-CORDEX za određivanje tipova vremena u sadašnjim i budućim klimatskim uvjetima.

Toplo zahvaljujem kolegici Luciji Blašković, na opsežnoj aktivnoj podršci prilikom digitalizacije, obrade i vizualizacije podataka o tuči kao i raspravama oko dobivenih rezultata. Također, veliko hvala kolegicama Barbari Malečić, Otiliji Anni Megyer, Andreini Belušić, Maji Bubalo, Sari Ivasić, Ivi Međugorac, kolegi Branimiru Omaziću, ali i ostalim kolegama na svim suradnjama i nebrojenim kavama uz koje smo diskutirali aktualne probleme, dileme i zaključke naših istraživanja i time gradili nova znanja i spoznaje koje su dobrim dijelom formirale ovaj rad.

Hvala i svim suradnicima na projektima MODES, VITCLIC, SWALDRIC, KLIMA4HR s kojima sam razvijao svoje vještine i obavljao istraživanja vezana uz izradu doktorske disertacije.

Posebno se zahvaljujem članovima povjerenstva za ocjenu dokorskog rada doc. dr. sc. Željku Večenaju, izv. prof. dr. sc. Ivani Herceg Bulić i nasl. doc. dr. sc. Nataši Strelec Mahović na uloženom trudu i vremenu, konstruktivnim komentarima, sugestijama i raspravama koje su ovaj rad učinile još potpunijim.

Za kraj, od srca hvala mojoj supruzi Kristini, sinu Jurju, sestri Editi, roditeljima Anđelki i Marinku te ostalim članovima obitelji na bezuvjetnoj podršci, požrtvornosti i ljubavi koju su pokazali na ovom putu.

U Zagrebu, prosinac 2022.

Informacije o mentorima:

Maja Telišman Prtenjak diplomirala je na PMF-u u Zagrebu (1995.), magistrirala je 2001. i doktorirala 2006. godine na Sveučilištu u Zagrebu. Od 1996. godine radi pri Geofizičkom odsjeku PMF-u Sveučilišta u Zagrebu, trenutno u zvanju izvanredne profesorice i znanstvene savjetnice. Dobitnica je Nagrade za znanstvenu izvrsnost MZOŠ-a 2009. Usavršavala se u inozemstvu i sudjelovala na nizu međunarodnih konferencija/radionica. Maja Telišman Prtenjak je ili je bila članica triju uredničkih odbora časopisa (Geofizika, *Meteorology and Atmospheric Physics* i Hrvatski meteorološki časopis) te je bila članica desetak organizacijskih/znanstvenih odbora međunarodnih znanstvenih i znanstveno-stručnih skupova i radionica. Sudjelovala je u radu više znanstvenih i stručnih međunarodnih i domaćih projekata, kao suradnik (11) i kao voditelj (4). Do sada je koautorica u više od 40 znanstvenih (*peer review*) radova i oko 130 konferencijskih priopćenja u suradnji s domaćim i inozemnim suradnicima. Recenzirala je više međunarodnih i domaćih projekata i oko 60 radova za više renomiranih međunarodnih i domaćih časopisa. Do sada je bila mentor u 22 diplomskih i 2 doktorata. Fokus rada je na mezoskalnim meteorološkim fenomenima (s posebnim osvrtom na opasne vremenske prilike kao što su tuča, munje, mraz, jak vjetar, šumski požari itd.) nad kompleksnom topografijom u sadašnjim i budućim klimatskim uvjetima koristeći i mjerenja te mezoskalne numeričke (prognostičke i klimatske) modele.

Ivan Güttler diplomirao je 2008. na PMF-u u Zagrebu na Geofizičkom odsjeku smjer meteorologije i fizičke oceanografije, a od 2009. godine zaposlen je na Državnom hidrometeorološkom zavodu. Doktorirao je na PMF-u 2014., znanstveno zvanje znanstveni suradnik stječe 2016., a od 2022. godine je zamjenik glavne ravnateljice DHMZ-a. Sudjeluje i kao asistent u nastavi na Geofizičkom odsjeku PMF-a, a 2020. godine angažiran je kao dio hrvatskog tima vezanog za klimatske pregovore u sklopu predsjedanja Republike Hrvatske Vijećem Europske unije. Prema bazi Google Scholar radovi su mu citirani 2266 puta uz h-indeks; h = 14. Godine 2013. je bio dobitnik Državne nagrade za znanost u kategoriji Godišnja nagrada za znanstvene novake. Uže polje specijalnosti su mu razvoj i primjena regionalnih klimatskih modela.

SAŽETAK

Tuča je jedna od ekstremnih meteoroloških pojava koja često uzrokuje značajne materijalne štete. Šteti je podložno gotovo sve, a kako raste veličina zrna tuče, tako je razmjer štete sve veći. Izraženije epizode tuče mogu proizvesti štete veće od milijardu dolara, a prema podacima za Hrvatsku, u razdoblju od 1981. do 2012. godine, oluje i tuča uzrokovale su približno 21 % ukupno zabilježenih šteta nastalih prirodnim nepogodama. Kako bi se na taj problem odgovorilo, proteklih nekoliko desetljeća u Europi, ali i svijetu, raste broj istraživanja usmjerenih na bolje razumijevanje tuče i njenih svojstava pa je tako i cilj ovog istraživanja pridonijeti boljem poznavanju tuče na području Hrvatske. Korištenjem opaženih podataka o tuči sa 186 postaja Državnog hidrometeorološkog zavoda diljem Hrvatske te promatranjem razdoblja od preko 50 godina, provedena je sveobuhvatna klimatološka analiza svojstava tuče. Zatim se uparivanjem dobivenih podataka o tuči i reanalize ERA5 dobila veza sinoptičkih i mezoskalnih uvjeta, a daljnjom obradom regionalnih klimatskih modela iz inicijative EURO-CORDEX i projekcija pojavnosti tuče u 21. stoljeću. Također, na osnovu mjerenja munja razvijen je algoritam za izračun indeksa intenziteta munja koji ističe područja s izraženom aktivnošću oborine, pojavom tuče te udarima vjetera. Glavni rezultati ovog istraživanja su sljedeći:

- 1: Prepoznata su tri različita tipa postaja u smislu godišnje dinamike tuče. Unutar Hrvatske razlikuje se „ljetni“ tip postaja koje tuču uglavnom bilježe tijekom toplog dijela godine, suprotni tj. „zimski“ tip postaje te „prijelazni“ tip koji bilježi podjednaku aktivnost tuče tijekom cijele godine. Odvojenim promatranjem navedenih tipova postaja ustanovljeno je da se i dnevni hodovi tuče značajno razlikuju, pri čemu je najinteresantniji „zimski“ tip koji maksimum aktivnosti tuče bilježi u 8 h ujutro.
- 2: Glavno obilježje tuče je velika prostorna i vremenska varijabilnost na svim promatranim skalama, što potvrđuju i različiti trendovi za različite tipove postaja te različite sezone.
- 3: U budućoj se klimi očekuje pad aktivnosti tuče za oko 8 %.
- 4: Indeks intenziteta munja pokazao se vrlo uspješan u prostornoj i vremenskoj identifikaciji intenzivne oborine i tuče. Zbog svoje prirode indeks homogeno popunjava prostor na rezoluciji $3 \text{ km} \times 3 \text{ km}$ te nudi visoku vremensku rezoluciju (2 min). Stoga ga je moguće koristiti za identifikaciju kratkoživućih, lokalnih grmljavinskih oluja koje su praćene potencijalno opasnim vremenskim događajima.

Ključne riječi: tuča, munje, indeks intenziteta munja, lokalna konvekcija, trendovi tuče, tuča u budućoj klimi, tipovi vremena

HAIL CHARACTERISTICS IN PRESENT AND FUTURE CLIMATE OVER CROATIA

EXTENDED ABSTRACT

Introduction

Most hail properties, such as its annual and diurnal cycles, trends, and interannual and seasonal variations, can be identified through hail climatology. To date, hail climatology at local or national scales has been analyzed for most European countries (Punge and Kunz, 2016). Data used in derivations of hail climatology include hailpad measurements (Manzato, 2011; Počakal et al., 2009; Sánchez et al., 2009), station measurements (e.g., Burceaetal., 2016; Ćurić and Janc, 2016; Kotinis-Zambakas, 1989; Vinet, 2001; Zhang et al., 2008), hail reports (e.g., Dessens, 1986; Tuovinen et al., 2009; Webb et al., 2001, 2009), radar estimates (Lukach et al., 2017; Nisi et al., 2016; Strzinar and Skok, 2018; Visser and van Heerden, 2000), satellite assessments (Punge et al., 2017), insurance damage data (Vinet, 2001), and global model outputs (Brooks et al., 2003; Hand and Cappelluti, 2011). Overall, the results show the presence of hail over much of Europe from the northern regions of Scandinavia (up to 67.5 °N), where the hail season is shortest (during summer) (e.g., Tuovinen et al., 2009), to the Mediterranean region, where hail can occur throughout the year (e.g., Baldi et al., 2014; Berthet et al., 2011; Punge and Kunz, 2016). In addition, while continental regions are mainly affected by hail during the warmer parts of the year (e.g., April–September), coastal (maritime) regions along the Atlantic Ocean or Mediterranean show different hail frequency distributions. For coastal hail climatology, most cases occur during winter and spring but with relatively few hailstones (Punge and Kunz, 2016; Santos and Belo-Pereira, 2019). According to Punge et al. (2014), the areas with the most frequent hail events are positioned between 39 °N and 50 °N. Hail hot spots are found in perialpine regions of the north and south, followed by the greater Pyrenees Region, Massif Central in France, Apennines in Italy, Dinarides in the Southeast Europe, and

Carpathians in the Pannonian Basin. Some reported hail frequencies have presented values of 0 – 2.4 hail days per year according to station measurements (Punge and Kunz, 2016), while radar-based estimates have reported values of 0 – 2 hail days per year (Nisi et al., 2016; Strzinar and Skok, 2018). A recent publication by Punge et al., (2017) provides an estimation of hail frequencies from satellite-based overshooting tops (OTs) and ERA-Interim reanalyses of Europe. The authors reported 10 km × 10 km gridded information for yearly hail frequency estimates that spanned from 0 to 2 hail days (Punge et al., 2017; their Figure 6) and the spatial distributions corresponded well with previous studies. While Croatia is situated in an area where strong impacts of hail are expected (e.g., Punge et al., 2014), the Adriatic coast has never been analyzed in detail, and its national hail climatology has not yet been developed. Nevertheless, several papers have addressed the hail characteristics of the continental region of Croatia which is an agricultural region that is well equipped with weather radars, meteorological stations, and hailpad networks. The hail properties and their characteristics in the continental part of Croatia are reported in Počakal and Štalec, (2003) and Počakal et al., (2009, 2018). In these papers, the analyses focused on the warm season (i.e., May–September), which is connected with the hail suppression network and hailpad data. The main results show that the spatial and temporal characteristics of hail in the period from 1981 to 2006 show higher hail activity on the windward slopes of mountains. The hail frequencies in Croatia range from 0.1 to 2.4 hail days/season. The first 3 months of the hail season represent 84 % of total hail cases, and hail is most active between 14 and 18 h local time. Various trend analysis have been made both in Croatia (Gajić-Čapka and Zaninović, 1993) and worldwide (Raupach et al., 2021) but there was no clear conclusion.

Thunderstorms can produce severe weather, such as heavy rain, large hail, wind gusts, tornadoes and cloud-to-ground lightning, which can cause significant damage and can endanger human lives (Hoeppe, 2016). Usually, these thunderstorms have large spatial and temporal scales, such as mesoscale convective systems (MCSs) or supercells. However, even local systems such as multicell storms or single-cell Cb can produce some of these severe weather elements. Considering some well-established criteria for severe weather identification, it can be seen that they are relatively strict (Púčik et al., 2019, 2015), involving hail larger than 2 cm, wind gusts above 25 m/s and flash floods. In agricultural terms, a dense hail with diameters <10 mm in the blooming season or just before harvest can produce significant damage (Changnon et al., 2009). Additionally, it can indirectly endanger human life, causing traffic accidents. Heavy rain does not need to be large in total quantity to cause harm if the local intensity is high and it can thus temporarily flood the area (Cipolla et al., 2020; Gaál et al., 2014). Wind gusts

pose elevated risks to structures, trees and any outdoor activities, and their reach is several tens of kilometers ahead of the storm (Klinge et al., 1987; Mohr et al., 2017). Active monitoring of these thunderstorm systems can be accomplished using remote sensors, such as radars, satellites, and a lightning detection network. Nevertheless, it is difficult to obtain good radar coverage in most regions due to the limited range and various sampling frequencies of radars, as well as their overall cost (Punge et al., 2016). Additionally, the frequency of satellite imaging is still relatively low to capture short-lived systems (Punge et al., 2014). Thus, lightning measurements are the only data source that has large spatial coverage and sufficiently high temporal resolution (1 s). Many convective storms are accompanied by lightning strikes, which are the main feature of storms over land (Ávila et al., 2010). The number of lightning strikes per storm generally depends on the concentrations of ice crystals and graupel and on the updraft intensity. When the updraft is sufficiently strong and a cloud contains both ice crystals and graupel, the non-inductive charging mechanism is triggered, and electrification (i.e., production of lightning strikes) will occur (Betz et al., 2009b; Mazzetti and Fuelberg, 2017; Takahashi, 1978). Depending on the strength of the updraft, lightning activity can increase or decrease, providing us with information on the development and intensity of a system.

The goal of this research is to provide comprehensive analysis of spatial and temporal hail properties over Croatia in present and future climate. Further, a link with synoptic and mesoscale conditions will be made. Finally, new thunderstorm intensity index (TSII) will be developed, verified, and applied to obtain spatially homogeneous coverage and climatology of potentially severe thunderstorms over Croatia.

Data and methods

To adequately analyze the hail distributions and properties in Croatia, several types of data were used. The first data set contains hail observations collected from weather stations from 186 weather stations located throughout the region of Croatia for a period of roughly 50 years, depending on the station. Data were obtained from Croatian Meteorological and Hydrological Service (DHMZ). Using the standardized data retrieval approach, we obtained 7925 data points in space and time and used them as the main source of data. The second data set used is the ECMWF reanalysis ERA5 (Copernicus Climate Change Service (C3S), 2017), which has a horizontal resolution of 0.25° and is used to determine objectively defined weather patterns related to hail as well as instability indices (most unstable CAPE, K index, lifted index), deep layer shear, and freezing level height to investigate relations to hail on the mesoscale level.

Further, using same objectively defined weather pattern algorithm, we analyzed simulations of the climate models from the EURO-CORDEX initiative using combinations of 4 global and 3 regional climate models to analyze future changes in hail patterns related to synoptic drivers in the future (Jacob et al., 2014). Additionally, lightning data acquired from Lightning Detection Network in Europe (LINET) (Betz et al., 2009a) was used for development, verification and climatological assessments of TSII. To support the verification process, additional data from DHMZ database for rain, wind and waterspouts, related to NE Adriatic region, were also used.

Hail analysis includes interannual, annual, seasonal, and diurnal scales as well as spatial analysis. Trends were computed on 28 selected stations with uninterrupted measurements for period of 1964. – 2019. where hail days, duration and hail intensity were considered. Additionally, hail days were used to determine synoptic forcing and the assessment of future climate, while hail cases were used to inspect mesoscale relations and relations to TSII.

Development of TSII index is based on previous method (lightning jump) which uses a set of mathematical operations that measure lightning behavior in shorter time intervals (1 – 5 min) over several steps (Schultz et al., 2009; Gatlin and Goodman, 2010; Chronis et al., 2015). One usually defines the storm center using some type of storm-tracking algorithm and area of influence, within which lightning strikes are collected in each timestep, is defined. The final steps include: (i) computation of the trend in the number of lightning flashes between several consecutive time steps, (ii) calculation of the standard deviation of several consecutive trends, (iii) the trend(s) is(are) compared against the standard deviation from the previous step and (iv) iteration of the procedure by moving one step forward. Finally, when a trend exceeds a predefined threshold of the standard deviation (the most common threshold is two sigma), it is considered that a lightning jump occurred. Although mathematically the same, the key difference between lightning jumps and the TSII is in lightning data retrieval. TSII does not require the use of a storm tracking algorithm and influence radius, because it observes a storm passing over a predefined grid on the ground, therefore, this approach offers a new angle. The storm is divided into arbitrarily small segments (i.e., a predefined grid), allowing identification of the potential impacts of the storm on a particular grid point and at a particular point in time. Since the TSII algorithm is computed independently for each grid point, severe storms will leave a trail of the TSII, revealing the area over which the most active part of the storm has passed. In other words, the TSII is a diagnostic tool that, in retrospect, highlights areas over which a storm was the most active. Additionally, due to the current computational settings, the TSII is a binary (yes/no) index that obtains a positive value (e.g., $TSII = 1$) if the storm intensifies rapidly, while otherwise TSII equals zero.

Results and conclusions

The preliminary analysis determined that the data on hail can be divided into three areas, according to the type of annual cycle. Thus, out of a total of 186 stations, 113 stations were identified as belonging to the "summer" type, 31 stations were associated with the transitional type, and remaining 42 stations were of the "winter" type. The "summer" type are the stations that predominantly recorded hail in the warm part of the year (May – October), while the "winter" stations are those that have more frequently measured hail in the cold part of the year (November – April). The transitional type has no preferences. Basic data analysis suggests that in Croatia hail occurs throughout the year, which is a new information considering that previously most research was concentrated on the warm part of the year, thus using only “summer” type stations (Gajić-Čapka and Zaninović, 1993, Počakal et al., 2009; Počakal et al., 2018).

Diurnal cycle also shows significant differences. While the "summer" type follows the so far well-accepted form with a maximum in the afternoon hours, the transitional type records significant hail activity already in the morning hours, with a maximum around noon. The "winter" type, on the other hand, records the maximum of hail occurrence as early as 8 a.m. Central European Time (UTC + 1), and hail activity remains pronounced until the late evening hours.

The interannual trend shows great variability for all three types of stations, and the variability dynamics do not coincide with each other for any of the considered elements (hail days, duration, and hail intensity). From these datasets, the trend was calculated for the whole of Croatia as well as for the individual areas and individual seasons. Regarding hail days, the obtained results indicate a negative trend for the whole of Croatia, for which the „summer“ and „winter“ type of stations are responsible, while the transitional type does not show any significant changes. Further analysis revealed that these trends are the result of a reduction in hail activity in the summer season for the „summer“ type and in the summer and autumn seasons for the „winter“ type of stations, within which there is an indication of a negative trend in the spring season.

The analysis of synoptic systems over the Croatian territory, in the context of hail, shows the dominance of cyclonic types, which is expected considering that these systems provide a large source of instability, higher CAPE values and abundant moist air. By combining the general distribution of weather types and those associated with hail, the percentage of hail in a

particular weather type is obtained, and this value was used to assess hail in the future climate. The result of that procedure showed that, compared to the reference period (1971 – 2000), hail activity decreases by up to 8 % as we move towards the end of the 21st century. The ensemble of climate simulations also shows a systematic reduction of the cyclonic type of weather, and an additional weakening of deep cyclonic systems, which is the main reason for the recorded decrease in hail in the future, given that the quasi non-gradient field is difficult to distinguish in the used climate models at 12.5 km resolution.

The mesoscale conditions for hail, obtained from the ERA5 reanalysis, confirm that hail forms in very unstable atmospheric conditions ($\text{CAPE} \sim 650 \text{ J/kg}$, $\text{LI} \sim -4.8 \text{ }^\circ\text{C}$, $\text{KI} \sim 31 \text{ }^\circ\text{C}$) with $\text{DSL} \sim 14.8 \text{ m/s}$, and the freezing level height $\sim 2500 \text{ m}$. There are certain differences between the individual station types, the most prominent of which are those between the "summer" and "winter" types. As the bulk of hail in the "winter" type is located within the cold part of the year, when the general potential and capacity for moisture and instability is reduced, the lowest CAPE values are also recorded. This lack of atmospheric instability is compensated by elevated DSL values, which is consistent with previous research (Púčik et al., 2017).

In the process of verifying the thunderstorm intensity index (TSII), data on rain, wind, hail and waterspouts recorded in the area of the northeastern Adriatic over a period of 11 years were used. The obtained results for rain (area of influence of 3 km) show a very good agreement between the trace of the TSII index and high values of intensity and total amounts of rain. The comparison with wind also showed that environments within a large area of influence that had a TSII footprint, recorded significantly higher wind values, regardless of whether it was a coastal station or a land station. Hail also had a pronounced positive connection with the TSII footprint, and in the northeastern Adriatic about 68 % of hail was associated with other products of deep convection within a 15 km area. In the extended analysis (over Croatia), it was found that this percentage is even higher (about 74 %), and if only the warm part of the year or the strong intensity of hail is observed, these percentages approach 90 %. This confirmed that the TSII trace really represents the systems and environments within which potentially extreme or extreme events are recorded. A somewhat unexpected benefit of the proposed method is the ability to detect local convective systems that still have potentially extreme effects. Through the results it was shown that the systems that have a trace of TSII smaller than 90 km^2 , still have very pronounced precipitation values, are still successfully associated with the occurrence of hail and strong wind gusts and are formed in equivalently unstable atmospheric conditions.

As the method allows monitoring the track of TSII at high spatial and temporal resolution, the obtained results are suitable for model verification, supplementing other

climatological studies, but also as an independent tool for assessing the risk of potentially extreme events. Through the results of this work, the daily and annual trends were also shown, which are in good agreement with those obtained for hail, but also in other hail surveys based on radar estimates in Slovenia (Stržinar and Skok 2018).

Further to the above, the importance of dense and detailed hail measurements cannot be emphasized enough. The observed spatial and temporal characteristics of hail are a clear sign that it is a highly variable phenomenon. The latest technologies and knowledge finally make it possible to start modeled hail research in terms of forecasting (Brimelow et al., 2002; Adams-Selin and Ziegler 2016; Malečić et al., 2022b). Therefore thorough analyzes of the spatial and temporal characteristics of hail, as well as more detailed and dense data sources, will be extremely important for such research. And for the areas in the Southeastern Europe that will not have them, such as currently Bosnia and Herzegovina, Montenegro, Albania (Punge and Kunz 2016) and other areas, the TSII index proposed in this paper could serve as a spatially filled replacement.

Keywords: hail, lightning, thunderstorm intensity index, local convection, hail trends, hail in future climate, weather types.

POPIS KRATICA I POJMOVA

<i>DHMZ</i>	<i>Državni hidrometeorološki zavod</i>
<i>DSL</i>	<i>Indeks smicanja</i>
<i>ECMWF</i>	<i>Europski centar za srednjoročnu prognozu vremena</i>
<i>ESWD</i>	<i>Europska baza za ekstremno vrijeme</i>
<i>GMP</i>	<i>Glavna meteorološka postaja</i>
<i>ITD</i>	<i>Okruženje s intenzivnom promjenom aktivnosti munja</i>
<i>KI</i>	<i>K-indeks</i>
<i>KMP</i>	<i>Klimatološka postaja</i>
<i>KŠP</i>	<i>Kišomjerna postaja</i>
<i>LI</i>	<i>Indeks podizanja</i>
<i>LINET</i>	<i>Mreža senzora za lociranje munja u Europi</i>
<i>MCS</i>	<i>Mezoskalni konvektivni sustav</i>
<i>MUCAPE</i>	<i>Indeks najnestabilnije raspoložive konvektivne potencijalne energije</i>
<i>NTD</i>	<i>Okruženje bez munja</i>
<i>TD</i>	<i>Okruženje s munjama</i>
<i>TSII</i>	<i>Indeks intenziteta munja</i>
<i>UTC</i>	<i>Univerzalno koordinirano vrijeme</i>
<i>VT</i>	<i>Tip vremena</i>
<i>WMO</i>	<i>Svjetska meteorološka organizacija</i>

SADRŽAJ

1	UVOD.....	1
1.1	Što je tuča i kako se mjeri.....	1
1.2	Prostorna i vremenska obilježja tuče u Europi	3
1.3	Istraživanja tuče u Hrvatskoj	5
1.4	Grmljavinske oluje	6
1.5	Sinoptički i mezoskalni uvjeti za nastanak tuče	9
1.6	Motivacija i cijevi istraživanja	10
2	BAZE PODATAKA.....	12
2.1	Baza podataka o tuči.....	12
2.2	Reanaliza ERA5 i klimatske simulacije inicijative EURO-CORDEX.....	15
2.3	Baza podataka o munjama.....	16
2.4	Baza podataka za verifikaciju indeksa intenziteta munja.....	17
2.4.1	Oborina.....	17
2.4.2	Vjetar.....	18
2.4.3	Tuča.....	19
2.4.4	Pijavice	19
3	METODOLOGIJA	20
3.1	Obrada podataka o tuči	20
3.2	Određivanje sinoptičkih i mezoskalnih uvjeta	21
3.3	Metoda određivanja indeksa intenziteta munja	23
3.4	Metoda verifikacije indeksa intenziteta munja.....	27
4	REZULTATI I DISKUSIJA.....	29
4.1	Prostorna i vremenska obilježja tuče	29
4.1.1	Podjela regija.....	29
4.1.2	Godišnji hod tuče	31
4.1.3	Dnevni hod tuče	33
4.1.4	Učestalost tuče.....	34
4.1.5	Međugodišnja varijabilnost tuče i trendovi	36
4.1.6	Trajanje tuče i trendovi.....	40
4.1.7	Intenzitet tuče i trendovi.....	42
4.1.8	Diskusija obilježja tuče	45
4.2	Sinoptički i mezoskalni uvjeti za tuču u sadašnjoj i budućoj klimi	47
4.2.1	Tipovi vremena (VT).....	47

4.2.2	Mezoskalni uvjeti za nastanak tuče	50
4.2.3	Ocjena tuče u budućim klimatskim uvjetima	51
4.2.4	Diskusija sinoptičkih i mezoskalnih uvjeta za nastanak tuče	56
4.3	Indeks intenziteta munja (TSII)	58
4.3.1	Veza TSII-ja i oborine	58
4.3.2	Veza TSII-ja i vjetra na 10 m	60
4.3.3	Veza TSII-ja i tuče	63
4.3.4	Veza TSII-ja s pijavicama	64
4.3.5	Veza TSII-ja s indeksima nestabilnosti atmosfere	66
4.3.6	Lokalne grmljavinske oluje	67
4.3.7	Sažetak evaluacije indeksa intenziteta munja	70
4.3.8	Klimatološka analiza indeksa intenziteta munja za područje sjeveroistočnog Jadrana	71
4.3.8.1	Prostorna obilježja	71
4.3.8.2	Vremenska obilježja	72
4.3.8.3	Tipovi vremena	73
4.3.9	Veza indeksa intenziteta munja i tuče za područje Hrvatske	75
4.3.10	Klimatološka obilježja indeksa intenziteta munje nad Hrvatskom	77
4.3.11	Daljnja istraživanja i razvoj indeksa intenziteta munja	80
4.3.12	Diskusija rezultata indeksa intenziteta munje	82
5	ZAKLJUČAK	85
6	LITERATURA	90
7	ŽIVOTOPIS	98

1 UVOD

Tuča je jedna od ekstremnih meteoroloških pojava koja često uzrokuje značajne materijalne štete. Šteti je podložno gotovo sve, a kako raste veličina zrna tuče tako je razmjer štete sve veći. Najčešće stradavaju poljoprivredne kulture, staklene površine (staklenici i prozori), zatim automobili te krovovi kuća. U slučaju iznimno velikih zrna tuče (promjer zrna > 5 cm) ozbiljno su ugrožene životinje, a značajne ozljede mogu zadobiti i ljudi koji se nađu na otvorenom (Púčik i sur., 2019). Epizode jake tuče mogu proizvesti štete veće od milijardu dolara (Brown i sur., 2015; Changnon i sur., 2009; Kunz i sur., 2018; Púčik i sur., 2019), a prema podacima za Hrvatsku, u razdoblju od 1981. do 2012. godine oluje i tuča uzrokovale su približno 21 % ukupno zabilježenih šteta nastalih prirodnim nepogodama, što ih svrstava na visoko 2. mjesto uz sušu koja je odgovorna za 44 % šteta (Perčec Tadić i sur., 2014). Za razliku od suše, koja se barem djelomično može ublažiti sustavnim navodnjavanjem, učinkovitih i ekonomski isplativih rješenja za prevenciju tuče još uvijek nema. Kako bi se na taj problem odgovorilo, proteklih nekoliko desetljeća u Europi, ali i svijetu raste broj istraživanja usmjerenih na bolje razumijevanje tuče i njenih svojstava (Allen i sur., 2020; Punge i Kunz, 2016).

1.1 Što je tuča i kako se mjeri

Prema definiciji Svjetske meteorološke organizacije (WMO) tuča je svako zrno leda koje pada iz oblaka s promjerom većim od 5 mm (WMO, 2011). Nastaje u dubokim konvektivnim sustavima koji imaju jake uzlazne struje, obiluju pothlađenom tekućinom te opstaju dovoljno dugo (Houze, 2014; Pruppacher i Klett, 2010). Pojava tuče najčešće se veže uz organizirane konvektivne sustave kao što su familije kumulonimbusa (*engl. multicell thunderstorm*), mezoskalni konvektivni sustavi (*engl. Mesoscale Convective System, MCS*) i superćelije, no tuča se može formirati i u jednoćelijskim kumulonimbusima. Udio pojedinog promjera zrna tuče opada logaritamski kako promjer raste pa se tako tuča veća od 5 cm vrlo rijetko pojavljuje, iako su mogući i veći promjeri (Počakal, 2012; Punge i sur., 2014). Najveće dosad zabilježeno zrno tuče u svijetu imalo je promjer oko 20 cm, mjereno po najduljoj dijagonali. U Europi, prema podacima Europske baze podataka o ekstremnim vremenskim pojavama (*engl. European Severe Weather Database, ESWD*) do rujna 2015. godine, najveće izmjereno zrno tuče imalo je 15 cm po najvećoj dijagonali, a ukupno 21 epizoda tuče sadržavala je zrna veća

od 10 cm. U Hrvatskoj, prema službenim podacima DHMZ-a¹, tuča veličine kokošjeg jajeta zabilježena je na Hvaru 25. kolovoza 2006. te u Karlovcu 24. srpnja 2010. Rekord od 8 cm su zabilježeni na otoku Hvaru 26. kolovoza 2008. i Murskom Središću 8. srpnja 2015. godine (Punge i Kunz, 2016), a prema podacima ESWD-a tuča s promjerima od 10 cm zabilježena je u Grabovcu, 8. lipnja 2018. te u mjestu Brod Moravice, 11. lipnja 2019.

Podatke o tuči moguće je dobiti na razne načine. Najistaknutija te ujedno i najstarija metoda je izravno opažanje tuče. Opažanja se mogu podijeliti na službena opažanja, koja dolaze od strane školovanih motritelja, zaposlenika institucija za praćenje vremena i klime kao što je npr. Državni hidrometeorološki zavod (DHMZ) u Hrvatskoj, ili neslužbena opažanja kao što su medijski zapisi ili u novije vrijeme dojava građana putem raznih aplikacija i kanala od kojih je u Europi najistaknutija baza podataka ESWD (npr. Punge i sur., 2014). Takvi podatci najčešće sadrže datum pojave te neke od sljedećih informacija: točno vrijeme početka pojave, trajanje, intenzitet, veličinu najvećeg opaženog zrna te eventualna opisna obilježja kao što su visina sloja tuče, prouzročena šteta i sl. Tako prikupljeni podatci odlikuju se dugim nizovima mjerenja i predstavljaju glavni izvor podataka za klimatološka istraživanja. Drugi oblik izravnog mjerenja veličine i broja zrna tuče je pomoću instrumenta. Iako su se proteklih godina pojavila razna moderna rješenja za mjerenje (vibracijski, optički i laserski instrumenti), njihova primjena je ograničena pa je i dalje najrasprostranjenija metoda mjerenja tuče klasičnim tučomjerom. Instrument se sastoji od metalnog stalka na koji je položena ploča od tvrdog stiropora, koji se prilikom pojave tuče udubljuje na mjestu udarca i time pruža informaciju o promjeru zrna tuče te o njihovoj gustoći (npr. Počakal i sur., 2009). Tučomjer je često pod nadzorom službenog motritelja što omogućuje dobivanje pouzdane informacije o početku i trajanju padanja tuče, a sam instrument nema pristranost prema noćnoj tuči koja može proći neopaženo. Osim izravnih mjerenja postoji i nekoliko neizravnih metoda kao što su procjena tuče temeljem podataka osiguravajućih društava (npr. Vinet 2001), procjene tuče na temelju radarskog odraza (npr. Stržinar i Skok 2018), te korištenjem premašujućih vrhova oblaka (*engl. Overshooting Tops*) na satelitskim snimkama (npr. Punge i sur., 2017). Također se procjene tuče mogu raditi i kombiniranjem raznih termodinamičkih parametara iz radiosondaža i/ili modela (npr. Brooks i sur., 2003; Hand i Cappelluti, 2011; Manzato, 2013) ili izravnim modeliranjem tuče (npr. Malečić i sur., 2022a, 2022b). Svi gore navedeni izvori podataka neophodni su za stvaranje

¹ https://meteo.hr/klima.php?section=klima_podaci¶m=met_ext

jasnije slike i bolje razumijevanje ove pojave na lokalnoj, regionalnoj i globalnoj skali s ciljem razvoja pouzdane i ekonomski prihvatljive metode prevencije šteta.

1.2 Prostorna i vremenska obilježja tuče u Europi

Većina prostornih i vremenskih obilježja tuče, kao što su međugodišnja varijabilnost i određivanje trenda te godišnji i dnevni hod, mogu se dobiti analizom dužih vremenskih nizova opažanja (Punge i Kunz, 2016; Raupach i sur., 2021). Dodatna obilježja, kao što su ukupna količina zrna tuče i kinetička energija, iziskuju izravna mjerenja pomoću tučomjera (Manzato, 2012; Počakal i sur., 2009; Sánchez i sur., 2009) dok se za određivanje prostorne raspodjele tuče koriste radarska mjerenja (Stržinar i Skok, 2018). Do danas je većina europskih zemalja objavila svoje nacionalne ili regionalne rezultate klimatoloških istraživanja tuče koja uključuju barem dio prostornih i vremenskih obilježja (Punge i Kunz, 2016). S obzirom na izvor podataka mogu se pronaći analize podataka s tučomjera (Manzato, 2012; Počakal i sur., 2009; Sánchez i sur., 2009), službeno opaženih podataka (Burcea i sur., 2016; Ćurić i Janc, 2016; Kotinis-Zambakas, 1989; Vinet, 2001; Zhang i sur., 2008), neslužbenih izvora podataka (Dessens, 1986; Tuovinen i sur., 2009; Webb i sur., 2009, 2001) te neizravnih mjerenja kao što su radarske procjene (Lukach i sur., 2017; Nisi i sur., 2016; Stržinar i Skok, 2018; Visser i van Heerden, 2000), satelitske procjene (Punge i sur., 2017), procjene temeljene na podacima osiguravajućih društava (Vinet, 2001) te procjene na osnovu globalnih klimatskih modela (Hand i Cappelluti, 2011). Na temelju svih navedenih vrsta podataka može se zaključiti da je tuča prisutna u gotovo cijeloj Europi. Najsjevernija točka na kojoj je zabilježena tuča nalazi se u Skandinaviji na 67.5° N, gdje se općenito tuča promjera većeg od 2 cm najčešće javlja u periodu od 01.05. do 15.09. (Tuovinen i sur., 2009). Prema jugu razdoblje u kojem se pojavljuje tuča sve je duže te se tako u cijelom području Sredozemlja tuča javlja tijekom cijele godine (Baldi i sur., 2014; Berthet i sur., 2011; Punge i Kunz, 2016). Kontinentalne postaje u pravilu bilježe glavnu aktivnost tuče u toplijem dijelu godine, tj. od svibnja do rujna, dok priobalne postaje bilježe proljetne i zimske maksimume (Punge i Kunz, 2016; Santos i Belo-Pereira, 2019). Najveća aktivnost tuče u Europi veže se za pojas 39° - 50° N (Punge i sur., 2014), unutar kojeg se može prepoznati i nekoliko izraženih područja gdje se tuča pojavljuje češće. To su područja u blizini Alpa sa sjeverne i južne strane, šire područje Pirineja, Središnji masiv u Francuskoj, Apenini u Italiji, Dinaridi u jugoistočnoj Europi te Karpati koji okružuju Panonsku nizinu. Općenito, dosad objavljena

učestalost tuče se kreće u intervalu od 0 do 2.4 dan/god za izravno mjerene ili opažene podatke (Punge i Kunz, 2016) dok su učestalosti neizravnih procjena u intervalu od 0 do 2 dan/god (Nisi i sur., 2016; Stržinar i Skok, 2018). Važno je istaknuti da su zbog različitih metodologija, ograničenosti podataka i raznovrsnosti njihovih izvora, međusobne usporedbe, posebno one kvantitativne, vrlo teške.. Stoga je ohrabrujuće primijetiti kako se nedavno objavljeni rad o procjeni tuče nad Europom, na temelju satelitskih opažanja premašujućih vrhova oblaka i podataka reanalize ERA-Interim, vrlo dobro slaže s postojećim radovima za pojedine zemlje (Punge i sur., 2017). Autori su prikazali rezultate na mreži podataka s razlučivošću od $10\text{ km} \times 10\text{ km}$, te pokazali kako se frekvencija tuče kreće u intervalu od 0 do 2 dan/god i time postavili prvu kontinuiranu kartu raspodjele tuče u Europi.

Analize trendova tuče su prisutne u brojnim radovima, a sveobuhvatan globalni pregled dan je u radu Raupach i sur. (2021). U tom se radu pokazuje da su trendovi tuče za Europu uglavnom pozitivni kada se koriste neizravni izvori podataka. Modelski ili radiosondažni produkti koji se temelje na smicanju vjetra i indeksima nestabilnosti (*engl. Proxy parameters for deep convection*) pokazuju različite rezultate tj. navode i pozitivan i neutralan trend. Podatci neslužbenih meteoroloških zapisa (medijske dojave, osiguravajuća društva i drugi javni i privatni izvori) pak pokazuju pozitivan trend. No, moguće je da je on posljedica sve veće dostupnosti informacija i većeg interesa medija za vremenske prilike nego što je to bilo u prošlosti. Analize pojedinih područja, najčešće na domeni država, pokazuju i pozitivne i negativne trendove. Zbirno, pozitivne trendove zabilježile su Njemačka, Italija, Finska, Engleska, Francuska, Španjolska, Švicarska, Turska i Hrvatska dok su negativne trendove zabilježile Srbija i Grčka. Istraživanja u Rumunjskoj pokazala su i pozitivne i negativne trendove, a daljnjim promatranjem rezultata u radu Raupach i sur. (2021), a posebno s njihove Slike 3, može se vidjeti da se i izvan Europe također pojavljuju različiti rezultati trendova. Na temelju klimatskih simulacija na Slici 4 iz Raupach i sur. (2021) prikazani su trendovi tuče u budućoj klimi, koji sugeriraju porast aktivnosti tuče u Italiju i Njemačkoj te Europi općenito, dok se za Englesku očekuje negativan trend tuče. Dodatno, autori opsežno komentiraju nepouzdanosti samih izvora podataka koji utječu na dobivene rezultate. Kao glavni nedostaci se ističu kratka razdoblja mjerenja, nehomogena prostorna raspodjela izvora podataka, nepouzdanosti u samom prikupljanju podataka te nedovoljno jasna veza između okruženja unutar kojih nastaje tuča i pojava same tuče u tim okruženjima. Stoga, zaključci o trendovima jako ovise o području za koje su izvedeni kao i metodama koje su pri tome korištene.

1.3 Istraživanja tuče u Hrvatskoj

Prva dokumentirana istraživanja svojstava tuče pojavljuju se još krajem 18. stoljeća kada se nad područjem Istre radilo istraživanje na nizu od 25 godina (1872. – 1896.), kako piše Rudolf Paškvan u svom radu iz 1955. u kojem uspoređuje podatke koje je prikupljao dvije godine (Paškvan, 1955). Bogdan Jugo (1962) se u svom uvodnom dijelu poziva na istraživanje tuče na području tadašnje Jugoslavije (nije posve jasan izvor tog istraživanja) na nizu od 15 godina (1925. – 1940.) u kojem Lika, Gorski kotar, Kordun te brdski dio Slavonije prosječno imaju 1 tuču godišnje, dok ostala područja bilježe od 1 do 2 događaja tuče godišnje. Također se navodi da se u pojedinim dijelovima Istre, Hrvatskog zagorja, Baranje te Srijema bilježe 3 – 4 događaja tuče godišnje dok je pojava najučestalija u planinskim predjelima Boke Kotorske s preko 12 događaja godišnje (Jugo, 1962). Opsežnije istraživanje podataka u kontinentalnoj Hrvatskoj temelji se na analizi 40-godišnjih nizova mjerenja tuče i podataka o grmljavini na tri meteorološke postaje (Gajić-Čapka i Zaninović, 1993). Provedena analiza podataka nije ukazala na statistički signifikantan trend učestalosti tuče. Počakal i Štalec (2003) te Počakal i sur. (2009) koriste opažanja s lansirnih postaja, kao dijela protugradne zaštite kontinentalnog dijela Hrvatske u razdoblju od 1981. do 2006. godine tijekom toplijeg dijela godine tj. od svibnja do rujna. Opaženi podatci sadrže točnu lokaciju, datum, vrijeme, trajanje, srednji promjer zrna tuče, ali i procijenjenu poljoprivrednu štetu. Iako se broj opažačkih mjesta mijenjao, autori navode prosječno 450 aktivnih opažačkih mjesta koja su u danom razdoblju zabilježila ukupno oko 11000 zapisa (Počakal i sur., 2009). Iz tih se podataka pokazalo kako se tuča najčešće pojavljuje u lipnju s 33 % ukupnog broja slučajeva tuče dok svibanj i srpanj sadrže dodatnih 26 % odnosno 25 % ukupno opaženih slučajeva tuče. Tijekom dana, aktivnost tuče počinje značajno rasti nakon 11 h po lokalnom vremenu te doseže svoj maksimum oko 17 h, a autori ističu da se glavina tuče bilježi u intervalu od 14 do 18 h. Analizom učestalosti tuče dobiven je podatak od 0 do 2.4 dan/god, a prostornom analizom učestalosti uočeno je više ugroženih područja. U sjevernom dijelu Hrvatske to su: (i) područje omeđeno planinama Strahinčica, Ivančica i Medvednica, (ii) područje uz granicu sa Slovenijom te (iii) jugozapadna strana Vukomeričkih gorica. Rezultati istraživanja Počakal i sur. (2009) također ukazuju na dodatna područja pojačane aktivnosti tuče kao što je okolica Požege i Županje (njihova Slika 8). Prosječno trajanje tuče iznosilo je 4.2 min s pozitivnim trendom rasta, iako autori nisu komentirali statističku signifikantnost tog rezultata. Dodatna opažanja omogućila su produljivanje niza podataka za analizu u Počakal i sur. (2018) na razdoblje 1981. – 2017., ukazujući na prosječno trajanje tuče od 4.3 min te na pozitivan i signifikantan trend.

1.4 Grmljavinske oluje

Grmljavinske oluje mogu biti praćene opasnim pa i ekstremnim vremenskim pojavama kao što su obilna kiša, tuča, jaki udari vjetra, pijavice, tornada i udari groma. Takve pojave često uzrokuju velike materijalne štete (Hoeppe, 2016). U pravilu se grmljavinske oluje povezuju s mezoskalnim konvektivnim sustavima (MSC) ili superćelijskim sustavima, no čak i lokalni sustavi kao što su familija kumulonimbusa ili jednoćelijski kumulonimbusi mogu biti popraćeni barem dijelom tih ekstremnih pojava. Ako se promotre dosad postavljeni kriteriji za određivanje ekstremnih vremenskih događaja, može se primijetiti da su oni relativno strogi, a uključuju pojavu zrna tuče promjera većeg od 2 cm, udare vjetra veće od 25 m/s i bujične poplave (Púčik i sur., 2019, 2015). U agrometeorološkom kontekstu, tuča manja od 1 cm u sezoni cvatnje ili u sezoni berbe također može prouzročiti značajne štete (Changnon i sur., 2009), a gusta sitna tuča izravno ugrožava sigurnost u prometu te time i ljudske živote. Jaka kiša ne mora biti iznimno velikih razmjera (prostorno i vremenski) da bi prouzročila štete. Uz dovoljno veliki intenzitet oborine i lokalna konvekcija može izazvati poplave na lokalnoj skali i time prouzročiti značajne materijalne štete (Cipolla i sur., 2020; Gaál i sur., 2014). Udari vjetra opasni su za razne građevine, drveće, ljude na otvorenom, a isti imaju efekt i na udaljenosti od nekoliko desetaka kilometara od izvora (Klinge i sur., 1987; Mohr i sur., 2017). No, čak i udari ispod 25 m/s mogu značajno omesti ciklus oprašivanja biljaka, stresti zrele plodove na tlo u sezoni berbe kada su plodovi najosjetljiviji, te u zonama gdje je zemlja rahla i mokra izvrtati nasade s plitkim sustavom korijenja. Takav tip šteta prijavljivali su poljoprivrednici na području Istre i Dubrovačko-neretvanske županije za vrijeme terenskih istraživanja provedenih u okviru projekata Geofizičkog odsjeka PMF-a „Vinogradarstvo i klimatske promjene na području Hrvatske“ (VITCLIC, 2017. – 2019.) i „Klimatska ranjivost Hrvatske i mogućnosti prilagodbe urbanih i prirodnih okoliša“ (Klima4HR, 2019. – 2022.). Stoga bi se svaka grmljavinska oluja praćena intenzivnom oborinom, tučom ili udarima vjetra trebala smatrati potencijalno opasnom.

Aktivno praćenje grmljavinskih oluja može se postići raznim daljinskim mjerenjima, kao što su radarska, satelitska odnosno mjerenja sustavima za lociranje munja. No, bez obzira na to, teško je postići dobru i kontinuiranu pokrivenost mjerenjima u većini regija. Naime, radarski domet je vrlo ograničen (100 do 200 km), frekvencije uzorkovanja variraju od radara do radara (5 – 15 min), a cjenovno su vrlo skupi (Punge i Kunz, 2016). Satelitske snimke također imaju limitiranu vremensku rezoluciju (> 5 min), što ograničava kvalitetnu detekciju kratkotrajnih grmljavinskih sustava (Punge i sur., 2014). Stoga su izravna mjerenja pojave munja jedini izvor podataka koji omogućava veliku prostornu (na području Europe) i

vremensku pokrivenost (1 s) (Betz i sur., 2009b). Velika većina konvektivnih oluja popraćena je i grmljavinom, što je i glavna odlika konvekcije nad kopnom (Ávila i sur., 2010). Broj munja koje jedna grmljavinska oluja može proizvesti ovisi o koncentraciji ledenih kristala, sugradice, vodenih kapljica te intenzitetu uzlazne struje u oblaku. Kada je uzlazna struja dovoljno jaka, a sustav sadrži dovoljno ledenih kristala, sugradice i kapi kiše, započinje mehaničko odvajanje naboja sudaranjem, što dovodi do elektrifikacije oblaka, a time i posljedičnog električnog pražnjenja tj. pojave munja (Betz i sur., 2009b; Mazzetti i Fuelberg, 2017; Takahashi, 1978). Ovisno o snazi uzlazne struje, aktivnost munja može slabjeti ili jačati, čime se neizravno dobiva informacija o razvoju i intenzitetu promatranog sustava.

Interes za istraživanjem grmljavinskih oluja postoji već dugi niz godina. Razvijane su razne metodologije ovisno o dostupnim tipovima podataka, a detaljan pregled može se pronaći u radu Hayward i sur. (2020). Prema tom radu, najčešće korištene metode klimatoloških analiza su analiza učestalosti grmljavinskih oluja, analiza smjera kretanja (putanja) oluja i analiza gustoće munja. Svaka od navedenih metoda pruža informaciju o prostornim i vremenskim obilježjima oluja nad nekim područjem te omogućava analizu prostornih i vremenskih trendova na raznim skalama. Učestalost pojave grmljavine (u nekom razdoblju i/ili terminu) je dobra mjera za međugodišnje, godišnje, sezonske i dnevne varijacije učestalosti i prostorne razdiobe konvektivnih sustava nad nekim područjem te se obično dobiva na temelju opažanja s meteoroloških postaja. Ukoliko se raspolaže daljinskim mjerenjima grmljavinskih oluja (sateliti, radari i sustavi za lociranje munja) moguće je raditi analize putanja oluja i gustoće munja. Iz putanja grmljavinskih oluja moguće je dobiti informaciju o područjima s većom učestalošću kao i vezu s mezoskalnim i sinoptičkim sustavima koji su pogodovali takvim događajima. Također su na raspolaganju i informacije o dobu dana kada se olujni sustav razvija, životnom vijeku i intenzitetu te brzini kretanja. Iz podataka o gustoći munjama dodatno se može ispitati i tip nastale munje (polaritet munje – pozitivna ili negativna munja), mjesto izbijanja – munja između dva oblaka, unutar oblaka ili između oblaka i zemlje, što pogoduje raznim primjenama. Na primjer, analiza pojave munja oblak – zemlja omogućava procjenu rizika od šteta nad promatranim područjem. Uz navedeno, promatranjem gustoće munja u vrlo kratkim vremenskim intervalima (nekoliko minuta), mogu se dobiti detaljna dinamička svojstva grmljavinske oluje. Ona omogućuju daljnje povezivanje s opasnim i/ili ekstremnim pojavama pri tlu.

Kroz prošlo desetljeće, razvijen je novi Lagrangeov pristup koji povezuje dinamiku gustoće munja s pojavom tuče, jakih udara vjetra i tornada. Metoda se temelji na matematičkom modelu koji detektira naglo povećanje gustoće munja poznato kao skok munje (*engl. Lightning*

jump) (Chronis i sur., 2015; Gatlin i Goodman, 2010; Schultz i sur., 2009). Metoda skoka munje koristi se u kratkoročnoj prognozi ekstremnih vremenskih pojava, budući da se skok munje u pravilu događa nekoliko minuta do tridesetak minuta prije ekstremnog događaja (Chronis i sur., 2015; Farnell i sur., 2018, 2017; Gatlin i Goodman, 2010; Pineda i sur., 2011; Schultz i sur., 2011; Wapler, 2017). U kratkoročnoj prognozi, fokus je na detekciji prvog skoka munje kako bi prognostičar dobio što je moguće veći vremenski odmak neophodan za izdavanje upozorenja. Iako oluja obično proizvodi veći broj skokova munja tijekom životnog ciklusa (Hayward i sur., 2020), kasniji skokovi ne nude toliki vremenski odmak i smatraju se manje relevantnim (Farnell i sur., 2017). Iako vrlo moćna, metoda skoka munja još uvijek ne daje točne informacije o području pojave ekstremnog vremenskog događaja.

Nijedna od gore navedenih metoda (gustoća munja i metoda skoka munje), ne ukazuje na točno područje na kojem bismo mogli očekivati štete uzrokovane opasnim pojavama. Tragovi munja koji se mogu dobiti iz gustoće munja, prostorno su preveliki da bi dovoljno precizno prikazali mjesta šteta, ako ih uopće ima. Ako se taj trag pokuša suziti postavljanjem donjeg rubnog uvjeta za gustoću munja, kako bi se uklonila područja s niskom gustoćom munja, moguće je da će se time isključiti značajan broj grmljavinskih oluja koje su prouzročile velike štete, ali nisu imale dovoljan potencijal razviti veći broj munja. Drugim riječima, gustoća munja je mjera realiziranih preduvjeta za nastanak munja u oluji, ali ne i mjera ekstremnih događaja koji su proizašli iz oluje. Stoga je za dobivanje informacija o ekstremnim vremenskim pojavama kroz aktivnost munja potrebno koristiti mjeru koja je invarijantna na ukupan broj munja. Metoda skoka munja invarijantna je na ukupan broj munja i ovisi samo o relativnoj promjeni dinamike munja, ali se točnost lokacije žrtvuje u korist dobivanja većeg vremenskog odmaka. Dodatno, metoda skoka munje uključuje neku vrstu praćenja oluje, bilo pomoću radara ili korištenjem neke druge metode za praćenje objekata s ciljem određivanja putanje oluje, a za potrebe kratkoročne prognoze (Farnell i sur., 2018) i/ili za definiranje radijusa oluje iz kojeg se dobivaju podatci o munjama za potrebe samog algoritma (Chronis i sur., 2015). Stoga postoji potreba razvijanja novih alata koji bi obuhvatili oba zahtjeva te pritom (i) uvažili invarijantnosti na ukupan broj munja i (ii) istodobno omogućili bolju detekciju lokacije pojave ekstremnog događaja.

1.5 Sinoptički i mezoskalni uvjeti za nastanak tuče

Nastanak grmljavinskih oluja, a time i pojava tuče, uvjetovan je atmosferskom dinamikom (ili stanjem) na sinoptickoj i/ili mezo-skali. Stoga su veliki naponi uloženi u razvoj metoda koje promatranjem atmosferskih stanja mogu ponuditi *a priori* informaciju o potencijalnom razvoju tuče (Philipp i sur., 2010). Primjenom takvih metoda na podatke klimatskih simulacija mogu se dobiti grube procjene pojave ekstremnog vremena u budućoj klimi (Mohr i sur., 2015; Púčik i sur., 2017; Santos i Belo-Pereira, 2019). Takve procjene predstavljaju znanstvenu podlogu nacionalnim tijelima za razvoj mjera otpornosti na klimatske promjene.

U kontekstu sinoptičkih uvjeta, najčešće se pokušava identificirati sinoptički tip vremena odgovoran za nastanak ekstrema. Tehnika određivanja može biti subjektivna (npr. Poje, 1965) pri čemu se na temelju sinoptičkih karata iskustvenom metodom određuje dominantni barički sustav (ciklona, anticiklona, fronta, greben visokog tlaka, dolina niskog tlaka i dr.). Također, tehnika može biti i objektivna (npr. Bissolli i Dittmann 2001) pri čemu se definiraju razni kriteriji pomoću kojih se prepoznaje tip sinoptičkog sustava, što je vrlo povoljno za analizu numeričkih simulacija i dugih razdoblja. Opsežniji pregled metoda može se pronaći u Philipp i sur. (2010). Takve objektivne metode, iako nesavršene, omogućavaju brz i efikasan pregled velikog broja različitih numeričkih modela. Za područje Hrvatske razvijen je jedan poluobjektivan pristup (Belušić Vozila, 2018; Belušić Vozila i sur., 2021) kao kombinacija više sinoptičkih tipova vremena prema Poje (1965) za podatke dostupne u formatu mreže (npr. Bissolli i Dittmann 2001). Razvijeni algoritam je korišten za analizu tipova vremena odgovornih za formiranje bure i juga na Jadranu, a primijenjen je na simulacijama regionalnih klimatskih modela inicijative EURO-CORDEX (Jacob i sur., 2014). Sam algoritam obuhvaća domenu $35^{\circ} - 50^{\circ}$ N, $5^{\circ} - 21^{\circ}$ E te računa Laplaceov operator prizemnog tlaka i geopotencijala na 500 hPa-plohi ($\nabla^2 p$, $\nabla^2 \phi$) koji daje informaciju o vrtložnosti unutar domene. Iz toga se dalje može odrediti 17 tipova vremena od kojih je osam ciklonalnih, osam anticiklonalnih te jedan kvazi-bezgradijentni tip koji predstavlja slučajeve kada sinoptički sustavi nisu imali velik doprinos nad promatranom domenom. Takav algoritam predstavlja alat za klasifikaciju tipova vremena s pomoću kojeg se može promatrati veza između bilo kojeg meteorološkog događaja unutar domene i sinoptičkog sustava koji je doprinosa tom događaju.

Mezoskalni uvjeti odgovorni za nastanak ekstremnog vremena također su u fokusu različitih istraživanja pri čemu oni, za razliku od sinoptičkih uvjeta, odgovaraju i na pitanje gdje se u prostoru može očekivati ekstremna pojava (npr. Púčik i sur., 2017). Navedeni uvjeti se najčešće izražavaju preko termodinamičkih i kinematičkih indeksa za procjenu atmosferske

nestabilnosti, kao što su indeks podizanja (*engl. Lifted Index*, LI), indeks najnestabilnije raspoložive konvektivne potencijalne energija (*engl. Most Unstable Convective Available Potential Energy*, MUCAPE), K-indeks (KI), indeks smicanja (*engl. Deep-Layer Shear*, DLS između 0 i 6 km iznad tla), visina točke ledišta i brojni drugi (npr. Manzato, 2012). Iako vrijednosti mogu odstupati ovisno o lokaciji i izvoru podataka koji se koriste, temeljem radio-sondažnih mjerenja ustanovljeno je da se ekstremne pojave (tuča, jaka kiša, udari vjetra i tornada/pijavice) javljaju u uvjetima u kojima je vrijednost MUCAPE > 500 J/kg te DSL > 14 m/s (Púčik i sur., 2015).

Analizom izmjerenih podataka o tuči te istodobno sinoptičkih i mezoskalnih uvjeta koji su prevladavali tijekom formiranja tuče, dobiva se sveobuhvatnija slika o samoj pojavi nad promatranim područjem.

1.6 Motivacija i ciljevi istraživanja

Hrvatska je jedna od rijetkih zemalja u Europi za koju do sada nije provedeno sustavno istraživanje tuče na nacionalnoj razini, iako je među rijetkima koja posjeduje vrlo duge nizove opažanja tuče, mjerene po istom standardu. Provedbom višeslojnog istraživanja ove pojave izravno kroz opažanja tuče, ali i neizravno korištenjem podataka o munjama i podataka klimatskih simulacija, ostvario bi se značajan znanstveni doprinos razumijevanju tuče u Hrvatskoj. Stoga se ovim istraživanjem želi, na nacionalnoj razini napraviti sveobuhvatna analiza svojstava tuče kako iz opaženih tako i iz drugih dostupnih podataka, na području Hrvatske. Glavni ciljevi i vezane hipoteze ovog rada su:

C1 – Istražiti prostorna i vremenska obilježja tuče na području cijele Hrvatske koristeći arhivske podatke dobivene s meteoroloških postaja DHMZ-a.

H1 – Obilježja tuče u Hrvatskoj pokazuju velike prostorne i vremenske razlike posebno između priobalnog i kontinentalnog dijela.

C2 – Povezati pojavu tuče s pripadnim tipovima vremena, izdvojiti dominantne tipove vremena koristeći bazu podataka ERA5 te temeljem dobivenih rezultata i klimatskih simulacija procijeniti pojavnost tuče u budućim klimatskim uvjetima.

H2 – Korištenjem tipizacije vremena moguće je dobiti relevantne alate za procjenu pojave tuče u budućim klimatskim uvjetima.

C3 – Razviti model skoka munje koji je neovisan o radarskim podacima, pronaći stabilnu vezu između pojave skoka munje i pojave tuče te predložiti prostornu razdiobu tuče procijenjenu iz izmjerenih podataka o munjama.

H3 – Postoji veza između pojave skoka munje i pojave tuče pri tlu preko koje se posredno mogu dobiti informacije o tuči na području gdje nema izravnih mjerenja.

Ostvarenjem navedenih ciljeva dobit će se cjelovita slika o klimatskim obilježjima tuče u Hrvatskoj kao i projekcija pojave tuče u budućim klimatskim uvjetima. Ovim radom također će se razviti novi alat za promatranje tuče na mjestima gdje nisu dostupni drugi izvori podataka.


2 BAZE PODATAKA

2.1 Baza podataka o tuči

Klasična meteorološka opažanja unutar DHMZ-a evidentiraju se ručno u meteorološke dnevnike, u kojima opažanja meteoroloških pojava imaju zasebne rubrike. Za svaku pojavu postoji jednoznačni simbol koji je opisuje te postoji jasno definirani standard zapisa svih popratnih informacija, kao što su točno vrijeme, trajanje i intenzitet pojave. Ukoliko je pojava bila od iznimnog značaja, npr. velika zrna tuče, iznimne količine oborine, motritelj može na poleđini izvještaja dodatno opisati samu pojavu, no takvi su zapisi rijetki. Podatci zapisani u dnevnik prolaze kontrolu kvalitete podataka te se nakon toga dio osnovnih podataka digitalizira. Od podataka vezanih uz pojavu tuče za glavne meteorološke postaje (GMP), klimatološke postaje (KMP) i kišomjerne postaje (KŠP) digitalizira se podatak o broju dana s tučom u mjesecu. Da bi se dobile dodatne informacije, kao što su datum, točno vrijeme, trajanje i intenzitet pojave, potrebno je ručno pregledavati dnevnik motrenja mjesec po mjesec. Primjer jednog mjesečnog zapisa meteoroloških pojava prikazan je na Slici 1 pri čemu je crvenim strelicama ukazano na zapis tuče koji se obilježava punim trokutom. Vremena pojave zapisuju se prema srednjoeuropskom vremenu (SEV), koje je u odnosu na univerzalno koordinirano vrijeme (UTC) pomaknuto za 1 h odnosno $SEV = UTC + 1 \text{ h}$. Intenzitet se zapisuje s desne strane povrha simbola, a može poprimiti vrijednosti 0, 1 i 2 te se u slučaju vrlo rijetke tuče zapisuje oznaka „tr“ koja sugerira pojavu u tragovima. Kako bi se postigla uniformnost digitalizacije podataka prilikom čitanja iz dnevnika uvedena su opća pravila:

- A. Svi se podaci zapisuju u .csv tablicu na način da je svaki od navedenih podataka zapisan u vlastitom stupcu: godina (yyyy), mjesec (mm), dan (dd), početno vrijeme (hhmm), trajanje (tt), intenzitet (iii).
- B. Svaka postaja ima svoju istoimenu .csv tablicu.
- C. Ukoliko za pojedini podatak ne postoji definirana vrijednost to se mjesto popunjava brojkama 9, odnosno nepoznato početno vrijeme zapisuje se kao „9999“, nepoznato trajanje kao „99“ te nepoznati intenzitet kao „999“.
- D. Kad motritelj nije siguran u točno vrijeme pojave zapisuje doba dana. U tom se slučaju vrijeme zapisuje kao 9991 za rano jutro, 9992 za prijepodne, 9993, za poslijepodne, 9994 kasna večer, te 9995 za noć.
- E. Trajanje pojave koje je duže od 90 min zapisuje se kao „99“.

- F. Ponekad tuča pada s prekidima, a motritelj svaku pojavu zavede kao novu tuču. U tom slučaju, ako je pojava zabilježena više puta unutar dva sata od prvog zapisa, zapisuje se samo ona tuča koja je imala najveći intenzitet, a ako je intenzitet isti onda se zapisuje ona koja je duže trajala.
- G. Ako motritelj samo napomene da je tuča padala s prekidima, a ne istakne kada su oni bili to se zanemaruje i zapisuje se ukupno navedeno trajanje pojave.
- H. Intenzitet vrijednosti „tr“ u bazu se zapisuje se kao intenzitet vrijednosti „0“.
- I. Nekada motritelj zapisuje promjene intenziteta npr. 0–1–0, 0–2–1–0 ili 0–2. U tom se slučaju zapisuje decimalni broj 0.5 ili 1.5 ovisno o tome je li najveći zabilježeni intenzitet bio 1 ili 2.



Slika 2. Karta meteoroloških postaja u Hrvatskoj korištenih za digitalizaciju podataka o tuči. Crvenim kružićima istaknute su glavne meteorološke postaje (GMP), znakom „x“ klimatološke postaje (KMP) te zelenim trokutićima kišomjerne postaje (KŠP).

Pridržavanjem navedenih pravila digitalizirani su svi dostupni podatci i time se formirala baza podataka o tuči. Navedena baza podataka uključuje podatke s ukupno 186 postaja. Njih 40 su glavne meteorološke postaje (od kojih je 6 pod nadzorom Hrvatske kontrole zračne plovidbe), 100 je klimatoloških postaja te dodatnih 46 kišomjernih postaja, uglavnom iz priobalnog dijela Hrvatske, kako i je prikazano na Slici 2. Za dio postaja nije bilo moguće dobiti detaljne informacije pa su korišteni dostupni digitalizirani podatci DHMZ-a kako bi se donekle kompenzirao manjak. Time se baza digitaliziranih podataka korištena u ovoj studiji svodi na 33 glavne postaje (GMP), 73 klimatološke te 46 kišomjernih postaja (ukupno 150 postaja). Digitalizirana razdoblja se značajno mijenjaju od postaje do postaje, a ovise o prvom datumu otvaranja motriteljskog mjesta, kontinuitetu rada postaje, dostupnosti podataka te manjim dijelom o uspješnosti samog motritelja u opažanju pojave koja je po prirodi vrlo rijetka i kratkog vijeka. Od ukupnog broja postaja tek 36 % njih (66 postaja) imaju neprekinuta motrenja od 1984., dok se na samo 28 postaja neprekidno motri od 1964. godine. Ipak, velika većina postaja ima zapisanu zadovoljavajuću količinu podataka pa ukupan broj zapisa tuče u bazi iznosi 5801 (detaljno opisani) podatak te dodatnih 2124 zapisa iz izvještaja.

2.2 Reanaliza ERA5 i klimatske simulacije inicijative EURO-CORDEX

Za potrebe analize sinoptičkih i mezoskalnih uvjeta pogodnih za pojavu ekstremnog vremena korištena je ECMWF² reanaliza ERA5 (Copernicus Climate Change Service (C3S), 2017) Preuzeti su podatci u razdoblju od 1979. do 2019. godine s horizontalnim razlučivanjem od 0.25° na standardnim izobarnim nivoima. Dostupnost meteoroloških polja je svakih šest sati (00, 06, 12, 18 UTC). Iz baze ERA5 preuzete su temperatura, specifična vlažnost, tlak, zonalna i meridionalna komponenta vjetra te geopotencijalna visina 500 hPa plohe.

Za potrebe analize budućih klimatskih uvjeta korištena je baza podataka inicijative EURO-CORDEX iz koje je izdvojeno 8 različitih simulacija. Za simulacije su korištena 4 globalna klimatska modela koja su bila uparena s tri regionalna klimatska modela, a detaljan prikaz kombinacija dan je u Tablici 1. Sve preuzete simulacije interpolirane su na prostorni mrežni korak od 0.125° svakih 6 h. Za svaku od navedenih simulacija preuzeta su polja prizemnog tlaka i geopotencijala na visini 500 hPa za povijesno razdoblje (1971. – 2000.), početak (2011. – 2040.), sredinu (2041. – 2070.) te kraj stoljeća (2071. – 2099.). Korišten je

² Europski centar za srednjoročnu prognozu vremena (*engl. European Centre for Medium-Range Weather Forecasts*).

najpesimističniji klimatski scenarij tj. RCP8.5 (Moss i sur., 2010) koji predviđa zagrijavanje atmosfere do 5 °C do kraja 21. stoljeća.

Tablica 1. Popis kombinacija regionalnih i globalnih klimatskih modela iz inicijative EURO-CORDEX.

Regionalni klimatski model	Institucija	Globalni klimatski model	Član ansambla
ALADIN53 ⁽¹⁾	Centre National de Recherches Met. (CNRM)	CNRM-CERFACS-CNRM-CM5 ⁽⁴⁾	rlilpl
CCLM4 ⁽²⁾	Climate Limited-area Modelling Community (CLMcom)	CNRM-CERFACS-CNRM-CM5	rlilpl
		ICHEC-EC-EARTH ⁽⁵⁾	rl2ilpl
		MPI-M-MPI-ESM-LR ⁽⁶⁾	rlilpl
RCA4 ⁽³⁾	Swedish Meteorological and Hydrological Institute (SMHI)	CNRM-CERFACS-CNRM-CM5	rlilpl
		ICHEC-EC-EARTH	rl2ilpl
		MPI-M-MPI-ESM-LR	rlilpl
		IPSL-IPSL-CM5A-MR ⁽⁷⁾	rlilpl

⁽¹⁾Colin i sur., (2010), ⁽²⁾Rockel i sur., (2008), ⁽³⁾Samuelsson i sur., (2011), ⁽⁴⁾Voldoire i sur., (2013), ⁽⁵⁾Hazeleger i sur., (2012), ⁽⁶⁾Giorgetta i sur., (2013), ⁽⁷⁾Dufresne i sur., (2013)

2.3 Baza podataka o munjama

Podatci o munjama korišteni u ovom radu dobiveni su iz mreže za lociranje munja LINET (*engl. Lightning Detection Network in Europe*; Betz i sur., 2009). Podatci uključuju prostorne koordinate, datum i vrijeme, polaritet (pozitivna ili negativna munja) te tip munje (oblak – oblak ili oblak – zemlja). Dobiveni podatci obuhvaćaju razdoblje od 1. siječnja 2008. do 31. prosinca 2020. godine, a pojava munja je zapisana u koordiniranom svjetskom vremenu (*engl. Coordinated Universal Time, UTC*). Sustav LINET temelji se na približno 130 senzora koji su instalirani diljem Europe (npr. Betz i sur., 2009). Ovaj sustav koristi vrlo nisko i nisko frekventno područje kako bi detektirao gustoću magnetskog toka tijekom atmosferskog pražnjenja pomoću dvije međusobno okomito postavljene prstenaste antene (Franc i sur., 2015; Stipetić i sur., 2017; Uglešić i sur., 2018). Svi senzori sustava LINET su istog tipa, što osigurava homogenost prikupljenih podataka i eliminira pojavu pogrešaka koje bi nastale korištenjem različitih vrsta senzora. Za određivanje točnosti lokacije munje koristi se metoda „vremena dolaska“ (*engl. Time of Arrival, TOA*) koja zahtijeva ugradnju većeg broja senzora.

U sklopu LINET mreže za lociranje munja, na području Hrvatske nalazi se šest senzora (Mikuš i sur., 2012), koje dodatno prati niz senzora u susjednim zemljama. Senzori su međusobno udaljeni najviše 250 km, čime se postiže učinkovitost detekcije veća od 90 % (Franc i sur., 2015). Struje veće amplitude obično potječu od pražnjenja oblak – tlo, dok su manje amplitude posljedica pražnjenja između oblaka ili unutar oblaka. U sustavu LINET efektivna vremenska točnost lociranja munja iznad Hrvatske iznosi ~ 0.2 ms. U razdoblju od 2009. do 2018. godine srednje vrijednosti detektiranih amplituda struje su se dvostruko smanjile (Stipetić i sur., 2017; Uglešić i sur., 2018), što pokazuje značajno poboljšanje u detekciji manjih amplituda struje kod udara munje. Prosječni minimalni detektirani signal je 0.7 kA, a srednja pogreška točnosti lokacije je ± 84 m (Jelić i sur., 2021). Ova statistička pogreška točnosti lokacije rezultat je matematičkih pravila, tehnologije sustava i performansi matematičkog algoritma koji se koristi u sustavu. Unatoč navedenim ograničenjima, nijedan od potencijalnih problema ne utječe značajno na izračune i zaključke u ovom radu. Razlog tome je što se korištena metoda bavi ukupnim brojem munja bez razlučivanja tipova ili polariteta munje te se podaci akumuliraju u rasteru od $3 \text{ km} \times 3 \text{ km}$.


Koristeći ukupan broj munja napravljena je 2D baza podataka o udarima munja u rezoluciji $3 \text{ km} \times 3 \text{ km}$ i intervalima od 2 min za cijelo razdoblje. Moguće su i veće vremenske i prostorne rezolucije, međutim one premašuju računske i skladišne resurse pa su navedene vrijednosti uzete kao kompromis. Ovdje korištena vremenska rezolucija bolja je od rezolucije dostupnih satelitskih i radarskih mjerenja za ovo područje i prostorno dovoljno visoka da se razaznaju lokalne grmljavinske oluje i njihovi utjecaji na lokalnoj razini.

2.4 Baza podataka za verifikaciju indeksa intenziteta munja

2.4.1 *Oborina*

Tijekom promatranog razdoblja (2008. – 2018.) na području sjeveroistočnog Jadrana korišteno je 37 meteoroloških postaja DHMZ-a koje su mjerile 24-satne količine oborine s početkom mjerenja u 07 CET (CET = UTC + 1 h) (plavi kružići na Slici 3). U promatranom razdoblju zabilježeno je 17532 dana s oborinom. Uz to se koristila i jedna automatska postaja za dobivanje minutnih dnevnih maksimuma intenziteta oborine. Ova postaja nalazi se na svjetioniku na malom otočiću/hridi Sveti Ivan na pučini (površine cca 3500 m^2), smještenom uz zapadnu obalu

Istre na oko 4.6 km južno od Rovinja (žuta zvijezda uz obalu na Slici 3). To je najudaljeniji otok lokalnog arhipelaga nezaklonjen drugim većim otocima. Ova automatizirana postaja radila je od 2009. do 2018. godine s povremenim prekidima. Bez obzira na prekide, dostupna su 2633 radna dana od čega je tijekom 881 dana zabilježena oborina. U daljnjem tekstu ova postaja će se navoditi kao obalna. Zbog jednostavnosti i robusnosti dan s oborinom definiran je kao dan u kojem je zabilježena bilo koja količina oborine bez postavljanja donjeg praga.



Slika 3. Karta postaja za Istru koje su korištene u evaluaciji indeksa intenziteta munja. Plavi kružići predstavljaju lokacije mjerenja 24-h oborine, crveni križići predstavljaju lokacije podataka o tuči dok su žutim zvjezdicama istaknute lokacije automatskih postaja za oborinu i vjetar.

2.4.2 Vjetar

Drugi skup mjerenja su podatci s automatiziranih anemometara koji se nalaze na spomenutoj obalnoj postaji te na GMP postaji Pazin (Slika 3). U daljnjem tekstu postaja Pazin će se voditi kao kopnena postaja. Važno je napomenuti da je zbog lokalne topografije ova postaja relativno zaštićena od jakih udara vjetra u odnosu na obalnu postaju pa su i maksimalne brzine vjetra nižih vrijednosti. S obje postaje su preuzete srednje 10-minutne vrijednosti vjetra za svaki dan, a maksimalna dnevna vrijednost korištena je kao aproksimacija najjačeg udara vjetra u

određenom danu. Obalna postaja radila je od rujna 2009. do kraja 2018. godine s povremenim prekidima pa je tako registrirano 3060 radnih dana, dok je kopnena postaja zabilježila 3896 radnih dana u promatranom razdoblju (2008. – 2018.).

2.4.3 Tuča

Baza podataka o tuči uključuje podskup podataka iza baze (I) u Tablici 2 (poglavlje 3.1), a vezan je za sjeverozapadni Jadran te razdoblje od 2008. do 2017. godine. Detaljan opis podataka dan je u poglavlju 2.1. ovog rada. U promatranom razdoblju zabilježeno je 269 podataka o tuči s 21 odabrane postaje označene crvenim križićima na Slici 3.

2.4.4 Pijavice

Na temelju nekoliko različitih izvora (npr. vremenske postaje, mediji, lokalno stanovništvo i meteorološki entuzijasti), kao i ankete koja je bila aktivna od 2011. (Renko i sur., 2016), prikupljeni su podatci o 42 dana s pijavicama iz 53 nezavisna izvješća tijekom razdoblja od 2008. do 2018. godine. Sva izvješća sastoje se od datuma i mjesta, većina ih ima i vrijeme nastanka i trajanje događaja, a 23 izvješća sadržavala su podatke o broju pijavica i/ili popratnim meteorološkim pojavama (kiša, grmljavina, munja i sl.). Iako je provedena provjera valjanosti svih izvješća (uglavnom potvrdom pomoću fotografija ili više izvora iste pojave) kako bi se izbjegle pogreške u daljnjoj analizi, i dalje je upitna kvaliteta tih podataka, posebice za pijavice zabilježene tijekom noći.

3 METODOLOGIJA

3.1 Obrada podataka o tuči

Na temelju izmjerenih podataka za potrebe daljnje analize nužno je definirati sljedeća tri pojma:

1. *Događaj tuče* je bilo koji zabilježen podatak o tuči na bilo kojoj postaji u bilo koje vrijeme;
2. *Slučaj tuče* podrazumijeva jedan ili više događaja tuče na jednoj postaji unutar 2 h od pojave prvog događaja;
3. *Dan s tučom* je jedan ili više slučajeva tuče na postaji ili širem području oko postaje unutar jednog kalendarskog dana.

Zbog postavljenih pravila digitalizacije baze podataka o tuči, događaji tuče su se izravno bilježili kao slučaj tuče. Slučajevi, a posebno dani s tučom, bit će glavni predmet istraživanja u ovom radu pa je zbog jasnoće potrebno definirati i dodatne pojmove:

- a) *Dnevni hod tuče* predstavlja skup podataka o tuči na određenom području i unutar promatranog razdoblja, pri čemu su slučajevi tuče grupirani po satima;
- b) *Godišnji hod tuče* predstavlja skup slučajeva ili dana s tučom na određenom području i unutar promatranog razdoblja, pri čemu su slučajevi ili dani tuče grupirani po mjesecima;
- c) *Međugodišnja varijabilnost tuče* predstavlja skup slučajeva ili dana s tučom na određenom području i unutar promatranog razdoblja, pri čemu su slučajevi ili dani tuče grupirani po godinama;
- d) *Učestalost tuče* je prosječan broj dana s tučom u godini dobiven iz višegodišnjeg neprekinutog niza mjerenja tuče na jednoj postaji.

Uz definirane pojmove, promatrat će se i trendovi pojedinih podskupova podataka o danima s tučom. Za tu će se potrebu koristiti neparametarski Mann-Kendall-ov test signifikantnosti s Theil-Sen-ovim nagibom (Gilbert, 1987).

Kako je preliminarnom analizom utvrđeno da značajan broj postaja ima prekide u opažanjima, bilo je potrebno napraviti podskupove podataka kako bi se mogli računati trendovi, ali i iskoristiti čim veći broj dostupnih podataka. Stoga je u Tablici 2, prikazan pregled korištenih skupova podataka s pojašnjenjima. U skupovima II i III izostavljeno je razdoblje od 1991. do 1994. kako bi se izbjegla nehomogenost opažanja zbog posljedica Domovinskog rata.

Tablica 2. Skupovi podataka o tuči s pojašnjenjima.

	Razdoblje	Broj postaja (podataka)	Opis
(I)	1948. – 2019.*	186 (5801)	Glavni skup podataka iz kojeg se računaju dnevni i godišnji hodovi dana s tučom, intenziteta i trajanja
(II)	1964. – 2019.	28 (3026)	Podskup od (I) s dugim neprekinutim nizom za analizu trenda dana s tučom
(III)	1984. – 2019.	67 (4471)	Podskup od (I) sa skraćenim nizom, ali puno većim brojem postaja koje zadovoljavaju neprekinutost mjerenja. Koristi se za analizu trendova dana s tučom, trajanja te intenziteta tuče


* navedeno razdoblje predstavlja maksimalno dostupno razdoblje, no veliki dio postaja počeo je s opažanjima u nekoj kasnijoj godini

3.2 Određivanje sinoptičkih i mezoskalnih uvjeta

Iz podataka reanalize ERA5, dostupnih svakih 6 sati, za razdoblje 1979. – 2017.³ izračunata su srednja dnevna polja varijabli. Zatim je na podatke primijenjen algoritam za klasifikaciju tipova vremena prema Belušić Vozila i sur. (2021) kako bi se odredili prevladavajući sinoptički uvjeti nad Hrvatskom. Sam algoritam temelji se na objektivnoj klasifikaciji koju su dali Bissolli i Dittmann (2001) te je modificiran subjektivnim pristupom koji je predložio Poje (1965) za ispitivanje vremenskih tipova u Hrvatskoj. Korištena je domena koja obuhvaća cijelu jadransku regiju, dio Sredozemlja i kontinentalno područje (35 – 50 °N, 5 – 21 °E) te koristi polje geopotencijala na 500 hPa i prizemni tlak. Pomoću Laplaceovog operatora primijenjenog na geopotencijal 500 hPa plohe i prizemni tlak ($\nabla^2\Phi_{500}$, ∇^2p) dobivaju se informacije o vrtložnosti unutar domene iz kojih se dalje definira 16 tipova vremena od kojih je osam ciklonskih i osam anticiklonskih. Osim toga, unutar spomenutih tipova vremena razlikujemo duboke i plitke sustave. Radi jednostavnosti duboke i plitke sustave svrstat ćemo u istu kategoriju koju ćemo nazvati VT (od 1 do 8), a na grafičkim će prikazima plitki i duboki sustavi biti istaknuti različitim bojama. U odnosu na domenu, središte sinoptičkog sustava može se naći u četiri različita područja kako je prikazano na Slici 4 čime se identificira dio sustava koji utječe na Hrvatsku. Za prednji dio sinoptičkog sustava koji utječe na Hrvatsku uvode se oznake VT1 i VT5, zatim VT2 i VT6 za gornji dio sustava koji utječe na Hrvatsku, stražnji dio sustava koji

³ Navedeno razdoblje bilo je dostupno u trenutku provedbe analize.

utječe na Hrvatsku nosi oznake VT3 i VT7 dok je za donji dio sinoptičkog sustava koji utječe na Hrvatsku uvedena oznaka VT4 i VT8. Brojevi 1 do 4 odnose se na ciklonalne tipove vremena dok su brojevi 4 do 8 vezani za anticiklonalne tipove. Kvazi-bezgradijentno polje je prisutno kada je srednja vrijednost u domeni $\nabla^2 p$ manja od 0.06 hPa/km pa se tako definira posljednji tip vremena. Kako bi se odredili prevladavajući tipovi vremena povezani s pojavom tuče, iz glavnog skupa podataka (I) izdvojeni su svi dani s tučom te su upareni s pripadnim tipom vremena.



Slika 4. Ilustracija područja unutar domene na temelju kojih je određena tipizacija vremena. Crvenim linijama označene su granice na temelju kojih objektivni algoritam pridružuje pojedini tip vremena. Bojama je označena visina topografije u metrima.

Mezoskalni uvjeti za pojavu tuče uglavnom se vežu uz termodinamičke indekse koji su izračunati pomoću programa „*Sounding and Hodograph Analysis and Research Programme*“ u *Pythonu* (SHARPPy) (Blumberg i sur., 2017). SHARPPy je zbirka besplatnih programa za analizu i vizualizaciju sondažnih podataka. Na temelju profila temperature, specifične vlažnosti, tlaka i komponenti vjetera iz reanalize ERA5, pomoću SHARPPy-a su izračunati indeks podizanja (LI), indeks najnestabilnijeg CAPE-a (MUCAPE), K-indeks (KI), indeks smicanja u prvih 6 km (DLS) te visina razine smrzavanja. LI je izračunat kao razlika između

temperature na 500 hPa i temperature česti zraka koja se podigne na 500 hPa od površine mokroadijabatičkim procesom. MUCAPE je procijenjen podizanjem česti s maksimalnom ekvivalentnom potencijalnom temperaturom u najnižih 400 hPa, tj. najnestabilnijom česti. Pomoću razlike temperature i temperature rosišta na 850 hPa te temperature na 500 hPa i sadržaja vlage u nižoj atmosferi određen je KI. DLS je određen kao razlika brzine vjetra na 10 m i 6 km. Kontinuirani vertikalni temperaturni profil je dobiven linearnom interpolacijom temperature između nivoa, iz čega je određena visina nulte izoterme (0°C) u odnosu na tlo. Kako bi se napravila veza između indeksa nestabilnosti i pojave tuče, za svaki slučaj tuče pronađeno je 9 najbližih točaka u reanalizi ERA5 te je izračunata srednja vrijednost promatranog indeksa. Tako dobiveni indeksi grafički su prikazani pomoću pravokutnih dijagrama (*engl. Box and whisker plot*).

3.3 Metoda određivanja indeksa intenziteta munja


U sklopu ovog rada razvijen je i novi indeks za intenzitet munja, matematički utemeljen na metodi koja se koristi za detekciju skoka munje. Metoda skoka munje koristi skup matematičkih operacija koje ocjenjuju ponašanje munje u kraćim vremenskim intervalima (1 – 5 min) u nekoliko koraka. Iako se u literaturi mogu pronaći različite iteracije ove metode (Gatlin i Goodman, 2010; Schultz i sur., 2009), vodeći princip je isti. Prije bilo kakvog izračuna, obično se definira središte oluje pomoću neke vrste algoritma za praćenje oluje. Nadalje, definira se područje utjecaja oko središta oluje unutar kojeg se prikuplja broj munja u svakom vremenskom koraku. Tako prikupljeni podatci se dalje računski obrađuju na sljedeći način: (i) izračun srednjeg broja munja u odabranom vremenskom intervalu (1 – 5 min) (ii) izračun težinskog kliznog srednjaka (iii) izračunavanje trenda u broju bljeskova munje između nekoliko uzastopnih vremenskih koraka, (iv) izračun standardne devijacije (σ) nekoliko uzastopnih trendova, (v) usporedba trenda sa standardnom devijacijom od prethodnog koraka te (vi) ponavljanje postupka pomicanjem za jedan korak unaprijed do posljednjeg vremenskog koraka. Konačno, ako trend prijeđe unaprijed definirani prag standardne devijacije (najčešći prag je $2 \times \sigma$), smatra se da je došlo do skoka munje.

Koristeći metodu skoka munje i prelazeći s Lagrangeovog u Eulerov sustav, dobiva se novi način za analizu munja i uvodi novi indeks intenziteta munja (*engl. Thunderstorm intensity indeks, TSII*). U ovom pristupu, nije potrebno koristiti radarske algoritme za praćenje oluje niti

metode za određivanje putanja oluje jer se svaka točka mreže računski promatra kao zaseban objekt. Iako su matematički u suštini isti, ključna razlika između algoritma skoka munje i TSII-ja je u grupiranju podataka o munjama čime se mijenja i sama interpretacija dobivenih rezultata. Oluja je podijeljena na proizvoljno male segmente (tj. unaprijed definiranu mrežu), a promatranje iz Eulerovog sustava omogućava praćenje svakog segmenta te oluje zasebno. Time se mogu detektirati značajne promjene tj. skokovi u dinamici munja unutar oluje nad svakom točkom mreže i u svakom trenutku. Drugim riječima, TSII je dijagnostički alat koji ističe područja na kojima je grmljavinska oluja bila najdinamičnija. Dodatno, zbog trenutnih računalnih postavki, TSII je binarni indeks koji dobiva pozitivnu vrijednost ($TSII = 1$) ako se broj udara munja naglo poveća, dok je inače TSII jednak nuli.

Kako bi se zorno prikazao proces računanja TSII-ja, odabran je jedan slučaj grmljavinske konvekcije (Slika 5a) iz baze podataka o munjama. Dana 11. svibnja 2018. lokalna konvekcija se na sjeveroistočnom Jadranu organizirala u jako grmljavinsko nevrijeme, koje je proizvelo bujične poplave, tuču i jak vjetar. Nevrijeme je ukupno trajalo oko 90 min. Iz medijskih zapisa u kojima je komentirano stanje vremena na promatrani datum (ružičaste zvjezdice) vidljiva je vrlo gusta tuča, praćena bujičnim poplavama na obje lokacije. Na sjevernoj zvjezdici je također zabilježen i jak vjetar. Prema podacima s kišomjernih postaja (krugovi) maksimalna akumulirana oborina iznosila je 55 mm. Dodatno, četiri uređaja za mjerenje tuče (crni trokuti) izmjerili su sitnu gustu tuču s maksimalnim promjerom od 11.6 mm i gustoćom od 2800 zrna/m².

Da bi se dobili podatci o munjama, domena je podijeljena na mrežu kvadratića veličine 3 km × 3 km, te su se za svaki kvadratić zbrojili svi bljeskovi munje za svaki 2-min interval kako je i navedeno u poglavlju 2.3. Veća prostorna i vremenska rezolucija je moguća, no nadilazi skladišne i računalne resurse dostupne za provedbu ovog istraživanja. Preliminarna istraživanja sugeriraju da se rezolucija može povećati do 1 km × 1 km nakon čega broj zabilježenih munja u 2 min intervalu pada na premale vrijednosti da bi se dobili upotrebljivi podatci.



Slika 5. (a) Slučaj grmljavinske konvekcije iz 11. svibnja 2018. zabilježen nad sjeveroistočnim Jadranom. Trag munja označen je svijetloplavom bojom, dok je trag TSII-ja označen žutom bojom. Krugovi pokazuju položaj kišomjernih postaja. Različite boje krugova ističu tri različita okruženja na koja postaja može utjecati. Crvena označava okruženje intenzivnog nevremena (ITD), zelena označava uobičajeno okruženje s munjama (TD), a plava označava okruženje bez munja (NTD). Četiri crna trokuta prikazuju zapise o tuči izmjerene pomoću tučomjera koji se nalazi u promatranom području. Ružičaste zvijezde označavaju medijske izvještaje o ekstremnim vremenskim prilikama (tuča, jaka kiša i jaki vjetar). Narandžaste linije povezuju postaje s količinama oborina zabilježenim tijekom promatranog dana. U (b), vremenska evolucija prosječne količine munja (plavo) se dalje obrađuje jednadžbama (2) (crvena linija) i (3) kako bi se dobio DFRDT (crna crtana linija). Točke koje prelaze zelenu liniju (2σ) i pojavljuju se iznad praga (ružičasta linija) smatraju se TSII = 1.

Na slici 5b grafički su prikazane vrijednosti parametara izračunatih na temelju jedne odabrane točke mreže sa Slike 5a. Računski tijek algoritma uključuje računanje prosječne gustoće munja po minuti u intervalima od 2 min:

$$FR_{avg}(ti) = \frac{FR(ti)}{2} \quad (1)$$

gdje se FR_{avg} mjeri u bljeskovima u minuti (plava linija na Slici 5b), a zatim se primjenjuje otežani klizni srednjak kako bi se dobili podatci prikazani crvenom linijom:

$$MFR_{avg}(ti + 3) = \frac{1}{3} \left[FR_{avg}(ti + 3) - \frac{2}{3} FR_{avg}(ti + 2) - \frac{1}{3} FR_{avg}(ti + 1) \right] \quad (2)$$

Dalje se računaju uzastopni trendovi za cijelo vremensko razdoblje (crna linija):

$$\frac{d}{dt} MFR_{avg}(ti + 4) = \frac{MFR_{avg}(ti + 4) - MFR_{avg}(ti + 3)}{(ti + 4) - (ti + 3)} = DFRDT \quad (3)$$


Standardna devijacija (σ) trendova (DFRDT) izračunata je za svaki od pet uzastopnih vremenskih koraka i pomnožena s 2 (zelena linija na Slici 5b). Da bi se dobio TSII, šesti uzastopni trend mora biti veći od $2 \times \sigma$ dobivenih iz prethodnih pet trendova (označeno strelicom koja pokazuje TSII-jeve). Wapler (2017) je u svom istraživanju obilježja munja i tuče pokazala da je lokalna srednja gustoća munja blizu opažene tuče veća od 1.25 udara po 1 km² tijekom 5 min. Preračunato na razlučivost od 3 km × 3 km i interval od 2 min, minimalni prag za TSII bi trebao biti 4.5 udarca tijekom 2 min. Stoga, kako bi se osigurala fizikalna interpretacija pojavljivanja TSII-ja, zanemaruju se svi TSII-jevi koji proizlaze iz manje od 5 udaraca munja u intervalu od 2 min (ružičasta linija na Slici 5b). Ponavljanjem metode za svaku od točaka mreže na Slici 5a, dobiven je ukupni trag TSII-ja (žuti pravokutnici) dok je ukupan trag munja istaknut svijetloplavom bojom. Treba napomenuti da jedna oluja može proizvesti više TSII-ova ovisno o svojoj veličini i intenzitetu, kao što se vidi u ovom primjeru.

Za razumijevanje i provjeru primjene TSII-ja, korišteni su različiti izvori podataka s područja Istre (Slika 3) navedeni u poglavlju 2.4. Radi robusnosti provjere predložene metode

dnevna suma traga TSII-ja uspoređivana je s dnevnim maksimumom minutnog intenziteta oborine, 24-h akumuliranom oborinom, dnevnim 10-min maksimumom vjetra te danom s tučom i danom s pijavicom. Za evaluaciju je uzeto razdoblje od 11 godina (2008. – 2018.). Svi dostupni izvori podataka georeferencirani su u odnosu na mrežu TSII-ja, odnosno svakoj postaji je pridružena mrežna točka $3 \text{ km} \times 3 \text{ km}$ koja najbolje odgovara njezinim geografskim koordinatama. Budući da su pijavice imale deskriptivnu lokaciju (obično obližnji grad ili selo na obali), ispitan je svaki slučaj posebno subjektivnim pristupom.

3.4 Metoda verifikacije indeksa intenziteta munja

Ovisno o varijabli, korištena su dva područja utjecaja oko lokacije varijable (crni pravokutnici na Slici 6a) kako bi se provjerio njezin odnos s TSII-jom, ali i pojavom munja. Na Slici 6b središnji kvadratić dimenzija $3 \text{ km} \times 3 \text{ km}$ predstavlja georeferenciranu postaju s koje su preuzeti podatci, zeleni kvadrat označava područje utjecaja od 3 km oko postaje koje se koristi za oborinu, a veći kvadrat je odabran kao područje utjecaja od 15 km za podatke o vjetru i pijavicama. Područje utjecaja za tuču je promatrano za razne razrede utjecaja od 3 – 30 km.



Slika 6. (a) Isto kao i Slika 3 uz dodana područja utjecaja (crni kvadrati) od 3 i 15 km od promatrane postaje. U (b) crni kvadrati predstavljeni su onako kako ih vidi algoritam za definiranje područja utjecaja. Nakon što se izabere postaja, ona se centrira u mrežu $3 \text{ km} \times 3 \text{ km}$ te se oko nje definira područje većeg i manjeg utjecaja. Zelenim kvadratićima označeno je područje utjecaja od 3 km dok je plavom označeno područje utjecaja od 15 km.

Korištenjem područja utjecaja definirana su tri potencijalna okruženja koja doprinose nastanku pojave. Ta su okruženja definirana na sljedeći način:

- 1) Okruženje bez munja (NTD): ako nije otkriven trag munje ili TSII-ja unutar unaprijed definiranog područja utjecaja;
- 2) Okruženje samo za munje (TD): ako je unutar unaprijed definiranog područja utjecaja otkriven samo trag munje;
- 3) Okruženje s intenzivnom promjenom aktivnosti munjam (ITD): ako je trag TSII-ja otkriven unutar unaprijed definiranog područja utjecaja.

Stvarni prikaz opisanih okruženja prikazan je na slici 5a, gdje je žutim i svijetloplavim bojama istaknut trag TSII-ja i trag munja. Različite boje krugova označavaju koje je okruženje dodijeljeno određenoj postaji. Ukupno je primijenjena definicija dala tri postaje s okruženjem ITD (crveni kružići), 11 postaja s okruženjem TD (zeleni kružići) i 23 postaje s okruženjem NTD (plavi kružići). Nadalje, za podatke o oborini, nakon što su dodijeljeni radijusi utjecaja, kreiran je dodatni filter kako bi se eliminirale one postaje koje nisu zabilježile oborinu. U ovom konkretnom slučaju sve NTD postaje imale su 0 mm oborine. Općenito, u slučaju mješovitih konvektivnih i stratiformnih sustava, mogla bi se dobiti znatna količina NTD-a. Dodatno, izračunati su 10., 25., 50., 75. i 90. percentili određene varijable i određenog okruženja kako bi se ispitale razlike među njima.

4 REZULTATI I DISKUSIJA

4.1 Prostorna i vremenska obilježja tuče


Kroz ovo se poglavlje ispituju prostorna i vremenska obilježja tuče, kao što su učestalost, godišnji i dnevni hod, međugodišnja varijabilnost, trendovi, ali i druga obilježja koja su bila dostupna kroz digitalizirane podatke (intenzitet i trajanje). Također, razmotrit će se i sezonski doprinosi trendovima kako na dužem tako i na skraćenom nizu podataka iz Tablice 2.

4.1.1 Podjela regija

Hrvatska je topografski vrlo kompleksna regija te je za očekivati da će se obilježja tuče razlikovati ovisno o promatranom području. Dijeljenje Hrvatske na geografski ili topografski slične regije nije se pokazalo prikladnim zbog nejednake prostorne gustoće postaja i posljedično količine podataka. U prilog tome idu rezultati nedavnih istraživanja koja su otkrila da pojedini dijelovi Istre bilježe tuču podjednako tijekom cijele godine (Jelić i sur., 2020) za razliku od unutrašnjosti Hrvatske gdje dominira izraženi ljetni maksimum. Također su uočeni različiti dnevni i godišnji hodovi tuče duž središnjeg i južnog dijela hrvatskog priobalja (Blašković, 2021). Uz obalu su detektirane postaje čiji podatci ukazuju na podjednake količine tuče kroz cijelu godinu s blago izraženijom aktivnošću tuče u proljetnom i/ili jesenskom razdoblju, odnosno lokacije gdje se tuča dominantno opaža tijekom hladnog dijela godine. Stoga su u ovom radu postaje grupirane prema sličnostima godišnjih obilježja tuče. Drugim riječima, postaje su kategorizirane prema godišnjem hodu tuče na sljedeći način:

- Izračunati su postotni udijeli tuče u toplom dijelu godine (svibanj – listopad) te u hladnom dijelu godine (studeni – travanj);
- Izračunata je razlika dobivenih postotaka (topli dio – hladni dio);
- Ako je razlika pozitivna i veća od 20 % postaja se naziva “ljetni” tip postaje;
- Ako je razlika negativna i manja od 20 % postaja se naziva “zimski” tip postaje;
- Ako je razlika unutar 20 % bez obzira na predznak, postaja se naziva “prijelazni” tip postaje.

Tako definirana karta postaja prikazana je na Slici 7 pri čemu su crvenim oznakama istaknute postaje s dominacijom opažene tuče u toplom dijelu godine, zelenim oznakama “prijelazne“ te plavim postaje sa značajnim udjelom tuče u hladnom dijelu godine.



Slika 7. Karta postaja sortiranih prema tipu godišnjeg hoda tuče. Crvenim kružićima istaknute su postaje s prevladavajućom tučom u toplom dijelu godine, zelenim kružićima su naznačene “prijelazne“ postaje te plavima postaje s prevladavajućom tučom u hladnom dijelu godine. Topli dio godine obuhvaća razdoblje od svibnja do listopada, a hladni od studenoga do travnja.

Iz dobivenih rezultata može se vidjeti kako u najvećem dijelu Hrvatske prevladavaju postaje s tučom u toplom dijelu godine koje se osim u cijelom kontinentalnom dijelu nalaze i u većem dijelu Gorske Hrvatske, Istre, ali i dijelovima Dalmatinske zagore. Crveni kružić na otoku Komiji odgovara kišomjernoj postaji Stončica koja, iako označena kao “ljetni“ tip postaje,


najvjerojatnije odgovara “prijelaznom” tipu, pošto su bliske postaje “zimskog” tipa. Razlog ovakvom rezultatu je relativno mali broj zapisa tuče na toj postaji (10 zapisa u razdoblju 1974. – 1990.) pa je uvjet od 20 % teško zadovoljiti. Prijelazne postaje prevladavaju na prostoru priobalnih dijelova Istre, Kvarnera, područja oko Zadra te većeg dijela Dalmatinske zagore, dok postaje s većim udjelom tuče u hladnim mjesecima dominiraju otočkim regijama, te priobaljem u srednjem Jadranu i gotovo cijelom Dubrovačko-neretvanskom županijom. Broj postaja, kao i broj zapisa tuče u pojedinom području dan je u Tablici 3. Uz to je naveden i broj postaja koje unutar svakog razdoblja posjeduju neprekinute nizove.

Tablica 3. Ukupan broj postaja podijeljenih po tipu s pripadnim brojem podataka o tuči te broj onih postaja koje su u promatranim razdobljima imale neprekinute nizove.

Tip postaje	Br. Postaja	Br. Dana s tučom	Neprekinuti niz 1964. – 2019. br. Postaja/br. Dana	Neprekinuti niz 1984. – 2019. br. Postaja/br. Dana
Postaje s većim udjelom tuče u toplim mjesecima (tzv. “ljetni” tip)	113	3993	15 / 1142	38 / 1844
“prijelazni” tip postaja	31	1617	5 / 673	12 / 962
Postaje s većim udjelom tuče u hladnim mjesecima (tzv. “zimski” tip)	42	2315	8 / 1211	17 / 1665

4.1.2 Godišnji hod tuče

Za ukupan broj dana s tučom (svi podatci iz Tablice 3.) izračunati su godišnji hodovi. S obzirom na to da je tuča rijetka pojava, bilo koja postaja koja je zabilježila podatak o tuči uzeta je u obzir te su rezultati prikazani na Slici 8. Prilikom prikaza, svaki je tip postaje normaliziran s ukupnim brojem vlastitih podataka. Na taj način dobiveni su postotni udjeli tuče na pojedinom tipu postaja u pojedinom mjesecu pa su tipovi postaja međusobno usporedivi. Postaje s većim udjelom tuče u toplim mjesecima (tzv. “ljetni” tip postaja) su prikazane crvenim pravokutnicima. Na tim je postajama najizraženija aktivnost tuče u razdoblju od travnja do kolovoza s maksimumom u lipnju. Ovi rezultati se dobro slažu s prethodnim istraživanjima iz Počakal i sur. (2009) i Počakal (2012) koji su promatrali samo kontinentalni dio Hrvatske. Ipak treba istaknuti da se u navedenim istraživanjima nisu analizirali podatci iz hladnog dijela godine, već samo od travnja do listopada. Rezultati na Slici 8, pokazuju da se za „ljetni” tip postaja tuča pojavljuje tijekom cijele godine te da se oko 14 % dana s tučom pojavljuje u razdoblju od studenog do ožujka.




Slika 8. Godišnji hod tuče za tri tipa postaja. “Ljetni“ tip postaje je prikazan crvenim, “prijelazni“ tip zelenim te “zimski“ tip postaje plavim stupcima. Svaki od tipova normaliziran je s ukupnim brojem dana s tučom u tipu te je na ordinati prikazan postotni udio dana s tučom za svaki mjesec.

Iz podataka s “prijelaznih“ postaja može se zaključiti kako je na tim postajama tuča podjednako vjerojatna tijekom cijele godine s naglascima na razdoblje od veljače do lipnja te mjesecu studenom koji zapravo ima najveći udio dana s tučom u godini. “Zimski“ tip postaje glavnu aktivnost tuče bilježi između studenoga i travnja, s maksimumom u veljači. Tuča je i ovdje moguća u toplijim mjesecima (od svibnja do listopada), iako je njen udio oko tri puta manji. Ovi rezultati za “zimski“ tip postaja možda nisu intuitivni, pošto su dosadašnja istraživanja tuče u Hrvatskoj bila vezana uz njen kontinentalni dio gdje je fokus bio na toplom dijelu godine zbog raširene poljoprivredne aktivnosti i provođenja motrenja unutar sustava obrane od tuče. No, uzmu li se u obzir osnovni mehanizmi nastajanja tuče (visina nulte izoterme, prisutnost vlažnog zraka, nestabilni uvjeti u atmosferi), ovakva je godišnja razdioba tuče očekivana. U priobalju, a posebno prema jugu, ljetne temperature su vrlo visoke pa su uvjeti za nastanak tuče otežani, dok se većina formirane tuče otopi prije nego padne na tlo. Zime su pak zbog utjecaja mora blage, a zrak bogat vlagom, što pogoduje razvoju nestabilnosti te se uz prisustvo visoke orografije konvektivni sustavi lakše formiraju. Usporedbom sva tri tipa može se zaključiti kako “ljetni“ tip ima najveću amplitudu kroz godinu, čime se glavnina pojave tuče koncentrira u svega 6 mjeseci (mesečni udio > 5 %), dok je amplituda “zimskog“ tipa puno manja te je aktivnost tuče izražena tijekom 8 mjeseci. “Prijelazni“ tip je uravnotežen kroz svih 12 mjeseci, iako se proljeće i kasna jesen ističu s nešto većom učestalošću pojave tuče. Rezultati slični

“zimskom“ tipu dobiveni su i za neke druge zemlje Sredozemlja. Naime, obalni dijelovi Grčke također bilježe maksimume tuče u hladnijem dijelu godine (Kotinis-Zambakas, 1989) dok su u Portugalu (Santos i Belo-Pereira, 2019) prisutni isključivo godišnji hodovi koji odgovaraju ovdje dobivenima za “zimске“ i “prijelazne“ tipove postaja.

4.1.3 Dnevni hod tuče

Slično prethodnom poglavlju ovdje su izračunati dnevni hodovi broja dana s tučom u pojedinom satu, a dobiveni rezultati dani su na Slici 9. Vidljivo je kako postoje značajne razlike između tipova od kojih je najistaknutija razlika u maksimumu pojavnosti tuče za pojedini tip.



Slika 9. Dnevni hod tuče za tri tipa postaja. “Ljetni“ tip postaje je prikazan crvenim, “prijelazni“ tip zelenim te “zimski“ tip postaje plavim stupcima. Svaki od tipova normaliziran je s ukupnim brojem dana s tučom u tipu pa je na ordinati prikazan postotni udio dana s tučom za svaki sat.


U “ljetnom“ tipu postaja maksimum aktivnosti tuče zabilježen je u 15 h po SEV-u, iako tuča podjednako često pada u razdoblju od 13 do 17 h dok je glavnina aktivnosti (satni udio > 4 %) smještena između 11 i 19 h. Takvi se rezultati podudaraju s istraživanjem tuče u kontinentalnom dijelu Hrvatske (Počakal i sur., 2009). Dnevni hod za “prijelazni“ tip oblikom donekle nalikuje na onaj za “ljetni“ tip postaja, no maksimum je zabilježen u 12 h, a glavnina aktivnosti tuče raspoređena je između 7 i 19 h. Neočekivani rezultat ovog istraživanja je vezan za “zimski“ tip

postaje, na kojima se maksimum aktivnost tuče pojavljuje u 8 h ujutro, što do sada nije evidentirano u domaćoj literaturi. Slična obilježja uočena su jedino tijekom analize koja je rađena za Kinu te objavljena u studiji Zhang i sur. (2008). U njoj autori navode određeni broj postaja koje maksimum tuče bilježe u noćnim i jutarnjim satima. U Kini je dio tih postaja vezan za jugozapadne dijelove obale, no postoje i dvije pokrajine u kontinentalnom dijelu koje bilježe ista svojstva. Autori komentiraju tek kontinentalni dio pri čemu navode da je za isto odgovorno formiranje noćne konvencije koja se advektira iz jedne pokrajine u drugu.

Osim što je uočen jutarnji maksimum na više postaja duž Jadrana, izraženija aktivnost tuče na „zimskim“ postajama proteže se tijekom cijelog dana pa sve do večernjih sati kada se pojavljuje i sekundarni maksimum u 20 h. Dobiveni rezultat sugerira postojanje dvaju odvojenih režima (jutarnji i večernji) koji doprinose formiranju tučonosne konvencije i time otvara nove smjerove budućih istraživanja. Općenito, na temelju dobivenih rezultata svih triju tipova postaja može se zaključiti kako je glavnina tuče ipak prisutna tijekom dana, iako je moguća i u noćnim satima kako je vidljivo sa Slike 9.

4.1.4 Učestalost tuče

Korištenjem skupa podataka (I) iz Tablice 2 (186 postaja s 5801 podatkom tuče) za svaku je postaju izračunata učestalost tuče. Za postaje koje su imale neprekinute nizove, ta je frekvencija izračunata na ukupnom nizu podataka, dok je za postaje koje su imale prekide, pronađen najduži neprekinuti niz mjerenja te je na temelju tog razdoblja izračunata učestalost. Rezultat učestalosti tuče po postajama prikazani su na Slici 10. Vrijednosti učestalosti poprimaju vrijednosti u intervalu od 0.1 do 3.8 dan/god s iznimkom postaje Zavižan za koju je učestalost 4.8 dan/god. Postaja Zavižan nalazi se na 1594 m nadmorske visine te je klasificirana kao prijelazna postaja, što sugerira da se tuča na toj postaji može opaziti tijekom cijele godine. Jedan od mogućih razloga takvoj učestalosti je visoka nadmorska visina postaje zbog koje se formirana tuča ne stigne otopiti prije pada na tlo. Sljedeća lokacija s razmjerno velikom učestalošću tuče od 3.8 dan/god je Grad Šibenik, a može se vidjeti kako i ostatak priobalnih postaja zapravo bilježi veliku učestalost tuče. Gledajući po županijama, Šibensko-kninska te sjeverni dio Splitsko-dalmatinske županije čine koridor s vrlo velikom učestalošću tuče (1.5 – 3.8 dan/god).



Slika 10. Prostorna razdioba učestalosti tuče za promatrane postaje na području Hrvatske. Bojom i veličinom kruga istaknute se vrijednosti učestalosti na pojedinoj postaji. Maksimalna učestalost tuče odnosi se na planinsku postaju Zavižan (crni krug) koju slijedi ona za postaju Šibenik. Minimalna učestalost uočena je na više postaja (zeleni kružići) od kojih se ističu one u Lici, na istočnim padinama Učke te češće na otocima (npr. na otoku Krku).


Također, priobalni dio Primorsko-goranske županije od Senja prema Rijeci pa zatim uz Učku te prema Pargu bilježi velike vrijednosti učestalosti tuče. Slijede još neka područja kao što su okolica doline rijeke Mirne u Istri, Ploče i Metković, te okolica grada Dubrovnika. I na nekim otočnim postajama uočljiva je zamjetna učestalost tuče. To su postaje Silba, Komiža, Hvar, Jelsa (na Hvaru) te Korčula. U Lici je najistaknutija postaja Gospić, no za tu je postaju učestalost već od 1.5 dan/god. U kontinentalnom dijelu, učestalost je uglavnom u intervalu od 0.3 do 1.6 dan/god s iznimkom postaja Županja (2.1 dan/god), Kutjevo (1.9 dan/god) i Križevci

(1.8 dan/god). S druge strane, prepoznata su i neka područja s učestalošću tuče manjom od 0.3 dan/god, koja su na slici označena zelenim kružićima. Najistaknutiji je sjeverni dio Jadrana i Lika gdje je tučom najmanje zahvaćen jugoistočni dio Učke, istočni predjeli Velebita, te otok Krk.

Usporedbom rezultata sa Slike 10 i rezultata prethodnih istraživanja u kontinentalnoj Hrvatskoj (Gajić-Čapka i Zaninović, 1993; Jugo, 1962; Paškvan, 1955; Počakal, 2012; Počakal i sur., 2009) može se vidjeti da se područja povećane učestalosti u određenoj mjeri poklapaju s rezultatima sa Slike 10, iako izvori podataka kao i razdoblja analiza nisu ista. Općenito, usporedbom s rezultatima koje u svom radu navodi Jugo (1962), može se vidjeti kvantitativno podudaranje vrijednosti učestalosti tuče na većini navedenih područja. Ipak postoje i neka odstupanja u vrijednostima učestalosti, kao što su podatci za Baranju i Srijem gdje se prosječne vrijednosti iz tog rada, od 3 do 4 dan/god, ne naziru u ovdje napravljenoj analizi. U kontekstu europskih istraživanja, učestalost tuče u Hrvatskoj je slična onima u drugim zemljama prikazanim u radu Punge i Kunz (2016), iako su neke ovdje dobivene vrijednosti puno veće (npr. za Šibenik). Također, u usporedbi sa satelitskim procjenama tuče na temelju premašujućih vrhova oblaka (Punge i sur., 2017) uočava se podudaranje za većinu regija posebno ako uzmemo u obzir da se radi o vremenskim nizovima različitog (odnosno kraćeg) trajanja (2004. – 2014.).

4.1.5 Međugodišnja varijabilnost tuče i trendovi

Varijabilnost tuče vidljiva je na svim prostornim i vremenskim skalama. U zapisima jedne postaje mogu se naći razdoblja s iznimno velikim brojem dana s tučom, kao i one godine kada tuče uopće nema. Kako bi se varijabilnost zornije prikazala, korištenjem skupova (II) i (III) iz Tablice 2, na Slici 11 prikazana je međugodišnja varijabilnost tuče za razdoblje od 1964. do 2019. (Slika 11a) te 1984. – 2019. godine (Slika 11b) za sve postaje zajedno (crna linija) te zasebno za “ljetni” tip (crvena linija), “prijelazni” tip (zeleno linija) te “zimski” tip (plava linija).



Slika 11. Međugodišnja varijabilnost tuče za cijelu Hrvatsku (crna linija), te dekompozicija na “ljetni” tip postaje (crvena linija), “prijelazni” tip (zeleni linija) te “zimski” tip postaje (plava linija). (a) razdoblje od 1964. do 2019., (b) razdoblje od 1984. do 2019. sukladno skupovima podataka (II) i (III) iz Tablice 2.

Na apscisi su istaknute godine, a na ordinati se nalazi ukupan broj dana s tučom za pojedinu godinu. Iako je prema dnevnicima motrenja veći dio postaja u razdoblju 1991. – 1994. obavljao motrenja, navedeno razdoblje je izostavljeno (okomite crtkane linije) jer se ne može s velikom sigurnošću tvrditi da su postaje u potpunosti provodile opažanja pojava. Promatranjem nizova za različita područja može se vidjeti da ne postoje nikakve pravilnosti od godine do godine, niti da se godine s povišenom/smanjenom aktivnosti ogledaju unutar različitih područja. Ovakav rezultat nije svojstven samo za Hrvatsku već se pronalazi i u drugim istraživanjima o tuči (npr. Ćurić i Janc, 2016; Punge i Kunz, 2016; Tuovinen i sur., 2009).

Tablica 4. Analiza trenda za Hrvatsku te za pojedine tipove postaja na dugom nizu podataka temeljenom na skupu (II) iz Tablice 2, a uključuje razdoblje od 1964. do 2019. godine. U polja se upisuje nagib pravca/nivo signifikantnosti (p). Narančastom bojom je istaknut $p < 0.05$ dok je žutom istaknut $p < 0.1$. “Ljetni” tip postaje ima dominantno zabilježenu tuču u toplom dijelu godine (svibanj – listopad) dok su “zimске” postaje one koje imaju često mjerenu tuču u hladnom dijelu godine (studenj – travanj). Važno je naglasiti da se “ljetni” tip postaje u godišnjem hodu razlikuje od ljetne sezone (LSK), odnosno “zimski” od zimske sezone (PSV). U drugom i trećem dijelu tablice Skup (II) rastavljen je na razdoblje od 1964. do 1990. odnosno od 1995. do 2019. godine.

Skup (II)	godina	PSV	OTS	LSK	RLS
Od 1964. do 2019.					
Hrvatska	-0.31 / 0.00	-0.02 / 0.40	0.00 / 0.91	-0.15 / 0.00	-0.13 / 0.00
“ljetni” tip	-0.10 / 0.06	0.00 / 0.56	0.02 / 0.36	-0.11 / 0.00	0.00 / 0.18
“prijelazni” tip	-0.04 / 0.17	0.00 / 0.62	0.00 / 0.78	0.00 / 0.22	0.00 / 0.06
“zimski” tip	-0.17 / 0.00	0.00 / 0.58	-0.04 / 0.06	-0.02 / 0.03	-0.06 / 0.00
Od 1964. do 1990.					
Hrvatska	-1.00 / 0.01	0.00 / 0.85	-0.07 / 0.60	-0.47 / 0.01	-0.50 / 0.00
“ljetni” tip	-0.50 / 0.01	0.00 / 0.62	0.00 / 0.92	-0.29 / 0.01	-0.11 / 0.02
“prijelazni” tip	-0.24 / 0.03	0.00 / 1.00	-0.06 / 0.27	-0.11 / 0.05	-0.13 / 0.04
“zimski” tip	-0.35 / 0.248	0.00 / 0.63	0.00 / 0.66	0.00 / 0.37	-0.21 / 0.01
Od 1995. do 2019.					
Hrvatska	-0.18 / 0.45	0.00 / 0.49	0.06 / 0.66	-0.04 / 0.80	-0.31 / 0.01
“ljetni” tip	0.03 / 0.81	0.00 / 0.76	0.17 / 0.08	0.00 / 0.93	0.00 / 0.28
“prijelazni” tip	-0.10 / 0.28	0.00 / 0.92	0.00 / 0.92	0.00 / 0.52	0.00 / 0.42
“zimski” tip	-0.06 / 0.54	0.17 / 0.09	0.00 / 0.58	0.00 / 0.55	-0.13 / 0.01

Tablica 5. Analiza trenda za cijelu Hrvatsku te za pojedine tipove postaja na skraćenome nizu podataka temeljenom na skupu (III) iz Tablice 2, koji uključuje razdoblje od 1984. do 2019. godine. U polja je upisan nagib pravca i nivo signifikantnosti. Narančastom bojom je istaknut $p < 0.05$ dok je žutom istaknut $p < 0.1$. “Ljetni” tip postaje ima dominantno zabilježenu tuču u toplom dijelu godine (svibanj – listopad) dok su “zimске” postaje one koje imaju često izmjerenu tuču u hladnom dijelu godine (studenj – travanj). Važno je naglasiti da se “ljetni” tip postaje u godišnjem hodu razlikuje od ljetne sezone (LSK), odnosno “zimski” od zimske sezone (PSV).


Skup (III)	godina	PSV	OTS	LSK	RLS
Hrvatska	0.13 / 0.73	0.07 / 0.51	0.12 / 0.53	0.08 / 0.42	0.00 / 0.71
“ljetni” tip	0.29 / 0.21	0.00 / 0.83	0.22 / 0.01	0.40 / 0.64	0.00 / 0.77
“prijelazni” tip	0.04 / 0.54	0.00 / 0.95	0.00 / 0.93	0.05 / 0.06	0.00 / 0.50
“zimski” tip	-0.09 / 0.51	0.11 / 0.36	-0.09 / 0.17	-0.02 / 0.25	-0.06 / 0.20

Numerička analiza trenda koja je dana u Tablici 4 osim ukupnog međugodišnjeg trenda uključuje i dekompoziciju pomoću analiza sezonskih trendova, ali i dekompoziciju na razdoblja prije (1964.-1990.) i nakon (1995.-2019.) prekida. Sezone su definirane u skladu s klimatološkim standardima; zimska sezona (PSV) obuhvaća prosinac, siječanj i veljaču, proljetna (OTS) je definirana za ožujak, travanj i svibanj, ljetna (LSK) se odnosi na lipanj, srpanj i kolovoz te jesenska (RLS) obuhvaća mjeseci rujna, listopada i studena. U svakom je polju naveden trend i nivo signifikantnosti, a razdijeljeni su znakom „/“. Polja koja imaju nivo signifikantnosti $p < 0.05$ istaknuta su narančastom, a za $p < 0.1$ korištena je žuta boja. Promatranjem stupca ukupnog niza po godinama potvrđuje se signifikantan negativan trend koji svoj glavni doprinos ima u “zimskom” tipu postaja, iako su i “ljetni” i “prijelazni” tip negativno nagnuti pri čemu je “ljetni” tip signifikantan na nivou $p < 0.1$. Daljnjom analizom po sezonama, može se izvesti zaključak da je za ukupan negativan trend tuče najodgovornija ljetna (LSK) i jesenska (RLS) sezona pri čemu “ljetni” tip postaja ima glavni doprinos u ljetnoj sezoni dok je za jesensko smanjenje aktivnosti tuče uglavnom odgovoran “zimski” tip postaja. Podjela na razdoblje prije i poslije prekida pokazuje kako glavni doprinos negativnom trendu dolazi iz predratnog razdoblja, a glavni doprinosi su u gubitku aktivnosti tuče u ljetnom i jesenskom razdoblju. U postratnom razdoblju nema signifikantnog trenda niti na jednom promatranom području, iako postoji signifikantan pad aktivnosti tuče u jesen, za što je odgovorno područje obuhvaćeno “zimskim” tipom postaja.


Korištenjem podataka iz razdoblja od 1984. do 2019. dobiva se značajno veći broj postaja koje sudjeluju u analizi, a fond podataka ovisno o tipu raste za oko 30 %, što je vidljivo kroz Tablicu 2 i Sliku 11b. Ipak, analizom trendova značajna promjena se vidi samo u porastu tuče u proljetnoj sezoni za “ljetni” tip postaje. Nadalje, ljetna sezona uglavnom pokazuje trend porasta koji je signifikantan na nivou $p < 0.1$ za “prijelazni” tip postaja (Tablica 5). Različitost rezultata između Tablica 4 i 5 sugerira osjetljivost analize podataka o tuči u odnosu na razdoblje analize. Preliminarna analiza osjetljivosti trenda na promatrano razdoblje objavljena je u Jelić i sur. (2020), gdje se pokazalo kako na području sjeveroistočnog Jadrana i korištenjem 30-godišnjeg niza podataka trend može jako varirati ovisno o odabiru promatranog razdoblja. Stoga se ovim rezultatima želi istaknuti osjetljivost analize trenda na dužinu nizova, količinu podataka te odabir područja s kojeg se prikupljaju podatci.

4.1.6 Trajanje tuče i trendovi

Osim samog podatka o danu s tučom, u dnevnicima su dovoljno često zapisivana trajanja i intenzitet tuče. Zbog ipak smanjenog broja tih podataka korišten je skup podataka (III) iz Tablice 2, koji predstavlja razdoblje od 1984. do 2019. godine, kako bi se povećao broj raspoloživih podataka te kako bi se analize po tipu postaja mogle kvalitetno odraditi. Također, radi zadržavanja što većeg broja podataka, za ovu potrebu nije isključeno razdoblje 1991. – 1994. jer se prednost dala samim podacima. Obradom tih podataka dobivene su dodatne informacije o obilježjima tuče, ali i načinu unosa podataka u dnevnike motrenja. Naime, ako se pogleda Slika 12, koja prikazuje čestinu zapisanih trajanja, vidi se da motritelji imaju sklonost zaokruživati vrijeme trajanja pojave na cijele brojeve, kao što su 5, 10, 15... min. Također, u značajnom broju slučajeva motritelji su pisali “zbirna vremena” tj. ukupno trajanje nevremena koje često uz tuču uključuje i kišu pa su tako ukupna vremena trajanja prelazila 30 pa i 60 min. Nadalje, u slučajevima kad je tuča padala s prekidima neki su motritelji prekide bilježili kao zasebne događaje, a neki združivali, čime se također moglo dobiti nerazumno dugo trajanje. Također, Slika 12 sugerira približno logaritamski pad trajanja kako se odmičemo od 2. minute pa je odlučeno da najdulje trajanje tuče može biti 29 min. Kako bi se dodatno umanjio utjecaj visokih vrijednosti trajanja, umjesto godišnjeg prosjeka trajanja korišten je godišnji medijan trajanja. Tako definirani uvjeti za rezultat imaju međugodišnje hodove trajanja prikazane na Slici 13 pri čemu je “ljetni” tip prikazan crvenom linijom, “prijelazni” tip zelenom linijom te “zimski” tip postaja plavom linijom dok je crnom linijom dan medijan trajanja za cijelu Hrvatsku. Iz slike se može vidjeti kako je varijabilnost iz godine u godinu također prisutna i u ovakvom tipu podatka te kako ne postoji jasna korelacija u trajanju između različitih tipova postaja.



Slika 12. Broj zabilježenih događaja tuče za cijelu Hrvatsku (N) u ovisnosti o njenom trajanju (min). Svaki stupac predstavlja kategoriju trajanja od jedne minute koje su na apscisi.



Slika 13. Medijan trajanja događaja tuče (M) u minutama (od 1 do 9 min) u Hrvatskoj po godinama (crna linija) te njegova dekompozicija po tipovima postaje; “ljetni” tip (crvena linija), “prijelazni” tip (zeleno linija) te “zimski” tip (plava linija). Na apscisi su istaknute godine, a na ordinati medijan vrijednosti za svaku od godina. “Ljetni” tip postaje ima dominantno zabilježenu tuču u toplom dijelu godine (svibanj – listopad) dok su “zimске” postaje one koje imaju često mjerenu tuču u hladnom dijelu godine (studen – travanj).

U Tablici 6 prikazana je srednja vrijednost godišnjih medijana za svako područje. “Ljetni” tip ima najkraće prosječno trajanje od približno 3 min, što je za oko 1.3 min manje od rezultata objavljenih u radovima Počakal i sur. (2009) te Počakal i sur. (2018). Također, “prijelazni” i “zimski” tip bilježe sustavno veće vrijednosti trajanja tuče. Ovi su podatci (iako nisu za isto područje) u suglasnosti s rezultatima u Počakal i sur. (2009) gdje je pokazano da postaje koje se nalaze na jugoistočnim stranama planina bilježe dulja trajanja padanja tuče.


Tablica 6. Srednje trajanje i trend za cijelu Hrvatsku te za pojedine tipove postaja na dugom nizu podataka temeljenom na skupu (III) iz Tablice 2, a uključuje razdoblje od 1984. do 2019. godine. Žutom bojom je istaknuta značajna signifikantnosti na nivou $p < 0.1$. “Ljetni” tip postaje ima dominantnu aktivnost tuče u toplom dijelu godine (svibanj – listopad) dok “zimski” postaje dominantnu aktivnost tuče bilježe u hladnom dijelu godine (studen – travanj).

Skup (III)	Srednjak medijana trajanja (min)	Trend signifikantnost (medijan)
Hrvatska	3.56	-0.00 / 0.85
“ljetni” tip	2.96	-0.00 / 0.99
“prijelazni” tip	3.89	0.03 / 0.38
“zimski” tip	4.65	-0.03 / 0.08

Razlike u dobivenim vrijednostima trajanja teško je definirati. Potencijalni razlozi mogu biti u razlici metoda računanja (srednjak medijana u odnosu na obični srednjak) i/ili razlici u izvoru podataka. Također, “ljetni” tip obuhvaća puno veće područje od kontinentalne Hrvatske analizirane u radu Počakal i sur. (2009). Nadalje, u citiranim radovima se ne pokazuje niti posebno komentira pouzdanost mjerenja i eventualna pristranost motrenja trajanja. Nadalje, u Tablici 6 analizirani su i trendovi trajanja koji ne pokazuju signifikantne nagibe, iako “zimski” tip postaje ima negativan trend trajanja. Rezultat za “ljetni” tip se donekle razlikuje u odnosu na prethodne rezultate trenda trajanja u kontinentalnoj Hrvatskoj koji sugeriraju signifikantan pozitivan trend (Počakal i sur., 2018). Razlozi neslaganja najvjerojatnije leže u gore navedenim razlikama (korištenje srednjeg trajanja i drugi izvor podataka) te značajno većem geografskom području koje je uključeno u “ljetni” tip.

4.1.7 Intenzitet tuče i trendovi

Intenzitet tuče predstavlja gustoću pojave, a time i okvirnu mjeru ugroženosti područja nad kojim je zabilježena. Na Slici 14 prikazan je međugodišnji hod intenziteta za cijelu Hrvatsku kao i dekompozicija na pojedine tipove postaja. Vidljivo je da i intenzitete prati velika međugodišnja varijabilnost kao i nepovezanost među područjima, iako podatak nije posve mjerodavan zbog nesustavnog bilježenja u dnevnik motrenja. Nad područjem Hrvatske uglavnom dominira srednji intenzitet s oko 44 % udjela (Tablica 7) dok je najjači intenzitet odnosno intenzitet 2 najmanje zastupljen (oko 22 %).



Slika 14. Kumulativne količine pojedinog intenziteta tuče u Hrvatskoj po godinama (a) te njegova dekompozicija po tipovima postaja: (b) “ljetni” tip, (c) “prijelazni” tip i (d) “zimski” tip postaje. Na apscisi su istaknute godine, a na ordinati kumulativne vrijednosti svakog intenziteta (N) za svaku od godina. Bojama opisanima u legendi prikazan je svaki od intenziteta; intenzitet 0 (intz0; plavo), intenzitet 1 (intz1; narančasto) i intenzitet 2 (intz2; zeleno).

Postoje i značajne razlike između tipova postaja kako je dano u Tablici 7 pri čemu “prijelazni” tip sadrži najviši postotak tuče intenziteta 2 (oko 29 %), ali i intenziteta 1 (oko 52 %), što sugerira da je to područje izloženo najvećim količinama tuče. U “ljetnom” tipu postaje podjednako je zastupljen intenziteta 0 i 1 dok je u “zimskom” tipu intenzitet 2 najmanje zastupljen. Analiza trenda intenziteta za Hrvatsku sugerira signifikantan porast intenziteta 0. Glavni doprinos dolazi od “ljetnog” tipa postaja, iako je vidljiv i u ostala dva tipa postaja. Intenzitet 2 je u porastu kod “prijelaznog” tipa postaja dok je isti u padu unutar “zimskog” tipa. Intenzitet 1 ne bilježi nikakve signifikantne promjene.

Tablica 7. Postotni udio pojedinog intenziteta za tri tipa postaja (“ljetni”, “prijelazni” i “zimski”).

(%)	Hrvatska	“ljetni” tip	“prijelazni” tip	“zimski” tip
Intenzitet 0	34	39	19	35
Intenzitet 1	44	40	52	47
Intenzitet 2	22	21	29	18

Tablica 8. Analiza trenda intenziteta za cijelu Hrvatsku te za pojedine tipove postaja na dugom nizu podataka temeljenom na skupu (III) iz Tablice 2, koji uključuje razdoblje od 1984. do 2019. godine. Narančastom je istaknut nagib pravca / nivo signifikantnosti za $p < 0.05$ dok je žutom istaknut za $p < 0.1$.

	Hrvatska	“ljetni” tip	“prijelazni” tip	“zimski” tip
Intenzitet 0	0.27 / 0.02	0.18 / 0.00	0.00 / 0.06	0.11 / 0.06
Intenzitet 1	0.10 / 0.30	0.08 / 0.27	0.00 / 0.62	0.00 / 0.91
Intenzitet 2	0.00 / 0.35	-0.04 / 0.89	0.05 / 0.02	-0.05 / 0.03

Iako se veličina samih zrnaca tuče u velikoj većini slučajeva nije zapisivala, iz dodatnih opisa značajnih pojava tuče može se naslutiti kako je pojava intenziteta 2 u pozitivnoj vezi s tučom većom od 1.5 cm. Naime, kad god je to bilo istaknuto u dodatnom opisu pojave, motritelji bi navodili deskriptivne veličine kao lješnjak, orah ili veće, a uz simbol za tuču su gotovo uvijek navodili intenzitet 2 te eventualno intenzitet 1. Ako se na takav način pokuša interpretirati značenje intenziteta iz rezultata u Tablici 7 može se vidjeti da je ugroženost “prijelaznog” tipa postaja najveća jer je zastupljenost potencijalno većih razreda tuče najveća. Dodatno, rezultati trendova intenziteta iz Tablice 8 sugeriraju da upravo prijelazno područje bilježi pozitivan signifikantan trend za najjače intenzitete dok se za “zimski” tip postaje pokazuje negativan trend intenziteta 2. Ako se uzme udio vrijednosti intenziteta 2 za cijelu Hrvatsku (oko 22 %) te

pretpostavi da je to udio tuče koja je potencijalno jednaka ili veća od 2 cm, zapravo se usuglašava s rezultatima Punge i sur. (2014) koji navode kako je unutar baze ESWD udio tuče veće od 2 cm oko 23 %. Intenzitet 0 jedini raste na cijelom području Hrvatske i to vrlo značajno s izraženim nagibom od 0.27. Glavni doprinos dolazi od “ljetnog” tipa postaja, a najmanji od “prijelaznog” tipa.

4.1.8 Diskusija obilježja tuče

Cilj prve hipoteze bio je pokazati razlike u prostornim i vremenskim karakteristikama tuče u Hrvatskoj pri čemu je bilo važno prikladno definirati različita područja. Geografska podjela postaja (npr. istočna, središnja, sjeverna, Gorska Hrvatska pa sjeverni, srednji i južni Jadran) nije se pokazala prikladnom kao ključ podjele i osnova za analizu izmjerenih podataka o tuči u Hrvatskoj. Pokazalo se da je zapravo sličnost godišnjeg hoda zabilježene tuče dobar način podjele jer se tako grupiraju postaje koje dijele slične osobine. Na taj je način cijela kontinentalna i Gorska Hrvatska, ali i veliki dio sjevernog Jadrana svrstan u jednu kategoriju tj. “ljetni” tip postaje (“A”-tip oblika godišnjeg hoda), dok je srednji i južni Jadran uglavnom svrstan u “zimski” tip postaje odnosno godišnji profil koji ima potpuno suprotni oblik (“U”-tip) od “ljetnog” tipa. Zanimljivo je da postoji i znatan broj postaja koje zapravo pripadaju “prijelaznom” tipu tj. tipu koji tijekom cijele godine bilježi podjednake količine tuče. Ti rezultati sami po sebi u potpunosti potvrđuju postavljenu hipotezu, a daljnje analize tako definiranih područja dodatno potvrđuju očekivane razlike.

Jedino zajedničko svojstvo svih promatranih podskupova je visoka međugodišnja varijabilnost svih promatranih parametara od broja dana s tučom, srednjih trajanja do intenziteta same tuče. Kroz rezultate se paralelno prikazivala analiza Hrvatske kao cjelina te dekompozicija na pojedine tipove. Tako je npr. prisutnost negativnog trenda tuče uočena za “ljetni” i “zimski” tip postaja, a gledano sezonski očituju se u gubitku ljetne i jesenske tuče, dok je “prijelazni” tip ostao neutralan. Trajanje ima blagi negativan trend samo za “zimski” tip dok se intenzitet 0 povećava za cijelu Hrvatsku, a glavni doprinos dolazi od “ljetnog” tipa. Intenzitet 2 je u ukupnom udjelu nepromijenjen, iako postoje suprotni signali u trendu za “prijelazni” (porast) i “zimski” tip (pad). Sama zastupljenost intenziteta značajno varira između tipova postaja, a važno je naglasiti uočen porast intenziteta 2 za “prijelazni” tip postaja koje inače imaju povišeni udio intenziteta 1 i 2 u odnosu na ostale tipove. Intenziteti 1 i 2 mogu biti

popraćeni i velikom količinom/gustoćom tuče, što dovodi do nastanka značajnih materijalnih šteta. “Zimski” tip postaja, iako popraćen velikom učestalosti tuče u većem dijelu priobalja, ima manji rizik za nastanak šteta u poljoprivredi zbog profila godišnjeg hoda. Naime, udio intenziteta 2 je vrlo malen te glavina tuče pada u hladnom dijelu godine kada je poljoprivredna aktivnost smanjena.

Analizom tuče na dnevnoj skali uočene su također značajne razlike između tipova postaja. Dok je još u prethodnim radovima kako za Hrvatsku tako i za Europu (npr. Punge i Kunz, 2016) pokazano da tuča prati dnevni hod konvekcije, “prijelazni” i “zimski” tip postaja otkrivaju nova obilježja pri čemu je “zimski” tip posebno naglašen jer maksimume tuče bilježi u jutarnjim satima, a podjednaka aktivnost je prisutna do kasnovečernjih sati.


Dodatnu diskusiju vrijedi pridodati i samoj analizi trenda. Naime, usporedbom dobivenih rezultata s prethodno objavljenim radom za sjeveroistočni Jadran (Jelić i sur., 2020) mogu se primijetiti svojevrsna neslaganja. U tom radu pokazano je da ne postoji signifikantan trend već da se događa redistribucija tuče s toplijeg dijela godine na hladniji. Taj rezultat sugerira kako je podjela područja po tipu godišnjeg hoda pregruba za analizu trenda, jer je moguće da se unutar promatranih skupova postaja nalaze postaje s oprečnim vrijednostima trenda, koji u konačnici rezultiraju nepouzdanim informacijama. Podjela postaja na manja područja (npr. geografski definirana) kao što je sjeveroistočni Jadran, mogla bi ponuditi pouzdanije rezultate, no problem tog pristupa je ograničeni broj podataka na nekim područjima. Također, moguće je koristiti neku drugu sličnost među postajama (npr. dnevni hod, nadmorsku visinu, udaljenost od obale) ili pak neku napredniju statističku metodu s kojom će se ispitati razne kombinacije postaja kao npr. metoda ponovljenog uzorkovanja (*engl. Bootstrap*). Takva metoda bi osim identifikacije samih postaja mogla ponuditi i intervale pouzdanosti za dobiveni rezultat. Naime, analiza trenda tuče izuzetno je osjetljiva na promatrani niz i vremensko razdoblje kako je prethodno pokazano u radovima Jelić i sur. (2020) i Raupach i sur. (2021). U radu Jelić i sur. (2020) gdje se promatrao trend tuče na 30-godišnjim uzastopnim nizovima, dobiven je velik rasap vrlo signifikantnih/nesignifikantnih trendova dok trend ukupnog niza nije bio vidljiv niti signifikantan. I u ovom se radu pokušala napraviti analiza trenda na skraćenim nizovima kako bi se povećao broj postaja koje sudjeluju u analizi. Rezultati su za većinu kombinacija pokazali da trend ne postoji. Štoviše jedini signifikantan trend bio je za porast tuče u proljetnoj sezoni za “ljetni” tip postaja te slabije značajan pozitivan trend za ljetnu sezonu u podacima niza “prijelaznog” tipa postaja. Također, ako se promotre trendovi u regiji ili šire (npr. Raupach i sur., 2021) može se uočiti značajno variranje među zemljama (npr. Italija, Grčka) pa čak i unutar njih (Srbija, Rumunjska).

Sumarno se može navesti da tuča u Hrvatskoj zaista pokazuje značajne promjene u prostoru, kako na većim tako i na vrlo malim prostornim skalama, što se može vidjeti iz raspodjele samih frekvencija tuče te jednako velike promjene na svim vremenskim skalama (višegodišnjoj, godišnjoj i dnevnoj skali). Također, promjene su vidljive u trajanjima, ali i samim intenzitetima tuče.

4.2 Sinoptički i mezoskalni uvjeti za tuču u sadašnjoj i budućoj klimi

4.2.1 Tipovi vremena (VT)

Analizom svih tipova vremena izračunatih iz reanalize ERA5 (1979. – 2017.) dobivena je opća slika sinoptičke raspodjele tlaka na Slici 15a. Na slici brojevi na apscisi označavaju položaje sustava i tipove vremena kako je opisano u poglavlju 3.2; VT1, VT2, VT3 i VT4 su oznake za prednji, gornji, stražnji i/ili donji sektor ciklone koja utječe na Hrvatsku, odnosno analogno VT5 – VT8 prednji, gornji, stražnji i/ili donji sektor za anticiklonalne sustave. Boje označavaju oblik sustava te su duboki sustavi označeni crvenim stupcima, a plitki sustavi plavim stupcima. Udio ciklonalnih sustava iznosi 48 %, nakon kojih slijede anticiklonalni sustavi s 42 %, dok je preostalih 10 % pridijeljeno kvazi-bezgradijentnoj raspodjeli prizemnog tlaka. Dominantan pojedinačni signal uočen je za sustave dubokih anticiklona (VT8) koje su se nalazile iznad Hrvatske (56 % unutar anticiklonalnih tipova vremena). Nasuprot tome, ciklone su bile ravnomjernije raspoređene, a VT3 su se najrjeđe pojavljivale.




Slika 15. (a) Klasifikacije tipova vremena (VT) za sve dane dobivene automatiziranom metodom (algoritmom) na temelju podataka reanalize ERA5 (1979. – 2017.). (b) Klasifikacija tipova vremena za dane s tučom iz skupa podataka (I), i (c) relativne učestalosti tipova vremena povezanih s danima s tučom u usporedbi sa svim tipovima vremena za 1979. – 2017. Na slikama crvenim su označeni duboki, a plavim plitki sustavi. VT1, VT2, VT3 i VT4 redom predstavljaju prednji, gornji, stražnji i donji sektor ciklona, dok VT5, VT6, VT7 i VT8 predstavljaju prednji, gornji, stražnji i donji sektor anticiklonalna. NG-VT predstavlja kvazi-bezgradijentno polje tlaka.

Iz skupa podataka (I) iz Tablice 2 izdvojeni su svi dani s tučom za promatrano razdoblje (1979. – 2017.) i pridruženi su im vremenski tipovi za svaki od dana (Slika 15b). Na toj se slici pokazuje da se približno 76 % tuče može pripisati ciklonoj aktivnosti, što se i očekuje budući da ciklonoj sustavi pružaju velik izvor nestabilnosti, imaju veće vrijednosti CAPE-a i obiluju vlažnim zrakom (Santos i Belo-Pereira, 2019).

Nadalje, 17 % pojava tuče povezano je s formiranim anticiklonoj sustavima, a 7 % je povezano s kvazi-bezgradijentnim poljem tlaka. Nadalje, VT4 koji predstavlja donje sektore dubokih i plitkih ciklona prisutan je u 33 % dana s tučom, a još 22 % dana s tučom se zbiva tijekom tipa vremena VT1 (Slika 15b). Kada se usporede tipovi vremena u situacijama s tučom s raspodjelom tipova vremena za cijelo razdoblje, dobiva se postotak pojavljivanja tuče za određeni tip vremena (Slika 15c). Tako se može vidjeti da prilikom formiranja duboke Genovske ciklone (VT1) vjerojatnost za tuču premašuje 41 %, a velike vjerojatnosti (oko 30 – 40 %) se uočavaju i za stražnji te gornji sektor ciklone (VT3 i VT4). Zanimljivo je primijetiti da je i prilikom djelovanja prednjeg i gornjeg sektora anticiklone vjerojatnost za formiranje tuče

umjerena (10 – 20 %). Također, duboki anticiklonalni sustavi, VT5 i VT6 pokazuju udjele veće od 10 %. S obzirom na to da je određeni dio tuče (17 %) povezan s anticiklonalnim sustavima, napravljeni su kompoziti prizemnog tlaka dubokih sustava po tipovima vremena zajedno s vjetrom na 700 hPa te su prikazani na Slici 16.




Slika 16. Kompoziti površinskog tlaka za pripadni tip vremena (VT1-VT8 i NG-VT) i duboke sinoptičke sustave uz vjetra na 700 hPa. Referentni vektor od 10 m/s nalazi se u gornjem lijevom kutu. Granica između sinoptičkih sustava sniženog i povišenog tlaka iznosi 1016 hPa na temelju klimatološkog prosjeka za promatranu domenu.

Iz slike se može prepoznati kako VT5, VT6 i VT8 imaju sjeverne komponente strujanja, što može advektirati hladnije zračne mase i stvarati nestabilna okruženja koja pogoduju konvekciji. Valja napomenuti da uslijed pojave manjih i bržih baričkih sustava koji u jednom danu mogu proizvesti više tipova vremena, može doći do pogrešnog povezivanja tuče i tipa vremena. No, kako se sinoptički sustavi uglavnom kreću sporo, a nerijetko su i statični (npr. Genovska ciklona), eventualne nepouzdanosti kod pojedinih događaja ne mogu bitno utjecati na ukupan rezultat. Vrijednosti sa Slike 15c predstavljaju grubu numeričku vezu između tuče i sinoptičkih uvjeta te se mogu koristiti kao alat za ocjenu tuče u budućoj klimi.

4.2.2 Mezoskalni uvjeti za nastanak tuče

Mezoskalni uvjeti za nastanak tuče važna su komponenta u razumijevanju tog procesa pa je za svaku od zabilježenih tuča u razdoblju 1984. – 2019. izračunata vrijednost MUCAPE-a, KI, indeksa LI, DSL-a te visine nulte izoterme, a rezultati su prikazani u obliku pravokutnih dijagrama na Slici 17. Crticama unutar dijagrama predstavljen je medijan vrijednosti, gornji i donji rub pravokutnika predstavljaju 25. i 75. percentil, dok vanjske horizontalne crtice predstavljaju 10. odnosno 90. percentil. Redni brojevi na apscisi (1 – 4) predstavljaju redom postaje iz cijele Hrvatske (1) te dekompoziciju na “ljetni” (2), “prijelazni” (3) i “zimski” (4) tip postaje.

Iz rezultata je jasno vidljivo kako se tuča u velikoj mjeri pojavljuje u vrlo nestabilnim uvjetima, no ipak postoje izvjesne razlike između područja. Tako je na primjer za “ljetni” tip postaje zabilježena najveća nestabilnost atmosfere, a za “zimski” tip najmanja, dok obrnuto vrijedi za smicanje vjetra. Visina nulte izoterme također je najviša za “ljetni” tip dok je za “zimski” najniža. Navedene razlike dobrim su dijelom vezane i za godišnji hod pojedinih indeksa (npr. Taszarek i sur., 2018) pa tako zimi i očekujemo manje vrijednosti MUCAPE-a (Slika 17a) i KI-a (Slika 17b) te manje vrijednosti LI-a (Slika 17c) i visine nulte izoterme (Slika 17e). Manje vrijednosti termodinamičkih parametara su kompenzirane pojačanim smicanjem vjetra, što je vidljivo na Slici 17d. Slično je pokazano u radu Púčik i sur. (2015) gdje se također mogu vidjeti usporedivi iznosi dobivenih vrijednosti, iako ne dolaze iz istog izvora i nisu dobivene istom metodom. Važno je naglasiti da su dobivene vrijednosti nulte izoterme iznad tla te najčešće u rasponu vrijednosti od 1700 m do 3200 m ovisno o tipu postaja.




Slika 17. Usporedbe indeksa nestabilnosti (na temelju podataka ERA5) vezanih za dane s tučom iz skupa podataka (III). Brojevi na apscisi predstavljaju redom, cijelu Hrvatsku (1), “ljetni” tip (2), “prijelazni” tip (3) te “zimski” tip (4) postaja. Medijan vrijednosti prikazan je vodoravnim linijama u pravokutniku, rubovi su 25. i 75. percentil, a vanjske horizontalne crtice predstavljaju 10. odnosno 90. percentil. (a) najnestabilniji CAPE (MUCAPE, J/kg); (b) Indeks podizanja 500 hPa (LI, °C); (c) K-indeks (KI, °C); (d) indeks smicanja (DLS, m/s) u najnižih 6 km; i (e) visina nulte izoterme (m).

4.2.3 Ocjena tuče u budućim klimatskim uvjetima


Automatiziranim postupkom iz poglavlja 4.2.1, za osam simulacija iz inicijative EURO-CORDEX koje su opisane u Tablici 1 napravljena je tipizacija vremena za povijesno razdoblje te za tri buduća razdoblja kako je opisano u poglavlju 2.3. Nadalje, kako bi se odredio statistički pouzdan prikaz tipova vremena unutar pojedinog razdoblja korištena je medijalna vrijednost ansambla od osam simulacija za svaki od tipova vremena. Dobiveni rezultati za povijesno

razdoblje (1971. – 2000.) prikazani su na Slici 18 pri čemu VT1, VT2, VT3 i VT4 predstavljaju prednji, gornji, stražnji i donji sektor ciklone koje utječu na Hrvatsku, odnosno VT5, VT6, VT7 i VT8 za anticiklone ekvivalentno kako je prikazano na Slici 4. Boje označavaju oblik sustava (duboki sustavi su označeni crvenim stupcima, a plitki sustavi su označeni plavim stupcima), a vertikalne linije prikazuju stupanj nepouzdanosti, tj. standardnu devijaciju pojedinog tipa vremena.

Kad se usporede rezultati inicijative EURO-CORDEX s onima dobivenim pomoću reanalize ERA5 vidljiva je značajna razlika u raspodjeli. Dominantan tip vremena u klimatskim simulacijama povijesnog razdoblja je VT6 tj. utjecaj gornjeg sektora plitke anticiklone na Hrvatsku. Odnos ciklona i anticiklona u korištenoj bazi podataka inicijative EURO-CORDEX je približno 40 % naprama 60 % dok je kvazi-bezgradijentno polje zastupljeno sa svega 1 %. Iako su dobivene razlike između reanalize ERA5 i inicijative EURO-CORDEX značajne, korištenjem istih postavki za buduću klimu i dalje se mogu promatrati relativni odnosi. U tom smislu na Slici 19 prikazane su relativne promjene tipova vremena u budućim klimatskim razdobljima za klimatske projekcije koje uvažavaju scenarij RCP8.5. Kao i na prethodnim slikama, crvenim bojama označeni su duboki, a plavim plitki sustavi s tim da različite nijanse boja prikazuju različita razdoblja. Tako je svjetlom nijansom označena promjena između povijesnog razdoblja i bliže budućnosti (2011. – 2040.), srednja nijansa predstavlja promjenu između povijesnog razdoblja i sredine stoljeća (2041. – 2070.) te tamna nijansa promjenu do kraja stoljeća (2071. – 2099.). Iz rezultata se može vidjeti kako sustavno raste broj anticiklonalnih tipova pa se ukupni omjer ciklona u odnosu na anticiklone do kraja stoljeća smanjuje za 3 %. Najveći doprinos tome ima jačanje oba tipa prednjeg sektora anticiklone odnosno jačanje Azorske anticiklone. Ovakav rezultat je u suglasnosti s istraživanjima (Hu i Wu, 2004) koji su primijetili pomicanje središta Azorskog maksimuma prema sjeveroistoku, što najviše doprinosi porastu učestalosti prednjeg sektora anticiklone tj. VT5. Posljedično, može se primijetiti pad utjecaja donjeg sektora ciklone, ali i sustavno smanjenje učestalosti dubokih ciklonalnih sustava koje je popraćeno većom učestalošću plitkih sustava.




Slika 18. Klasifikacije tipova vremena (VT) za povijesno razdoblje (1971. – 2000.) inicijative EURO-CORDEX. Crveni stupci označavaju duboke, a plavi plitke sustave. Oznake VT1, VT2, VT3 i VT4 predstavljaju prednji, gornji, stražnji i donji sektor ciklona, redom, dok VT5, VT6, VT7 i VT8 predstavljaju iste sektore anticiklonalnih sustava. NG-VT predstavlja kvazi-bezgradijentno polje tlaka. Okomite crne linije predstavljaju standardnu devijaciju ansambla odabranih simulacija inicijative EURO-CORDEX za svaki od navedenih tipova vremena.



Slika 19. Relativna promjena u tipu vremena na temelju podataka inicijative EURO-CORDEX između povijesnog razdoblja i bliže budućnosti (2011. – 2040.) istaknuta je svijetlim nijansama, povijesnog razdoblja i sredine stoljeća (2041. – 2070.) srednjim nijansama te povijesnog razdoblja i kraja stoljeća (2071. – 2099.) tamnim nijansama.

Na temelju rezultata iz poglavlja 4.2.1, a vezano za Sliku 15c iskoristit će se vrijednosti udjela tuče u pojedinom tipu vremena kako bi se ocijenila njena prisutnost, tj. dobila relativna promjena u budućoj klimi. Za svako se razdoblje i za svaki od osam modela izračunao ukupni broj dana s tučom, višegodišnji srednjak svih modela te se napravila razlika srednjaka te minimalnih i maksimalnih vrijednosti između povijesnog i preostalih razdoblja. Rezultat tog pristupa dan je na Slici 20. Crvenom linijom označena je srednja relativna promjena tuče dok su sivom i plavom linijom označene maksimalna odnosno minimalna vrijednost promjene. Iako je početkom stoljeća moguć i porast učestalosti tuče, najvjerojatniji ishod prema dobivenim rezultatima je sustavno smanjenje pojavnosti tuče u Hrvatskoj. Ovaj rezultat se podudara s trenutno opaženim negativnim trendom za cijelu Hrvatsku kako je prikazano Tablicom 4. Rezultati sugeriraju smanjenje učestalosti tuče od 4 do 8 % do kraja stoljeća za scenarij RCP8.5. No, treba imati na umu da su NG-VT polja najvjerojatnije podcijenjena korištenom metodom tipizacije vremena te ostaje pitanje koliko tuče je zapravo povezano sa slobodnom konvekcijom i koliko to utječe na dobiveni negativni trend. Nadalje, ova analiza ne omogućava zaključak o prostornoj raširenosti tuče (jer dan s tučom je bilo koji broj događaja tuče, na proizvoljno puno lokacija unutar promatranog područja), trajanju tuče niti intenzitetu. Suprotno ovim rezultatima i korištenjem termodinamičkih varijabli iz inicijative EURO-CORDEX, Púčik i sur. (2017) su u svom radu (Slika 12.) dobili porast broja dana s ekstremnim vremenom u cijeloj Europi. Autori su ekstremno vrijeme definirali korištenjem termodinamičkog indeksa LI i indeksa DLS, te polja oborine, postavljajući uvjet da je dan s ekstremnim vremenom ostvariv ako je $LI < -2$ °C, ako postoji jako smicanje vjetra s $DLS > 15$ m/s te ako se stvara oborina > 1 mm. No, pouzdanost tih pozitivnih promjena nad Hrvatskom je niska, tj. srednje promjene nad Hrvatskom uglavnom su usporedive s varijabilnosti između modela.



Slika 20. Relativna promjena čestine tuče između povijesnog razdoblja i tri promatrana razdoblja kako je navedeno na apscisi. Sivom linijom označena je maksimalna, crvenom srednja te plavom minimalna uočena promjena korištenjem ansambla modela inicijative EURO-CORDEX.

Globalni modeli ukazuju na porast nestabilnosti za sve sezone u Europi (Lepore i sur., 2021), no treba uzeti u obzir da niti jedna od metoda nema izravno razlučivanje tuče već se sve temelje na promatranju neizravnih mjera, najčešće indeksa nestabilnosti. U radu Raupach i sur. (2021) kao motivacija se upravo navodi ta problematika, te se fokus istraživanja stavlja na tuču. U tom se radu ističe kako vjerojatno postoji blaga tendencija ka porastu pojave tuče, no postoji previše nepouzdanosti i kontradikcija da bi se izveli konkretni zaključci. Također, prema izvješću Međuvladinog panela za klimatske promjene⁴ radne skupine 1 (poglavlje 11; Seneviratne i sur., 2021), atmosferski doprinos oborinskim ekstremima razdvojen je na dinamički i termodinamički doprinos. Pri tome, termodinamički doprinos sugerira da postoji globalni porast oborinskih ekstrema od 4 do 8 % za svaki stupanj porasta površinske temperature, dok je dinamički doprinos uglavnom negativan, iako postoji neslaganje u rezultatima različitih modela. Na području Hrvatske termodinamički doprinos je oko 1 do 3 % dok je dinamički između -6 i -1 %. S obzirom na to da je u ovom radu kao ulazni podatak korišten prizemni tlak te geopotencijal na 500 hPa, sama analiza tipova vremena predstavlja dinamički doprinos tuči pa su stoga dobiveni negativni trendovi tuče u skladu s prethodnim istraživanjem. Ipak, valja

⁴ <https://www.ipcc.ch>

istaknuti da se područje Hrvatske nalazi se upravo na granici zone povišene nepouzdanosti modela pa je teško procijeniti koji će doprinos prevladati.

4.2.4 Diskusija sinoptičkih i mezoskalnih uvjeta za nastanak tuče

Druga hipoteza ovog istraživanja pretpostavlja da tipizacija vremena omogućava dobivanje odgovarajućih alata za procjenu tuče u budućoj klimi. Ispitivanje takve hipoteze je složen proces koji se sastoji od niza koraka. Prvenstveno, potrebno je definirati odnose sinoptičkih sustava u atmosferi te pronaći koji su sustavi i u kojoj mjeri odgovorni za formiranje tuče nad promatranim područjem tj. Hrvatskom. Naravno, odgovorni sustavi i njihova mjera zastupljenosti prvenstveno ovise o količini i kvaliteti podataka o tuči nad promatranim područjem. Porastom gustoće mjernih postaja raste i stupanj zastupljenosti pošto se sve više događaja uspješno detektira, a time i povezuje s pojedinim sinoptičkim tipom vremena. Stoga je razumno pretpostaviti da su stvarne vrijednosti uvijek veće od dobivenih, no relativan odnos zastupljenosti tuče između pojedinih tipova vremena je stalan dok god postoji dovoljna količina podataka, što potvrđuje i usporedba rezultata dobivenih za sjeveroistočni Jadran u radu Jelić i sur. (2020) (njihova Slika 8b) i ovdje prikazanog rezultata za cijelu Hrvatsku na Slici 15b. Pod pretpostavkom da je dobivena raspodjela udjela tuče za pojedini tip vremena pod značajnim utjecajem lokalnih obilježja (osobito topografije i zemljišnog pokrova), tj. promatranog područja, može se očekivati da se ona ni u budućoj klimi neće značajno mijenjati. Stoga, ukoliko je poznata raspodjela tipova vremena u sadašnjoj i budućoj klimi, moguće je procijeniti očekivane promjene tuče. Ovakav pristup do sada nije razmatran kroz druga istraživanja pa dobiveni rezultati predstavljaju nove spoznaje koje za područje Hrvatske sugeriraju negativan trend tuče u budućoj klimi. Usporedno s dobivenim rezultatima za razdoblje 1964. – 2019. na temelju opažanja, izgleda da se negativan trend tuče samo nastavlja i u budućnosti. No i dalje je teško izvesti čvrste zaključke, s obzirom na to da mjereni podatci sežu tek 50-ak godina u prošlost, a projekcije u ovom radu se rade za skoro 100 godina u budućnost. Također, treba imati u vidu da je ovdje analiziran samo dinamički doprinos pojavi tuče. Termodinamički doprinos ekstremnom vremenu prema analizi Púčik i sur., (2017) sugerira porast ekstremnog vremena, no tu tuča nije razlučena od ostalih pojava (jaka kiša, udari vjetera, tornado). Uz to, zbog izraženih neslaganja među modelima (Seneviratne i sur., 2021) nije moguće ponuditi

zaključak, već samo ponuditi podlogu dobivenih dinamičkih doprinosa i otvoriti vrata novim istraživanjima.

Mezoskalni uvjeti zabilježeni za dane s tučom sugeriraju visoki stupanj statičke nestabilnosti u atmosferi s izraženim smicanjem u prvih 6 km. Postaje koje odgovaraju “ljetnom” tipu u pravilu pokazuju nešto slabija smicanja i izraženiju nestabilnost (npr. veći MUCAPE) dok su priobalne postaje uglavnom povezane s manjom nestabilnosti i većim smicanjem vjetra. Takvi rezultati su u dobrom slaganju s ostalim istraživanjima (npr. Púčik i sur., 2015, Slika 5; Púčik i sur., 2017, Slika 3), ali i lokalnim istraživanjem za sjeveroistočni Jadran (Jelić i sur., 2021, Slika 13). U tim je radovima upravo i prikazan odnos smicanja i nestabilnosti koji potvrđuje ovdje dobivene rezultate.

Ocjena budućih mezoskalnih uvjeta potrebnih za formiranje tuče za područje Europe i šire (npr. Lepore i sur., 2021; Púčik i sur., 2017) najčešće je rađena pomoću indeksa nestabilnosti izračunatih na temelju podataka iz inicijative EURO-CORDEX. Iako takav tip analize nije bio u fokusu ovog rada, moguće je napraviti kvalitativnu usporedbu s ovdje analiziranim tipovima vremena. Púčik i sur. (2017) su promatrali kombinaciju $DLS > 15 \text{ m/s}$, $LI < -2 \text{ °C}$ i prisutnost oborine kako bi definirali ekstremno vrijeme (tuča, jaka kiša, udari vjetra, tornada). Tako definirani sustav primijenili su na ansambl klimatskih simulacija dobivenih za scenarije RCP4.5 i RCP8.5 kroz cijelo 21. stoljeće, a rezultat su finalno prikazali na njihovoj Slici 12 (Púčik i sur., 2017). Glavni zaključci su da je čestina ekstremnih uvjeta nad područjem Hrvatske u prosjeku između 2 i 12 dana u godini (s većim vrijednostima duž obale i Gorske Hrvatske), a da se po scenariju RCP8.5 do kraja stoljeća ta čestina povećava za 30 – 70 % pri čemu su signifikantne vrijednosti dobivene za kontinentalnu Hrvatsku. Njihov rezultat je u suprotnosti s ovdje provedenom analizom na temelju sinoptičkih tipova, koja barem za Hrvatsku u cjelini sugerira smanjenje tuče u budućoj klimi. Treba istaknuti da se uspoređivani podatci ipak razlikuju jer se ovdje prati tlak i geopotencijalna visina na 500 hPa dok se u radu Púčik i sur., (2017) koriste index LI, smicanje vjetra (DLS) i oborina. Također, za potrebe sinoptičke ocjene dobiveni su isključivo udjeli za tuču te se s tim udjelima procjenjivao udio u rezultatima klimatskih simulacija. Za potrebe mezoskalne analize korištene su kombinacije indeksa nestabilnosti koje su korelirane s pojavom jednog ili više ekstremnih elemenata (tuča, jaka kiša, udari vjetra, tornada). Stoga bi se moglo reći da je porast ekstremnih događaja pouzdan, ali da se zapravo ne zna raspodjela samih ekstrema. S druge strane, u klimatskim je simulacijama kvazi-bezgradijentno polje podcijenjeno (Slika 18), dok je u reanalizi tipova vremena zastupljeno sa oko 10 %. Također, korišteni modeli iz inicijative EURO-CORDEX sugeriraju trend smanjenja ciklonskih tipova vremena, i to zbog slabljenja dubokih ciklona. Ta

činjenica otvara mogućnost mezoskalnim sustavima da češće preuzmu dominaciju u formiranju olujnih sustava, što opet ide u prilog porastu ekstremnih događaja, ali i daje novu informaciju o mogućim razlozima porasta. Izložena diskusija opisuje sukob rezultata dinamičkog i termodinamičkog doprinosa tuči i naglašava da je potrebno razviti novu metodu za analizu tuče u modelima koja će združeno promatrati oba doprinosa (pošto oni mogu i pozitivno i negativno međudjelovati) kako bi se smanjila nepouzdanost same procjene količine tuče, ali i drugih ekstrema.

4.3 Indeks intenziteta munja (TSII)


Potencijal TSII-ja analiziran je korištenjem podataka o oborini, maksimalnoj brzini vjetra, tuči i pijavicama na području sjeveroistočnog Jadrana. Nadalje je ispitan odnos TSII-ja i indeksa nestabilnosti te smicanja vjetra u prvih 6 km (DLS), izračunatih iz podataka reanalize ERA5. Posebna je pozornost posvećena mogućoj primjeni TSII-ja u detekciji i opisivanju prostorno malih konvektivnih sustava nad promatranom domenom (Slika 6a).

4.3.1 Veza TSII-ja i oborine

Prvi je korak ispitati kako je pojava TSII-ja povezana s intenzivnim oborinama koristeći podatke automatske postaje (žuta zvijezda na obali na Slici 6a). U promatranom razdoblju automatska kišomjerna postaja imala je 2633 radna dana, od čega 881 dan s kišom, a 202 dana s munjama. Od navedenih dana s munjama, 72 dana uključivala su prisutnost traga ITD-a u neposrednoj blizini postaje. Slika 21a prikazuje pravokutne dijagrame dnevnog maksimalnog jednogminutnog intenziteta oborine za okruženja NTD (plavo), okruženja TD (zeleno) i okruženja ITD (crvena).

Rezultati pokazuju da su tijekom okruženja NTD ukupni intenziteti oborine bili mali, s medijalnom vrijednosti od 0.06 mm/min. Tijekom okruženja TD, intenzitet oborine bio je veći s medijanom od 0.18 mm/min, a za okruženja ITD su intenziteti kiše bili najveći, pokazujući srednju vrijednost od 0.51 mm/min. Takav rezultat sugerira da konvektivni sustav koji ima intenzivni porast aktivnosti munja kao posljedicu može imati vrlo velike intenzitete oborine dok sam trag TSII-ja sugerira gdje su se ti intenziteti pojavili. Ovi rezultati su u skladu s onima

iz Gaál i sur. (2014) gdje su predstavljeni granični maksimalni intenziteti za četiri oborinske postaje u Švicarskoj. Drugim riječima, dobiveni rezultati upućuju na to da TSII doista prepoznaje područja koja su tijekom grmljavinskog nevremena bilježila oborinu velikog intenziteta.



Slika 21. Usporedbe pravokutnih dijagrama (a) intenziteta oborina izvedenog iz 1-minutnih dnevnih maksimalnih intenziteta za automatsku kišomjernu postaju smještenu na obali, (b) ukupne dnevne oborine za istu postaju i (c) ukupne dnevne oborine na temelju 37 kišomjernih postaja koje se nalaze na području sjeveroistočnog Jadrana. Medijan vrijednosti prikazan je vodoravnim linijama u pravokutnicima; rubovi pravokutnika su 25. i 75. percentil, a vanjske horizontalne linije predstavljaju 10. i 90. percentil. Plava boja odnosi se na okruženja NTD (okruženja bez munja), zelena na TD (okruženja samo s munjama), a crvena na okruženja ITD (intenzivna okruženja s munjama).

Nadalje, ispitane su 24-h akumulirane oborine s automatske kišomjerne postaje. Iako podatci o oborini predstavljaju ukupni doprinos i stratiformne i konvektivne oborine, rezultati na Slici 21b pokazuju jasnu razliku između pojedinih okruženja, pri čemu okruženja ITD imaju najveće vrijednosti. Za potvrdu dobivenih rezultata sa Slike 21b korišteno je 37 oborinskih postaja koje su bilježile ukupne dnevne količine oborine i za svaku od njih je ponovljena metoda. Ukratko, u razdoblju od 11 godina te su postaje zabilježile 17532 zapisa o oborini, od kojih je 4179 uključivalo bilježenje munja, a 1149 je uključivalo trag TSII-ja. Odnosno, oko 30 % oborinskih događaja bilo je povezano s munjama, dok je 7 % sadržavalo intenzivne promjene munja zbog dobivenih pozitivnih vrijednosti TSII-ja. Drugim riječima, 27 % grmljavinskih oluja je u blizini kišomjerne postaje zabilježilo naglu promjenu aktivnosti munja, što je rezultiralo izraženijim količinama oborine kako je vidljivo na Slici 21c i time potvrdilo prethodno dobivene rezultate na Slici 21b.

Općenito, preklapanje vrijednosti iz različitih okruženja se očekuje, posebno između okruženja TD i ITD i to iz nekoliko razloga. Prvo, metoda je osmišljena tako da bude dovoljno robusna da omogući promatranje odnosa sa svim ekstremnim pojavama. Stoga je za detaljniju analizu je ovu metodu potrebno prilagoditi specifičnom ekstremnom elementu (jaka kiša, tuča,


vjetar, pijavice). Drugo, ovdje metoda uzima u obzir sve tipove oborine, bez obzira na to je li ona stratiformna ili konvektivna te koliki joj je intenzitet, pa se stoga očekuje da vrlo veliki sustavi proizvode veće intenzitete oborina i veće ukupne količine na većem području, što u konačnici više doprinosi okruženju TD. Treće, georeferenciranje postaja na mrežu od 3 km ponekad može svrstati postaje u kut promatranog kvadratića, a uvođenjem dodatnog područja utjecaja od 3 km, u nekim slučajevima, može svrstati postaje dalje od željenog okruženja, uzrokujući podcjenjivanje vrijednosti. Posljedica je očita za manje vrijednosti dobivene iz ITD-a. Četvrto, tijekom jednog dana, više različitih sustava (konvektivnih i/ili stratiformnih) može dati svoj doprinos ukupnoj oborini na nekoj postaji koja je zahvaćena nekim od okruženja (TD ili ITD). Statistički gledano, postoji devet puta više NTD-a i tri puta više okruženja TD u usporedbi s okruženjima ITD, što također opravdava povećane vrijednosti količina oborine za okruženja NTD i TD. Peto, za kratkotrajne i male grmljavinske sustave, trag intenzivnih oborina može biti manji od 3 km i može lako mimoići postaju. Konačno, zbog složene topografije, lokalna brda mogu utjecati na putanje oluja i neizravno štititi ili pojačano izložiti postaju utjecaju oluje ovisno o smjeru njenog nailaska. Bez obzira na to, medijalne vrijednosti pokazuju jasne razlike između odabranih okruženja i sugeriraju da trag TSII-ja zaista sadrži intenzivnije oborine u usporedbi s drugim okruženjima, čime pruža dodatne informacije o opaženom grmljavinskom sustavu.

4.3.2 Veza TSII-ja i vjetra na 10 m


Fronte udara vjetra (*engl. gust front*) koje se formiraju ispod kumulonimbusa i propadi zraka (*engl. downburst*) također su jedna od posljedica grmljavinskog nevremena. Dok je male propade vrlo teško uhvatiti zbog njihove izrazito lokalizirane prirode, fronte udara vjetra obično dosežu 50 km od središta oluje (Mohr i sur., 2017; Poljak i sur., 2014). Za usporedbu, uzete su u obzir samo oluje s munjama i TSII događaji koji su se dogodili u relativnoj blizini postaje, tj. do 15 km od postaje. Analizom brzine vjetra s dvije postaje (obalna, Sv. Ivan na pučini, Slika 22a) i kopnena (tj. GMP Pazin, Slika 22b), utvrđena je značajna razlika u grupiranju maksimalnih brzina vjetra, što je i očekivano jer je kopnena postaja djelomično zaklonjena lokalnom topografijom dok je obalna postaja na otvorenom moru. Međutim, jasno je vidljivo da su za okruženja TD izmjereni veći maksimumi brzine vjetra u usporedbi s okruženjima NTD, a za okruženja ITD zabilježeni su najveći medijani maksimalne brzine vjetra. Promatrane su i

vrijednosti iznad 90. percentila iz cijelog razdoblja i svaku promatranu postaju kako bi se izolirao vrlo jak vjetar za obje postaje. Vrijednost 90. percentila za obalnu postaju iznosi 17.0 m/s, dok je za kopnenu 12.8 m/s. Time je za obalnu postaju dobiveno da je 6 % jakog vjetra vezano za okruženje NTD, 19 % za TD te 35 % za okruženje ITD dok je za kopnenu postaju taj odnos bio 8 %, 15 % i 25 %.

Na Slici 23 prikazane su ruže vjetra za srednje maksimume vjetra uz svakih $\pm 11.25^\circ$. Prvi red (a–c) označava kopnenu postaju, dok drugi red (d–f) označava obalnu postaju. Stupci označavaju okruženja NTD, TD i ITD. Stupci 1 (NTD) i 2 (TD) prikazuju dominantan vjetar iz prvog i drugog kvadranta, koji su dobro poznati smjerovi za buru (uglavnom NE – E; Belušić i sur., 2018; Grisogono i Belušić, 2009) i jugo (uglavnom SE – S; Horvath i sur., 2008). Bura je jak i mahovit vjetar koji donosi suh i hladan zrak nad obalno područje, dok je jugo topao i vlažan vjetar često praćen konvekcijom. Oba tipa vjetra mogu biti povezana s velikim brzinama vjetra; međutim, uglavnom se jugo može vidjeti unutar okruženja TD i ITD. Za okruženja ITD i drugi smjerovi vjetra postaju podjednako zastupljeni. Za obalnu postaju, najčešće izmjereni smjerovi vjetra bili su zapadni, što sugerira da se oluje stvaraju nad morem i putuju u unutrašnjost, te istočni smjer koji se djelomično može objasniti premještanjem konvekcije iz unutrašnjosti prema obali (Jelić i sur., 2020).



Slika 22. Isto kao na Slici 21, ali za dnevnu maksimalnu brzinu vjetra dobivenu iz srednjih 10-minutnih podataka (m/s) za (a) obalnu postaju Sv. Ivan na Pučini i (b) kopnenu postaju smještenu u Pazinu.



Slika 23. Ruže vjetra (u m/s) za 90. percentila maksimalnog 10 minutnog srednjeg vjetra za kopnenu postaju (GMP Pazin, a–c), i obalnu (Sv. Ivan na Pučini, d–f) postaju za okruženje NTD (prvi stupac), TD (drugi stupac) i ITD (treći stupac). Linije označavaju čestinu srednjeg smjera vjetra, a brojevi na vrhu linija su srednje vrijednosti tog određenog smjera. Boje označavaju određene raspone brzine vjetra kako je naznačeno u legendi.

Za postaju u unutrašnjosti dominantan je vjetar SE smjera (jugo), dok je smjer NE – E najmanje zastupljen (16 %) najvjerojatnije zbog visokih orografskih prepreka (Slika 6a) koje djelomično štite Pazin od grmljavinskih oluja iz tog smjera. Iako je uočen pozitivan odnos između traga TSII-ja i udara vjetra, ukupni intenziteti i relativne frekvencije ukazuju na to da je kopneno područje rijetko pod utjecajem jakog vjetra, dok obalno područje doživljava jake udare koji su povezani i s okruženjima TD i ITD. Djelomično je za to odgovoran i sam položaj postaje koji je relativno zaštićen od jakih naleta vjetra.


Važnost južnih smjerova vjetra za pojavu obilnih oborina na istočnoj strani Alpa istaknuta je i u radu Ivančan-Picek i sur. (2003). Na temelju polja vjetra simuliranih modelom ALADIN/LACE utvrđeno je da je analizirani događaj jakih oborina bio uzrokovan frontalnom modifikacijom na koju je utjecala površinska konvergencija između toplog juga i hladnijeg sjeveroistočnog vjetra. Štoviše, Toreti i sur. (2016) istraživali su odnos između ekstremnih oborina u Sredozemlju i pridruženih struktura sinoptičkog strujanja na višim nivoima. Pokazalo se da se tijekom ekstremnih oborina na zapadnom Balkanskom poluotoku, široka dolina potencijalne vrtložnosti nalazi iznad srednje Europe. Tada je zapadni dio Balkanskog poluotoka

zahvaćen istočnim dijelom doline i pod utjecajem je jakog jugozapadnog vjetrova na 850 hPa. Tako dolazi do interakcije između jugozapadnog vjetrova i orografije orijentirane NW – SE tj. do prisilnog uzdizanja zračne mase, što je povoljno za formiranje konvekcije.

4.3.3 Veza TSII-ja i tuče

Prema Changnonu (1992), tuča se obično javlja u blizini središta oluje. U većini slučajeva javljaju se bočno (lijevo ili desno) u odnosu na središte oluje, ali se također može pojaviti duž linije kretanja oluje ili pod nekim kutom u odnosu na liniju. Iako autor nije komentirao prosječne ili maksimalne pomake između središta oluje i traga tuče, može se zaključiti da prosječna udaljenost od središta oluje ne prelazi 20 km. Wapler (2017) je analizirala životni ciklus oluja s tučom koristeći radarske podatke i podatke o munjama. Otkrila je da se tuča najčešće javlja u području malo jugozapadno od središta oluje, a munje u radijusu od 15 km od središta. Pozitivan indeks TSII, u prvoj aproksimaciji, mogao bi se povezati s centrom oluje kako su predstavili spomenuti autori; stoga treba očekivati da se opažena tuča javlja s određenim prostornim odmakom od traga TSII-ja. Prvo, prostorna distribucija slučajeva tuče prema podacima pojedinih postaja ukazuje na veliku prostornu varijabilnost u učestalosti tuče (označeno veličinom i bojom kruga; Slika 24a).

Osim toga, veće vrijednosti tuče dobivaju se u blizini planina i brda, što ukazuje na orografski induciranu tuču (Počakal i sur., 2018). Nadalje, uz korištenje većeg područja utjecaja od 15 km, 185 zapisa o tuči povezano je s okruženjem ITD, dok je dodatnih 58 povezano s okruženjima TD (Slika 24b). Provedena je i detaljnija analiza kako bi se ispitaio učinak različitih područja utjecaja. Slika 24c prikazuje da 28 % zapisa o tuči sadrži trag TSII-ja neposredno iznad postaje, još 29 % u neposrednoj blizini (3 km), dok se udio tuče povezane s okruženjem ITD značajno smanjuje s porastom područja utjecaja, kao što je prikazano na Slici 24c. Ovi se rezultati dobro slažu s rezultatima Changnon (1992) i Wapler (2017). Od 84 slučaja koji nisu bili povezani s okruženjem ITD (Slika 24b), 58 je vezano uz razdoblje niske aktivnosti munja (od listopada do travnja) (Galanaki i sur., 2018). Uzimajući u obzir rezultate sa Slike 24b, može se zaključiti da je gotovo sva opažena tuča na sjeveroistočnom Jadranu nastala u grmljavinskim olujama, dok se tijekom sezone niske aktivnosti munja, tuča obično javlja bez prisutnosti traga TSII-ja.




Slika 24. (a) Prostorna razdioba slučajeva tuče po postajama za promatrano razdoblje (2008. – 2017.) uz broj ukupnih slučajeva upisanih u krugove. Veličine krugova i boja označavaju učestalost tuče; manja učestalost tuče od 1 slučaja godišnje (žuta boja), učestalost tuče manja od 2 slučajeva godišnje (narančasta boja) i učestalost tuče veća od 2 slučajeva tuče godišnje (ljubičasta boja). Obojane konture označavaju nadmorsku visinu (m). (b) Raspodjela slučajeva tuče u odnosu na različita okruženja koristeći područje utjecaja od 15 km. (c) Udio tuče povezan s TSII-jem kao funkcija udaljenosti od okruženja ITD (intenzivna okruženja s munjama).

Tuča se javlja relativno rijetko u kontekstu mjerenja na određenoj postaji (0 – 4 puta, a u prosjeku oko jedanput godišnje u Hrvatskoj) te taj podatak prostorno predstavlja vrlo malu površinu. Stoga izravna veza između TSII-ja i tuče nije moguća bez radarskih procjena koje bi popunile opću sliku. Međutim, važno je primijetiti da TSII u postupku verifikacije pomoću tablice kontingencije daje nekoliko puta manje lažnih signala u usporedbi s podacima munja, jer ima značajno manji otisak u odnosu na otisak munja. Osim toga, promatranjem pojedinih događaja tuče primijetilo se da su neke pojave tuče povezane s aktivnosti munja koje proizvode višestruke TSII-jeve, kao što je sugerirano na Slici 5.

4.3.4 Veza TSII-ja s pijavicama

Većina izvještaja o pijavicama dolazi sa zapadne obale Istre (Slika 25a), a njihova pojava značajno varira iz godine u godinu (Slika 25b). Vidljivo grupiranje pijavica oko naseljenih područja je očekivano, pošto naseljena područja povećavaju mogućnost opažanja pojave. Prema Slici 25c, za promatrano razdoblje od 11 godina, detektirano je 15 dana s pijavicom kada nije bila prisutna oluja (okruženje NTD). To je prilično mali broj ako se uzme u obzir da u ovoj

kategoriji pripada otprilike polovica opaženih pijavica u Jadranu (Renko i sur., 2016). Budući da je za neke događaje dostupan samo datum, uvodi se pretpostavka da su isti sinoptički uvjeti uzrokovali razvoj pijavica na određeni dan pa se time dobiva konačan broj od 27 dana s munjama, od čega je 20 dana uključivalo okruženje ITD na udaljenosti od 15-ak km od mjesta opažanja pijavice.



Slika 25. (a) Lokacije opaženih pijavica na temelju raspoloživih podataka u razdoblju od 2008. do 2018. za područje sjeveroistočnog Jadrana. (b) Međugodišnja aktivnosti pijavica. (c) Raspodjela dana s pijavicom u odnosu na različita okruženja s munjama na području utjecaja od oko 15 km.

Polovica prijava povezanih s ITD-om bili su događaji s dvije ili više pijavica, a najveći broj od 11 u jednom događaju evidentiranih pijavica je uočen 28. kolovoza 2013., što je i najveće dokumentirano pojavljivanje pijavica tijekom jedne oluje u Jadranskom moru (Renko i sur., 2018; Sioutas i sur., 2014). Samo tri dana (događaja) koji su povezani s TSII-jem opažena su u razdoblju niske aktivnosti munja. Iako je teško uspostaviti izravnu vezu između TSII-ja i pojave pijavica, očito je da je u ovom skupu podataka veliki broj pijavica povezan s tragom TSII-ja (20 od 27). Postoji prostor za daljnja istraživanja koja se mogu provesti za veća područja i duže nizove podataka, no za takva istraživanje bi bilo potrebno uključiti i dodatne izvore podataka, kao što su, primjerice nedavno postavljeni radari^{5,6}.

Prema Renko i sur. (2016), većina pijavica u Jadranu nisu izazvane mezociklonama, a otprilike polovica njih nastaje bez prisutnosti munja. Ipak, mjereno po Fujita ljestvici, neke od njih mogu uzrokovati štetu na razini F2 ili više. Jače pijavice ($\geq F/EF2$), kako ih je izvorno


⁵ https://meteo.hr/podaci.php?section=podaci_mjerenja¶m=radari&el=debeljak

⁶ https://meteo.hr/podaci.php?section=podaci_mjerenja¶m=radari&el=goli

definirao Hales (1988), uglavnom se razvijaju iz mezociklona. Budući da su mezociklone često popraćene intenzivnim munjama može se nagađati da bi za jače pijavice TSII mogao biti dobar prediktor.

4.3.5 Veza TSII-ja s indeksima nestabilnosti atmosfere

Osim izmjerenih i opaženih podataka, za usporedbu su korišteni i podatci o smicanju vjetra u prvih 6 km (DLS) te različiti indeksi nestabilnosti: MUCAPE (J/kg), LI (°C) i KI (°C), izračunati korištenjem reanalize ERA5, te je provjerena veza i razlika između dana s različitim utjecajnim okruženjima (NTD, TD i ITD). Rezultati ovih parametara prikazani su na Slici 26 u obliku pravokutnih dijagrama, s raspodjelom za dane NTD, TD i ITD prikazane plavom, zelenom, odnosno crvenom bojom. Iako je promatrano razdoblje relativno kratko (11 godina) u usporedbi s promatranim razdobljem iz Jelić i sur. (2020), rezultati indeksa nestabilnosti za dane bez tuče dobro odgovaraju trenutno dobivenim danima NTD. Očekivano, dani TD imaju statički nestabilniju atmosferu, što potvrđuju pravokutni dijagrami zelene boje (Slika 26a–c). U usporedbi s danima NTD i TD, dan s okruženjem ITD pokazuje još više nestabilnosti, što je prikazano crvenim pravokutnim dijagramom. Medijan MUCAPE-a u danima s munjama iznosi 652 J/kg, dok je ona na ITD 832 J/kg. Ovi rezultati za dane ITD se slažu s drugim istraživanjima intenzivnih konvektivnih sustava u Europi, poput onih u radu Púčik i sur. (2015). Slični rezultati dobiveni su za KI i LI, dok DLS nije pokazivao velike razlike tijekom svih dana. Jedan od mogućih razloga može biti previše izgladnena polja strujanja, jer su se za sve izračune koristila srednja dnevna polja, čineći DLS nedovoljno osjetljivim u usporedbi. Drugi razlog može biti i to što je područje sjeveroistočnog Jadrana slabo zastupljeno u podacima ERA5 zbog vrlo složene topografije koja se ne može dovoljno dobro razlučiti malim brojem točaka zbog relativno grube razlučivosti podataka ERA5. Ipak, dobiveni rezultati pokazuju da su dani s tragom TSII-ja uglavnom povezani s vrlo nestabilnim okruženjima koja su povoljna za formiranje potencijalno opasnih konvektivnih oluja s munjama i praćena intenzivnom oborinom, tučom, pijavicama i/ili udarima vjetra.



Slika 26. Usporedbe pravokutnih dijagrama indeksa nestabilnosti u danima s NTD (plavo), TD (zeleno) i ITD (crveno) okruženjima te za (a) najnestabilniji CAPE (MUCAPE, J/kg), (b) K-indeks (KI, °C), (c) indeks podizanja (LI, °C) i (d) smicanje vjetra (DLS, m/s) u najnižih 6 km. Medijan vrijednosti prikazan je vodoravnom linijama u pravokutniku; rubovi pravokutnika su 25. i 75. percentil, a vanjske horizontalne linije predstavljaju 10. i 90. percentil.


4.3.6 Lokalne grmljavinske oluje

Lokalne oluje s grmljavinom obično su kratkotrajne i slabije vidljive na radarskim i satelitskim snimkama (Brown i sur., 2015; Kehler-Poljak i sur., 2017; Li i sur., 2017; Mecikalski i sur., 2016; Poljak i sur., 2014). Lokalne konvektivne oluje s munjama, zbog svog malog prostornog utjecaja, u usporedbi s MCS-ovima ili većim sustavima često se čine beznačajnim i obično se zanemaruju ili ignoriraju unutar općeg istraživanja grmljavinskih sustava. Međutim, lokalne oluje s munjama također mogu biti vrlo intenzivne i proizvesti značajne posljedice. Nedostatak tehnika za učinkovito prepoznavanje takvih sustava u konačnici rezultira općenitim

nerazumijevanjem takvih procesa, ali i nedostatkom informacija koje bi bile u službi evaluacije lokalnih pojava u modelima velike razlučivosti.


Kako bi se pridonijelo boljem razumijevanju lokalnih oluja s munjama, napravljen je pokušaj izoliranja manjih intenzivnih lokalnih oluja s munjama, kao što su jednoćelijski i multićelijski kumulonimbusi (Cb). Kao kriterij odabira korišteni su samo oni dani u kojima veličina traga TSII-ja nije prelazila 90 km^2 . To odgovara veličini od 10 piksela mreže ($3 \text{ km} \times 3 \text{ km}$), što je otprilike 11 % promatrane domene (Slika 6a). Ovaj odabir nije idealan jer u jednom danu može nastati nekoliko izoliranih intenzivnih lokalnih oluja koje kumulativno prelaze kriterij od 10 piksela. Međutim, ovi kriteriji jednoznačno omogućuju ispitivanje atmosferskih okruženja koja dovode do ovih lokaliziranih pojava. Cilj je provjeriti uspješnost metode prvenstveno korištenjem podataka o oborini, jer ona predstavlja najveću raspoloživu bazu podataka. Budući da je efekte lokalne konvektivne oluje s munjama teško zabilježiti točkastim mjerenjima te kako bi se eventualne pogreške uparivanja svele na minimum, trag TSII-ja i podatci s postaje su izravno uspoređeni, tj. bez korištenja područja utjecaja.

Tijekom 364 dana u kojima su detektirane izolirane konvektivne oluje, bilo je moguće izravno povezati 79 zapisa o oborini s okruženjem ITD. Nadalje, 1081 zapis oborine povezan je s TD-om i 7168 zapisa s okruženjem NTD. Usporedba ovih rezultata može se vidjeti na na Slici 27 koja prikazuje događaje s okruženjem NTD, TD i ITD.



Slika 27. Pravokutni dijagrami 24-h oborine (mm) za događaje NTD (plavo), TD (zeleno) i ITD (crveno). Rezultati se temelje na setu podataka koji uključuje 364 dana s intenzivnim lokalnim olujama na 37 oborinskih postaja prikazanih na Slici 6a.

Rezultati pokazuju da konvektivna oluja s munjama može biti i potencijalno opasna bez obzira na veličinu sustava, jer su čak i za najmanje sustave ITD okruženja odgovorna za najveće vrijednosti oborine.



Slika 28. Usporedbe pravokutnih dijagrama indeksa nestabilnosti u danima s NTD (plavo), TD (zeleno) i ITD (crveno) okruženjima te za (a) najnestabilniji CAPE (MUCAPE, J/kg), (b) K-indeks (KI, °C), (c) indeks podizanja (LI, °C) i (d) smicanje vjetra (DLS, m/s) u najnižih 6 km. Crni pravokutnici pokazuju 109 dana s tragom od samo jednog TSII piksela (ITD₁), 364 dana s tragom od 1 – 10 TSII piksela (ITD₁₀) i 740 dana s tragom bilo kojeg broja piksela (ITD). Medijan vrijednosti prikazan je vodoravnim linijama u pravokutniku; rubovi pravokutnika su 25. i 75. percentil, a vanjske horizontalne linije predstavljaju 10. i 90. percentil.

Čak i za dane koji uključuju najmanji mogući trag TSII-ja (samo jedan raster s pozitivnim TSII-jem (3 km × 3 km)), dobivaju se slični rezultati (nije prikazano zbog premalog uzorka). Dodatno, analizirana je i veza s tučom pri čemu je 11 zapisa o tuči bilo povezano s tragom TSII-ja, a najveća udaljenost između traga TSII-ja i zapisa o tuči bila je 9 km. Korištenjem područja utjecaja od 15 km za kopnenu postaju (GMP Pazin) pronađeno je 11 događaja s jakim vjetrom, a 5 događaja jakog vjetra povezano je s tragom TSII-ja. Nadalje, pijavice povezane s TSII-jem obično se javljaju unutar velikih sustava, a samo je jedan događaj bio povezan s intenzivnom lokalnom olujom. Analizirana je i veza između lokalnih oluja s indeksima nestabilnosti, pri čemu je posebna pozornost dana olujama s najmanjim tragom TSII-ja (jedan element rastera), a rezultati su prikazani na Slici 28. Ukupno, 109 dana je povezano sa samo jednim elementom rastera TSII (ITD₁), 364 dana s više (1 – 10) elemenata rastera TSII (ITD₁₀) i, kao na Slici 26,

svi dani s bilo kojim brojem elemenata rastera TSII (ITD). Iznenadujuće je primijetiti koliko je mala razlika između ITD_1 , ITD_{10} , i ITD-a. Intenzivne lokalne oluje s munjama (ITD_1 i ITD_{10}) imaju nešto manje nestabilna okruženja za sve indekse, dok je nešto jače smicanje (DSL) zabilježeno u slučajevima ITD_1 . Međutim, sve vrijednosti indeksa nestabilnosti sugeriraju nestabilnija okruženja u usporedbi s okruženjima TD, kao što je prikazano na Slici 26. Ovi rezultati sugeriraju da vrlo nestabilna okruženja imaju tendenciju stvarati intenzivne oluje bez obzira na njihovu veličinu i tip (jednoćelijski, višćelijski i superćelijski sustavi).

4.3.7 Sažetak evaluacije indeksa intenziteta munja

Ukratko, TSII uvodi dodanu vrijednost u analizu oluja, kao što je sažeto u Tablici 9. Postoji jaka veza između traga TSII-ja i intenziteta oborine te ukupnih količina oborina. Vjetar unutar okruženja ITD obično je jači, dok i tuča i pijavice preferiraju prisutnost jakih oluja s munjama koje imaju trag TSII-ja. Otprilike je 76 % tuče proizašlo iz oluja povezanih s okruženjima ITD. Intenzivne grmljavinske oluje također se formiraju u najnestabilnijim okruženjima kako je vidljivo iz indeksa MUCAPE, KI i LI i to bez obzira na njihovu zastupljenost u prostoru; vrijednosti dobivene za okruženja ITD_{10} su slične onima dobivenim za sva okruženja ITD. Budući da je i vrijeme i mjesto indeksa TSII poznato, po prvi puta je moguće dobiti i prostorne i vremenske informacije o potencijalno opasnim događajima, koje mogu biti vrlo korisne za analizu vremenske dinamike pojava, ali i za dokazivanje odštetnih zahtjeva te prepoznavanje opasnih područja s ciljem planiranja mjera prilagodbe.

Tablica 9. Zbirna tablica medijalnih vrijednosti intenziteta oborine, ukupne 24-h oborine, vjetra, tuče i pijavice te indeksa nestabilnosti za tri promatrana okruženja (NTD, TD, ITD). Priloženi su i podatci intenzivnih lokalnih oluja (ITD_{10}) radi usporedbe; „X“ označava nedostupne podatke.

	Intenzitet oborine [mm/min]	Ukupna oborina [mm/dan]	Vjetar [m/s]		Tuča [N]	Pijavice [N]	Indeksi nestabilnosti		
			Obala	Pazin			CAPE [J/kg]	KI [°C]	LI [°C]
NTD	0.06	4.7	9.1	7.4	28	15	220	13.9	-1.4
TD	0.18	9.8	12.1	8.8	56	6	658	23.3	-5.8
ITD	0.46	17.6	14.9	10.2	185	20	832	26.8	-7.9
ITD_{10}	X	15.2	X	X	X	X	785	24.8	-7.2

4.3.8 Klimatološka analiza indeksa intenziteta munja za područje sjeveroistočnog Jadrana


Kroz prethodna je poglavlja demonstrirana sposobnost TSII-ja da poveže intenzivne vremenske posljedice s konvektivnim olujama. Korištenjem TSII-ja dobiva se i prostorna i vremenska informacija o potencijalno opasnom događaju koji može biti kiša, tuča, udar vjetra ili pijavica. S obzirom na to da je na promatranoj domeni dostupan niz od 11 godina podataka o munjama, moguće je ispitati prostorne i vremenske aktivnosti intenzivnih oluja, ali i manjih lokalnih oluja (tijekom 364 dana kada su identificirane). Dodatno će se ispitati i sinoptički sustavi koji su bili prisutni u danima s okruženjem NTD, TD, ITD i ITD₁₀.

4.3.8.1 Prostorna obilježja

Na Slici 29 prikazana su prostorna obilježja skupa svih dana s munjama, skupa dana kada postoji trag TSII-ja te skupa dana s manjim lokalnim intenzivnim olujama. Rezultati dobiveni za skup dana s munjama (Slika 29a) su u skladu s rezultatima prikazanim u Galanaki i sur. (2018) za razdoblje od 2005. do 2014., koji je promatrao dane s munjama za cijelo područje Sredozemlja na rezoluciji 10 km × 10 km. Također, jednako dobro slaganje vidljivo je i s prethodnim istraživanjem dana s grmljavinom nad područjem Jadrana za razdoblje 1948. – 1966. (Penzar i sur., 2001). Iako je grmljavina zvučni efekt munje te njeno opažanje sugerira da je negdje u krugu od oko 10 km došlo do pojave munje, sam oblik razdiobe dana s grmljavinom dobro odgovara ovdje dobivenom rezultatu te pokazuje da 50-ak godina kasnije nema značajnih promjena u prostornoj raspodjeli munja.

Međutim, ovdje dobiveni rezultati pokazuju na postojanje kompleksnije i varijabilnije prostorne strukture zbog veće razlučivosti (3 km × 3 km), što je razlog manjem ukupnom broju dana s munjama u pojedinoj točki mreže usporedno s rezultatima iz Galanaki i sur. (2018). Ipak za razliku od dana s munjama, TSII (Slika 29 b) ukazuje na područja za koje postoji veća vjerojatnost da će biti pogođena opasnim vremenskim pojavama. Usporedba skupova dana s munjama i dana s TSII-jem (Slika 29a, b) naznačuje da sjeveroistočni dio područja Istre (kao i južni dijelovi Slovenije) bilježe značajan broj dana s munjama, no samo je nekoliko od tih dana okarakterizirano potencijalno opasnim vremenskim uvjetima. Osim toga, dijelovi sjeverozapadne i južne Istre, preciznije područje rijeke Mirne i šire područje Labina i Rabca, bilježe manje dana s munjama od ostalih područja, ali je veći dio njih bio intenzivan. Intenzivne lokalne oluje s munjama (Slika 29c) također imaju preferirana područja pojavljivanja, što je naznačeno većim brojevima na karti. Oborine se mogu izravno usporediti s tragom TSII-ja, jer

je pokazano da postaja ispod traga TSII-ja bilježi najveće intenzitete i količine oborine (Tablica 9). Veza između pojave tuče i TSII-ja nije jednoznačna, no promatranjem područja u krugu od 15 km oko određene točke može se procijeniti vjerojatnost pojave tuče. To donekle potvrđuje razdioba tuče prikazana na Slici 24a koja se uglavnom podudara sa Slikom 29b kao i procjene koje su dobili Stržinar i Skok (2018) (njihova Slika 8), na temelju radarskih produkata za topli dio godine (od svibnja do kolovoza) unutar razdoblja od 2002. do 2010. godine, pri čemu su djelomično zahvatili sjeverni dio domene koja je korištena u ovom radu. Jaki vjetar povezan s intenzivnim munjama i olujnim sustavima češće se javlja u unutrašnjosti, iako se veće brzine mogu javiti duž zapadne obale, kao što sugeriraju rezultati prikazani na Slici 23. Na temelju dobivenih rezultata prikazanih na Slici 29b istočni dio domene koji je pokriven morem također je zahvaćen intenzivnim pojavama munja, no nažalost, za to područje nema dostupnih podataka pomoću kojih bi se mogla napraviti verifikacija.




Slika 29. Prostorna raspodjela (a) srednjeg godišnjeg broja dana s munjama, (b) skupa dana kada je zabilježen trag TSII-ja i (c) skup dana s intenzivnim, ali manjim lokalnim olujama na temelju 11-godišnjeg niza podataka o munjama (2008. – 2018.).

4.3.8.2 Vremenska obilježja

U prosjeku, godišnje se u Istri zabilježi 118 dana s munjama od kojih je 67 dana obilježeno okruženjem ITD. Dani s lokalnim grmljavinskim olujama (ITD_{10}) obično se javljaju prosječno 33 puta godišnje. Međugodišnje varijacije u ukupnim danima s munjama, danima TD, ITD i ITD_{10} (Slika 30a) ukazuju na umjerene do jake varijacije tijekom ispitivanog razdoblja, s najmanjom aktivnošću u 2015. te najjačom u 2018. godini. Dok je TD imao maksimum u 2009., ITD_{10} okruženja ne pokazuju nikakva izražena povećanja ili smanjenja tijekom promatranih godina. Nadalje, udio ITD_{10} unutar ITD-ja je približno 50 % te se mijenja za oko ± 10 %. U tom kontekstu, interesantno je primijetiti da godine 2014. i 2016. imaju najmanji udio intenzivne lokalne aktivnosti s 36 %, odnosno 38 % te da su prema izvješćima DHMZ-a okarakterizirane

kao vrlo vlažne do izrazito vlažne u kontekstu oborine. Nasuprot tome, godine 2008. i 2013. imaju velik udio intenzivne lokalne konvektivne aktivnosti (oko 60 %), a izvješća DHMZ-a ih ocjenjuju kao prosječne do vlažne.




Slika 30. Vremenska dekompozicija dana s munjama (crna linija), dana TD (zelena linija), dana ITD (crvena linija) i dana ITD₁₀ (siva linija) za (a) međugodišnje i (b) godišnje varijabilnosti.

Godišnji hodovi prikazani na Slici 30b pokazuju da okruženja ITD imaju najjaču aktivnost tijekom toplijeg dijela godine, što je u skladu s drugim istraživanjima o aktivnosti munja (Manzato i sur., 2016; Mikuš i sur., 2012; Púčik i sur., 2017), a maksimum vrijednosti postiže se u srpnju. ITD₁₀ ima sličan hod, premda vrhunac dostiže odmah u svibnju i nastavlja postupno opadati do kraja godine uz još uvijek izraženu aktivnost u lipnju i srpnju. Godišnja razdioba dana TD ima nepravilniji oblik, počinju se povećavati mjesec dana ranije (travanj) i dostižu vrhunac u svibnju, iako za razliku od dana ITD, ne bilježe nagli pad prema kraju godine. Zanimljiv rezultat je blagi porast u studenom za dane TD i dane ITD. Kao što je ranije objavljeno za obilne oborine u sjeveroistočnoj Italiji (Manzato i sur., 2016), pijavice nad Jadranskim morem (Renko i sur., 2016) i tuču nad Istrom (Jelić i sur., 2020), studeni se ističe kao mjesec s izraženom konvektivnom aktivnošću na većem dijelu Jadrana (npr. Belušić i sur., 2018). Dodatno, isti je zaključak dobiven za zapadnu i srednju Europu (Rädler i sur., 2019) korištenjem podataka munja iz mreže EUCLID.

4.3.8.3 Tipovi vremena

Dobiveni rezultati tipova vremena za cijelo razdoblje (2008. – 2018., Slika 31), suglasni su s rezultatima prikazanim na Slikama 15a i 16 za ograničeno područje sjeveroistočnog Jadrana za dane s tučom. Slika 31 prikazuje raspodjelu određenih tipova vremena za čitavu Hrvatsku za a)

dane s okruženjem NTD, b) TD, c) ITD i d) dane s okruženjem ITD₁₀. Dani s NTD okruženjem se pojavljuju u svim tipovima vremena, s povišenim udjelom anticiklonalnog i kvazi-bezgradijentnog okruženja od oko 60 %. Dani TD, ITD i ITD₁₀ imaju međusobno prilično slične razdiobe, pri čemu jasno dominiraju ciklonalno i kvazi-bezgradijentno okruženje sa 75 %, 84 % odnosno 82 % udjela u ukupnom broju takvih dana.



Slika 31. Klasifikacije tipa vremena (VT) dobivene iz automatizirane klasifikacije uz korištenje podataka reanalize ERA5 (2008. – 2018.) za (a) dane NTD, (b) dane TD, (c) dane ITD i (d) dane ITD₁₀. Crveno označava duboke sustave, a plavo označava plitke sustave. VT1, VT2, VT3 i VT4 predstavljaju prednju, gornju, stražnju i donju stranu ciklona, dok VT5, VT6, VT7, VT8 predstavljaju prednju, gornju, stražnju i donju stranu anticiklonskih sustava. NG-VT predstavlja kvazi-bezgradijentno prizemno polje tlaka.

Većina anticiklonalnih oluja s munjama i okruženja ITD povezano je s VT8 koji predstavlja stražnju stranu dubokih (crvenih) i plitkih (plavih) sustava, što je slično rezultatima prikazanim na Slici 15b za dane s tučom. Za VT8 i VT5, strujanje zraka dolazi iz smjera NW i NE, što omogućava priljev hladnije zračne mase sa sjevera i potiče stvaranje nestabilnih okruženja koja pogoduju razvoju konvektivnih oluja (Slika 16).

Promatranjem dobivenih rezultata može se uočiti:


1. izražena sličnost sinoptičkih sustava povezanih s intenzivnim lokalnim olujama s munjama i intenzivnim olujama većih razmjera (Slike 15c i Slike 15d),

2. te sličnosti u odnosu na atmosferske indekse nestabilnosti (Tablice 9).

Ovi rezultati sugeriraju da će okruženja ITD-a jednako vjerojatno formirati i velike i lokalne oluje koje mogu proizvesti neke od intenzivnih efekata (tuča, jaka kiša, udari vjetra, pijavice). Dakle, rezultati sugeriraju da se korištenjem samo modelskih podataka (npr. reanaliza) mogu identificirati jaka i nestabilna okruženja, kao što je to već i učinjeno u primjerice Rädler i sur. (2019) te Taszarek i sur. (2018), ali se neće dobiti informacije o konačnoj veličini oluje niti o područjima zahvaćenim munjama.

4.3.9 Veza indeksa intenziteta munja i tuče za područje Hrvatske

Kako bi se ispitali rezultati iz poglavlja 4.4.3. napravljena je usporedba tuče i indeksa TSII za cijelu Hrvatsku (Slika 32, crna linija). Dodatno je ispitan i odnos toplog (svibanj – listopad, crvena linija) i hladnog dijela godine (plava linija). Linijama je predstavljen udio broja dana s tučom koji je povezan s TSII-jem za razne utjecajne radijuse te se može primijetiti kvalitativno podudaranje crne linije sa Slikom 24c. Također, promatranjem samo toplog dijela godine, kada je konvektivna aktivnost pojačana, uočava se da se tuča češće pojavljuje u neposrednoj blizini traga TSII-ja, tj. 63 % je unutar 3 km dok je tijekom hladnog razdoblja takvih slučajeva svega 23 %. Povećanjem područja utjecaja na 15 km u toplom djelu godine, 83 % tuče povezuje se pojavom indeksa TSII, dok je za hladni dio godine veza vidljiva u oko 58 % slučajeva (Tablica 10). Nadalje, uz veći intenzitet tuče vjerojatnija je pojava traga TSII-ja, što je i očekivano, s obzirom na to da veći intenzitet sugerira veći broj zrnaca tuče, što pak znači da je konvektivni sustav imao veće koncentracije elemenata za odvajanje naboja tj. produkciju munja (Hales 1988). Dodatno je provjeren i udio onih događaja tuče koji nisu imali zabilježen intenzitet (zadnji stupac u Tablici 10 sastavljen od 438 podataka). Ovi rezultati poklapaju se s prvim stupcem, tj. ukupnim podacima.



Slika 32. Udio tuče povezane s indeksom TSII kao funkcija prostorne udaljenosti između traga TSII i mjesta gdje je zabilježena tuča. Crnom linijom označeni su rezultati svih podataka dok crvena i plava linija predstavljaju dekompoziciju na topli i hladni dio godine kako je navedeno u legendi.

Tablica 10. Udio tuče povezane s indeksom TSII za referentne udaljenosti. Stupci pokazuju vezu za cijelu godinu, odvojeno za topli i hladni dio godine te za različite intenzitete.


(%) →	Cijela godina	Topli dio	Hladni dio	Intenzitet 0	Intenzitet 1	Intenzitet 2	Intenzitet nepoznat
R=15 (km)	74	83	58	70	73	82	74
R=30 (km)	84	89	74	81	84	89	84
R=90 (km)	95	97	91	95	97	94	93

Navedeno sugerira da je zastupljenost pojedinih intenziteta u toj skupini slična vrijednostima iz Tablice 7 čime se dodatno potvrđuje valjanost odnosa u toj tablici. Iako se iz radova Wapler (2017) i Changnon (1992) vidi da je udaljenost između tuče i središta grmljavinskih oluja uglavnom ispod 15 km pa je stoga ta vrijednost uzeta kao referentna za prikazane rezultate, neka druga istraživanja sugeriraju kako postoji veliki vremenski odmak (preko 60 min) između pojave skoka munje i same pojave tuče u blizini na tlu (npr. Farnell i sur., 2017). Kako se u tim radovima radi o skoku munje, ne može se sa sigurnošću tvrditi da između prvog skoka munje (koji se koristi za računanje vremenskog odmaka) i pojave tuče nije bilo dodatne intenzivne konvektivne aktivnosti s munjama. Ipak, treba naglasiti da konvektivni sustavi mogu prijeći veliki put u 60 min. Stoga je u ovom istraživanju razmotreno i iznimno veliko područje utjecaja (30 i 90 km) te su rezultati prikazani u Tablici 10. Za područje utjecaja od 30 km dobiva se da je 84 % ukupnih podataka tuče u promatranom razdoblju povezano s intenzivnom aktivnosti

munja, te da je u toplom dijelu godine taj udio oko 89 %, a u hladnom dijelu 74 %. Sličan porast vidljiv je i za različite intenzitete dok je za područje utjecaja od 90 km udio ukupnih podataka povezanih s TSII-jem na visokih 95 %. Rezultati iz zadnjeg reda Tablice 10 vjerojatno nisu fizikalno prihvatljivi, s obzirom na to da je za konvektivnih dana sasvim očekivano da se pojavljuje veći broj sustava iznad promatranog područja čime dolazi do lažnog dodjeljivanja veze s TSII-jem. Zaključno, pojava tuče usko je vezana uz pojavu traga TSII-ja, a njihov prostorni odmak rijetko prelazi 15 km.


4.3.10 *Klimatološka obilježja indeksa intenziteta munje nad Hrvatskom*

Za maksimalno dostupno vremensko razdoblje podataka o munjama (2008. – 2020.) napravljena je karta srednjeg broja dana s tragom TSII-ja za Hrvatsku i okolno područje (Slika 33).



Slika 33. Prostorna raspodjela srednjeg godišnjeg broja dana s tragom TSII-ja na temelju 13- godišnjeg niza podataka (2008. – 2020.) o munjama iz mreže LINET.


Dobiveni rezultati pokazuju da se najveći broj dana s intenzivnim vremenom može očekivati u priobalnom području, a posebno na području sjeverno od Kvarnera, zatim na području Šibensko-kninske i sjevernom dijelu Splitsko-dalmatinske županije te južnom dijelu Dubrovačko-neretvanske županije. Istaknuta priobalna područja, slažu se s prethodnim istraživanjem od Penzar i sur. (2001) koji su analizirali srednji broj grmljavinskih dana na području Jadrana za razdoblje od 1948. do 1966. godine.



Slika 34. Godišnji hod prostorne raspodjele broja dana s tragom TSII-ja na temelju 13-godišnjeg niza podataka (2008. – 2020.) o munjama iz mreže LINET.

Također, zone povećanog broja dana intenzivnog vremena pronalaze se u većem dijelu unutrašnjosti Hrvatske, a jedini s malim brojem dana TSII-ja bilježe se na području Like, dijelu Gorskog kotara, te dijelu dalmatinskih otoka. Sama pojavnost intenzivnog vremena u prosjeku se kreće između 1 i 4.5 dana godišnje, iako prevladavaju vrijednosti u rasponu od 2.5 do 4 dana

godišnje. Iako jednoznačna veza TSII-ja i tuče nije utvrđena (jer je pojava TSII-ja vezana i uz pojavu jake kiše, udara vjetra i pijavica), vidljivo je da se dobivene vrijednosti ugrubo podudaraju s dobivenim rezultatima za većinu dijelova Hrvatske (Slika 10), bez obzira što se ne radi o istom promatranom razdoblju. Također, usporedba ovih rezultata s rezultatima za Sloveniju (Stržinar i Skok, 2018), dobivenim na temelju radarske procjene padanja tuče, daju vrlo dobro slaganje. S obzirom na to da je TSII povezan s pojavom jake kiše i tuče te da se u TSII okruženju pojavljuju jači udari vjetra i pijavice, ovakva karta predstavlja kartu rizika za pojave intenzivnog nevremena na širem području Hrvatske.



Slika 35. Dnevni hod (UTC) prostorne raspodjele broja dana s tragom TSII-ja na temelju 13 godina (2008. – 2020.) podataka o munjama iz mreže LINET. Svaka od slika predstavlja dvosatnu sumu TSII-ja u satima navedenim u gornjem desnom uglu.

Prostorni prikaz godišnjeg hoda na Slici 34 pokazuje da je glavnina intenzivnih oluja vezana za topli dio godine (svibanj – rujan), dok je u priobalnom dijelu vidljiva prisutnost tijekom cijele godine. Sličan rezultat, iako je istraživanje rađeno samo za topli dio godine te na trogodišnjem nizu podataka o munjama (2006. – 2009.), dobiven je u radu Mikuš i sur. (2012). Tamo je definiran dan s konvekcijom kao dan kada se u promatranom području pojavi više od 10 munja unutar jednog sata. S obzirom na to da za različite metode kvantitativna usporedba nije moguća, kvalitativnom analizom Slike 34 i rezultata koje navode Mikuš i sur. (2012., njihova Slika 2) uočava se sličnost na cijelom području Hrvatske. Detaljnijim promatranjem može se uočiti kako promatrane veličine u pojedinim dijelovima Hrvatske poprimaju maksimume u različitim mjesecima pa je tako većina kontinentalnog dijela najjače zahvaćena tijekom lipnja, iako neki dijelovi bilježe najveće vrijednosti u srpnju kada se maksimum pojavljuje i na području Istre i Dalmatinske zagore. Hrvatsko primorje maksimume aktivnosti bilježi uglavnom u rujnu.

Ovi rezultati sugeriraju da zimska tuča najvjerojatnije ima druge dominantne faktore nastanka u odnosu na ljetnu. Tome u prilog idu i rezultati sa Slike 17 koji sugeriraju da se za “zimski” tip postaja dobivaju najniže vrijednosti CAPE-a te najviše vrijednosti DLS-a. Dnevni prostorni hod TSII-ja prikazan je na Slici 35 pri čemu svaka od slika predstavlja dvosatnu sumu. Vidljivo je da su intenzivne oluje nad Hrvatskom prisutne tijekom svih 24 h. U kontinentalnim dijelovima TSII se najčešće pojavljuje u razdoblju od 12 h – 20 h, što je u suglasnosti s dnevnim hodom tuče (Slika 9). U priobalnim dijelovima maksimumi se uglavnom javljaju u prijepodnevnim satima (6 h – 12 h), iako je aktivnost prisutna tijekom cijelog dana (također sukladno “zimskom” tipu postaja sa Slike 9). Ono što se značajno razlikuje od rezultata sa Slike 9 jest izražena prisutnost noćnih intenzivnih oluja (22 h – 5 h) koje nisu vidljive u dnevnom hodu tuče. S obzirom na to da se u tom periodu motrenja vrše otežano, tj. motritelji uglavnom spavaju, moguće je da ova metoda relevantnija od motrenja kada je u pitanju noćna grmljavinska konvekcija.

4.3.11 Daljnja istraživanja i razvoj indeksa intenziteta munja

U prikazanom istraživanju uspostavljena je nova robusna i učinkovita metoda za identifikaciju potencijalno jakih oluja pomoću traga TSII-ja, koja je vrlo prikladna za klimatološke analize, a ujedno ima i dijagnostički potencijal. Međutim, na temelju izloženih rezultata i spoznaja,

potencijal TSII-ja daleko nadmašuje očekivanja postavljena u hipotezi H3. Iako su korišteni fizikalni ili empirijski utvrđeni pragovi, kao što je minimalno 4.5 munje za filtriranje TSII-ja i 2σ kao kriterij detekcije, obje se vrijednosti mogu mijenjati kako bi se metoda prilagodila određenom intenzivnom događaju. Ako, na primjer, TSII prijeđe 3σ ili više, onda to može sugerirati vrlo snažnu promjenu (kao što se vidi na Slici 5b ako se usporedi prvi i drugi detektirani TSII) i potencijalno ima dodatnu vrijednost u finijem stupnjevanju intenziteta grmljavinskih sustava.

Nadalje, uvođenjem mjere $\alpha\sigma$, gdje je α faktor skoka, TSII može prijeći iz binarnog u kontinuirani indeks koji pokazuje snagu intenziviranja, kao što je prethodno prikazano za proračun skoka munje (Chronis i sur., 2015). Tu treba primijetiti da se osim pozitivnih vrijednosti mogu dobiti i negativne (također Slika 5b) koje zapravo sugeriraju prestanak intenzivnog dijela i time ponuditi procjenu trajanja intenzivnog sustava nad promatranim područjem. Nadalje, moguće je detektirati više TSII-eva iz jedne oluje, kao što je prikazano na Slici 5b pa se višestruke pojave također mogu koristiti kao mjera dinamike intenzivnog sustava u vremenu.

Izrazito je važno naglasiti da ovaj model temeljen na TSII-ju dopušta detekciju intenzivnih lokalnih sustava koji su jedan od najvećih problema u detekciji/proгноzi duboke konvekcije. Kroz ovaj je rad ta mogućnost demonstrirana na relativno maloj domeni pa se sam algoritam detekcije mogao pojednostavljeno koristiti uzimajući u obzir uvjet popunjenosti od 11 % domene. Za analizu većih područja, kao što je npr. domena prikazana na Slici 33, potrebno je definirati neki tip objektne klasifikacije (Farnell i sur., 2017) koja bi mogla razlikovati pojedine sustave, pošto se na velikoj domeni rijetko pojavljuje samo jedan izolirani sustav. U formiranju takvog algoritma mogli bi se koristiti i radarski podatci koji bi sugerirali položaje i putanje središta konvektivnih sustava. Time bi se otvorila mogućnost detaljne analize lokalnih intenzivnih sustava s potencijalno opasnim efektima, što je od velike važnosti sada kada i numerički modeli mogu razlučivati ekstremne pojave na lokalnoj skali (npr. Malečić i sur., 2022b).

Iako je fokus rada na dijagnostici i klimatološkim obilježjima, TSII bi mogao imati prediktivna svojstva slična skoku munje. Ako bi se uspostavila obrada podataka munja u realnom vremenu, prvih nekoliko vrijednosti TSII-ja bi ukazivalo na početak intenziviranja aktivnosti munja. Oblik i veličina TSII-ja traga munje mogli bi ukazivati na trenutnu veličinu i intenzitet oluje, dok bi svaki novi vremenski korak sugerirao putanju i dinamiku oluje. Međutim, za ovu svrhu trebalo bi uzeti u obzir i snagu intenzifikacije ($\alpha\sigma$), a ne unaprijed definiranu binarnu vrijednost. Sličnu metodu, ali za proračun skoka munje, uveli su Farnell i

sur. (2017; 2018), gdje su autori koristili mrežu $1 \text{ km} \times 1 \text{ km}$ za pronalaženje munje, a zatim definirali veću ćeliju grupirajući sve točke mreže s više od jednog bljeska zajedno. Nadalje, primijenili su računski algoritam koristeći prag od 2σ i provjerili vrijeme između prvog skoka munje i većine pojava tuče. Njihovi su rezultati pokazali da su neki događaji zabilježili skokove munje tek nakon što je uočena tuča, što je također primijećeno i u drugim radovima (Wapler, 2017). Moguće je da ovdje predložena metoda za TSII smanji broj zakašnjelih detekcija, ali za to je potrebno provesti daljnja istraživanja i testiranja.

U razvoju prognostičkih modela, potencijalno koristan smjer bio bi pronaći vezu između nedavno razvijenog indeksa za potencijalni razvoj munja (LPI) (Yair i sur., 2010) i TSII-ja te tu vezu koristiti kao alat za verifikaciju područja pogođenih intenzivnim munjama. Dodatno, HAILCAST, kao vremenski ovisan model rasta tuče (Brimelow i sur., 2002), relativno je nov alat za prognozu tuče koji je testiran pomoću dva prognostička sustava: WRF (Adams-Selin i Ziegler, 2016) te COSMO (Malečić i sur., 2022a). S obzirom na to da TSII predstavlja područja koja su pod utjecajem intenzivnog vremena, može se koristiti kao nadopuna za ona područja koja nemaju direktnih mjerenja.

4.3.12 Diskusija rezultata indeksa intenziteta munje

Hipoteza H3 pretpostavlja postojanje veze između pojave skoka munje i pojave tuče na tlu, pomoću koje se implicitno mogu izvoditi klimatološka obilježja o tuči na području gdje nema izravnih mjerenja. U procesu primjene metode skoka munje pojavila se potreba za odmicanjem od originalne metode te je uvedena matematički slična, ali interpretacijski potpuno drugačija, nova metoda. Zbog toga je indeksu pridruženo i novo ime, TSII (*engl. Thunderstorm intensity index*) odnosno indeks intenziteta munje, a sam indeks ukazuje na postojanje nagle pozitivne promjene aktivnosti munja nad nekim područjem u Eulerovskoj mreži. Ta metoda omogućila je nova saznanja i bolje razumijevanje dinamike munja, a različitosti i prednosti dobivene metode detaljno su opisane u uvodnim i metodološkim dijelovima ovog rada. Kroz dobivene rezultate pokazalo se kako je sama metoda povoljna za promatranje potencijalno opasnog vremena, što s jedne strane ne dozvoljava jednoznačan odgovor na provjeru hipoteze H3 ovog rada, ali s druge strane otvara više novih pravaca za daljnja istraživanja. Iako se već kroz preliminarna istraživanja ustanovilo kako indeks može poprimati razne vrijednosti, radi jednostavnosti te dobivanja grube, ali zorne slike, indeks je definiran kao binarna vrijednost 0

ili 1. Pri tome je TSII uvijek 0 osim kada se dogodi značajan pozitivan porast aktivnosti munja u promatranoj točki mreže. Primjenom opisane metode dobio se novi produkt – trag intenzivnog dijela oluje nad određenim područjem. U detaljnoj analizi koja je napravljena za sjeveroistočni dio Jadrana pokazalo se da je taj otisak izravno vezan za pojavu epizoda intenzivne oborine, da se oko 68 % tuče povezuje s otiskom u radijusu od 15 km te da se u istom radijusu u prosjeku bilježe jači udari vjetra. U proširenom istraživanju odnosa indeksa i tuče pokazano je da se na području Hrvatske 74 % tuče povezuje s TSII-jem, a ako se promatra konvektivno aktivniji, topli dio godine, taj se postotak penje na preko 86 %. Iako je zbog relativno velikog područja utjecaja pouzdanost rezultata nad pojedinom točkom umanjena, rezultati su u zadovoljavajućem slaganju s klimatološkim obilježjima tuče dobivenim izravnim opažanjima.

Kao glavni rezultat, u klimatološkom smislu, dobiva se karta rizika od pojave potencijalno opasnog vremena na rezoluciji $3\text{ km} \times 3\text{ km}$ za Hrvatsku i okolno područje. Rezultati dobiveni iz 13 godina mjerenja u klimatološkom smislu nisu idealni, no to je najdulji niz mjerenja ukupnog električnog pražnjenja nad Hrvatskom. S druge strane, radi se o recentnom razdoblju pa se sami rezultati analiza mogu smatrati referentnima za aktualno stanje grmljavinskih oluja. Iako je u kontinentalnom dijelu Hrvatske provedeno nekoliko istraživanja vezanih za svojstva tuče, izvori podataka bili su točkastog tipa i nisu uzimali u obzir radarska mjerenja, a analize koje uključuju više izvora podataka o ekstremnom vremenu do sada nisu publicirane za Hrvatsku. Ovim se rezultatom, po prvi puta uopće, ističu obilježja potencijalno opasnog vremena nad cijelom Hrvatskom, a posebno važan dio rezultata je vezan za priobalno područje te područje Gorskog kotara i Like gdje do sada nije bilo nikakvih istraživanja u tom smjeru.

Drugi očiti doprinos ove metode je mogućnost vrlo detaljne vremenske analize događaja. Iako su u ovom radu promatrane međugodišnja, godišnja i dnevna skala, sama metoda ima vremensku rezoluciju od 2 min. To znači da se grmljavinski sustavi mogu pratiti u realnom vremenu, a zbog visoke rezolucije ($3\text{ km} \times 3\text{ km}$) i vrlo lokalno. U dijagnostičkom smislu, svaka intenzivna oluja ostavlja otisak intenzivnog dijela, što znači da se u nedostatku bolje informacije (izravna mjerenja, opažanja ili radarske procjene) otisak može koristiti kao potvrda postojanja uvjeta za nastanak ekstremne pojave. Takva informacija može biti u službi verifikacije produkata raznih simulacija (npr. verifikacija konvektivne oborine, LPI-ja, HAILCAST-a) ili pak primijenjenog tipa, u kombinaciji s klasičnim izvorima informacija, za dokazivanje šteta pri osiguravajućim kućama.

Treći doprinos jest detekcija te mogućnost izolacije lokalnih grmljavinskih sustava koji imaju potencijal prouzročiti opasno vrijeme. Do sada su se takvi sustavi zanemarivali, zbog

nemogućnosti detekcije i razlučivanja, te zbog nedostatka očitih posljedica. No, kako se TSII računa u svakoj točki mreže neovisno o susjednim točkama te kako su uvjeti za dobivanje otiska neovisni o ukupnom broju munja, dokle god je zadovoljen prag ($2 \times \sigma$) moguće je dobiti otisak. Time se mogu detektirati i vrlo kratko živeći sustavi koji uspijevaju razviti intenzivnu promjenu u aktivnosti munja. Jedan vrlo robustan, ali i uspješan pokušaj demonstriran je u prethodnim poglavljima te predstavlja podlogu za sva daljnja istraživanja u tom smjeru.

Sama činjenica da se TSII u ovom radu tretirao kao binarna vrijednost onemogućila je prepoznavanje amplitude intenzifikacije. Ta amplituda omogućila bi bolje razlučivanje pojedinih pojava te bi sljedeći koraci trebali ići u tom smjeru. Dodatno je primijećeno kako veći sustavi, sastavljeni od više ćelija, u kratkom vremenu (oko 30-ak minuta) prelazeći preko promatrane točke mogu opetovano proizvesti pozitivnu vrijednost TSII-ja. Takva područja su pod naglašenim opterećenjem potencijalno opasnog vremena pa je razumno pretpostaviti da bi takva područja mogla bilježiti povećane intenzitete promatranih pojava.

Još jedna potpuno neistražena mogućnost je i negativna vrijednost indeksa TSII koja u osnovi može sugerirati prestanak intenzivnog dijela oluje. Kombiniranje početka i kraja intenzivnog dijela oluje također bi predstavljalo dodatnu informaciju o trajanju ekstrema, što bi u kombinaciji s brojem ekstremnih događaja omogućilo vjerodostojniju procjenu rizika od ekstremnog nevremena nad određenim područjem.

5 ZAKLJUČAK

U ovom su radu prikazani rezultati istraživanja tuče nad područjem Hrvatske za sadašnju i buduću klimu kao i rezultati istraživanja svojstava indeksa intenziteta munja koji predstavlja potencijalno opasne vremenske uvjete (tuča, jaka kiša, udari vjetera i pijavice). Istraživanje je provedeno na dugim arhivskim nizovima podataka o tuči koji su preuzeti iz dnevnika motrenja s meteoroloških postaja Državnog hidrometeorološkog zavoda na području Hrvatske, uključujući i 6 postaja Hrvatske kontrole zračne plovidbe. Analiza je obuhvatila sve dostupne podatke glavnih i klimatoloških postaja te izabranih kišomjernih postaja na području sjeveroistočnog i južnog Jadrana. Ukupno je za analizu bilo dostupno 7925 podataka sa 186 postaja. Razdoblja s dostupnim podacima se mijenjaju od postaje do postaje pa je analiza trenda napravljena za duže razdoblje (1964. – 2019.) na temelju podataka s 28 postaja te za kraće razdoblje (1984. – 2019.) na temelju podataka sa 67 postaja. Za analize koje ne zahtijevaju neprekinuti niz korišteni su svi dostupni podatci.

Za izračune tipova vremena te atmosferskih indeksa nestabilnosti korišteni su podatci reanalize ERA5 za razdoblje 1979. – 2017., prostorne razlučivosti od 0.25° , dok je za ocjenu tuče u budućoj klimi korišten ansambl simulacija regionalnih klimatskih modela. Ansambl se sastojao od osam kombinacija simulacija dobivenih kombinacijama triju regionalnih i četiriju globalnih modela iz inicijative EURO-CORDEX s prostornim razlučivanjem 0.125° . Promatrana razdoblja su 1970. – 2000. kao povijesno tj. referentno razdoblje, 2011. – 2040. (bliska budućnost), 2041. – 2070. (sredina stoljeća) te 2071. – 2099. kao kraj 21. stoljeća.

Za razvoj metode za izračun indeksa intenziteta munje korištena je matematička podloga skoka munje, a kao izvor podataka korištena je baza LINET koja sadrži podatke o ukupnom električnom pražnjenju (oblak-oblak, oblak-zemlja, te pozitivne i negativne munje) u razdoblju od 2008. do 2020. godine. Podatci o munjama razvijeni su u 2-D bazu 2-min podataka na rezoluciji $3 \text{ km} \times 3 \text{ km}$ te tako sustavno obrađeni i spremljeni u satna akumulirana polja indeksa TSII koji su poslužili za daljnju obradu.

U ovom je radu definirana i detaljno objašnjena metoda digitalizacije arhivskih podataka o tuči te predstavlja prijedlog standarda za sva daljnja digitaliziranja ove, ali i drugih pojava. Također, definirana je i metoda izračuna indeksa intenziteta munje te je diskutiran mogući razvoj i predložena su daljnja istraživanja.

Preliminarnom analizom je utvrđeno kako se podatci o tuči mogu podijeliti u tri grupe ovisno o tipu godišnjeg hoda. Tako je od ukupno 186 postaja identificirano 113 postaja koje pripadaju “ljetnom” tipu postaja, 31 postaja je pridružena “prijelaznom” te 42 postaje

“zimskom“ tipu. Na “ljetnom“ tipu postaje tuča dominira u toplom dijelu godine (svibanj-listopad), dok su “zimske“ postaje one koje najvećim dijelom imaju zabilježenu tuču u hladnom dijelu godine (studen-travanj). “Prijelazni” tip su one postaje koje imaju zabilježenu tuču podjednako često tijekom cijele godine. Osnovna analiza podataka sugerira da se u Hrvatskoj tuča pojavljuje tijekom cijele godine, što je novi podatak s obzirom na to da je većina istraživanja do sada bila usredotočena na topli dio godine, što je donekle povezano sa sustavom obrane od tuče (Počakal i sur., 2009, 2018). Na “ljetnom“ tipu postaja većina događaja tuče se pojavljuje od svibnja do kolovoza. “Prijelazni” tip postaja bilježi podjednake učestalosti tuče tijekom cijele godine, iako se travanj i studeni ističu kao najaktivniji mjeseci. “Zimski“ tip maksimum aktivnosti tuče bilježi u veljači dok je glavna aktivnost tuče smještena u razdoblju od studenoga do ožujka.

Dnevni hodovi također pokazuju naglašene razlike. Dok “ljetni“ tip prati prethodnim istraživanjima prikazan hod s maksimumom u popodnevnom satima, “prijelazni” tip značajniju aktivnost tuče bilježi već u priepodnevnom satima, a maksimum oko podneva. “Zimski“ tip pak svoj maksimum bilježi već u 8 h ujutro po srednjoeuropskom vremenu (SEV = UTC+1h), a aktivnost tuče ostaje izražena do kasnovečernjih sati.

Međugodišnja varijabilnost tuče pokazuje veliku varijabilnost za sva tri tipa tuče bez vidljivih pravilnosti između područja. Iz tih su se podataka izračunali trendovi kako za cijelu Hrvatsku tako i za pojedina područja te pojedine sezone, a za cijelu Hrvatsku, signifikantan trend dobivena je samo za duži niz (1964 – 2019). Dobiveni rezultati ukazuju na negativni trend za cijelu Hrvatsku koji je posljedica prvenstveno promjena u “ljetnom“ i “zimskom“ tipu tuče, dok “prijelazni” tip ne pokazuje statistički značajan trend. Daljnjom analizom ustanovljeno je kako su glavni doprinosi ukupnom negativnom trendu pad aktivnosti tuče u ljetnoj sezoni za “ljetni“ tip te ljetnoj i jesenskoj sezoni za “zimski“ tip.

Analizom trajanja tuče dobiveno je srednje medijalno trajanje tuče između otprilike 3 i 4.5 min pri čemu tuča u “ljetnom“ tipu traje najkraće, a u “zimskom“ najduže. Analizom trenda trajanja zabilježen je blago negativan trenda trajanja (signifikantnost na nivou $p < 0.1$) za “zimski“ tip postaje dok ostali tipovi ne bilježe promjene u trajanju.

Analizom intenziteta tuče pokazalo se da je “prijelazni“ tip najizloženiji jakim i umjerenim intenzitetima, što potencijalno predstavlja problem za poljoprivredu u tom kraju, posebno ako se uzme u obzir da tuča u tom području podjednako pada tijekom cijele godine. U “zimskom“ tipu jaki intenzitet je najmanje izražen sa svega 18 %. Trendovi intenziteta sugeriraju na generalni porast intenziteta 0 u svim područjima dok je intenzitet 2 u porastu za “prijelazni” tip te u padu za “zimski“ tip postaja.

Analizom sinoptičkih sustava nad područjem Hrvatske pokazano je da ciklonalni sustavi prevladavaju s udjelom od 48 %, anticiklonalni sustavi zastupljeni su s 42 %, a preostalih 10 % pripada situacijama s kvazi-bezgradijentnim prizemnim poljem tlaka. Unutar anticiklonalnih sustava najistaknutiji je donji sektor anticiklone, dok su ciklonalni tipovi ravnomjernije raspoređeni s najmanjim udjelom stražnjeg sektora ciklone. U danima s tučom, vidljiva je dominacija ciklonalnih tipova s obzirom na to da ti sustavi pružaju velik izvor nestabilnosti, veće vrijednosti CAPE-a i obiluju vlažnim zrakom. Udio tuče povezan s ciklonama iznosi 76 %, s anticiklonama 17 %, a s kvazi-bezgradijentnim prizemnim poljem tlaka povezano je preostalih 7 % dana s tučom.

Kombiniranjem opće raspodjele tipova vremena i onih koji su povezani s tučom dobiva se postotni udio tuče u pojedinom tipu vremena i ta se vrijednost iskoristila za ocjenu tuče u budućim klimatskim uvjetima. Rezultat pokazuje da se u odnosu na referentno razdoblje (1971. – 2000.) aktivnost tuče smanjuje za do 8 % prema kraju 21. stoljeća. Ansambl klimatskih simulacija također ukazuju na sustavno smanjenje ciklonalnog tipa vremena, te dodatno slabljenje dubokih ciklonalnih sustava, što je i glavni razlog očekivanog pada tuče u budućnosti, uz nedovoljnu zastupljenost kvazi-bezgradijentnog polja tlaka, koje je u reanalizi ERA5 zastupljeno s 10 %. Treba napomenuti da je ovim pristupom uvažen samo dinamički doprinos pojavi tuče, dok termodinamički doprinos nije uzet u obzir. Prema istraživanju ekstremne oborine (Seneviratne i sur., 2021), na području Hrvatske termodinamički doprinos iznosi oko 1 do 3 % dok je dinamički između -6 i -1 % što ide u prilog ovdje dobivenim rezultatima, iako postoji neslaganje u korištenim modelima.

Mezoskalni uvjeti za nastanak tuče dobiveni na temelju reanalize ERA5 potvrđuju da se tuča formira u vrlo nestabilnim atmosferskim uvjetima ($CAPE \sim 650 \text{ J/kg}$, $LI \sim -4.8 \text{ }^{\circ}\text{C}$, $KI \sim 31 \text{ }^{\circ}\text{C}$) uz $DSL \sim 14.8 \text{ m/s}$ i visinu nulte izoterme oko 2500 m. Između pojedinih tipova postoje određene razlike od kojih su najistaknutije one između “ljetnog” i “zimskog” tipa. Kako je glavnina tuče u “zimskom” tipu smještena unutar hladnog dijela godine, kada je kapacitet za vlagu i nestabilnost smanjen, tako se za taj tip poprimaju i najmanje vrijednosti CAPE-a. Manja nestabilnost atmosfere je kompenzirana povišenim vrijednostima DSL-a, što je u skladu s prethodnim istraživanjem (Pučik i sur., 2017).

U procesu verifikacije indeksa intenziteta munja korišteni su podatci o kiši, vjetru, tuči i pijavicama zabilježenima na području sjeveroistočnog Jadrana u razdoblju od 11 godina. Pritom su promatrana dva područja utjecaja (3 km i 15 km) za koje se radila usporedba. Dobiveni rezultati za kišu (područje utjecaja od 3 km) pokazuju vrlo dobro slaganje između traga indeksa TSII i visokih vrijednosti intenziteta kiše kao i ukupnih količina kiše. Usporedba

s vjetrom također je pokazala da su okruženja unutar velikog područja utjecaja koja su imala otisak TSII-ja bilježila znatno veće vrijednosti brzine vjetra, bez obzira radi li se o obalnoj ili o kopnenoj postaji. Tuča je također imala izraženu pozitivnu vezu s otiskom TSII-ja te je na području sjeveroistočnog Jadrana oko 68 % tuče povezano s TSII-jem unutar 15 km područja. U proširenoj analizi ustanovljeno je da je taj postotak i veći (oko 74 %), a ako se promatra samo topli dio godine ili jaki intenzitet tuče ti se postotci primiču ka vrijednosti od 90 %. Iako je dostupan relativno mali broj podataka o pojavi pijavica, i za njih je pokazano da se one češće javljaju unutar intenzivnog konvektivnog okruženja makar se značajan dio pijavica pojavljuje i bez prisustva munja. Time je potvrđeno da trag TSII-ja ukazuje na sustave i okruženja unutar kojih su mogući opasni, ali i ekstremni događaji.

Pomalo neočekivana dodatna primjena predložene metode je sposobnost detekcije lokalnih konvektivnih sustava koji mogu imati opasne učinke. Rezultati ukazuju da sustavi s tragom TSII-ja manjim od 90 km² također imaju izražene vrijednosti oborine, može ih se povezati s pojavom tuče i jakim udarima vjetra te nastaju u jednako nestabilnim atmosferskim uvjetima kao i ostali sustavi s većim tragom TSII-ja.

Prethodno verificirani trag TSII-ja predstavlja i novu podlogu za klimatološka istraživanja ekstremnog vremena pošto nudi prostornu sliku za razliku od točkastih opažanja s meteoroloških postaja. Također, za razliku od radara, domena na kojoj je moguće dobiti homogene podatke puno je veća jer su antene istog tipa za detekciju munja dostupne u velikom dijelu Europe (Betz i sur., 2009a). S toga se podloga TSII-ja može koristiti kao nadopunu opasnim pojavama za područja koja nisu obuhvaćena drugim tipovima mjerenja, verifikaciju opasnih pojava u modelima ili kao samostalan alat za ocjenu rizika od potencijalno opasnih pojava. Takva podloga po prvi puta je predstavljena u ovom radu, a metoda publicirana u članku Jelić i sur. (2021).

Identificirane su i dodatne mogućnosti ove metode. Prelazak s binarnog TSII-ja na realni sustav omogućio bi informaciju o amplitudi promjene (koja u tom slučaju može biti i negativna) pomoću čega bi se mogla vršiti i procjena trajanja intenzivnog sustava nad nekim područjem. Također, uključivanjem radarskih podataka dobio bi se dodatan izvor podataka za analizu kroz koju bi se moglo izolirati i pojedine ekstremne efekte. Za sada, iz klimatološke slike TSII-ja vidljivo je da postoji izražena prostorna struktura čestine pojavljivanja ekstremnog vremena nad promatranom domenom koja je u dobroj mjeri suglasna s dobivenom strukturom dana s tučom.

Nastavno na navedeno, važnost gustih i detaljnih mjerenja tuče ne može se dovoljno naglasiti. Opažena prostorna i vremenska obilježja tuče jasan su znak da se radi o izrazito

promjenjivoj pojavi. Najnovije tehnologije i znanja omogućavaju razvoj modeliranja i prognoziranja tuče (Adams-Selin i Ziegler, 2016; Brimelow i sur., 2002; Malečić i sur., 2022b). Za takva će istraživanja od iznimne važnosti biti upravo ovakve analize prostornih i vremenskih obilježja tuče kao i detaljniji i gušći izvori podataka. Za područja koja ih neće imati, kao što je to trenutno Bosna i Hercegovina, Crna gora, Albanija i druga područja na jugoistoku Europe (Punge i Kunz, 2016), TSII podloge predložene u ovom radu bit će jedini izvor podataka.

6 LITERATURA

- Adams-Selin, R.D., Ziegler, C.L., 2016. Forecasting Hail Using a One-Dimensional Hail Growth Model within WRF. *Monthly Weather Review* 144, 4919–4939. <https://doi.org/10.1175/MWR-D-16-0027.1>
- Allen, J.T., Giammanco, I.M., Kumjian, M.R., Jurgen Punge, H., Zhang, Q., Groenemeijer, P., Kunz, M., Ortega, K., 2020. Understanding Hail in the Earth System. *Rev. Geophys.* 58. <https://doi.org/10.1029/2019RG000665>
- Ávila, E.E., Bürgesser, R.E., Castellano, N.E., Collier, A.B., Compagnucci, R.H., Hughes, A.R.W., 2010. Correlations between deep convection and lightning activity on a global scale. *Journal of Atmospheric and Solar-Terrestrial Physics* 72, 1114–1121. <https://doi.org/10.1016/j.jastp.2010.07.019>
- Baldi, M., Ciardini, V., Dalu, J.D., De Filippis, T., Maracchi, G., Dalu, G., 2014. Hail occurrence in Italy: Towards a national database and climatology. *Atmospheric Research* 138, 268–277. <https://doi.org/10.1016/j.atmosres.2013.11.012>
- Belušić, A., Prtenjak, M.T., Güttler, I., Ban, N., Leutwyler, D., Schär, C., 2018. Near-surface wind variability over the broader Adriatic region: insights from an ensemble of regional climate models. *Clim Dyn* 50, 4455–4480. <https://doi.org/10.1007/s00382-017-3885-5>
- Belušić Vozila, A., 2018. Wind characteristics in the present and future climate obtained from regional climate models' simulations over broader Adriatic Region (PhD). University of Zagreb Faculty of Science (Department of Geophysics), Zagreb.
- Belušić Vozila, A., Telišman Prtenjak, M., Güttler, I., 2021. A Weather-Type Classification and Its Application to Near-Surface Wind Climate Change Projections over the Adriatic Region. *Atmosphere* 12, 948. <https://doi.org/10.3390/atmos12080948>
- Berthet, C., Dessens, J., Sanchez, J.L., 2011. Regional and yearly variations of hail frequency and intensity in France. *Atmospheric Research* 100, 391–400. <https://doi.org/10.1016/j.atmosres.2010.10.008>
- Betz, H.D., Schmidt, K., Laroche, P., Blanchet, P., Oettinger, W.P., Defer, E., Dziewit, Z., Konarski, J., 2009a. LINET—An international lightning detection network in Europe. *Atmospheric Research* 91, 564–573. <https://doi.org/10.1016/j.atmosres.2008.06.012>
- Betz, H.D., Schumann, U., Laroche, P. (Eds.), 2009b. *Lightning: principles, instruments and applications: review of modern lightning research*. Springer, Dordrecht.
- Bissolli, P., Dittmann, E., 2001. The objective weather type classification of the German Weather Service and its possibilities of application to environmental and meteorological investigations. *metz* 10, 253–260. <https://doi.org/10.1127/0941-2948/2001/0010-0253>
- Blašković, L., 2021. Obilježja tuče u priobalnom dijelu Jadrana. Prirodoslovno-matematički fakultet u Zagrebu. <https://www.bib.irb.hr/1153120>
- Blumberg, W.G., Halbert, K.T., Supinie, T.A., Marsh, P.T., Thompson, R.L., Hart, J.A., 2017. SHARPPy: An Open-Source Sounding Analysis Toolkit for the Atmospheric Sciences. *Bulletin of the American Meteorological Society* 98, 1625–1636. <https://doi.org/10.1175/BAMS-D-15-00309.1>
- Brimelow, J.C., Reuter, G.W., Poolman, E.R., 2002. Modeling Maximum Hail Size in Alberta Thunderstorms. *WEATHER AND FORECASTING* 17, 15.
- Brooks, H.E., Lee, J.W., Craven, J.P., 2003. The spatial distribution of severe thunderstorm and tornado environments from global reanalysis data. *Atmospheric Research* 67–68, 73–94. [https://doi.org/10.1016/S0169-8095\(03\)00045-0](https://doi.org/10.1016/S0169-8095(03)00045-0)

- Brown, T.M., Pogorzelski, W.H., Giammanco, I.M., 2015. Evaluating Hail Damage Using Property Insurance Claims Data. *Weather, Climate, and Society* 7, 197–210. <https://doi.org/10.1175/WCAS-D-15-0011.1>
- Burcea, S., Cică, R., Bojariu, R., 2016. Hail Climatology and Trends in Romania: 1961–2014. *Monthly Weather Review* 144, 4289–4299. <https://doi.org/10.1175/MWR-D-16-0126.1>
- Changnon, S., Changnon, D., Hilberg, S., 2009. Hailstorms Across the Nation: An Atlas about Hail and Its Damages. *Illinois State Water Survey* 101.
- Changnon, S.A., 1992. Temporal and Spatial Relations between Hail and Lightning. *Journal of Applied Meteorology and Climatology*, [https://doi.org/10.1175/1520-0450\(1992\)031<0587:TASRBH>2.0.CO;2](https://doi.org/10.1175/1520-0450(1992)031<0587:TASRBH>2.0.CO;2) 31, 587–604.
- Chronis, T., Carey, L.D., Schultz, C.J., Schultz, E.V., Calhoun, K.M., Goodman, S.J., 2015. Exploring Lightning Jump Characteristics. *Weather and Forecasting* 30, 23–37. <https://doi.org/10.1175/WAF-D-14-00064.1>
- Cipolla, G., Francipane, A., Noto, L.V., 2020. Classification of Extreme Rainfall for a Mediterranean Region by Means of Atmospheric Circulation Patterns and Reanalysis Data. *Water Resour Manage* 34, 3219–3235. <https://doi.org/10.1007/s11269-020-02609-1>
- Colin, J., Déqué, M., Radu, R., Somot, S., 2010. Sensitivity study of heavy precipitation in Limited Area Model climate simulations: influence of the size of the domain and the use of the spectral nudging technique. *Tellus A: Dynamic Meteorology and Oceanography* 62, 591–604. <https://doi.org/10.1111/j.1600-0870.2010.00467.x>
- Copernicus Climate Change Service (C3S), 2017. ERA5: Fifth generation of ECMWF atmospheric reanalyses of the global climate. Copernicus Climate Change Service Climate Data Store (CDS). <https://doi.org/25>. June 2020, <https://cds.climate.copernicus.eu/cdsapp#!/home>
- Ćurić, M., Janc, D., 2016. Hail climatology in Serbia: HAIL CLIMATOLOGY. *Int. J. Climatol.* 36, 3270–3279. <https://doi.org/10.1002/joc.4554>
- Dessens, J., 1986. Hailfall characteristics and hailstrom environment. *Journal of Climate and Applied Meteorology* 25, 35–47.
- Dufresne, J.-L., Foujols, M.-A., Denvil, S., Caubel, A., Marti, O., Aumont, O., Balkanski, Y., Bekki, S., Bellenger, H., Benshila, R., Bony, S., Bopp, L., Braconnot, P., Brockmann, P., Cadule, P., Cheruy, F., Codron, F., Cozic, A., Cugnet, D., de Noblet, N., Duvel, J.-P., Ethé, C., Fairhead, L., Fichefet, T., Flavoni, S., Friedlingstein, P., Grandpeix, J.-Y., Guez, L., Guilyardi, E., Hauglustaine, D., Hourdin, F., Idelkadi, A., Ghattas, J., Joussaume, S., Kageyama, M., Krinner, G., Labetoulle, S., Lahellec, A., Lefebvre, M.-P., Lefevre, F., Levy, C., Li, Z.X., Lloyd, J., Lott, F., Madec, G., Mancip, M., Marchand, M., Masson, S., Meurdesoif, Y., Mignot, J., Musat, I., Parouty, S., Polcher, J., Rio, C., Schulz, M., Swingedouw, D., Szopa, S., Talandier, C., Terray, P., Viovy, N., Vuichard, N., 2013. Climate change projections using the IPSL-CM5 Earth System Model: from CMIP3 to CMIP5. *Clim Dyn* 40, 2123–2165. <https://doi.org/10.1007/s00382-012-1636-1>
- Farnell, C., Rigo, T., Pineda, N., 2018. Exploring radar and lightning variables associated with the Lightning Jump. Can we predict the size of the hail? *Atmospheric Research* 202, 175–186. <https://doi.org/10.1016/j.atmosres.2017.11.019>
- Farnell, C., Rigo, T., Pineda, N., 2017. Lightning jump as a nowcast predictor: Application to severe weather events in Catalonia. *Atmospheric Research* 183, 130–141. <https://doi.org/10.1016/j.atmosres.2016.08.021>
- Franc, B., Uglešić, I., Piliškić, S., 2015. Lightning data utilization in power system control. *Journal of Energy* 64, 62–77.

- Gaál, L., Molnar, P., Szolgay, J., 2014. Selection of intense rainfall events based on intensity thresholds and lightning data in Switzerland. *Hydrol. Earth Syst. Sci.* 18, 1561–1573. <https://doi.org/10.5194/hess-18-1561-2014>
- Gajić-Čapka, M., Zaninović, K., 1993. VREMENSKE PROMJENE POJAVE TUČE I GRMLJAVINE NA PODRUČJU BJELOVARA, KRIŽEVACA I ČAZME. *Hrvatski meteorološki časopis* 28, 59–64.
- Galanaki, E., Lagouvardos, K., Kotroni, V., Flaounas, E., Argiriou, A., 2018. Thunderstorm climatology in the Mediterranean using cloud-to-ground lightning observations. *Atmospheric Research* 207, 136–144. <https://doi.org/10.1016/j.atmosres.2018.03.004>
- Gatlin, P.N., Goodman, S.J., 2010. A Total Lightning Trending Algorithm to Identify Severe Thunderstorms. *Journal of Atmospheric and Oceanic Technology* 27, 3–22. <https://doi.org/10.1175/2009JTECHA1286.1>
- Gilbert, R.O., 1987. *Statistical methods for environmental pollution monitoring*. Wiley, New York Chichester Weinheim.
- Giorgetta, M.A., Jungclaus, J., Reick, C.H., Legutke, S., Bader, J., Böttinger, M., Brovkin, V., Crueger, T., Esch, M., Fieg, K., Glushak, K., Gayler, V., Haak, H., Hollweg, H.-D., Ilyina, T., Kinne, S., Kornblueh, L., Matei, D., Mauritsen, T., Mikolajewicz, U., Mueller, W., Notz, D., Pithan, F., Raddatz, T., Rast, S., Redler, R., Roeckner, E., Schmidt, H., Schnur, R., Segschneider, J., Six, K.D., Stockhause, M., Timmreck, C., Wegner, J., Widmann, H., Wieners, K.-H., Claussen, M., Marotzke, J., Stevens, B., 2013. Climate and carbon cycle changes from 1850 to 2100 in MPI-ESM simulations for the Coupled Model Intercomparison Project phase 5: Climate Changes in MPI-ESM. *J. Adv. Model. Earth Syst.* 5, 572–597. <https://doi.org/10.1002/jame.20038>
- Grisogono, B., Belušić, D., 2009. A review of recent advances in understanding the meso- and microscale properties of the severe Bora wind. *Tellus A* 61, 1–16. <https://doi.org/10.1111/j.1600-0870.2008.00369.x>
- Hales, J.E., 1988. Improving the watch/warning system through the use of significant event data. Presented at the 15th Conf. on Severe Local Storms, Amer. Meteor. Soc., Baltimore, MD, pp. 165–168.
- Hand, W.H., Cappelluti, G., 2011. A global hail climatology using the UK Met Office convection diagnosis procedure (CDP) and model analyses: Global hail climatology. *Met. Apps* 18, 446–458. <https://doi.org/10.1002/met.236>
- Hayward, L., Whitworth, M., Pepin, N., Dorling, S., 2020. Review article: A comprehensive review of datasets and methodologies employed to produce thunderstorm climatologies. *Nat. Hazards Earth Syst. Sci.* 20.
- Hazeleger, W., Wang, X., Severijns, C., Ștefănescu, S., Bintanja, R., Sterl, A., Wyser, K., Semmler, T., Yang, S., van den Hurk, B., van Noije, T., van der Linden, E., van der Wiel, K., 2012. EC-Earth V2.2: description and validation of a new seamless earth system prediction model. *Clim Dyn* 39, 2611–2629. <https://doi.org/10.1007/s00382-011-1228-5>
- Hoeppe, P., 2016. Trends in weather related disasters – Consequences for insurers and society. *Weather and Climate Extremes* 11, 70–79. <https://doi.org/10.1016/j.wace.2015.10.002>
- Horvath, K., Lin, Y.-L., Ivančan-Picek, B., 2008. Classification of Cyclone Tracks over the Apennines and the Adriatic Sea. *Monthly Weather Review* 136, 2210–2227. <https://doi.org/10.1175/2007MWR2231.1>
- Houze, R.A., 2014. *Cloud dynamics*, International Geophysics Series. Academic Press, San Diego.

- Hu, Z.-Z., Wu, Z., 2004. The intensification and shift of the annual North Atlantic Oscillation in a global warming scenario simulation. *Tellus A: Dynamic Meteorology and Oceanography* 56, 112–124. <https://doi.org/10.3402/tellusa.v56i2.14403>
- Ivančan-Picek, B., Glasnović, D., Jurčec, V., 2003. Analysis and Aladin prediction of a heavy precipitation event on the Eastern side of the Alps during Map IOP 5. *metz* 12, 103–112. <https://doi.org/10.1127/0941-2948/2003/0012-0103>
- Jacob, D., Petersen, J., Eggert, B., Alias, A., Christensen, O.B., Bouwer, L.M., Braun, A., Colette, A., Déqué, M., Georgievski, G., Georgopoulou, E., Gobiet, A., Menut, L., Nikulin, G., Haensler, A., Hempelmann, N., Jones, C., Keuler, K., Kovats, S., Kröner, N., Kotlarski, S., Kriegsmann, A., Martin, E., van Meijgaard, E., Moseley, C., Pfeifer, S., Preuschmann, S., Radermacher, C., Radtke, K., Rechid, D., Rounsevell, M., Samuelsson, P., Somot, S., Soussana, J.-F., Teichmann, C., Valentini, R., Vautard, R., Weber, B., Yiou, P., 2014. EURO-CORDEX: new high-resolution climate change projections for European impact research. *Reg Environ Change* 14, 563–578. <https://doi.org/10.1007/s10113-013-0499-2>
- Jelić, D., Megyeri, O.A., Malečić, B., Belušić Vozila, A., Strelec Mahović, N., Telišman Prtenjak, M., 2020. Hail Climatology Along the Northeastern Adriatic. *J. Geophys. Res. Atmos.* 125. <https://doi.org/10.1029/2020JD032749>
- Jelić, D., Telišman Prtenjak, M., Malečić, B., Belušić Vozila, A., Megyeri, O.A., Renko, T., 2021. A New Approach for the Analysis of Deep Convective Events: Thunderstorm Intensity Index. *Atmosphere* 12, 908. <https://doi.org/10.3390/atmos12070908>
- Jugo, B., 1962. TUČA, NJENA ŠTETNOST ZA VOĆARSTVO I MOGUĆNOSTI SUZBIJANJA. *Agronomski glasnik* 12, 1141–1144.
- Kehler-Poljak, G., Telišman Prtenjak, M., Kvakić, M., Šariri, K., Večenaj, Ž., 2017. Interaction of Sea Breeze and Deep Convection over the Northeastern Adriatic Coast: An Analysis of Sensitivity Experiments Using a High-Resolution Mesoscale Model. *Pure Appl. Geophys.* 174, 4197–4224. <https://doi.org/10.1007/s00024-017-1607-x>
- Klingbeil, D.L., Smith, D.R., Wolfson, M.M., 1987. Gust Front Characteristics as Detected by Doppler Radar. *Monthly Weather Review* 115, 905–918. [https://doi.org/10.1175/1520-0493\(1987\)115<0905:GFCADB>2.0.CO;2](https://doi.org/10.1175/1520-0493(1987)115<0905:GFCADB>2.0.CO;2)
- Kotinis-Zambakas, S.R., 1989. Average spatial patterns of hail days in Greece. *Journal of Climate* 2, 508–511.
- Kunz, M., Blahak, U., Handwerker, J., Schmidberger, M., Punge, H.J., Mohr, S., Fluck, E., Bedka, K.M., 2018. The severe hailstorm in southwest Germany on 28 July 2013: characteristics, impacts and meteorological conditions: Severe Hailstorm in Southwest Germany. *Q.J.R. Meteorol. Soc.* 144, 231–250. <https://doi.org/10.1002/qj.3197>
- Lepore, C., Abernathy, R., Henderson, N., Allen, J.T., Tippet, M.K., 2021. Future Global Convective Environments in CMIP6 Models. *Earth's Future* 9. <https://doi.org/10.1029/2021EF002277>
- Li, H., Cui, X., Zhang, D.-L., 2017. On the Initiation of an Isolated Heavy-Rain-Producing Storm near the Central Urban Area of Beijing Metropolitan Region. *Monthly Weather Review* 145, 181–197. <https://doi.org/10.1175/MWR-D-16-0115.1>
- Lukach, M., Foresti, L., Giot, O., Delobbe, L., 2017. Estimating the occurrence and severity of hail based on 10 years of observations from weather radar in Belgium. *Meteorol. Appl.* 10.
- Malečić, B., Ruoi, C., Velasques, P., Jelić, D., Telišman Prtenjak, M., Horvath, K., Ban, N., Demory, M., D., Schär, C., 2022a. Simulating Hail and Lightning over the Alpine Adriatic Region – A model Intercomparison Study. *Journal of Geophysical Research: Atmospheres*: in review.

- Malečić, B., Telišman Prtenjak, M., Horvath, K., Jelić, D., Mikuš Jurković, P., Ćorko, K., Mahović, N.S., 2022b. Performance of HAILCAST and the Lightning Potential Index in simulating hailstorms in Croatia in a mesoscale model – Sensitivity to the PBL and microphysics parameterization schemes. *Atmospheric Research* 272, 106143. <https://doi.org/10.1016/j.atmosres.2022.106143>
- Manzato, A., 2013. Hail in Northeast Italy: A Neural Network Ensemble Forecast Using Sounding-Derived Indices. *Weather and Forecasting* 28, 3–28. <https://doi.org/10.1175/WAF-D-12-00034.1>
- Manzato, A., 2012. Hail in Northeast Italy: Climatology and Bivariate Analysis with the Sounding-Derived Indices. *Journal of Applied Meteorology and Climatology* 51, 449–467. <https://doi.org/10.1175/JAMC-D-10-05012.1>
- Manzato, A., Cicogna, A., Pucillo, A., 2016. 6-hour maximum rain in Friuli Venezia Giulia: Climatology and ECMWF-based forecasts. *Atmospheric Research* 169, 465–484. <https://doi.org/10.1016/j.atmosres.2015.07.013>
- Mazzetti, T.O., Fuelberg, H.E., 2017. An Analysis of Total Lightning Flash Rates Over Florida. *J. Geophys. Res. Atmos.* 122. <https://doi.org/10.1002/2017JD027579>
- Mecikalski, J.R., Rosenfeld, D., Manzato, A., 2016. Evaluation of geostationary satellite observations and the development of a 1-2 h prediction model for future storm intensity: Forecasting Storm Intensity. *J. Geophys. Res. Atmos.* 121, 6374–6392. <https://doi.org/10.1002/2016JD024768>
- Mikuš, P., Telišman Prtenjak, M., Strelec Mahović, N., 2012. Analysis of the convective activity and its synoptic background over Croatia. *Atmospheric Research* 104–105, 139–153. <https://doi.org/10.1016/j.atmosres.2011.09.016>
- Mohr, S., Kunz, M., Keuler, K., 2015. Development and application of a logistic model to estimate the past and future hail potential in Germany: LOGISTIC MODEL ESTIMATING HAIL POTENTIAL. *J. Geophys. Res. Atmos.* 120, 3939–3956. <https://doi.org/10.1002/2014JD022959>
- Mohr, S., Kunz, M., Richter, A., Ruck, B., 2017. Statistical characteristics of convective wind gusts in Germany. *Nat. Hazards Earth Syst. Sci.* 17, 957–969. <https://doi.org/10.5194/nhess-17-957-2017>
- Moss, R.H., Edmonds, J.A., Hibbard, K.A., Manning, M.R., Rose, S.K., van Vuuren, D.P., Carter, T.R., Emori, S., Kainuma, M., Kram, T., Meehl, G.A., Mitchell, J.F.B., Nakicenovic, N., Riahi, K., Smith, S.J., Stouffer, R.J., Thomson, A.M., Weyant, J.P., Wilbanks, T.J., 2010. The next generation of scenarios for climate change research and assessment. *Nature* 463, 747–756. <https://doi.org/10.1038/nature08823>
- Nisi, L., Martius, O., Hering, A., Kunz, M., Germann, U., 2016. Spatial and temporal distribution of hailstorms in the Alpine region: a long-term, high resolution, radar-based analysis: Spatial and Temporal Distribution of Hailstorms in the Alpine Region. *Q.J.R. Meteorol. Soc.* 142, 1590–1604. <https://doi.org/10.1002/qj.2771>
- Paškvan, R., 1955. TUČA I NJENA UČESTALOST U ISTRI I UŽEM PODRUČJU POREČA. *Agronomski glasnik* 5, 176–184. <https://hrcak.srce.hr/175940>
- Penzar, B., Penzar, I., Orlić, M., 2001. Weather and Climate of East Adriatic (in Croatian). Nakladna kuća Dr.Feletar 258.
- Perčec Tadić, M., Gajić-Čapka, M., Zaninović, K., Cindrić, K., 2014. Drought Vulnerability in Croatia. *Agriculturae Conspectus Scientificus* 79, 31–38.
- Philipp, A., Bartholy, J., Beck, C., Erpicum, M., Esteban, P., Fettweis, X., Huth, R., James, P., Jourdain, S., Kreienkamp, F., Krennert, T., Lykoudis, S., Michalides, S.C., Pianko-Kluczynska, K., Post, P., Álvarez, D.R., Schiemann, R., Spekat, A., Tymvios, F.S., 2010. Cost733cat – A database of weather and circulation type classifications. *Physics*

- and Chemistry of the Earth, Parts A/B/C 35, 360–373.
<https://doi.org/10.1016/j.pce.2009.12.010>
- Pineda, N., Bech, J., Rigo, T., Montanyà, J., 2011. A Mediterranean nocturnal heavy rainfall and tornadic event. Part II: Total lightning analysis. *Atmospheric Research* 100, 638–648. <https://doi.org/10.1016/j.atmosres.2010.10.027>
- Počakal, D., 2012. Energija zrna tuče u kontinentalnom dijelu hrvatske. Prirodoslovno-matematički fakultet Sveučilišta u Zagrebu.
https://www.bib.irb.hr/577197/download/577197.Energija_zrna_tuce_u_kontinentalnom_dijelu_Hrvatske.pdf
- Počakal, D., Štalec, J., 2003. Statistical analysis of hail characteristics in the hail-protected western part of Croatia using data from hail suppression stations. *Atmospheric Research* 67–68, 533–540. [https://doi.org/10.1016/S0169-8095\(03\)00071-1](https://doi.org/10.1016/S0169-8095(03)00071-1)
- Počakal, D., Večenaj, Ž., Mikuš Jurković, P., Grisogono, B., 2018. Analysis of orographic influence on hail parameters in NW Croatia. *Int J Climatol* 38, 5646–5658.
<https://doi.org/10.1002/joc.5769>
- Počakal, D., Večenaj, Ž., Štalec, J., 2009. Hail characteristics of different regions in continental part of Croatia based on influence of orography. *Atmospheric Research* 93, 516–525. <https://doi.org/10.1016/j.atmosres.2008.10.017>
- Poje, D., 1965. Glavni tipovi vremena u Jugoslaviji i njihova zavisnost o visinskim strujanjima, Doktorska disertacija.
- Poljak, G., Prtenjak, M.T., Kvakić, M., Strelec Mahović, N., Babić, K., 2014. Wind patterns associated with the development of daytime thunderstorms over Istria. *Ann. Geophys.* 32, 401–420. <https://doi.org/10.5194/angeo-32-401-2014>
- Pruppacher, H.R., Klett, J.D., 2010. *Microphysics of Cloud and Precipitation*. Kluwer Academic Publisher, Dordrecht.
- Púčik, T., Castellano, C., Groenemeijer, P., Kühne, T., Rädler, A.T., Antonescu, B., Faust, E., 2019. Large Hail Incidence and Its Economic and Societal Impacts across Europe. *Monthly Weather Review* 147, 3901–3916. <https://doi.org/10.1175/MWR-D-19-0204.1>
- Púčik, T., Groenemeijer, P., Rädler, A.T., Tijssen, L., Nikulin, G., Prein, A.F., van Meijgaard, E., Fealy, R., Jacob, D., Teichmann, C., 2017. Future Changes in European Severe Convection Environments in a Regional Climate Model Ensemble. *J. Climate* 30, 6771–6794. <https://doi.org/10.1175/JCLI-D-16-0777.1>
- Púčik, T., Groenemeijer, P., Rýva, D., Kolář, M., 2015. Proximity Soundings of Severe and Nonsevere Thunderstorms in Central Europe. *Monthly Weather Review* 143, 4805–4821. <https://doi.org/10.1175/MWR-D-15-0104.1>
- Punge, H.J., Bedka, K.M., Kunz, M., Reinbold, A., 2017. Hail frequency estimation across Europe based on a combination of overshooting top detections and the ERA-INTERIM reanalysis. *Atmospheric Research* 198, 34–43.
<https://doi.org/10.1016/j.atmosres.2017.07.025>
- Punge, H.J., Bedka, K.M., Kunz, M., Werner, A., 2014. A new physically based stochastic event catalog for hail in Europe. *Nat Hazards* 73, 1625–1645.
<https://doi.org/10.1007/s11069-014-1161-0>
- Punge, H.J., Kunz, M., 2016. Hail observations and hailstorm characteristics in Europe: A review. *Atmospheric Research* 176–177, 159–184.
<https://doi.org/10.1016/j.atmosres.2016.02.012>
- Rädler, A.T., Groenemeijer, P.H., Faust, E., Sausen, R., Púčik, T., 2019. Frequency of severe thunderstorms across Europe expected to increase in the 21st century due to rising instability. *npj Clim Atmos Sci* 2, 30. <https://doi.org/10.1038/s41612-019-0083-7>

- Raupach, T.H., Martius, O., Allen, J.T., Kunz, M., Lasher-Trapp, S., Mohr, S., Rasmussen, K.L., Trapp, R.J., Zhang, Q., 2021. The effects of climate change on hailstorms. *Nat Rev Earth Environ* 2, 213–226. <https://doi.org/10.1038/s43017-020-00133-9>
- Renko, T., Ivušić, S., Telišman Prtenjak, M., Šoljan, V., Horvat, I., 2018. Waterspout Forecasting Method Over the Eastern Adriatic Using a High-Resolution Numerical Weather Model. *Pure Appl. Geophys.* 175, 3759–3778. <https://doi.org/10.1007/s00024-018-1833-x>
- Renko, T., Kuzmić, J., Šoljan, V., Mahović, N.S., 2016. Waterspouts in the Eastern Adriatic from 2001 to 2013. *Nat Hazards* 82, 441–470. <https://doi.org/10.1007/s11069-016-2192-5>
- Rockel, B., Will, A., Hense, A., 2008. The Regional Climate Model COSMO-CLM (CCLM). *metz* 17, 347–348. <https://doi.org/10.1127/0941-2948/2008/0309>
- Samuelsson, P., Jones, C.G., Will'En, U., Ullerstig, A., Gollvik, S., Hansson, U., Jansson, E., Kjellström, C., Nikulin, G., Wyser, K., 2011. The Rossby Centre Regional Climate model RCA3: model description and performance. *Tellus A: Dynamic Meteorology and Oceanography* 63, 4–23. <https://doi.org/10.1111/j.1600-0870.2010.00478.x>
- Sánchez, J.L., Gil-Robles, B., Dessens, J., Martin, E., Lopez, L., Marcos, J.L., Berthet, C., Fernández, J.T., García-Ortega, E., 2009. Characterization of hailstone size spectra in hailpad networks in France, Spain, and Argentina. *Atmospheric Research* 93, 641–654. <https://doi.org/10.1016/j.atmosres.2008.09.033>
- Santos, J.A., Belo-Pereira, M., 2019. A comprehensive analysis of hail events in Portugal: Climatology and consistency with atmospheric circulation. *Int J Climatol* 39, 188–205. <https://doi.org/10.1002/joc.5794>
- Schultz, C.J., Petersen, W.A., Carey, L.D., 2011. Lightning and Severe Weather: A Comparison between Total and Cloud-to-Ground Lightning Trends. *WEATHER AND FORECASTING* 26, 12.
- Schultz, C.J., Petersen, W.A., Carey, L.D., 2009. Preliminary Development and Evaluation of Lightning Jump Algorithms for the Real-Time Detection of Severe Weather. *Journal of Applied Meteorology and Climatology* 48, 2543–2563. <https://doi.org/10.1175/2009JAMC2237.1>
- Seneviratne, S.I., Zhang, X., Adnan, M., Badi, W., Dereczynski, C., Luca, A.D., Ghosh, S., Iskandar, I., Kossin, J., Lewis, S., Otto, F., Pinto, I., Satoh, M., Vicente-Serrano, S.M., Wehner, M., Zhou, B., 2021. Weather and Climate Extreme Events in a Changing Climate, in: *Climate Change 2021: The Physical Science Basis: Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. pp. 1513–1766.
- Sioutas, M.V., Renko, T., Szilagyi, W., Keul, A.G., 2014. Waterspout climatology over the Central-Eastern Mediterranean, in: *COMECAP 2014, E-Book of Proceedings*. Presented at the 12 International Conference of Meteorology, Climatology and Atmospheric Physics, 12 International Conference of Meteorology, Climatology and Atmospheric Physics, Heraklion, Crete, Greece, pp. 154–158.
- Stipetić, N., Franc, B., Uglešić, I., Mesić, M., Ivanković, I., 2017. Improving lightning location system and advance control, maintenance and planning of transmission power system using lightning location system data. Presented at the International Colloquium on Lightning and Power Systems, Ljubljana.
- Stržinar, G., Skok, G., 2018. Comparison and optimization of radar-based hail detection algorithms in Slovenia. *Atmospheric Research* 203, 275–285. <https://doi.org/10.1016/j.atmosres.2018.01.005>

- Takahashi, T., 1978. Riming Electrification as a Charge Generation Mechanism in Thunderstorms. *Journal of Atmospheric Sciences* 35, 1536–1548.
[https://doi.org/10.1175/1520-0469\(1978\)035<1536:REAACG>2.0.CO;2](https://doi.org/10.1175/1520-0469(1978)035<1536:REAACG>2.0.CO;2)
- Taszarek, M., Brooks, H.E., Czernecki, B., Szuster, P., Fortuniak, K., 2018. Climatological Aspects of Convective Parameters over Europe: A Comparison of ERA-Interim and Sounding Data. *Journal of Climate* 31, 4281–4308. <https://doi.org/10.1175/JCLI-D-17-0596.1>
- Toreti, A., Giannakaki, P., Martius, O., 2016. Precipitation extremes in the Mediterranean region and associated upper-level synoptic-scale flow structures. *Clim Dyn* 47, 1925–1941. <https://doi.org/10.1007/s00382-015-2942-1>
- Tuovinen, J.-P., Punkka, A.-J., Rauhala, J., Hohti, H., Schultz, D.M., 2009. Climatology of Severe Hail in Finland: 1930–2006. *Mon. Wea. Rev.* 137, 2238–2249.
<https://doi.org/10.1175/2008MWR2707.1>
- Uglešić, I., Franc, B., Stipetić, N., 2018. Lightning stroke measurements, data verification and application in power systems. Presented at the VI Russian Conference on Lightning Protection, Saint Petersburg.
- Vinet, F., 2001. Climatology of hail in France. *Atmospheric Research* 56, 309–323.
[https://doi.org/10.1016/S0169-8095\(00\)00082-X](https://doi.org/10.1016/S0169-8095(00)00082-X)
- Visser, P.J., van Heerden, J., 2000. Comparisons of hail kinetic energy derived from radar reflectivity with crop damage reports over the eastern Free State 6.
- Voldoire, A., Sanchez-Gomez, E., Salas y Mélia, D., Decharme, B., Cassou, C., Sénési, S., Valcke, S., Beau, I., Alias, A., Chevallier, M., Déqué, M., Deshayes, J., Douville, H., Fernandez, E., Madec, G., Maisonnave, E., Moine, M.-P., Planton, S., Saint-Martin, D., Szopa, S., Tyteca, S., Alkama, R., Belamari, S., Braun, A., Coquart, L., Chauvin, F., 2013. The CNRM-CM5.1 global climate model: description and basic evaluation. *Clim Dyn* 40, 2091–2121. <https://doi.org/10.1007/s00382-011-1259-y>
- Wapler, K., 2017. The life-cycle of hailstorms: Lightning, radar reflectivity and rotation characteristics. *Atmospheric Research* 193, 60–72.
<https://doi.org/10.1016/j.atmosres.2017.04.009>
- Webb, J.D.C., Elsom, D.M., Meaden, G.T., 2009. Severe hailstorms in Britain and Ireland, a climatological survey and hazard assessment. *Atmospheric Research* 93, 587–606.
<https://doi.org/10.1016/j.atmosres.2008.10.034>
- Webb, J.D.C., Elsom, D.M., Reynolds, D.J., 2001. Climatology of severe hailstorms in Great Britain. *Atmospheric Research* 56, 291–308. [https://doi.org/10.1016/S0169-8095\(00\)00081-8](https://doi.org/10.1016/S0169-8095(00)00081-8)
- WMO, 2011. Manual on codes, international codes, volume I.1, part A — alphanumeric codes. Tech. Rep. WMO-No. 306.
- Yair, Y., Lynn, B., Price, C., Kotroni, V., Lagouvardos, K., Morin, E., Mugnai, A., Llasat, M. del C., 2010. Predicting the potential for lightning activity in Mediterranean storms based on the Weather Research and Forecasting (WRF) model dynamic and microphysical fields. *J. Geophys. Res.* 115, D04205.
<https://doi.org/10.1029/2008JD010868>
- Zhang, C., Zhang, Q., Wang, Y., 2008. Climatology of Hail in China: 1961–2005. *Journal of Applied Meteorology and Climatology* 47, 795–804.
<https://doi.org/10.1175/2007JAMC1603.1>

7 ŽIVOTOPIS

DAMJAN JELIĆ

Datum rođenja 21.01.1986.
Adresa A. Šenoe 66
10360 Zagreb
E-mail adresa djelic@gfz.hr
Telefon +385 92 1996 138
Nacionalnost Hrvat

Obrazovanje

2010 – 2013 magistar Fizike-Geofizike, Prirodoslovno-matematički fakultet, Zagreb
2005 – 2010 prvostupnik Geofizike, Prirodoslovno-matematički fakultet, Zagreb

Radna iskustva

8.5.2019. – 30.11.2022. **Severe Weather over the Alpine-Adriatic region in a Changing Climate (SWALDRIC)**
Geofizički odsjek Prirodoslovno-matematičkog fakulteta Sveučilište u Zagrebu
Cilj projekta je bolje razumijevanje olujnih vremenskih pojava, evaluacija njihove reprezentacije u vremenskim i klimatskim modelima i istraživanje njihovog odgovora na klimatske promjene. Glavne odgovornosti su dizajn i provedba istraživanja tuče i munja, izrada baza podataka o tuči i munjama, asistiranje u nastavi (2 kolegija 3. godina prediplomskog studija) te sumentorstvo na diplomskom radu
Asistent

02.05.2017. - 31.03.2019. **Vinogradarstvo i klimatske promjene na području Hrvatske (VITCLIC),** *Geofizički odsjek Prirodoslovno-matematičkog fakulteta Sveučilište u Zagrebu*
Cilj projekta je analiza utjecaja vremena, klime i klimatskih promjena na kvalitetu vina i vinove loze u Hrvatskoj. Glavni zadaci su bili analiza vremenskih nizova tuče i munja pa području Istarske županije te postavljanje mreže tučomjernih postaja.
Suradnik na projektu

01.03.2014 - 31.12.2016. **Modal analysis of atmospheric balance, predictability and climate (MODES),** *University of Ljubljana, Slovenia. (ERC funded project, PE10, ERC-2011-StG) <http://meteo.fmf.uni-lj.si/MODES/>*
Glavni ciljevi projekta bili su finalni razvoj MODES softvera te dijagnoza inercijalno-gravitacijskih valova u globalnim meteorološkim modelima.
Kao suradnik, glavne odgovornosti bile su: izvođenje dijagnoza na globalnim modelima (MPI-ESM, EC-EARTH, CNRM-CM5, CCSM4, GFDL-CM3, MIROC5), testiranje i unaprjeđenje softvera te vizualizacija rezultata, pisanje korisničkog priručnika te podrška korisnicima.
Znanstveni programer-istraživač

Volonterski rad

2006 – 2014 Član i voditelj projekta Fizika Ekspres, Hrvatsko fizikalno društvo, Zagreb
2008 – 2015 Mentor i suorganizator na projektu Ljetna Tvornica Znanosti, Mediteranski institut za istraživanje života, Split

Osobne vještine i kompetencije

Kompjutorske vještine i kompetencije

- vrlo dobar u radu s velikim skupovima meteoroloških podataka i formata (NETCDF, GRIB, BIN, TXT)
- vrlo dobar u statističkoj obradi podataka
- vrlo dobar u poznavanju programskog paketa MATLAB i NCL (paketi za matematičko programiranje, obradu i vizualizaciju)
- dobro poznavanje programskog jezika Fortran F90
- dobro poznavanje baze podataka CMIP5 te rad s reanalizama ERAI, MERRA i JRA
- aktivno korištenje pomoćnih alata za manipulaciju podataka i automatizaciju (CDO, Panoply, BASH)
- aktivno korištenje operativnog sustava LINUX
- dobro poznavanje i korištenje MS Windows i MS Office alata

Socijalne vještine i kompetencije

- sposobnost razvoja interdisciplinarne i internacionalne suradnje radi ostvarenja zajedničkih ciljeva razvijene za vrijeme rada na projektima MODES i Ljetna Tvornica Znanosti
- jake komunikacijske i prezentacijske vještine stečene sudjelovanjem na konferencijama i radionicama te kroz rad na projektima MODES, Fizika Ekspres i Ljetna Tvornica Znanosti
- iskustva u samostalnom radu, radu u grupi te radu u lančanoj strukturi na svim pozicijama
- sposobnost aktivnog slušanja i poticanja rasprave
- sposobnost sintetiziranja bitnih informacija
- sposobnost izražavanja rječnikom slušatelja
- sposobnost davanja povratnih informacija
- sposobnost rješavanja sukoba s pozitivnim ishodom

Organizacijske vještine i kompetencije

- sposobnosti organiziranja i upravljanja razvijene za vrijeme rada na projektima Fizika Ekspres i Ljetna Tvornica Znanosti
- iskustvo u organizaciji radionica, predavanja, sastanaka, konferencija i javnih događanja
- sposoban inicirati, ali i preuzeti inicijativu
- sposoban prilagoditi se i učiti iz novonastale situacije

Jezici

Odličan	Engleski
Vrlo dobar	Slovenski
Slab	Njemački

Znanstveni doprinosi

Radovi u časopisima

Znanstveni i pregledni radovi

Malečić, Barbara; Telišman Prtenjak, Maja; Horvath, Kristian; **Jelić, Damjan**; Mikuš Jurković, Petra; Ćorko, Karol; Strelec Mahović, Nataša
Performance of HAILCAST and the Lightning Potential Index in simulating hailstorms in Croatia in a mesoscale model – Sensitivity to the PBL and microphysics parameterization schemes. // Atmospheric research (2022) doi:10.1016/j.atmosres.2022.106143
(međunarodna recenzija, prihvaćen)

- Jelić, Damjan**; Telišman Prtenjak, Maja; Malečić, Barbara; Belušić Vozila, Andreina; Megyeri, Otília Anna; Renko, Tanja
A new approach for the analysis of deep convective events: Thunderstorm Intensity Index. // Atmosphere, 12 (2021), 7; 908, 28 doi:10.3390/atmos12070908 (međunarodna recenzija, članak, znanstveni)
- Anić, Marina; Osrečak, Mirela; Andabaka, Željko; Tomaz, Ivana; Večenaj, Željko; **Jelić, Damjan**; Kozina, Bernard; Karoglan Kontić, Jasminka; Karoglan, Marko
The effect of leaf removal on canopy microclimate, vine performance and grape phenolic composition of Merlot (*Vitis vinifera* L.) grapes in the continental part of Croatia. // Scientia horticulturae, 285 (2021), 110161, 8 doi:10.1016/j.scienta.2021.110161 (međunarodna recenzija, članak, znanstveni)
- Jelić, Damjan**; Megyeri, Otília Anna; Malečić, Barbara; Belušić Vozila, Andreina; Strelec Mahović, Nataša; Telišman Prtenjak, Maja
Hail climatology along the northeastern Adriatic. // Journal of geophysical research. Atmospheres, 125 (2020), 23; e2020JD032749, 17 doi:10.1029/2020JD032749 (međunarodna recenzija, članak, znanstveni)
- Franzke, Christian L. E.; **Jelić, Damjan**; Lee, Sukyoung; Feldstein, Steven B.
Systematic decomposition of the MJO and its Northern Hemispheric extratropical response into Rossby and inertio-gravity components. // Quarterly Journal of the Royal Meteorological Society, 145 (2019), 720; 1147-1164 doi:10.1002/qj.3484 (međunarodna recenzija, članak, znanstveni)
- Dörnbrack, Andreas; Gisinger, Sonja; Kaifler, Natalie; Portele, Tanja Christina; Bramberger, Martina; Rapp, Markus; Gerding, Michale; Söder, Jens; Žagar, Nedjeljka; and **Jelić, Damjan**
Gravity waves excited during a minor sudden stratospheric warming // Atmospheric chemistry and physics, 18 (2018), 17; 12915-12931 doi:10.5194/acp-18-12915-2018 (međunarodna recenzija, članak, znanstveni)
- Žagar, Nedjeljka; **Jelić, Damjan**; Alexander, M. J.; Manzini, E.
Estimating Subseasonal Variability and Trends in Global Atmosphere Using Reanalysis Data. // Geophysical research letters, 45 (2018), 23; 12, 999-13, 007 doi:10.1029/2018gl080051 (međunarodna recenzija, članak, znanstveni)
- Žagar, Nedjeljka; **Jelić, Damjan**; Blaauw, Marten; and Bechtold, Peter
Energy Spectra and Inertia–Gravity Waves in Global Analyses. // Journal of the atmospheric sciences, 74 (2017), 8; 2447-2466 (međunarodna recenzija, članak, znanstveni)

Radovi u zbornicima skupova

Znanstveni radovi u zbornicima skupova

Karoglan, Marko; Telišman Prtenjak, Maja; Šimon, Silvio; Osrečak, Mirela; Karoglan Kontić, Jasminka; Andabaka, Željko; Tomaz, Ivana; Grisogono, Branko; Belušić, Andreina; Marki, Antun; Prša, Željka; Omazić, Branimir; **Jelić, Damjan**; et al.

Within-vineyard temperature variability in the Jazbina hills of Croatia. // Proceedings of 54th Croatian & 14th International Symposium on Agriculture / Boro Mioč, Ivan Širić (ur.).

Zagreb: Grafomark d.o.o., Zagreb, 2019. str. 541-545. (<https://www.bib.irb.hr/1003991>) (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

Karoglan, Marko; Telišman Prtenjak, Maja; Šimon, Silvio; Osrečak, Mirela; Anić, Marina; Karoglan Kontić, Jasminka; Andabaka, Željko; Tomaz, Ivana; Grisogono, Branko; Belušić, Andreina; Marki, Antun; Prša, Željka; Omazić, Branimir; **Jelić, Damjan**; et al.

Classification of Croatian winegrowing regions based on bioclimatic indices. // E3S Web of Conferences 50, 01032 XII Congreso Internacional Terroir

Zaragoza: Sociedad Aragonesa de Gestión Agroambiental, 2018. str. 1-5

doi:10.1051/e3sconf/20185001032 XII (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

Sažeci sa skupova

Sažeci u zbornicima i časopisima

Jelić, Damjan; Telišman Prtenjak, Maja; Malečić, Barbara; Renko, Tanja

INTRODUCTION TO NEW THUNDERSTORM INTENSITY INDEX (TSII). // Knjiga sažetaka, MI8 Zagreb, Hrvatska, 2022. str. 24-24 (predavanje, sažetak, znanstveni)

Telišman Prtenjak, Maja; Karoglan, Marko; Šimon, Silvio; Kordej-De Villa, Željka; Grisogono, Branko; Belušić, Andreina; Večenaj, Željko; Marki, Antun; **Jelić, Damjan**; Omazić, Branimir et al.

VITCLIC project. // EMS Annual Meeting: European Conference for Applied Meteorology and Climatology 2017

Dublin, Irska, 2017. str. 1-1 (predavanje, međunarodna recenzija, sažetak, znanstveni)

Druga sudjelovanja na skupovima

Blašković, Lucija; **Jelić, Damjan**; Malečić, Barbara; Omazić, Branimir; Telišman Prtenjak, Maja

Characteristics of hail in the Croatian coastal part of the Adriatic. // European Geosciences Union

Beč, Austrija, 2022. (predavanje, međunarodna recenzija, neobjavljeni rad, znanstveni)

Blašković, Lucija; **Jelić, Damjan**; Malečić, Barbara; Omazić, Branimir; Telišman Prtenjak, Maja

Characteristics of hail on the Croatian Adriatic coast. // Meteorološki izazovi 8 - Zrak koji udišemo zrak, koji prognoziramo / Challenges in meteorology 8 - The air we breathe, the air we forecast

Zagreb, Hrvatska, 2022. str. 1-1 (predavanje, domaća recenzija, sažetak, znanstveni)

Malečić, Barbara; Cui, Ruoyi; **Jelić, Damjan**; Telišman Prtenjak, Maja; Horvath, Kristian; Ban, Nikolina; Demory, Marie-Estelle; Mikuš Jurković, Petra; Strelec Mahović, Nataša; Schär, Christoph

Convection-permitting simulations of hailstorms and lightning activity over the Alpine-Adriatic region using COSMO and WRF models. // Meteorološki izazovi 8

Zagreb, Hrvatska, 2022. (predavanje, međunarodna recenzija, neobjavljeni rad, znanstveni)

Malečić, Barbara; Cui, Ruoyi; **Jelić, Damjan**; Horvath, Kristian; Telišman Prtenjak, Maja; Ban, Nikolina; Demory, Marie-Estelle; Mikuš Jurković, Petra; Strelec Mahović, Nataša; Schär, Christoph

Performance of HAILCAST and lightning potential index coupled with WRF and COSMO in convection-permitting simulations of hailstorms over the Alpine-Adriatic region. // European Geophysical Union General Assembly 2022

Beč, Austrija, 2022. (predavanje, međunarodna recenzija, neobjavljeni rad, znanstveni)

Malečić, Barbara; **Jelić, Damjan**; Telišman Prtenjak, Maja; Horvath, Kristian; Strelec Mahović, Nataša; Mikuš Jurković, Petra

Lightning Potential Index performance in convection-permitting simulations of hail events in Croatia – sensitivity to microphysics and PBL schemes. // 8th International Conference on Meteorology and Climatology of the Mediterranean

Virtualno, 2021. (predavanje, neobjavljeni rad, znanstveni)

Jelić, Damjan; Malečić, Barbara; Telišman Prtenjak, Maja; Renko, Tanja; Megyeri, Otilia Anna; Belušić Vozila, Andreina

Potential uses of new Thunderstorm Intensity Index. // 3rd European Hail Workshop / na. (ur.).

Online skup (njemačka), 2021. na., 1 (poster, neobjavljeni rad, znanstveni)

Malečić, Barbara; **Jelić, Damjan**; Horvath, Kristian; Strelec Mahović, Nataša; Mikuš Jurković, Petra; Babić, Karmen; Telišman Prtenjak, Maja

Performance of HAILCAST and Lightning Potential Index in simulating hail events over Croatia – sensitivity to microphysics and PBL parameterization schemes. // 3rd European Hail Workshop

Karlsruhe, Njemačka, 2021. (predavanje, međunarodna recenzija, pp prezentacija, ostalo)

Jelić, Damjan; Malečić, Barbara; Telišman Prtenjak, Maja; Belušić Vozila, Andreina; Renko, Tanja; Megyeri, Otilia Anna

Inspection of new thunderstorm intensity index. // EGU General Assembly 2021

Beč, 2021. EGU21-16163, 1 (poster, međunarodna recenzija, sažetak, znanstveni)

Malečić, Barbara.; **Jelić, Damjan**; Horvath, Kristian; Strelec Mahović, Nataša; Mikuš Jurković, Petra; Babić, Karmen; Telišman Prtenjak, Maja

Application of the WRF-HAILCAST model to the Croatian area – sensitivity to PBL schemes. // Meteorološki izazovi 7

Zagreb, Hrvatska, 2020. (predavanje, domaća recenzija, pp prezentacija, znanstveni)

Jelić, Damjan; Malečić, Barbara; Vodarić Šurića, Barbara; Mikuš Jurković, Petra; Telišman Prtenjak, Maja; Strelec Mahović, Nataša

Estimation of hail occurrence from satellite, lightning and radar data in Croatia. // EGU 2020 Beč, Austrija, 2020. str. 1-1 (predavanje, međunarodna recenzija, sažetak, znanstveni)

Malečić, Barbara; **Jelić, Damjan**; Horvath, Kristian; Babić, Karmen; Telišman Prtenjak, Maja; Strelec Mahović, Nataša Petra Mikuš Jurković

Simulation of hail events with the WRF - HAILCAST model - sensitivity to microphysics and PBL parameterization schemes. // EGU 2020

Beč, Austrija, 2020. str. 1-1 (predavanje, međunarodna recenzija, sažetak, znanstveni)

Damjan Jelić, Barbara Malečić, Barbara Vodarić Šurića, Maja Telišman Prtenjak

Estimation of hail using lightning vs radar data, Case study of 25 June 2017. // Meteorološki izazovi 7

Zagreb, Hrvatska, 2020. (predavanje, neobjavljeni rad, znanstveni)

Jelić, Damjan; Megyeri, Otília Anna; Belušić Vozila, Andreina; Telišman Prtenjak, Maja

Hail climatology along northeastern Adriatic and corresponding weather types. // FIMO-CROHUN & VITCLIC WORKSHOP

Čigoč, Croatia, 2019. str. 1-1

doi:https://www.pmf.unizg.hr/_news/44059/Program_FIMOCROHUN_Workshop_final.pdf
(predavanje, sažetak, znanstveni)

Schär, Christoph; Telišman Prtenjak, Maja; Fuhrer, Oliver; Grisogono, Branko; Strelec Mahović, Nataša; Ban, Nikolina; Güttler, Ivan; Horvath, Kristian; Večenaj, Željko; Babić, Karmen **et al.**

The SWALDRIC project. // 5th PannEx Workshop

Novi Sad, Srbija, 2019. (poster, međunarodna recenzija, neobjavljeni rad, znanstveni)

Ćorko, Karol; Malečić, Barbara; **Jelić, Damjan**; Horvath, Kristian; Strelec Mahović, Nataša; Mikuš Jurković, Petra; Telišman Prtenjak, Maja

Analysis of modeled hail parameters obtained by numerical mesoscale WRF-HAILCAST model. // The EMS Annual Meeting 2019

Kopenhagen, Danska, 2019. str. 1-1 (poster, međunarodna recenzija, sažetak, znanstveni)

Omazić, Branimir; Telišman Prtenjak, Maja; Belušić Vozila, Andreina; Prša, Ivan; Vučetić, Višnjica; Karoglan, Marko; Karoglan Kontić, Jasminka; Prša, Željka; **Jelić, Damjan**; Güttler, Ivan

Climate change impacts on the viticulture in Croatia ; viticultural zoning and future potential. // The EMS Annual Meeting 2019

Kopenhagen, Danska, 2019. str. 1-1 (predavanje, međunarodna recenzija, sažetak, znanstveni)

Jelić, Damjan; Telišman Prtenjak, Maja; Skok, Gregor; Malečić, Barbara

Capabilities of Eulerian based lightning jump algorithm. // 10th European Conference on Severe Storms

Krakov, Poljska, 2019. (poster, neobjavljeni rad, znanstveni)

Malečić, Barbara; Ćorko, Karol; **Jelić, Damjan**; Horvath, Kristian; Strelec Mahović, Nataša; Mikuš Jurković, Petra; Telišman Prtenjak, Maja
Analysis of the WRF-HAILCAST model applied to the Croatian area. // European Conference on Severe Storms
Krakov, Poljska, 2019. (poster, međunarodna recenzija, neobjavljeni rad, znanstveni)

Jelić, Damjan; Megyeri, Otília Anna; Belušić, Andreina; Telišman Prtenjak, Maja
New perspectives and applications of lightning jump. // EMS Annual Meeting: European Conference for Applied Meteorology and Climatology 2018 ; Weather and climate: global change and local hazards
Budimpešta, Mađarska, 2018. str. 1-1 (poster, međunarodna recenzija, sažetak, znanstveni)

Belušić, Andreina; Güttler, Ivan; Ahrens, Bodo; Obermann-Hellhund, Anika; **Jelić, Damjan**; Megyeri, Otília Anna; Telišman Prtenjak, Maja
The relationship between wind and pressure fields over the broader Adriatic Region in CORDEX Climate Change Scenarios. // EMS Annual Meeting: European Conference for Applied Meteorology and Climatology 2018 ; Weather and climate: global change and local hazards
Budimpešta, Mađarska, 2018. str. EMS2018-10 (predavanje, međunarodna recenzija, sažetak, znanstveni)

Jelić, Damjan; Megyeri, Otília Anna; Belušić, Andreina; Telišman Prtenjak, Maja
Lightning data as proxy for hail detection. // Challenges in meteorology 6/Meteorološki izazovi 6
Zagreb, Hrvatska, 2018. str. 21-21 (predavanje, domaća recenzija, sažetak, znanstveni)

Jelić, Damjan; Megyeri, Otília Anna; Belušić, Andreina; Telišman Prtenjak, Maja
The spatial and temporal hail characteristics over Croatia with a particular focus on Istria region. // Challenges in meteorology 6/Meteorološki izazovi 6
Zagreb, Hrvatska, 2018. str. 23-23 (predavanje, domaća recenzija, sažetak, znanstveni)

Jelić, Damjan; Megyeri, Otília Anna; Belušić Andreina; Telišman Prtenjak, Maja
Hail climatology and lightning jump climatology along northeastern Adriatic region with accompanying weather types. // EMS Annual Meeting: European Conference for Applied Meteorology and Climatology 2018 ; Weather and climate: global change and local hazards
Budimpešta, Mađarska, 2018. str. 1-1 (predavanje, međunarodna recenzija, sažetak, znanstveni)