



Sveučilište u Zagrebu
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

Jaša Čalogović

UTJECAJ SUNČEVE AKTIVNOSTI NA ZEMLJIN SVEMIRSKI OKOLIŠ I KLIMU

DOKTORSKI RAD

Zagreb, 2014.



University of Zagreb
FACULTY OF SCIENCE
DEPARTMENT OF GEOPHYSICS

Jaša Čalogović

INFLUENCE OF SOLAR ACTIVITY ON EARTH'S SPACE ENVIRONMENT AND CLIMATE

DOCTORAL THESIS

Zagreb, 2014.



Sveučilište u Zagrebu
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

Jaša Čalogović

UTJECAJ SUNČEVE AKTIVNOSTI NA ZEMLJIN SVEMIRSKI OKOLIŠ I KLIMU

DOKTORSKI RAD

Mentor: dr. sc. Bojan Vršnak

Zagreb, 2014.



University of Zagreb
FACULTY OF SCIENCE
DEPARTMENT OF GEOPHYSICS

Jaša Čalogović

INFLUENCE OF SOLAR ACTIVITY ON EARTH'S SPACE ENVIRONMENT AND CLIMATE

DOCTORAL THESIS

Supervisor: dr. sc. Bojan Vršnak

Zagreb, 2014.

Informacije o mentoru

Bojan Vršnak, zaposlen je na Opservatoriju Hvar Geodetskog fakulteta Sveučilišta u Zagrebu od 1981. g. Diplomirao je teorijsku fiziku na Prirodoslovno-matematičkom fakultetu u Zagrebu 1980. g., magistrirao u području atomske i molekularne fizike 1983. g., te doktorirao u području astrofizike (fizika Sunca) 1987.g. Godine 2000. izabran je u trajno zvanje znanstvenog savjetnika.

Osnovno područje njegova znanstvenog istraživanja je Sunčeva aktivnost, a posebice eruptivni procesi u Sunčevoj atmosferi, njihovo djelovanje na heliosferu i utjecaj na Zemljinu magnetosferu. Objavio je više od 300 znanstvenih radova i priopćenja (od kojih 141 u međunarodnim časopisima indeksiranim u "Current Contents", CC), koji su citirani više od 3700 puta. Objavio je sveučilišni udžbenik "Temelji fizike plazme", tri vježbenice/udžbenika iz astronomije za osnovne i srednje škole, trinaest poglavlja u raznim knjigama, te veći broj znanstveno-popularnih članaka.

Bojan Vršnak održava nastavu iz dva kolegija na poslijediplomskom studiju fizike na Prirodoslovno-matematičkom fakultetu (PMF) u Zagrebu. Održavao je nastavu na dodiplomskom studiju PMF-a, a u dva navrata također je bio gostujući profesor na Karl-Franzens Universitaet Graz. Mentorirao je veći broj studenata u izradi diplomskih, magistarskih i doktorskih radnji. Do sada je bio recenzent gotovo stotinu znanstvenih članaka u raznim međunarodnim CC-časopisima, te recenzent većeg broja inozemnih znanstvenih projekata. Član je uredništva CC/SCI znanstvenog časopisa "Solar Physics" (Kluwer), SCI znanstvenog časopisa "The Scientific World Journal" (Hindawi), znanstvenog časopisa "Central European Astrophysical Bulletin", te znanstveno-popularnih časopisa "Čovjek i svemir" i "Bolid". Član je udruga "International Astronomical Union", "European Astronomical Society", Hrvatskoga Astronomskog Društva i Hrvatskoga Fizikalnog Društva.

Hvala mojem mentoru i prijatelju, dr. sc. Bojanu Vršnaku na brojnim stručnim savjetima, potpori i pomoći svih proteklih godina. Posebno cijenim slobodu u istraživačkom radu i motivirajuća putovanja, koje mi je omogućio.

Zahvaljujem svim ostalim djelatnicima Opservatorija Hvar, s kojima je ugodno raditi i družiti se.

Zahvaljujem dr. sc. Benjaminu Lakenu na odličnoj suradnji i zanimljivim diskusijama.

Zahvaljujem svim dragim ljudima i prijateljima koji su me motivirali i davali mi podršku u mom znanstvenom radu.

Posebno hvala mojim roditeljima na velikoj potpori i ljubavi.

Sažetak

Sunčeva aktivnost, koja se manifestira u pojavama kao što su Sunčeve pjege, Sunčevi bljeskovi, ili koronini izbačaji mase, može snažno utjecati na Zemljin svemirski okoliš i atmosferu. Stoga je proučavanje, razumijevanje i predviđanje takvih pojava od važnosti za čovjeka.

Koronini izbačaji mase mogu izazvati dalekosežne posljedice za mnoge ljudske tehnologije i djelatnosti (npr. telekomunikacije, opskrba električnom energijom) te ih je korisno predvidjeti. S tom svrhom razvijen je analitički model magnetohidrodinamičkoga otpora, koji omogućava brz i jednostavan izračun dolaska međuplanetarnih koroninih izbačaja sa Sunca na Zemlju. Konačna implementacija modela izvršena je u obliku javnoga prognostičkog sučelja na internetu.

Također je proučavana povezanost koroninih izbačaja mase i korotirajućih interakcijskih područja s kratkoročnim promjenama u toku kozmičkoga zračenja (tzv. Forbushevih smanjenjima). Utvrđeno je da su smanjenja toka kozmičkoga zračenja najviše povezana s povećanjima u jakosti međuplanetarnoga magnetskog polja i njegovim fluktuacijama.

Nadalje, detaljno je ispitana hipoteza o utjecaju kozmičkoga zračenja na naoblaku, koja zaokuplja mnoge znanstvenike. Usprkos brojnim dugoročnim i kratkoročnim analizama, ta hipoteza do sada nije pouzdano empirijski potvrđena. U ovome radu razmotreni su mogući razlozi: i) ne postoji veza između kozmičkoga zračenja i naoblake, ii) drugi Sunčevi parametri (npr. ukupno Sunčevo zračenje) mogu utjecati na rezultate, iii) veza postoji, ali je taj utjecaj premalen da bi bio detektiran u postojećim podacima za naoblaku.

Korelacije između efektivne atmosferske ionizacije uzrokovane kozmičkim zračenjem i satelitskih podataka o globalnoj naoblaci za vrijeme šest Forbushevih smanjenja nisu bile značajne tijekom perioda posmaka od 10 dana. Analizom naoblake na različitim visinama (niski, srednji i visoki sloj) i u različitim područjima (različite geografske širine ili područja iznad kopna odnosno oceana) također nisu dobivene značajne korelacije.

Primjenom tzv. kompozitne analize, metode koja se odlikuje svojstvom odvajanja malog signala od šuma, nisu također uočene značajnije promjene u naoblaci koje bi bile uzrokovane varijacijama ukupnog Sunčeva zračenja, kozmičkoga zračenja i ultraljubičastoga Sunčeva zračenja. Stoga, ukupno i ultraljubičasto Sunčevo zračenje ne ometaju detekciju utjecaja kozmičkoga zračenja na naoblaku.

Korištenjem dnevnog raspona temperatura zraka na površini Zemlje kao indirektnog podatka za naoblaku može se analizirati duže vremensko razdoblje u odnosu na razdoblje dostupnosti satelitskih podataka. Kompozitna analiza tih podataka, koja je obuhvatila 267 Forbushevih smanjenja (uključujući 29 događaja sa smanjenjem intenziteta u toku kozmičkoga zračenja većim od 7%) nije ukazala na značajne promjene u naoblaci koje bi bile povezane s promjenama u toku kozmičkoga zračenja.

Primjenom podobnih metoda obrade podataka i konstrukcije kompozita te Monte Carlo metode za pouzdanu provjeru statističke značajnosti, razmotreni su mogući razlozi proturječnih rezultata objavljenih radova kao i mogući izvori pogrešaka. Utvrđeno je da su glavni uzroci za proturječnost rezultata neprimjerene statističke provjere i metodološke razlike u analizi kompozita. Korisnici podataka o naoblaci često ne posjeduju dovoljno informacija, npr. o detekcijskim i kalibracijskim pogreškama tih podataka. Analize takvih podataka karakteriziraju izražene autokorelacije, što ima bitne implikacije u određivanju statističke pouzdanosti.

Kratkoročne i dugoročne analize ne pružaju uvjerljiv dokaz koji podržava hipotezu utjecaja kozmičkoga zračenja na naoblaku. Utjecaj kozmičkoga zračenja na naoblaku se ne može potpuno isključiti na lokalnoj i regionalnoj razini, ali ako postoji, onda je vrlo malen i prekriven sinoptičkim šumom u naoblaci. Iz toga se može polučiti zaključak da kozmičko zračenje globalno ne utječe na naoblaku te da nije uzrok većim promjenama klime ili današnjem globalnom zatopljenju.

Ključne riječi: Sunce – Sunčeva aktivnost – koronini izbačaji mase (CME) – korotirajuća interakcijska područja (CIR) – kozmičko zračenje – Forbusheva smanjenja – naoblaka – atmosferska ionizacija – klima – satelitski podaci o naoblaci – statističke metode

Abstract

Solar activity exhibits various phenomena such as sunspots, solar flares or coronal mass ejections, all of them strongly influencing the Earth's space environment and atmosphere. Hence, the research, understanding and prediction of such phenomena are important for mankind.

Coronal mass ejections may cause serious consequences for many aspects of human technologies and activities (e.g. telecommunications, electricity supply) reinforcing the need to predict such events. For this purpose magnetohydrodynamic drag model was developed, allowing fast and simple calculation of the interplanetary coronal mass ejections transit times from Sun to Earth. The final model implementation has been provided in the form of a public online forecast tool.

Moreover, the relationship between coronal mass ejections as well as corotating interaction regions and short term changes in the cosmic ray flux (so-called Forbush decreases) was investigated. It was shown that decreases in the cosmic ray flux are mostly linked to the increases in the interplanetary magnetic field and its fluctuations.

Furthermore, cosmic ray - cloud connection hypothesis, currently the subject of an intense and controversial debate, was investigated in detail. Despite of the numerous short- and long-term investigations using the cloud observations, this hypothesis is still not definitely confirmed or rejected. In this dissertation the following reasons were evaluated: i) there is no connection between cosmic rays and clouds, ii) other solar parameters (e.g. total solar irradiance) may influence the results, iii) there is a connection, but it is too small to be detected with current cloud datasets.

The correlations between the effective atmospheric ionization induced by cosmic rays and the global cloud cover satellite data during 6 Forbush decreases were not significant in the lag period of 10 days. Analysis of clouds at different altitudes (low, middle and high clouds) and in different geographic regions (high and low latitudes or regions over land and ocean) showed no significant correlations as well.

Significant changes in the cloud cover related to changes in the total solar irradiance, cosmic rays or ultraviolet (UV) solar irradiance were also not detected using the composite analysis (so-called superposed epoch analysis), useful for isolating low amplitude signals within the data where noise would otherwise obscure the detection. Hence, total or UV

solar irradiance are not masking a solar-cloud response.

Diurnal range of surface level air temperature can be used as cloud cover proxy, allowing to cover longer time periods than satellite cloud data periods. The composite analysis comprising 267 Forbush events (including 29 events with reductions in cosmic ray flux larger than 7 %) showed no response in cloud cover related to changes in the cosmic ray flux.

By applying adequate methods of data processing and construction of composites as well as using the Monte Carlo method to reliably test the statistical significance, the possible reasons for contradictory results in published studies and sources of major errors were evaluated. Main causes of these contradictions may relate to differences in the various methodological approaches employed by these studies and to evaluation of the statistical significance of results. Users of the cloud data often do not possess enough information about these datasets, e.g. about detection or calibration errors in the cloud data. Such data are frequently characterized with strong autocorrelations, having important implications for the determination of statistical significance.

There is no compelling evidence to support a cosmic ray - cloud connection hypothesis using the satellite cloud data with long- or short-term studies. However, the cosmic ray - cloud link can not be completely ruled out on local and regional scale. If such connection exists, it is very small and is masked by meteorological variability of the cloud data. In conclusion, cosmic rays do not globally affect the cloud cover and cannot explain the larger climate changes or current global warming.

Key words: Sun – solar activity – coronal mass ejections (CME) – corotating interactive regions (CIR) – cosmic rays – Forbush decreases – clouds – atmospheric ionization – climate – satellite cloud data – statistical methods

Sadržaj

1. Uvod	1
2. Propagacija međuplanetarnih koroninih izbačaja mase	9
2.1. Koronini izbačaji mase	9
2.2. Opažanja međuplanetarnih koroninih izbačaja mase	11
2.2.1. Podaci i metode	11
2.2.2. Rezultati i diskusija	12
2.3. Model magnetohidrodinamičkog otpora	14
2.3.1. Provjera modela	16
2.4. Prognostičko sučelje magnetohidrodinamičkoga modela otpora na internetu	21
3. Kozmičko zračenje	25
3.1. Osnovne značajke kozmičkoga zračenja	25
3.2. Sunčeva modulacija kozmičkoga zračenja	29
3.3. Geomagnetsko polje i kozmičko zračenje	31
3.4. Atmosferski pljuskovi čestica uzrokovani kozmičkim zračenjem	33
3.5. Detekcija kozmičkoga zračenja	35
3.6. Forbusheva smanjenja i sporadične promjene kozmičkoga zračenja	36
3.7. Modulacija kozmičkoga zračenja korotirajućim interakcijskim područjima .	39
3.7.1. Podaci i metoda	40
3.7.2. Diskusija i rezultati	41
3.8. Kozmogeni radionuklidi i analiza ^{10}Be	44
4. Sveza kozmičkoga zračenja i naoblake	49
4.1. Utjecaj Sunčeve aktivnosti na Zemljinu klimu	49
4.2. Mehanizmi i modeli utjecaja kozmičkoga zračenja na naoblaku	51
4.2.1. Mehanizam kondenzacijskih jezgri	52
4.2.2. Mehanizam globalnoga električnog strujnog kruga	54
4.3. Eksperimentalna istraživanja: ionizacija i nukleacija aerosola	56
4.4. Procjene utjecaja kozmičkoga zračenja na klimu	57

5. Analize dugoročnih utjecaja kozmičkoga zračenja na naoblaku	59
5.1. Provjera korelacija kozmičkoga zračenja i naoblake u razdoblju 1983-1994 .	60
5.2. Pogreške u ISCCP podacima o naoblaci	63
5.3. Korelacije i satelitski podaci o naoblaci u posljednje 3 dekade	67
6. Utjecaj kozmičkoga zračenja na naoblaku tijekom Forbushevih smanjenja	71
6.1. Podaci i metode	73
6.1.1. Izračun efektivne ionizacije u atmosferi	75
6.1.2. Statistička analiza korelacija	77
6.1.3. Kontrolni događaji i provjere osjetljivosti	80
6.2. Rezultati i diskusija	82
6.2.1. Regionalna analiza	85
7. Utjecaj ukupnoga Sunčevog zračenja na naoblaku	89
7.1. Podaci i metode	90
7.2. Rezultati i diskusija	95
8. Indirektni podaci za naoblaku - dnevni raspon temperatura	99
8.1. Podaci	100
8.2. Rezultati i diskusija	102
9. Kompoziti i Monte Carlo simulacije kao ključ interpretacije hipoteze	109
9.1. Metoda kompozitne analize	109
9.2. Podaci	111
9.3. Filtriranje podataka	112
9.4. Omjer signala i šuma kao ograničavajući faktor u konstrukciji kompozita .	115
9.5. Procjena statističke značajnosti primjenom Monte Carlo simulacija	118
9.6. Procjena statističke značajnosti na primjeru kozmičkoga zračenja i naoblake	121
9.7. Neki primjeri loših procjena statističke značajnosti	124
9.7.1. Provjera statističke značajnosti rada Svensmarka i suradnika	127
10. Zaključak	133
A. Dodatak	139
A.1. Kratice	139
A.2. Tablice	141
Bibliografija	143

1. Uvod

Već dugo je poznato da Sunce nije sasvim statična zvijezda i da postoje određene promjene Sunčeve aktivnosti u vremenu. Sunčeva aktivnost se može opisati cijelim nizom različitih procesa koji se događaju u unutrašnjosti (konvekcijska zona), na površini (fotosfera) i u atmosferi Sunca (korona). Većina tih procesa je povezana s promjenama Sunčevoga magnetskog polja, koje također utječu na promjene u Sunčevom zračenju. Sunčevo elektromagnetsko zračenje primarni je izvor energije na Zemlji i pokretač cjelokupnog klimatskog sustava. No osim Sunčevog zračenja, na Zemljin svemirski okoliš i Zemljinu klimu bitno utječu i međudjelovanje Sunčevog i Zemljinog magnetskog polja te kozmičko zračenje. Čitav taj povezani sustav dovodi do bitnih promjena u Zemljinom svemirskom okolišu, geomagnetskom polju i Zemljinoj atmosferi.


Kako bi se moglo potpuno razumjeti utjecaj Sunčeve aktivnosti na Zemljinu klimu potrebno je imati spoznaje o: (1) kratkoročnim i dugoročnim promjenama u Sunčevoj aktivnosti; (2) međudjelovanju između Sunca i Zemlje; (3) mehanizmima koji su odgovorni za odziv klimatskog sustava na Zemlji ([Rind, 2002](#)).

Sunčeva aktivnost najčešće se veže za pojavu i učestalost Sunčevih pjega (slika 1.1) koje predstavljaju anomalije u Sunčevom globalnom magnetskom polju. Tu povezanost je već sredinom 19. stoljeća uočio astronom amater Heinrich Schwabe, koji je promatranjem Sunčevih pjega ustanovio da se Sunčeve pjege pojavljuju u ciklusima od oko 11 godina ([Schwabe, 1843](#)). Na početku 20. stoljeća George Hale otkrio je da su Sunčeve pjege povezane sa snažnim magnetskim poljima i njihovim polaritetom te da Sunce okreće polaritet magnetskog polja u svakom ciklusu što rezultira 22-godišnjim ciklusom promjene globalnog Sunčevog magnetskog polariteta ([Hale i sur., 1919](#)). Pouzdani, instrumentima izmjereni podaci o Sunčevoj aktivnosti dostupni su samo za razdoblje kraće od dva stoljeća, no postoje indirektni podaci o Sunčevoj aktivnosti dobiveni pomoću određenih radioaktivnih izotopa, kao što su ^{10}Be , ^{14}C , ili ^{36}Cl . Oni su omogućili utvrđivanje daljnjih dugoročnih ciklusa na Suncu kao što je Gleissbergov ciklus od 87 godina, Suessov ciklus od 208 godina i Hallstattov ciklus od 2300 godina (poglavlje 3.8).

Kratkoročne promjene Sunčeve aktivnosti očituju se u pojavama velikih grupa Sunčevih pjega (slika 1.1), Sunčevim bljeskovima (dobro vidljivih u kromosferi, slika 1.1), koroninim izbačajima, koroninim šupljinama itd. a učestalost tih pojava je određena dugoročnim

HVARSKI DVOSTRUKI SOLARNI TELESKOP

aktivno područje: 1515, 4.7.2012, 11:55 UTC



Slika 1.1.: Sunčevo aktivno područje snimljeno u bijelom svijetlu: fotosfera koja prikazuje Sunčevu površinu zajedno sa Sunčevim pjegama (lijevo) te isto područje snimljeno u $H\alpha$ liniji (656 nm), koja prikazuje Sunčevu kromosferu (desno). Obje slike su snimljene pomoću Hvarskog solarnog teleskopa dana 4.7.2012 u 11:55 UTC (srednje vrijeme po Greenwichu), a broj aktivnog područja je 1515. Slike su snimili Nikša Novak i Jaša Čalogović.

ciklusima kao Schwabe-ov ciklus od 11 godina.


Za vrijeme jake Sunčeve aktivnosti u tzv. Sunčevom maksimumu, Sunčevi bljeskovi i koronini izbačaji predstavljaju najbitnije pojave koje utječu na Zemljin svemirski okoliš i klimu. Snažni Sunčevi bljeskovi uzrokuju porast rendgenskog i UV zračenja, što dovodi do pojačane ionizacije u višim slojevima atmosfere. Sunčevi bljeskovi mogu odaslati i Sunčeve energetske čestice (SEP)¹, a često su popraćeni i koroninim izbačajima (CME)². Te pojave povezane su s eruptivnom promjenom globalne magnetske konfiguracije na Suncu (Vršnak, 2008) i mogu stvoriti međuplanetarne koronine izbačaje (ICME)³. ICME-i koji su usmjereni prema Zemlji najčešće uzrokuju jake geomagnetske oluje. U doba minimuma Sunčeve aktivnosti na Zemljin svemirski okoliš utječu korotirajuća interakcijska područja (CIR)⁴ povezana s koroninim šupljinama na Suncu i brzim Sunčevim vjetrom (poglavlje 3.7). Sve navedene pojave, ICME, CIR i SEP mogu imati značajne učinke na Zemljino magnetsko polje te biti uzrok većim geomagnetskim poremećajima. Takvi poremećaji geomagnetskoga polja i prodori visoko-energetskih čestica (npr. SEP) u Zemljinu atmosferu mogu imati dalekosežne posljedice za modernu tehnologiju i uzrokovati značajne promjene u atmosferi (slika 1.2). Tako npr. mogu biti oštećeni ili uništeni sateliti, zračenje

¹eng. *Solar Energetic Particles*, SEP

²eng. *Coronal Mass Ejection*, CME

³eng. *Interplanetary Coronal Mass Ejection*, ICME

⁴eng. *Corotating Interactive Regions*



Slika 1.2.: Utjecaj poremećaja u Zemljinom svemirskom okolišu i atmosferi na ljudske tehnologije i djelatnosti te na Zemljinu klimu. (Bell Laboratories, Lucent Technologies)

može utjecati na zrakoplove, mogu se javiti poremećaji u radio-komunikaciji, navigaciji, opskrbi električnom energijom, radu elektroničkih uređaja na Zemlji itd. Promjene u atmosferi također mogu utjecati na vrijeme i klimu.

S ciljem da se Sunčeva aktivnost (npr. CME, SEP) prati i očekivani štetni učinak na Zemlji predvidi na vrijeme, razvijena je jedna grana Sunčeve fizike pod nazivom "svemirsko vrijeme i prognostika"⁵. Ona se može shvatiti kao analogija meteorološkoj prognozi. No za razliku od meteorološke prognoze, svemirska prognostika je tek predmet brojnih istraživanja i utvrđivanja modela koji će u budućnosti pružiti nešto pouzdaniju svemirsku prognozu. Jedna od bitnih tema svemirske prognostike je i propagacija koroninih izbačaja do Zemlje (poglavlje 2).

Kozmičko zračenje (CR)⁶ se može definirati kao tok visoko-energetskih čestica, uglavnom protona, koji konstantno zasipaju Zemljinu atmosferu. Ono se može podijeliti na Sunčevo kozmičko zračenje (SEP događaji) i galaktičko kozmičko zračenje koje dolazi iz izvora izvan Sunčevog sustava (npr. supernove, pulsari, međuzvjezdani plin). Na intenzitet kozmičkog zračenja utječe Sunčeva aktivnost odnosno Sunčev vjetar i magnetsko polje (poglavlje 3.2). Mjerenja toka kozmičkog zračenja pokazuju dobro izraženu anti-korelaciju sa Sunčevom aktivnošću. Promjene intenziteta kozmičkoga zračenja pokazuju iste dugo-

⁵eng. *space weather*

⁶eng. *cosmic rays*

ročne cikluse kao i Sunce (Schwabe, Hale ciklus itd.). Na kozmičko zračenje kratkoročno utječu ICME i CIR događaji koji na Zemlji uzrokuju tzv. Forbusheva smanjenja (Fd)⁷. To su nagla smanjenja toka kozmičkog zračenja koja se mogu detektirati neutronske monitorima smještenima na Zemlji, a traju u pravilu nekoliko dana (Cane, 2000; Dumbović i sur., 2011). Iako postoji mnogo studija koje se bave proučavanjem Fd događaja te teorijskom interpretacijom istih, točan mehanizam je još predmet istraživanja. Stoga, statistička analiza povezanosti ICME i CIR događaja s karakteristikama Fd događaja može dati empiričku bazu za daljnju teorijsku interpretaciju (poglavlje 3.6 i 3.7).

Herschel (1801) je bio prvi koji je pretpostavio da Sunce i Sunčeva aktivnost utječu na promjenu klime. On je promatrao Sunčeve pjege i zaključio da biljke posjeduju duže periode rasta u vrijeme Sunčeva maksimuma aktivnosti. Herschelova teorija je bila zasnovana na naivnom vjerovanju da je Sunce naseljeno isto kao i Zemlja, a Sunčeve pjege su zapravo rupe u oblacima na Suncu. No Herschelovi zaključci o Sunčevom utjecaju na klimu nisu bili pogrešni, što se je pokazalo u drugoj polovici 20. stoljeća. Od 70-tih godina prošlog stoljeća slijedio je niz radova koji su također upućivali na tu povezanost (Herman i Goldberg, 1978), ali mnogi radovi su kasnije dovedeni u pitanje zbog statističke nepouzdanosti (Pittock, 1978). Jedan od najvažnijih dokaza utjecaja Sunčeve aktivnosti na klimu objavio je Eddy (1976), zaključivši da je u vrijeme izostanka Sunčeve aktivnosti u 17/18. stoljeću (1645-1715) klima na Zemlji bila značajno hladnija (tzv. Maunderov minimum).


U protekloj dekadi napravljen je niz paleoklimatoloških studija koje su pokazale širok raspon povezanosti između Sunčeve aktivnosti i klimatskih parametara u prošlosti (npr. Ram i Stolz, 1999; Beer i sur., 2000; Versteegh, 2005). Stoga danas u znanstvenoj zajednici malo tko još dvoji da Sunce utječe na klimatske promjene (pregled istraživanja u npr. Gray i sur., 2010). No još nije jasno koji su mehanizmi odgovorni da relativno male promjene Sunčeve aktivnosti mogu uzrokovati značajnije promjene u Zemljinoj klimi. Primjera radi, ukupno Sunčevo zračenje (TSI)⁸ se mijenja tijekom Sunčevih ciklusa samo za 0.1 % što nije dovoljno da se objasni uočeni utjecaj na klimu. Stoga su mogući mehanizmi predmet velikih diskusija u znanstvenim krugovima (poglavlje 4.1).

Predloženi mehanizmi se ugrubo mogu podijeliti na utjecaj Sunčevog zračenja i kozmičkoga zračenja na Zemljinu klimu.

Promjene u ukupnom Sunčevom zračenju mogu imati utjecaj na temperaturu oceana (Meehl i sur., 2009), a promjene u ultraljubičastom zračenju (UV) mogu djelovati na ozon u stratosferi (Haigh, 1996). Varijacije ozona u stratosferi mogu putem određenih mehanizama uzrokovati promjene u troposferi i na površini Zemlje.

⁷eng. *Forbush decrease*

⁸eng. *Total Solar Irradiance*



Slika 1.3.: Shematski prikaz energetskega tokova i bilance Zemljinog klimatskog sustava. Dio kratkovalnog dolaznog Sunčevog zračenja se reflektira (albedo), a dio apsorbiraju Zemljina atmosfera i površina. Apsorbiranu energiju atmosfera i površina zrače u dugovalnom području, a pri tome se dio opet može apsorbirati u atmosferi. Oblaci i vodena para imaju ključnu ulogu u tim tokovima. (Houghton i sur., 1996)

Iako Zemljino magnetsko polje sprječava ulazak dijela kozmičkog zračenja nižih energija, čestice koje uspijevaju ući u Zemljinu atmosferu proizvode tzv. atmosferske pljuskove čestice⁹. Oni nastaju kao posljedica nuklearnih interakcija u atmosferi, koje ujedno uzrokuju i ionizaciju čestica (Bazilevskaya i sur., 2008).

Ney (1959) je prvi pretpostavio da bi kozmičko zračenje moglo utjecati na vrijeme na Zemlji, a samim time i na Zemljinu klimu. Prvi mehanizam je potom predložio Dickinson (1975), pretpostavljajući da ionizacija kozmičkim zračenjem u atmosferi može utjecati na promjene naoblake putem oblačnih kondenzacijskih jezgri odgovornih za nastanak oblaka (poglavlje 4.2.1). Naime, poznato je da naoblaka ima ključnu ulogu u bilanci i raspodjeli energetskega tokova u Zemljinom klimatskom sustavu (slika 1.3). Stoga je za očekivati da će i vrlo male globalne promjene u naoblaci od svega nekoliko postotaka imati vrlo snažan učinak na energetskega bilancu i klimatske promjene.

U novije vrijeme neki modeli su pokazali da stvaranje i brzina rasta kondenzacijskih jezgri ovise o vrijednosti ionizacije u atmosferi (npr. Kazil i Lovejoy, 2004). Važnost te hipoteze dokazuje i laboratorijski projekt u CERNu pod nazivom CLOUD, koji se njome bavi (4.3). Uz spomenuti mehanizam ubrzanog rasta kondenzacijskih jezgri pod utjecajem ionizacije, predložen je i mehanizam koji opisuje globalni električni strujni krug

⁹eng. *cosmic ray shower*

u atmosferi, gdje promjene u električnoj nabijenosti atmosfere mogu dovesti do promjena u mikrofizikalnim svojstvima oblaka (poglavlje 4.2.2).

Razvojem sve boljih globalnih satelitskih podataka o naoblaci, znanstvenici su pokušali empirijski dokazati povezanost kozmičkog zračenja i naoblake. Studija danskih znanstvenika [Svensmark i Friis-Christensen \(1997\)](#) vjerojatno je izazvala najviše interesa znanstvenih krugova i javnosti za tu temu. Na temelju dobivenih korelacija između toka kozmičkog zračenja i globalnih satelitskih podataka o naoblaci, autori su zaključili da su između 1983. i 1995. promjene u naoblaci od 2-3 % pratile promjene u toku kozmičkoga zračenja te da je taj utjecaj promjene naoblake na klimu vrlo značajan, jer se može usporediti s utjecajem stakleničkih plinova na globalno zatopljenje i temperaturu. To je izazvalo burne reakcije ne samo u znanstvenom svijetu nego i u javnosti s bitnim političkim implikacijama. Mnogi su autori, potaknuti tim radom kao i kasnijim Svensmarkovim radovima ([Marsh i Svensmark, 2003](#)), oštro kritizirali empirijske rezultate dugoročnih analiza danskih znanstvenika (poglavlje 5). Najvažnije kritike odnosile su se na instrumentalne i kalibracijske pogreške satelitskih podataka te na utjecaj ostalih čimbenika koji osim kozmičkoga zračenja mogu utjecati na naoblaku kao npr. ENSO¹⁰, vulkanske erupcije itd. (poglavlje 5.3).

Alternativa dugoročnim analizama su kratkoročne (dnevne) analize naoblake koje koriste Forbusheva smanjenja (npr. [Pudovkin i Veretenenko, 1995](#); [Todd i Kniveton, 2001](#)) i koje nisu vezane za spomenute probleme dugoročnih analiza. Iako je sinoptički šum u naoblaci nešto veći u slučaju dnevnih analiza nego za dugoročne analize, prikladnim metodama moguće je smanjiti šum na prihvatljivu razinu te na taj način dobiti pouzdanije zaključke o mogućoj svezi kozmičkog zračenja i naoblake. To je učinjeno u ovome radu kako bi se uz pomoć izračunate efektivne ionizacije u atmosferi dobila pouzdana provjera hipoteze utjecaja kozmičkoga zračenja na naoblaku (poglavlje 6).

U proteklih nekoliko godina objavljeno je mnogo radova koji koriste Forbusheva smanjenja sa svrhom povezivanja kozmičkoga zračenja i klimatskih parametara. Rezultati i zaključci tih radova se, međutim, ne poklapaju. Uzrok tome mogao bi biti utjecaj drugih Sunčevih parametara, kao što je ukupno ili ultraljubičasto Sunčevo zračenje, mogu utjecati na naoblaku. To je također provjereno u ovome radu detaljnom analizom u kojoj su razmotreni događaji s najvećim promjenama u ukupnome i ultraljubičastome zračenju (poglavlje 7).

Drugi mogući razlog proturječnosti rezultata je raznolikost metodologije i statističkih provjera u objavljenim radovima. To u slučaju neprimjerenih metoda s obzirom na specifičnost podataka može imati kao ishod pogrešnu procjenu statističke značajnosti te dovesti do pogrešnih zaključaka. S tom svrhom je u ovome radu detaljno opisana i analizirana

¹⁰El Niño - južna oscilacija, eng. *El Niño-Southern Oscillation*

metoda kompozitne analize¹¹, koja se najčešće koristi u mnogim radovima, kao i Monte Carlo metode za određivanje statističke značajnosti (poglavlje 9). Budući da je uklanjanje šuma metodom kompozita presudno za detekciju traženoga signala u naoblaci, napravljene su procjene šuma u naoblaci te je određena gornja granica detekcije (poglavlje 9). Na temelju ove analize diskutirani su neki objavljeni radovi (poglavlje 8 i 9.7.1) i razmotrene su mogućnosti provjere hipoteze ovisnosti kozmičkoga zračenja i naoblake s podacima koji su dostupni u današnje vrijeme (poglavlje 10).

Posljednjih desetljeća konsenzus oko čovjekovog utjecaja na klimu sve je jači u znanstvenoj i široj zajednici (IPCC, 2013)¹². Utjecaj stakleničkih plinova i drugih antropogeno uvjetovanih čimbenika koji utječu na promjenu klime u fokusu je klimatologa. Sukladno dobivenim alarmantnim rezultatima sve više smo okruženi crnim prognozama o budućnosti, gdje će bitne antropogeno uzrokovane promjene u klimi značajnije utjecati na svjetske društvene i ekonomske aspekte. Ne samo da se porast temperature veže za porast razine mora i oceana, nego i za učestalost ekstremnih događaja kao što su suše, nevremena, ekstremne temperature itd. (npr. Alley i sur., 2003; Schär i sur., 2004). U zadnjih nekoliko izvješća Međuvladinog panela o klimatskim promjenama, IPCC (2013), antropogeni utjecaj stoji kao najvažniji (i gotovo jedini) čimbenik klimatskih promjena. Utjecaj prirodnih čimbenika poput Sunca djelomično je zanemaren i trenutačno stavljen u drugi plan. Razlog tome je i daljnje nepoznavanje egzaktnoga mehanizma utjecaja Sunca na Zemljinu klimu, što i dalje ostavlja puno otvorenih pitanja. Postoje realne naznake da bi Sunčeva aktivnost iz sadašnjeg dugoročnoga maksimuma u sljedećim dekadama mogla prijeći u nešto mirniju fazu s manje izraženim 11 godišnjim ciklusima (Abreu i sur., 2008) što će također biti prilika da se još bolje kvantificira utjecaj Sunca na promjene Zemljine klime.

S druge strane, postoji grupa pojedinaca i znanstvenika koji negiraju rezultate IPCC-a te opažene promjene klime na Zemlji tumače isključivo utjecajem prirodnih čimbenika odnosno povezanošću Sunca i Zemljine klime. Jedan od posebno omiljenih argumenata tzv. "skeptika" čovjekovog utjecaja na klimu se bazira na hipotezi utjecaja kozmičkoga zračenja na naoblaku (Calder, 1997; Svensmark i Calder, 2007).

Ovaj rad je prilog području istraživanja prirodnih čimbenika, posebice kozmičkoga zračenja, na klimu. Znanstvene, gospodarske i političke diskusije pomaknut će se korak naprijed ako se hipoteza o utjecaju kozmičkoga zračenja na naoblaku sa sigurnošću potvrdi ili odbaci. Za to je potrebna čvrsta empirička podloga koja danas još nedostaje. Ovaj rad je doprinos nastojanjima da se identificiraju problemi koji onemogućavaju jasne zaključke.

¹¹superponirajuća analiza epoha (eng. *superposed epoch analysis*)

¹²eng. *Intergovernmental Panel on Climate Change*

2. Propagacija međuplanetarnih koroninih izbačaja mase

2.1. Koronini izbačaji mase

Sprega između Sunčeve diferencijalne rotacije¹, konvektivnih gibanja i magnetskih polja određuju Sunčev magnetohidrodinamički (MHD) dinamo koji je odgovoran za manifestacije Sunčeve aktivnosti. Kao posljedica tih procesa induciraju se električne struje koje se skladište u strujno vodljivim magnetskim strukturama. Jedan dio te energije se prenosi od Sunčeve površine do korone i troši se na zagrijavanje korone². Drugi dio energije se djelomično oslobađa u eruptivnim procesima na Suncu kao što su koronini izbačaji mase, CME i Sunčevi bljeskovi (Priest, 1982).

Pojedini CME-i mogu biti povezani sa Sunčevim bljeskovima (Švestka, 2001), što je čest slučaj za jake bljeskove i brze CME-e. Međutim, općenito ta povezanost nije velika (Gosling, 1993). Opažanja ukazuju da dinamika CME-a utječe na oslobađanje energije u pridruženim Sunčevim bljeskovima te obrnuto da Sunčevi bljeskovi s oslobađanjem energije utječu na kinematiku CME-a (Vršnak i sur., 2005; Maričić i sur., 2007).

Učestalost CME-a povezana je sa Sunčevom aktivnošću, a pronađena je korelacija između broja Sunčevih pjega i učestalosti CME-a (Webb i Howard, 1994; Robbrecht i sur., 2009). Procijenjeno je da učestalost CME-a tijekom Sunčeva minimuma u prosjeku iznosi jedan CME (ili manje) po danu, a tijekom Sunčeva maksimuma oko pet CME-a po danu (Webb i Howard, 1994; Robbrecht i sur., 2009; Gopalswamy i sur., 2010).

CME predstavlja eruptivnu promjenu globalne magnetske konfiguracije Sunčeve korone. Pri tome je Lorentzova sila odgovorna za ubrzanje nestabilnih koroninih magnetskih struktura do brzina potrebnih da se one izbace u međuplanetarni prostor (Forbes, 2000; Vršnak, 2008).

Nakon uzdizanja CME-a, na njihovu dinamiku snažno utječe međudjelovanje eruptirajućih struktura s okolnom magnetoplazmom. Brzi CME-i prenose svoj moment i energiju

¹Sunce ne rotira kao kruto tijelo, već ekvator rotira brže (25 dana) od polova (34 dana)

²Sunčeva korona ima temperaturu od oko 2 milijuna K dok Sunčeva površina ima temperaturu od oko 5800K

na Sunčev vjetar, dok je za spore CME-e situacija obrnuta pa Sunčev vjetar prenosi moment i energiju na izbačaj. Stoga kao rezultat sprege između Sunčeva vjetra i CME-a, izbačaji koji su brži od Sunčeva vjetra usporavaju s vremenom, a oni sporiji od Sunčeva vjetra ubrzavaju (Gopalswamy i sur., 2000; Manoharan, 2006; Vršnak i Žic, 2007).

Na dinamiku CME-a može utjecati i interakcija s drugim CME-ima (Wang i sur., 2005). Takav jednostavan slučaj se dešava kada su dva CME-a odaslana u kratkom vremenskom periodu iz istog aktivnog područja na Suncu. U slučaju da je drugi CME brži od prvoga, rezultat međudjelovanja ta dva CME-a bit će ubrzavanje prvoga te usporavanje drugoga CME-a (Wang i sur., 2005). CME-i imaju početnu brzinu reda veličine od 1000 km s^{-1} i nose u prosjeku 10^{11} do 10^{13} kg koronine plazme u međuplanetarni prostor (Webb i sur., 1994).

Smatra se da su uzrok CME-a erupcije zatvorenih petlji magnetskih silnica, što u usporedbi s ostalim oblicima Sunčeve aktivnosti zahtijeva najveći utrošak energije, koji u prosjeku iznosi oko 10^{25} J (Gopalswamy, 2006). Upravo zbog toga ti procesi imaju najznačajniji utjecaj na Zemljin svemirski okoliš i geomagnetsko polje.

Poznato je da su međuplanetarni koronini izbačaji mase, ICME-i, uzrok najvećim geomagnetskim olujama (Gosling i sur., 1990; Koskinen i Huttunen, 2006), koje mogu imati značajne posljedice za mnoge ljudske tehnologije i djelatnosti te utjecati na Zemljinu klimu (slika 1.2, poglavlje 1). Stoga su predviđanja dolaska ICME-a od Sunca do Zemlje jedna od važnih tema tzv. svemirske prognostike.

S tom svrhom razvijene su različite prognostičke metode temeljene na statističkim ili empiričkim modelima (npr. Brueckner i sur., 1998; Gopalswamy i sur., 2000; Michałek i sur., 2004; Schwenn i sur., 2005; Vršnak i Žic, 2007), analitičkim propagacijskim modelima (npr. Smart i Shea, 1985; Cargill, 2004; Cantó i sur., 2005; Vršnak i Žic, 2007; Borgazzi i sur., 2009) ili numeričkim MHD modelima (npr. González-Esparza i sur., 2003; Manchester i sur., 2004; Smith i sur., 2009; Taktakishvili i sur., 2009). Točnost modela je provjerena u više radova (npr. Cho i sur., 2003; Dryer i sur., 2004; McKenna-Lawlor i sur., 2006; Taktakishvili i sur., 2009; Vršnak i sur., 2010) te se je pokazalo da u današnje vrijeme točnost predviđanja iznosi oko ± 10 sati s time da pogreške ponekad mogu biti veće od 1 dana.

ICME-i također uzrokuju značajne promjene u toku kozmičkoga zračenja na Zemlji (poglavlje 3.6).

2.2. Opažanja međuplanetarnih koroninih izbačaja mase

Opažanja CME-a vrše se najčešće pomoću koronografa³ u vidljivoj svjetlosti (npr. LASCO⁴, Brueckner i sur., 1995; SECCHI⁵, Howard i sur., 2008), no mogu se također opažati i u rendgenskom, dalekom ultraljubičastom ili radio spektru.

Utjecaj Sunčeva vjetra na kinematiku ICME-a može se opažati pomoću koronografskih podataka. Koristeći koronografske podatke Vršnak (2001) je analizirao kinematiku 12 brzih ICME-a te zaključio da je usporavanje ICME-a povezano s njihovom početnom brzinom i udaljenošću od Sunca. U nastavku analize ispitana je ovisnost ubrzanja i brzine CME-a u uzorku od 5000 CME-a promatranih pomoću LASCO koronografa (Vršnak i sur., 2004). Uočena je jasna antikorelacija između ta dva parametra ukazujući da na ICME-e snažno utječe magnetohidrodinamički ("aerodinamični") otpor. Vršnak i sur. (2004) su također pokazali da: 1) djelovanje otpora opada sa radijalnom udaljenošću od Sunca te da ovisi o veličini CME-a; 2) Lorentzova sila i dalje djeluje na CME-e na udaljenosti od 2 do 30 polumjera Sunca⁶ ($a \approx 10 \text{ ms}^{-2}$).

S ciljem da se proširi analiza koju su napravili Vršnak i sur. (2004), u ovom radu istražena je ovisnost ubrzanja i brzine CME-a $a(v)$ o masi koristeći veći uzorak CME-a. Sukladno teoriji o aerodinamičnom otporu (Cargill i sur., 1996; Cargill, 2004) ovisnost $a(v)$ treba biti statistički različita za različite mase CME-a.

Budući da prema teoriji aerodinamičnoga modela otpora Sunčev vjetar i brzina CME-a najviše utječu na vrijeme dolaska ICME-a na Zemlju, dodatno je istražena ovisnost tranzitnog vremena ICME-a o brzini Sunčeva vjetra i CME-a.

2.2.1. Podaci i metode

U analizi su korišteni podaci iz LASCO CME kataloga (http://cdaw.gsfc.nasa.gov/CME_list/) u razdoblju od siječnja 1997. do lipnja 2006. U tom razdoblju zabilježeno je ukupno 11108 CME-a, a procjena za masu (Vourlidas i sur., 2000, 2002) postojala je za 6910 CME-a. Nakon što su uklonjeni CME-i s nepouzdanim procjenama za ubrzanje ili masu, konačan uzorak se sastojao od 3091 CME-a.

Za svaki CME su uzeti podaci za srednju brzinu v , srednje ubrzanje a i masu m koji su određeni u vidnom polju LASCO koronografa.

Kako bi se istražila ovisnost tranzitnog vremena ICME-a o brzini Sunčeva vjetra i brzini

³uređaj koji blokira direktno svjetlo sa Sunčeva diska kako bi se vidjela puno tamnija Sunčeva korona

⁴*Large Angle and Spectrometric Coronagraph*, instrument smješten na SoHO (*Solar and Heliospheric Observatory*) satelitu

⁵*Sun Earth Connection Coronal and Heliospheric Investigation*, instrument smješten na STEREO (*Solar Terrestrial Relations Observatory*) satelitima

⁶naime toliko iznosi vidno polje LASCO koronografa

CME-a, korišteni su podaci tranzitnoga vremena iz rada [Schwenn i sur. \(2005\)](#) u kojem su identificirana 91 ICME-a u razdoblju od 1997. do 2001. i za koje je utvrđeno da su stigli na Zemlju⁷. Mjerenja Sunčeva vjetra uzeta su s Advanced Composition Explorer (ACE) satelita ([Stone i sur., 1998](#)) smještenog u blizini Zemlje.

2.2.2. Rezultati i diskusija


Na slici [2.1a](#) su prikazana srednja ubrzanja a za 3091 CME kao funkcija njihovih srednjih brzina v . Uočava se jasna antikorelacija između a i v s koeficijentima korelacije $C = 0.24$, što ukazuje da su spori CME-i u prosjeku ubrzani, a brzi usporeni. Prikazan je i pravac prilagodbe koji sječe x-os pri vrijednosti $v_{a=0} \approx 400 \text{ kms}^{-1}$, što odgovara prosječnoj brzini Sunčeva vjetra tijekom Sunčeva ciklusa. Na slici [2.1a](#) je također uočljivo da CME-i malih brzina u pravilu ne pokazuju usporavanje ($a < 0$). S druge strane postoje vrlo brzi CME-i koji i dalje ubrzavaju ($a > 0$). To ukazuje da Lorentzova sila djeluje na te CME-e i na većim udaljenostima od 20 polumjera Sunca.

Na slici [2.1b](#) je prikazana ovisnost a o v za dva uzorka CME-a različitih masa. Prvi uzorak sadrži 500 CME-a najmanjih masa (srednja masa $\bar{m} = 7 \cdot 10^{10} \text{ kg}$), a drugi 500 CME-a najvećih masa ($\bar{m} = 7 \cdot 10^{12} \text{ kg}$). Uočljivo je da pravac prilagodbe za uzorak malih CME masa (sivi kružići) ima veći nagib k od uzorka velikih masa (slika [2.1b](#)). To je potvrdila i statistička analiza pokazavši da su pravci prilagodbe za ova dva uzorka značajno različiti na 99 % razini pouzdanosti. U daljnoj analizi 3091 CME-a su podijeljeni u ukupno 27 razreda (uzoraka) s različitim masama što je omogućilo da se procijeni utjecaj mase na ubrzanja CME-a s trendom $k \propto m^{-\frac{1}{3}}$. Ta vrijednost vrlo dobro odgovara teorijskoj ovisnosti ubrzanja o masi koja je dana u modelu magnetohidrodinamičkog otpora (poglavlje [2.3](#)).

Slika [2.2a](#) prikazuje ovisnost vremena dolaska ICME-a na Zemlju (TT) o početnoj brzini CME-a, v , određenoj LASCO koronografom na uzorku od 91 ICME ([Schwenn i sur., 2005](#)). Brži CME-i imaju kraće tranzitno vrijeme nego sporiji. Ovisnost TT o v prati potencijalsku funkciju te odgovarajuća krivulja ima sporiji pad za sve CME-e brže od 500 kms^{-1} , što je posljedica aerodinamičkoga otpora. Ovisnost tranzitnog vremena ICME-a o brzini Sunčeva vjetra, w ⁸, je prikazana na slici [2.2b](#). Ako se usporede slika [2.2a](#) i [2.2b](#) uočava se da tranzitno vrijeme ICME-a više ovisi o Sunčevom vjetru nego o početnoj brzini CME-a. To potvrđuje i veći koeficijent korelacije za ovisnost TT i w ($C = 0.75$) u odnosu na onaj koji je dobiven za ovisnost TT i v ($C = 0.62$). To znači

⁷ovisno o položaju na Sunčevom disku odakle je CME odaslan i njegovoj širini samo dio ICME-a može pogoditi Zemlju


⁸budući da CME-i stvaraju poremećaje u Sunčevom vjetru, w je u ovome slučaju određen kao srednja vrijednost prije i poslije CME-a



Slika 2.1.: Ovisnost ubrzanja (a) i brzine (v) CME-a. a) antikorelacija između a i v temeljena na uzorku od 3091 CME. b) antikorelacije između a i v za uzorak CME-a s malim (sivi kružići) i velikim masama (crni križići). Prikazani su pravci linearne prilagodbe (metoda najmanjih kvadrata).

da se veći dio ubrzanja ili usporavanja ICME-a događa blizu Sunca, a ostatak puta do Zemlje većina ICME-a prevale s brzinom koja je slična brzini Sunčeva vjetra.

Stoga se može zaključiti da je Sunčev vjetar ključni parametar koji određuje tranzitno vrijeme ICME-a do Zemlje. Dobiveni rezultati su sukladni tzv. "Buecknerovom 80-satnom pravilu" (Brueckner i sur., 1998) prema kojem tipično tranzitno vrijeme za ICME-e mase manje od 10^{12} kg iznosi oko 80 sati, budući da se može pretpostaviti da većina CME-a propagira kroz sporiji Sunčev vjetar. Najkraća tranzitna vremena ($TT < 1$ dana) su moguća samo u slučaju CME-a velike mase i velikih brzina izbačaja ($v_0 > 2000 \text{ km s}^{-1}$).



Slika 2.2.: a) Transitno vrijeme (TT) u ovisnosti o brzini CME-a, v . b) TT u ovisnosti o brzini Sunčeva vjetra, w . Prikazana je prilagodba potencijalnoj funkciji (crna linija).

2.3. Model magnetohidrodinamičkog otpora

Dinamika CME-a je određena Lorentzovom silom, gravitacijom i aerodinamičnim otporom (Cargill, 2004). Ukupno ubrzanje CME-a se definira kao:

$$a = a_L - g + a_d, \quad (2.1)$$

gdje je a_L ubrzanje pod utjecajem Lorentzove sile, g gravitacijsko ubrzanje i a_d ubrzanje uslijed aerodinamičnog otpora.

Nadalje, pretpostavlja se da nakon što CME prijeđe put od 20 Sunčevih radiusa ($r > 20r_\odot$), utjecaj Lorentzove sile i gravitacije postaje zanemariv (Vršnak, 2001; Vršnak i sur., 2004), što ima za posljedicu da je $a \approx a_d$.

Ubrzanje aerodinamičnog otpora može se izraziti kao (Cargill i sur., 1996; Cargill,

2004):

$$a_d = -\gamma(v - w)|v - w|, \quad (2.2)$$

gdje v predstavlja brzinu CME-a, a w brzinu okolnoga Sunčeva vjetra. Prema jednadžbi (2.2), CME će usporavati ako je $v > w$, a ubrzavat će ako je $v < w$. Parametar γ se najčešće definira kao:

$$\gamma = c_d \frac{A\rho_w}{m} \quad (2.3)$$

gdje c_d predstavlja koeficijent otpora, A je poprečna površina CME-a okomita na pravac njegova gibanja, ρ_w je gustoća okolnoga Sunčeva vjetra, a m je masa CME-a.

Stoga se očekuje da usporavanje ili ubrzanje CME-a, nakon što Lorentzova sila i gravitacija postanu zanemarive, ovisi o brzini w i gustoći ρ_w Sunčeva vjetra kao i o brzini v , masi m i površini A CME-a.

Za jednadžbu (2.2) također je moguće načiniti linearnu aproksimaciju:

$$a = -k(v - w). \quad (2.4)$$

U (2.4) se može uvrstiti srednja brzina $\bar{v}$ i srednje ubrzanje $\bar{a}$ iz slike 2.1 u prethodnom poglavlju. Tada koeficijent k odgovara nagibu linearnih prilagodbi prikazanih na slici 2.1 i može se izraziti kao:

$$k = \gamma(v - w). \quad (2.5)$$

Ako se aproksimira da je $A \sim V^{\frac{2}{3}}$, gdje V označava volumen CME-a i masa CME-a se definira kao $m = V\rho_{CME}$, tada iz (2.5) proizlazi da je nagib k proporcionalan masi CME-a ($k \propto m^{-\frac{1}{3}}$).

Kada se uvrsti $a = d^2r/dt^2$ i $v = dr/dt$ u (2.2) dobiva se jednadžba:

$$\frac{d^2r}{dt^2} = -\gamma(r) \left(\frac{dr}{dt} - w(r) \right) \left| \frac{dr}{dt} - w(r) \right|, \quad (2.6)$$

koju je moguće riješiti numerički (Vršnak i Žic, 2007). Ako se pretpostavi da su γ i brzina Sunčeva vjetra w konstantni i ne ovise o r , jednadžbu (2.6) je moguće riješiti analitički (Vršnak i sur., 2004). Te pretpostavke su dobre za $r > 20r_\odot$ što su potvrdili numerički izračuni putem jednadžbe (2.6) u kojima su odstupanja za tranzitna vremena u odnosu na analitička rješenja bila općenito manja od 1 sata. Takve pogreške su puno manje od pogrešaka u ulaznim vrijednostima jednadžbe koja su uzrokovana nepozdanošću mjerenja.

Uz pretpostavku da je $\gamma = konst.$ i $w = konst.$ analitička rješenja jednadžbe (2.6) su:

$$v(t) = \frac{v_0 - w}{1 \pm \gamma(v_0 - w)t} + w, \quad (2.7)$$

$$r(t) = \pm \frac{1}{\gamma} \ln[1 \pm \gamma(v_0 - w)t] + wt + r_0, \quad (2.8)$$

gdje je r_0 početna radijalna udaljenost CME-a od Sunca (npr. $r_0 = 20r_\odot$), a v_0 je brzina CME-a pri r_0 . Predznak ovisi o tome da li CME ubrzava ili usporava tj. predznak je pozitivan za $v_0 > w$, a negativan za $v_0 < w$.

Pomoću funkcija $r(t)$ i $v(t)$ je moguće odrediti tranzitno vrijeme dolaska ICME-a do Zemlje (ili nekoga drugoga objekta u Sunčevom sustavu), a pomoću funkcije $v(r)$ brzinu CME-a u blizini Zemlje (ili nekoga drugoga objekta).

Iako je prednost modela magnetohidrodinamičkoga otpora (DBM)⁹ jednostavniji i brži izračun u usporedbi s kompliciranijim numeričkim modelima (npr. ELNIL, [Taktakishvili i sur., 2009](#)), treba napomenuti da postoje i određena ograničenja ovoga prognostičkog modela.

Za brže CME-e ($v_0 > w$) Lorentzova sila, koja je u modelu zanemarena, ponekad djeluje i na većim udaljenostima od $20r_\odot$, što utječe na ubrzanje CME-a. To može uzrokovati krive procjene vremena dolaska ICME-a na Zemlju i njegove brzine u blizini Zemlje. Taj problem može se izbjeći ako se koriste mjerenja brzine CME-a na većim radijalnim udaljenostima od Sunca (npr. $r_0 = 30r_\odot$) gdje Lorentzova sila definitivno postaje zanemariva ([Vršnak i sur., 2004](#)).

Model uzima u obzir samo pojednostavljenu strukturu Sunčeva vjetra, tj. pretpostavlja da Sunčev vjetar ima izotropan tok te da mu brzina ne ovisi o udaljenosti od Sunca. No u stvarnosti to nije tako pa ICME-ovi mogu prolaziti kroz različite režime Sunčeva vjetra: npr. brzi ICME može prvo proći kroz sporiji Sunčev vjetar te potom ući u područje brzoga Sunčeva vjetra ([Temmer i sur., 2011](#)).

Nadalje, brži ICME-i mogu naići na sporije ICME-e odaslane nešto ranije u istome smjeru, a kao posljedica toga sporiji ICME-i će dobiti dio impulsa brzih ICME-a ([Temmer i sur., 2012](#)). Stoga je za očekivati da će u slučaju međudjelovanja dva ili više ICME-a, koje nije obuhvaćeno u DBM-u, procjena tranzitnih vremena ICME-a biti opterećena pogreškama.

2.3.1. Provjera modela

Od ulaznih parametara koji su potrebni za DBM brzina Sunčeva vjetra, w i parametar γ povezani su s najvećim pogreškama obzirom da ne postoje direktna (*in-situ*) mjerenja tih

⁹eng. *Drag Based Model*

parametara.

Parametar γ moguće je procijeniti na temelju jednadžbe (2.3) i masa CME-a (poglavlje 2.2, $m \sim 10^{12} - 10^{13}$ kg). Ako se pretpostavi da je tipična kutna širina CME-a $\phi = 60^\circ \sim 1$ rad (Vršnak i sur., 2007a), a pri $r = 20r_\odot$, uzimajući u obzir konusni model (Zhao i sur., 2002), poprečna površina, A , CME-a iznosi $\sim 10^{20}$ m² te pretpostavljajući da je $c_d = 1$, a tipična gustoća Sunčeva vjetra $n \sim 10^9$ m⁻³ (Leblanc i sur., 1998), može se izračunati da parametar γ poprima vrijednosti od $2 \cdot 10^{-8}$ do $2 \cdot 10^{-7}$ km⁻¹.

U slučaju ICME-a velikih masa (sjajni CME-i na koronografskim slikama) parametar γ bi trebao imati male vrijednosti, reda veličine 10^{-8} km⁻¹ dok je u slučaju ICME-a malih masa (tamniji CME-ovi na koronografskim slikama) γ bliže gornjoj granici od $2 \cdot 10^{-7}$ km⁻¹.

S ciljem da se DBM statistički provjeri upotrijebljeni su uzorci od 91 ICME iz rada Schwenn i sur. (2005) i 30 ICME iz rada Manoharan (2006). Koristeći jednadžbu (2.8) moguće je dobiti dvije algebarske jednadžbe za w i γ iz kojih se uz pomoć spomenutih uzoraka (ako su poznate vrijednosti za r_0, r_1, v_0, v_1 i t) mogu izračunati vrijednosti za w i γ (slika 2.3).

Razdioba izračunatih vrijednosti za w je prikazana na slici 2.3a i uspoređena s razdiobom vrijednosti *in-situ* mjerenja w pomoću ACE¹⁰ satelita za vrijeme male učestalosti ICME-a (25 do 125 dan u 2005. godini; Vršnak i sur., 2007c; Temmer i sur., 2007)¹¹. Izračunate (DBM) i izmjerene (ACE) razdiobe za w su slične i imaju većinu brzina u rasponu od 300 - 700 kms⁻¹ sa srednjom vrijednosti od (470 ± 190) kms⁻¹. No u nekim slučajevima razdioba temeljena na DBM-u pokazuje precijenjenost odnosno podcijenjenost brzina Sunčeva vjetra u odnosu na ACE vrijednosti. Te pogreške se mogu pripisati netočnim ulaznim parametrima za CME kao što je početna brzina CME-a.


Razdioba vrijednosti za parametar otpora γ izračunatih pomoću DBM-a je prikazana na slici 2.3b. Izračunate vrijednosti u grubo odgovaraju procijenjenim $((0.2 - 2) \cdot 10^{-7}$ km⁻¹), a srednja vrijednost za γ iznosi $(1 \pm 0.6) \cdot 10^{-7}$ km⁻¹.

U daljnjem koraku je korišten uzorak od 91 ICME (Schwenn i sur., 2005) kako bi se izračunalo vrijeme dolaska ICME-a na Zemlju koristeći različite kombinacije w i γ u rasponu vrijednosti od $(0.2 - 2) \cdot 10^{-7}$ km⁻¹ i 300 - 700 kms⁻¹. Izračunata tranzitna vremena (C) nakon toga su uspoređena s promatranim (O) vremenima dolaska ICME-a na Zemlju te je određena njihova razlika (O-C).

Za svaku kombinaciju w i γ parametra razmotrene su pogreške (O-C) s ciljem da se nađu takve kombinacije gdje srednja vrijednost za O-C postaje jednaka nuli. Pokazalo

¹⁰Advanced Composition Explorer

¹¹budući da CME-i također utječu na promjene brzine Sunčeva vjetra, potrebno je uzeti referentno razdoblje u doba slabe Sunčeve aktivnosti kada nije zabilježena pojava CME-a



Slika 2.3.: Razdioba vrijednosti za a) brzinu Sunčeva vjetra w i b) parametar γ . Plavo su označene vrijednosti dobivene pomoću DBM-a, a crveno vrijednosti izmjerene pomoću ACE satelita.

se da su pogreške DBM-a najmanje u slučaju $w = 500 \text{ kms}^{-1}$ i $\gamma = 1 \cdot 10^{-7} \text{ km}^{-1}$, što u grubo odgovara rezultatima prikazanim na slici 2.3.

Na slici 2.4a je prikazana razdioba za O-C koja je grupirana oko nule gdje pokazuje najveće vrijednosti. Vrijednost od +54 sata u histogramu može se smatrati netipičnom, budući da je pogreška veća od 2 dana, što je najvjerojatnije uzrokovano krivom identifikacijom CME/ICME para¹². Standardno odstupanje prikazanoga histograma (2.4a) iznosi 16 sati (tj. 15 sati ako se ukloni već spomenuta netipična vrijednost). Kumulativna razdioba O-C vrijednosti ukazuje da oko 55 % ICME-a ima pogrešku u tranzitnom vremenu manju od 12 sati, a za 85 % ICME-a je ta pogreška manja od 1 dana.

S ciljem da se detaljno provjere mogućnosti DBM-a proučavana je kinematika ICME-a na tri tipična primjera CME-a: 15.11.2007, 12.12.2008. i 2.6.2008. U slučaju sva tri ICME-a kinematika je rekonstruirana na temelju satelitskih mjerenja (STEREO) i uspoređena s izračunatom pomoću DBM-a. Za prva dva CME-a (15.11.2007. i 12.12.2008.) korištena su mjerenja iz rada Liu i sur. (2010) dok su za treći CME (2.6.2008.) korišteni radovi Temmer i sur. (2011) i Rollett i sur. (2012).


Prvi ICME (15.11.2007) karakteriziran je vrlo malom početnom brzinom $v_0 = 270 \text{ kms}^{-1}$ i kontinuiranim ubrzavanjem pod utjecajem Sunčeva vjetra do brzina od 500-600 kms^{-1} (slika 2.5b). Najbolje poklapanje modela i opažanja postignuto je pri $w = 600 \text{ kms}^{-1}$ i $\gamma = 1.6 \cdot 10^{-7} \text{ km}^{-1}$ (slika 2.5a). Velika vrijednost za γ je opravdana obzirom da je taj ICME opisan kao slab na koronografskim snimkama, što znači da se radilo o CME-u male mase.

Drugi ICME (12.12.2008) je ubrzavao pod utjecajem Lorentzove sile do brzine od 740 km s^{-1} (v_0) na udaljenosti od $R \sim 23r_\odot$ te je nakon toga postupno usporavao zbog aerodinamičnoga otpora do brzine od 350 km s^{-1} (slika 2.5d). U ovom slučaju najbolje poklapanje je dobiveno za $w = 350 \text{ kms}^{-1}$ i $\gamma = 2 \cdot 10^{-7} \text{ km}^{-1}$ (slika 2.5c). Ovaj događaj je bio još slabije vidljiv od prvog ICME-a (15.11.2007.), što je posljedica male mase. Mala vrijednost brzine Sunčeva vjetra bila je posljedica nepostojanja većih koroninih šupljina na Suncu. Ovaj primjer ICME-a pokazuje da su moguće značajne pogreške izračuna pomoću modela ako se početna brzina ICME-a, v_0 , određuje na manjoj udaljenosti, npr. za $R \sim 12r_\odot$. Pri toj vrijednosti za R ICME je imao brzinu od samo 320 kms^{-1} , a na ICME je još djelovala Lorentzova sila.


Treći ICME (2.6.2008.) je praćen mjerenjima (STEREO) čak do udaljenosti od preko $200r_\odot$ ¹³ na kojoj je ICME poprimio brzinu Sunčeva vjetra od otprilike 400 km s^{-1} . Uvrštavanjem parametara $w = 440 \text{ kms}^{-1}$ i $\gamma = 2 \cdot 10^{-7} \text{ km}^{-1}$ DBM je najbolje reproducirao

¹²naime u slučaju više uzastopnih CME-a na Suncu, što je čest slučaj u maksimumu Sunčeva ciklusa ponekad je teško na osnovu mjerenja odrediti koji CME-i su pogodili Zemlju, a koji su je promašili

¹³1 astronomska jedinica ili udaljenost između Zemlje i Sunca iznosi $214r_\odot$



Slika 2.4.: a) Razdioba razlika između opažanih i izračunatih vrijednosti (O-C) za tranzitna vremena ICME-a. Izračunate vrijednosti tranzitnih vremena (C) su dobivene pomoću $\gamma = 1 \cdot 10^{-7} km^{-1}$ i $w = 500 km s^{-1}$ te pomoću početnih položaja i brzine CME-a. b) Kumulativna razdioba za apsolutne razlike (O-C).



Slika 2.5.: Kinematika tri ICME-a u heliosferi: (a-b) 15.11.2007, (c-d) 12.12.2008 i (e-f) 2.6.2008. Na lijevoj strani (a,c,e) prikazane su udaljenosti (R) u ovisnosti o vremenu, dok su na desnoj strani (b,d,f) prikazane brzine (v) u ovisnosti o udaljenosti (R) izražene u Sunčevim polumjerima ($R = r/r_{\odot}$). Sivi križići označavaju izmjerene vrijednosti, a crvena linija označava vrijednosti izračunate pomoću DBM-a. Plavi kvadratići označavaju vrijednosti *in-situ* mjerenja.

ovaj ICME koji je također posjedovao malu masu.

2.4. Prognoštičko sučelje magnetohidrodinamičkoga modela otpora na internetu

Obzirom da model vrlo brzo analitički računa (manje od 1 sekunde na običnom računalu), načinjeno je javno prognoštičko sučelje DBM-a na internetu, koje je u mogućnosti izračunati dolazak ICME-a na Zemlju (<http://oh.geof.unizg.hr/DBM/dbm.php>).

Web stranica prognoštičkoga sučelja s ulaznim parametrima modela prikazana je na

2. Propagacija međuplanetarnih koroninih izbačaja mase

slici 2.6. Prva dva parametra se odnose na datum i vrijeme kada je CME detektiran na koronografskim slikama (npr. LASCO, STEREO) na nekoj udaljenosti R_0 . U trećem polju se definira udaljenost R_0 u Sunčevim polumjerima. Poželjno je da R_0 ima vrijednost od 20 ili veću. U četvrtom polju se definira početna brzina CME-a, v_0 , koja odgovara udaljenosti R_0 .

Forecasting the Arrival of ICMEs: The Drag-Based Model

The screenshot shows the 'Basic DBM' tab of a web application. It contains several input fields for parameters: 'CME take-off date' (Jun 2, 2014), 'CME take-off time (UTC)' (04 h 16 min), ' R_0 - starting radial distance of CME (R_s)' (22), ' v_0 - speed of CME at R_0 (km/s)' (306), ' Γ - drag parameter (10^{-7} km^{-1})' (2), ' w - asymptotic solar wind speed (km/s)' (440), and ' R_{target} - target heliocentric distance (AU)' (1). At the bottom are 'Calculate' and 'Reset!' buttons.

Slika 2.6.: Web stranica s ulaznim parametrima za DBM (<http://oh.geof.unizg.hr/DBM/dbm.php>).

Od preostalih parametara potrebni su još γ i w . Parametar γ je izražen u jedinicama 10^{-7} km^{-1} i može poprimiti već diskutirane vrijednosti u rasponu od 0.2 do 2. Masivni CME-i karakterizirani su malim vrijednostima γ dok CME-i male mase imaju najveće vrijednosti za γ . Brzina Sunčeva vjetra, w u većini slučajeva ima vrijednosti između 300-600 kms^{-1} . U prisutnosti izraženijih koroninih šupljina na Suncu potrebno za w koristiti nešto veće vrijednosti, tj. 500-600 kms^{-1} dok u razdobljima bez koroninih šupljina sa sporijim Sunčevim vjetrom, w može poprimiti vrijednosti od 300-400 kms^{-1} . U određivanju brzine Sunčeva vjetra koristan je prognostički model brzine Sunčeva vjetra iz rada [Rotter i sur. \(2012\)](http://oh.geof.unizg.hr/CH/ch.php) (<http://oh.geof.unizg.hr/CH/ch.php>). Koristeći različite vrijednosti za γ i w (parametri koje je najteže procijeniti i povezani su s najvećim nesigurnostima) također je moguće odrediti prozor u kojem se očekuje dolazak ICME-a.

Zadnje (sedmo) polje odnosi se na udaljenost objekta u Sunčevom sustavu (R_{target}) izraženu u astronomskim jedinicama za koji model vrši proračun. U slučaju Zemlje R_{target} ima vrijednost 1.

Nakon što se proračun modela pokrene pritiskom na gumb "calculate", pojavljuje se stranica s rezultatima DBM-a (slika 2.7) na kojoj se nalazi datum i vrijeme dolaska ICME-a na R_{target} (ili na Zemlju u slučaju da je $R_{\text{target}} = 1$), tranzitno vrijeme od Sunca

Forecasting the Arrival of ICMEs: The Drag-Based Model

Results | [v-R-t plots](#) | [Documentation](#)

Output:

CME arrival at target (date & time): **06.06.2008 at 00h:12min**
Transit time: **91.94** h
Impact speed at target (at 1 AU): **426** km/s

Input parameters:

CME take-off date & time: **02.06.2008 at 04h:16min**
 $R_0=22 R_s$, $v_0=306$ km/s, $\Gamma=2\times 10^{-7}$ km $^{-1}$, $w=440$ km/s, $R_t=1$ AU.

Calculated in 0.26 seconds.

Slika 2.7.: Web stranica s izračunatim (izlaznim) vrijednostima DBM-a.

do R_{target} u satima i brzina ICME-a pri R_{target} .

U sklopu europskog FP7 projekta COMESEP (COronal MAAss Ejections and Solar Energetic Particles) načinjena je također potpuno automatizirana verzija DBM-a koja u stvarnom vremenu koristi podatke mjerenja satelita (STEREO) i ubacuje ih direktno u model kako bi se predvidio dolazak ICME-a na Zemlju (<http://comesep.eu/alert/>).

3. Kozmičko zračenje

3.1. Osnovne značajke kozmičkoga zračenja

Kozmičko zračenje, CR, se definira kao skup subatomske čestice velikih energija koje dolaze iz svemira i sudaraju se sa Zemljinom atmosferom. Iako bi točnije bilo “kozmičke čestice”, naziv kozmičko zračenje je ostao iz doba otkrića čestica, kada se vjerovalo da su one oblik elektromagnetskoga zračenja.

Kozmičko zračenje je otkrio Viktor Hess ([Hess, 1912](#)) u eksperimentima s balonima, primijetivši da se elektroskopi na većoj visini brže prazne. To je pripisao do tada nepoznatoj vrsti zračenja koje dolazi iz svemira. Za ovo je otkriće 1936. godine dobio Nobelovu nagradu.

Primarne čestice kozmičkoga zračenja, tj. one koje su nastale izvan Zemljine atmosfere, sastavljene su uglavnom od nukleona (~99 %) i malim dijelom od elektrona (~1 %). U nukleonskom dijelu kozmičkog zračenja prevladavaju protoni (~90 %), zatim slijede jezgre helija ili tzv. alfa-čestice (~9 %) i na kraju jezgre atoma težih elemenata s atomskom masom do 90, koje su zastupljene s oko 1 % ([Toptygin, 1985](#)). Točna zastupljenost pojedinih čestica ovisi o njihovim energijama, a uz spomenute čestice prisutne su također i čestice anti-materije koje su trenutačno predmet intenzivnog istraživanja (?).

Po podrijetlu se kozmičko zračenje može podijeliti na: a) galaktičko kozmičko zračenje (GCR)¹ b) Sunčevo kozmičko zračenje (SCR)² i c) anomalno kozmičko zračenje (ACR)³.

GCR ima podrijetlo izvan Sunčeva sustava i karakteriziraju ga čestice najvećih energija (do 10^{21} eV⁴). Čestice GCR-a energija do 10^{18} eV imaju podrijetlo unutar naše galaksije, a mogući izvori su eksplozije i ostaci supernova, pulsari, dvostruke zvijezde te udarni valovi u međuzvjezdanom prostoru. Čestice s energijama većim od 10^{18} eV imaju podrijetlo izvan naše galaksije i nastaju u specifičnim objektima u svemiru kao što su radio galaksije i kvazari. GCR je modulirano Sunčevom aktivnošću (poglavlje 3.2).

Sunčevo kozmičko zračenje, koje se također naziva i Sunčeve energetske čestice (SEP)⁵,

¹eng. *Galactic Cosmic Rays*

²eng. *Solar Cosmic Rays*

³eng. *Anomalous Cosmic Rays*

⁴energija ekvivalentna kinetičkoj energiji bejzbol lopte brzine od 100 km/h

⁵eng. *Solar Energetic Particles*

potječe najvećim dijelom iz Sunčevih bljeskova, kako je to pokazao [Forbush \(1946\)](#). Koronini izbačaji i udarni valovi u međuplanetarnom prostoru mogu također proizvesti SEP. SCR ima mnogo manju energiju u odnosu na GCR. Energija SCR-a najčešće iznosi nekoliko stotina MeV, a vrlo rijetko doseže vrijednosti od nekoliko GeV. Takve čestice u pravilu mogu zbog Zemljinog magnetskog polja prodrijeti do atmosfere samo u polarnim područjima i pri visokim geografskim širinama (poglavlje 3.3). Sastav tih čestica ovisi o svojstvima Sunčevog događaja u kojem su proizvedene.


Anomavno kozmičko zračenje (ACR) otkriveno je tek 1973. godine kao ispupčenje u spektru kozmičkoga zračenja kod nekih elemenata kao što su He, N, O i Ne pri energijama od 10 MeV ([Garcia-Munoz i sur., 1973](#)). Ta treća vrsta kozmičkog zračenja nastaje od neutralnih međuzvjezdanih atoma koji u unutrašnjem dijelu heliosfere bivaju ionizirani, nakon čega, nošeni Sunčevim vjetrom, stižu do graničnog udarnog vala⁶ (poglavlje 3.2, slika 3.2). Kada dođu do graničnog udarnog vala, ioni se s njime u puno navrata sudaraju, što rezultira ubrzanjem tih čestica do energija od nekoliko desetaka MeV. Neke od tih čestica difuzijom ponovno uđu u heliosferu.

Iznad 10 GeV, u spektru kozmičkoga zračenja smanjuje se tok čestica pri porastu energije s eksponentom γ ($E^{-\gamma}$, slika 3.1). Stoga čestice velikih energija imaju malu učestalost (npr. čestica s energijom od 10^{18} eV ima tok od oko 1 čestice po km^2 godišnje). Pri približno 10 MeV spektar pokazuje malo udubljenje. U tom dijelu spektra tok se više ne smanjuje s eksponentom γ i rezultat je superpozicije GCR i SCR. Pri još nižim energijama spektar je podložan promjenama koje ovise o Sunčevoj aktivnosti i heliosferi. U području energija ispod 10 MeV dominiraju Sunčeve energetske čestice. Najveći dio čestica GCR ima energije od 100 MeV do 10 GeV. Važno je napomenuti da je ukupna energija kozmičkog zračenja koje dolazi na Zemlju za faktor 10^9 manja u odnosu na zračenje koje Zemlja dobiva od Sunca i usporediva s količinom zračenja koje zvijezde imaju na noćnom nebu.

Tok kozmičkog zračenja na Zemlji nije konstantan već promjenjiv na različitim vremenskim skalama. Pregled svih promjena je sažeto prikazan u tablici 3.1. Varijacije u kozmičkom zračenju možemo podijeliti na one koje se događaju uslijed promjena geomagnetskog polja i Zemljine atmosfere (zemaljsko podrijetlo) i one koje nastaju u heliosferi (vanzemaljsko podrijetlo). Također postoje periodične i sporadične promjene. Dnevne periodične varijacije zemaljskog podrijetla, za koje je već [Parker \(1964\)](#) postavio teoriju, u pravilu su manje od 1 %. Sporadične promjene geomagnetskog polja za vrijeme geomagnetskih oluja mogu uzrokovati kratkoročne poraste u intenzitetu kozmičkoga zračenja do 10 % (poglavlje 3.3).

Periodične i sporadične promjene kozmičkoga zračenja u heliosferi povezane su s promjenama Sunčeve aktivnosti. Izražene periodične promjene (do 30 %) slijede periode

⁶eng. *termination shock*



Slika 3.1.: Spektar svih hadronskih čestica kozmičkoga zračenja s pripadnim vrijednostima γ eksponenta ($\gamma_1 = 2.68$). Spektar pokazuje tzv. koljeno (eng. *knee*) pri energiji čestica od 10^{15} eV nakon kojeg γ eksponent ima nešto veću vrijednost ($\gamma_2 = 3.15$), što uzrokuje nešto veći pad toka kozmičkoga zračenja na vrlo visokim energijama. (Grieder, 2001)

od 11 i 22 godine (poglavljje 3.2, slika 3.3). Sporadične promjene vezane su uz pojavu Sunčevih bljeskova, koroninih izbačaja i promjena u Sunčevom vjetru (poglavljje 3.6).

GCR u međuzvjezdanom prostoru ima također određene varijacije u vremenu, ali su te varijacije prisutne na vrlo dugim vremenskim skalama većim od 100000 godina (Jokipii i Marti, 1986). Mjerenja određenih radio izotopa u meteoritima su pokazala da je GCR u zadnjih nekoliko milijuna godina otprilike konstantno odnosno unutar oscilacija od 10 % (Vogt i sur., 1990).

Promjene toka kozmičkoga zračenja			
Zemaljsko prodrijetlo		Vanzemaljsko prodrijetlo	
periodične	sporadične	periodične	sporadične
Sezonske varijacije <1 % (promjene u atmosferi uslijed godišnjih doba)	Promjene u geomagnetskom polju porast <10 % (smanjenje vertikalnog graničnog rigiditeta za vrijeme geomagnetskih oluja)	11-godišnje i 22-godišnje varijacije <30% (ciklusi Sunčeve aktivnosti)	SEP porast <300 % (utjecaj SEP događaja)
Dnevne varijacije <1 % (dnevne atmosferske promjene i asimetrija magnetosfere)		27-dnevne varijacije <2 % (Sunčeva rotacija)	Fd i CIR smanjenje<30% (povezano s CME i poremećajima u Sunčevom vjetru)
		Dnevne varijacije <1 % (anizotropija CR toka)	Udarni val (Fd) povećanje <2 % (prije Fd, čestice na udarnom valu od CME-a)

Tablica 3.1.: Vrste i uzroci promjena u toku kozmičkoga zračenja.

3.2. Sunčeva modulacija kozmičkoga zračenja

Osim što emitira kozmičko zračenje nižih energija (SEP), Sunce također utječe na tok galaktičkoga kozmičkog zračenja. Kako bi došle do Zemlje, čestice GCR moraju proći heliosferu, u kojoj dominiraju Sunčev vjetar i međuplanetarno magnetsko polje modulirajući GCR (slika 3.2).

Heliosfera, koju formira Sunčev vjetar šireći se u svim smjerovima od Sunca, može se opisati kao svojevrsni mjehur polumjera od oko 100-150 astronomskih jedinica (AJ)⁷. Budući da Sunčev vjetar sa sobom nosi i Sunčevo magnetsko polje, tj. Sunčevo magnetsko polje je "zamrznuto" u toku Sunčevog vjetra, heliosfera se također može definirati kao magnetski mjehur u međuzvjezdanom prostoru. Sunčev vjetar napušta Sunčevu koronu i na udaljenosti od nekoliko Sunčevih radijusa poprima supermagnetosonične brzine od 300 - 800 kms^{-1} , ovisno o Sunčevoj aktivnosti. Obzirom da brzina Sunčeva vjetra počinje opadati na velikim udaljenostima od Sunca, ona prelazi u submagnetosoničnu brzinu na određenoj udaljenosti od Sunca. Područje gdje se to događa naziva se zaustavni udarni val⁸ (slika 3.2). Svemirska sonda Voyager 1 je 2004. godine na udaljenosti od 94 AJ potvrdila postojanje zaustavnog udarnog vala. Sunčev vjetar završava u heliopauzi⁹, nakon koje počinje područje iza čeonog udarnog vala¹⁰ koje sadrži čestice kozmičkoga zračenja iz međuzvjezdanog prostora (slika 3.2). Zbog utjecaja čestica iz međuzvjezdanog prostora, heliosfera, slično kao i Zemljina magnetosfera, poprima izduženi oblik. Ovisno o Sunčevoj aktivnosti i jačini Sunčevog vjetra, heliosfera se povećava i smanjuje te također jače ili slabije modulira ulazak GCR u heliosferu.

Jačina modulacije GCR je ovisna o energiji čestice koja ulazi u heliosferu i može jako varirati za različite energije. Tako na primjer za vrijeme Sunčevog ciklusa modulacija za čestice energije od nekoliko desetaka GeV iznosi nekoliko postotaka po nukleonu, dok za čestice s energijama od 300 MeV modulacija može imati faktor od 100. Stoga samo kozmičko zračenje vrlo visokih energija ($>100\text{GeV}$) ili neutralni atomi mogu nesmetano proći kroz heliosferu. S druge strane GCR s manjim energijama od stotinjak MeV praktički je potpuno izbačeno iz unutarnjeg dijela heliosfere.


Obzirom da su Sunčev vjetar i Sunčevo magnetsko polje isključivo ovisni o Sunčevoj aktivnosti, za očekivati je da će i modulacija kozmičkog zračenja biti pod utjecajem Sunčeve aktivnosti (slika 3.3, tablica 3.1). U doba veće Sunčeve aktivnosti modulacija GCR je veća pa će tok kozmičkog zračenja biti manji i obrnuto. Zbog toga upravo najveće peri-odične varijacije u toku kozmičkog zračenja u iznosu do 30 % imaju period od 11 godina

⁷1AJ=150 · 10⁶ km

⁸eng. *termination shock*

⁹eng. *heliopause*

¹⁰eng. *bow shock*




Slika 3.2.: Ilustracija heliosfere, Sunčevog vjetra i kozmičkog zračenja. Također su naznačeni trenutačni položaji sonda Voyager (NASA).

kao i Sunčev ciklus (slika 3.3). Osim 11-godišnjih varijacija u toku kozmičkog zračenja, postoje i 22-godišnje varijacije, koje su povezane s promjenom u polaritetu Sunčevog magnetskog polja. Na slici 3.3 može se uočiti da su maksimumi u toku kozmičkoga zračenja na Zemlji različiti: npr. zaobljeni maksimum (1972-1978) slijedi oštar maksimum (1987) što je posljedica različite propagacije čestica kroz heliosferu obzirom na polaritet Sunčevog magnetskog polja¹¹. Postoji još i 27-dnevna varijacija u toku kozmičkoga zračenja koja je povezana sa Sunčevom rotacijom, asimetrijama u međuplanetarnom magnetskom polju i strukturi Sunčevoga vjetra.

Mehanizmi i teorija Sunčeve modulacije kozmičkog zračenja još i dalje nisu u potpunosti poznati pa mjerenja kozmičkoga zračenja i empirički pristupi modulaciji mogu dati novi doprinos teoriji (Lockwood, 1971; Belov, 2000).

Sporadične promjene u toku kozmičkog zračenja, kao npr. Forbusheva smanjenja, su također vezane za Sunčevu aktivnost. Te su varijacije uzrokovane uglavnom koroninim izbačajima i korotirajućim interakcijskim područjima (poglavlje 3.6).

¹¹većina čestica kozmičkoga zračenja je pozitivno nabijena




Slika 3.3.: Tok kozmičkog zračenja izmjeren pomoću neutronske monitorka Climax (gornji graf) i ugađeni broj Sunčevih pjega (donji graf) u razdoblju od 1950. do 2006. godine. Promjene u polaritetu Sunčeva magnetskoga polja su označene s N (sjever) i S (jug). (?)

3.3. Geomagnetsko polje i kozmičko zračenje

Zemljino geomagnetsko polje, slično kao i heliosfera, modulira tok kozmičkoga zračenja. Na geomagnetsko polje snažno utječu Sunčev vjetar i interplanetarno magnetsko polje i ono stoga ima izdužen oblik (slika 3.4). Mogućnost da nabijene čestice kozmičkog zračenja prođu kroz geomagnetsko polje i dospiju u Zemljinu atmosferu ovisi o vertikalnom graničnom geomagnetskom rigiditetu (VGGR)¹² i upadnom kutu čestica (Cooke i sur., 1991; Smart i sur., 2000). Magnetski rigiditet se definira kao $P = p/q = r_L * B$ gdje je p impuls, q naboj čestice, a r_L predstavlja Larmorov polumjer koji određuje mogućnost da čestica prođe kroz magnetsko polje na određenoj lokaciji (Herbst i sur., 2013).

VGGR je definiran kao minimalni moment po naboju čestice koji je potreban da ta čestica dosegne određenu lokaciju, a moguće ga je izračunati za svaku točku u Zemljinoj magnetosferi (Shea i sur., 1985) kako je prikazano na slici 3.5. Samo nabijene čestice s energijama većim od VGGR mogu pod određenim kutem doseći određenu točku u Zem-


¹²eng. *cut-off rigidity*



Slika 3.4.: Shematski prikaz Zemljinog geomagnetskog polja (Grieder, 2001).

ljinoj magnetosferi. VGGR raste od magnetskih polova do ekvatora gdje ima najveće vrijednosti (slika 3.5) pa intenzitet kozmičkoga zračenja sukladno tome opada od polova do ekvatora.

Geomagnetsko polje nije konstantno nego varira u ovisnosti o promjenama u Zemljinom magnetskom dinamu. Te promjene su relativno spore i događaju su na dugoročnim skalama od 1000 godina. Međutim, u periodima dužim od 100 godina takve promjene mogu dovesti do razlika u modulaciji kozmičkoga zračenja od nekoliko postotaka (Herbst i sur., 2013). Postoji i kratkoročna komponenta promjene geomagnetskog polja, vezana za promjene Sunčevog vjetrova i interplanetarnog magnetskog polja.



Slika 3.5.: Primjer vertikalnog graničnog magnetskog rigiditeta (VGGR) iznad troposfere na visini od 20 km za 19.3.1991. u 00:00 sati (UTC) kao funkcija geografske dužine i širine. Profil VGGR je izračunat pomoću modela "Tsyganenko89c" s programom PLANETOCOSMIC (poglavlje 6.1.1). Ubačena slika gore desno prikazuje iste podatke projicirane na kartu svijeta.

3.4. Atmosferski pljuskovi čestica uzrokovani kozmičkim zračenjem

Nakon prolaska kroz geomagnetsko polje čestice kozmičkoga zračenja zbog svoje velike energije pokreću nuklearne reakcije u Zemljinoj atmosferi. Pri ulasku u atmosferu primarne čestice kozmičkoga zračenja sudaraju se s molekulama, najčešće s kisikom ili dušikom, te pri tome nastaju daljnje čestice kao što su pioni, mioni, neutroni, protoni, elektroni, neutrini, fotoni itd. (slika 3.6). Takav proces se naziva atmosferski pljusak čestica ili atmosferska kaskada¹³, jer stvorene čestice, ako imaju dovoljno energije, mogu prouzročiti daljnje nuklearne reakcije i nove čestice. Čestice nastale kao produkt interakcije primarnih čestica s materijom odnosno u nuklearnim reakcijama nazivaju se sekundarne čestice. Proces atmosferske kaskade se prekida kada sekundarne čestice više ne posjeduju

¹³eng. *cosmic ray shower*

3. Kozmičko zračenje

dovoljno energije da pokrenu nove nuklearne reakcije.

Nuklearne reakcije u atmosferi su istovjetne onima koje su predmet istraživanja u nuklearnoj fizici te fizici elementarnih čestica i ispituju se u modernim akceleratorima na Zemlji. Zanimljivo je spomenuti da najveći akcelerator čestica na svijetu, CERN-ov LHC¹⁴, ima 8 redova veličina manju energiju (14 TeV) nego čestice kozmičkoga zračenja s najviše izmjerene energije.



Slika 3.6.: Shematski prikaz atmosferskog čestičnog pljuska. (Close i sur., 1989)

Čestice kozmičkog zračenja u atmosferi mogu se općenito podijeliti na tri komponente: a) mionsku (mioni koji su nastali raspadanjem piona), b) elektromagnetsku (rendgensko i γ zračenje) i c) hadronsku komponentu (npr. nastali protoni i neutroni).

Sekundarne čestice mogu, osim u nuklearnim reakcijama (elastični i neelastični sudari),

¹⁴eng. *Large Hadron Collider*

nastati i u elektromagnetskim međudjelovanjima (ionizacija, "Bremsstrahlung", fotoelektrični efekt, Comptonov efekt itd.) te u reakcijama nuklearnog raspada (veliki broj nastalih čestica naime nije stabilan). Na slici 3.6 može se uočiti da do Zemljine površine stiže samo mali broj čestica što je i omogućilo život na Zemlji budući da su visokoenergetske čestice štetne za većinu organizama na Zemlji. Tok sekundarnih čestica na visini od 15 do 20 km doseže maksimum jer su tamo zbog gustoće atmosfere nuklearne reakcije najučestalije.

Važan proces u atmosferskim pljuskovima čestica je ionizacija (Bazilevskaya i sur., 2008). Osim protona i drugih nabijenih čestica ionizaciji također mogu u manjoj mjeri doprinijeti i neutroni. Ionizacija je najveća na visini od oko 12 do 15 km i smanjuje se prema Zemljinoj površini (poglavlje 6.1.1, slika 6.4).

3.5. Detekcija kozmičkoga zračenja


Kozmičko zračenje može se detektirati na više načina, što ovisi o vrsti čestica koje se detektiraju i lokaciji na kojoj se detektiraju (npr. na površini Zemlje, na nekoj visini u atmosferi, pomoću satelita izvan geomagnetskog polja). Sateliti i letjelice imaju prednost da mogu detektirati smjer čestica kozmičkoga zračenja jer imaju pristup primarnim česticama u međuzvezdanom prostoru. Baloni ne mogu detektirati smjer kozmičkoga zračenja budući da su ispod geomagnetskoga polja koje utječe na smjer čestica, ali na visinama od 40-70 km mogu također detektirati primarne kozmičke čestice. Detektori na površini Zemlje detektiraju samo sekundarne čestice kozmičkoga zračenja. Postoji više tipova detektora kao što su npr. Čerenkovljevi detektori koji mjere elektromagnetsko zračenje (Čerenkovljev efekt), mionski detektori koji mjere mione ili neutronske monitori koji mjere neutrone.

Zbog velikog broja neutrona koji nastaju u atmosferskim kaskadama te zbog svoje jednostavnosti i pouzdanosti, neutronske monitori (NM) su se pokazali najefikasnijima za mjerenje ukupnoga spektra kozmičkoga zračenja. Položaj NM određuje njegov VGGR pa stoga i energije čestica koje mogu detektirati. Zbog toga je 50-tih godina 20-tog stoljeća započeto postavljanje svjetske mreže NM-a. Danas se ta mreža sastoji od 50 do 70 postaja¹⁵ razmještenih po cijelom svijetu (slika 3.7).

Princip rada neutronske monitora temelji se na nuklearnim reakcijama u kojima se koriste određeni izotopi (npr. ^{10}B). Ti izotopi se u sudaru s neutronima raspadaju na druge elemente ili izotope (npr. ^7Li) i pri tome nastaju nabijene čestice (α čestice)¹⁶ koje se potom detektiraju. Izotopi su najčešće smješteni u cijevima okruženima tzv.

¹⁵broj varira od godine do godine, jer neke postaje prestaju s radom, a neke počinju

¹⁶čestice identične jezgri Helija, koje se sastoje od 2 protona i 2 neutrona



Slika 3.7.: Položaji NM postaja na svjetskoj karti. Crne linije označavaju područja istog vertikalnog graničnog geomagnetskog rigiditeta u GeV. (IZMIRAN, <http://cr0.izmiran.rssi.ru>)

moderatorom i olovom koji omogućuju efikasniju detekciju. Najčešće vrste neutronske monitora su IGY i NM-64, a razlikuju se po broju cijevi, vrsti moderatora i dizajnu.

Postoje i indirekne metode mjerenja kozmičkoga zračenja na Zemlji. Naime, kozmičko zračenje prirodno stvara neke izotope u atmosferi (kozmodogeni radionuklidi) kao ^{10}Be i ^{14}C . Koncentracije tih izotopa mogu se izmjeriti u uzorcima leda (^{10}Be) ili drva (^{14}C) te određenim modelima izračunati tok kozmičkog zračenja u Zemljinoj povijesti do više desetaka tisuća godina u prošlost, a u nekim slučajevima i za puno duža razdoblja (poglavlje 3.8).

3.6. Forbusheva smanjenja i sporadične promjene kozmičkoga zračenja


Forbusheva smanjenja (Fd)¹⁷ su nagla smanjenja u toku kozmičkoga zračenja koja traju po nekoliko dana. Prvi ih je uočio Scott E. Forbush za vrijeme 17-mjesečnog eksperimenta s ionizacijskim komorama smještenim na različitim lokacijama po svijetu (Forbush, 1938).

Isprva se je vjerovalo da su Forbusheva smanjenja uzrokovana poremećajima u geomagnetskom polju za vrijeme geomagnetskih oluja. Tek su promatranja Forbushevih smanjenja na geomagnetskim polovima u pedesetim godinama 20. stoljeća pokazala da

¹⁷eng. *Forbush decrease*

su Sunčeva aktivnost i promjene u Sunčevom magnetskom polju glavni uzroci ove pojave (Simpson, 1954).

Danas je poznato da su za Forbusheva smanjenja odgovorni međuplanetarni koronini izbačaji, ICME-i. Naime udarni val i odaslane Sunčeve energetske čestice mogu u vrlo kratkom roku prouzročiti značajna smanjenja u toku galaktičkoga kozmičkoga zračenja (Lockwood, 1971). Forbusheva smanjenja se mogu okarakterizirati s dvije faze pada kozmičkoga zračenja (Flückiger, 1985; Cane i sur., 1994). Prvu fazu uzrokuje područje turbulentnog magnetskog polja iza udarnog vala¹⁸, a u drugoj fazi se tok galaktičkoga kozmičkoga zračenja dodatno može smanjiti prolaskom nešto sporijeg izbačaja¹⁹ odnosno magnetoplazme (slika 3.8).




Slika 3.8.: Primjer dva Forbusheva smanjenja (lijevo - rujn 1978, desno - travanj 1979) koja jasno pokazuju dvije faze (udarni val i izbačaj). Tanka linija prikazuje razvoj Forbushevog smanjenja pod utjecajem udarnog vala, a iscrtkana površina djelovanje izbačaja. Satno usrednjeni podaci izmjereni su pomoću tri neutronska monitora (Deep River, Mt. Wellington, Kerguelen, SAD); standardno odstupanje je prikazano na dnu slike. (Wibberenz i sur., 1998)

Na slici 3.9 su prikazana dva moguća scenarija: scenario A s klasičnim Forbushevom smanjenjem u dvije faze i scenario B s postupnijim Forbushevom smanjenjem, jer je izbačaj promašio Zemlju pa je na tok kozmičkoga zračenja utjecao samo udarni val. Udarni val u pravilu uzrokuje smanjenje u kozmičkom zračenju od nekoliko dana dok se prolazak izbačaja može smatrati lokalnim efektom i traje oko 1 dan (slika 3.8). Tok kozmičkoga

¹⁸eng. *shock*

¹⁹eng. *ejecta*

zračenja se vraća na prvobitne vrijednosti u roku od oko 5 dana²⁰ (Cane, 2000; Dumbović i sur., 2011). Obje komponente, udarni val i izbačaj, obično pridonose smanjenju kozmičkoga zračenja u jednakim omjerima, no u mnogim slučajevima njihova superpozicija može prouzročiti kompleksne strukture u padu kozmičkoga zračenja.



Slika 3.9.: Shematski prikaz koroninog izbačaja s udarnim valom i izbačajem koji dovode do Forbushevog smanjenja. Desni profil intenziteta kozmičkoga zračenja (A) prikazuje klasično Forbushevo smanjenje u dvije faze, gdje prvo udarni val (S), a potom izbačaj (Ej) smanjuju intenzitet kozmičkoga zračenja. Lijevi profil intenziteta kozmičkoga zračenja (B) prikazuje slučaj kada na pad kozmičkoga zračenja utječe samo udarni val jer izbačaj, koji ima manji polumjer širenja od udarnog vala, promaši Zemlju. (Cane, 2000)

Amplituda smanjenja toka kozmičkoga zračenja tijekom Forbushevih događaja usko je povezana s povećanjem jakosti magnetskoga polja i njegovim fluktuacijama, a to je pak posljedica poremećaja u Sunčevu vjetru odnosno prolaska ICME-a pored Zemlje (Dumbović i sur., 2011, 2012b). Nadalje, trajanje Forbushevog smanjenja također ovisi o veličini ICME-a i jakosti magnetskoga polja. Period uspostavljanja prvobitnog toka kozmičkoga zračenja može se objasniti djelovanjem "sjene" ICME-a na kozmičko zračenje. Kako se ICME odmiče od Zemlje tako je utjecaj "sjene" sve manji pa se tok kozmičkoga zračenja vraća na vrijednosti prije poremećaja. To je također razlog da vremena početka,

²⁰može varirati od 3 do 10 dana

maksimuma i završetka Forbushovog smanjenja kasne (3, 7 i 26 sati) za promjenama u međuplanetarnom magnetskom polju ([Dumbović i sur., 2011](#)).

Mnoga Forbusheva smanjenja pokazuju mali porast toka kozmičkoga zračenja (npr. B profil slika 3.9) neposredno prije samog događaja, što je posljedica refleksije čestica od samog udarnog vala. Najveća Forbusheva smanjenja mogu rezultirati s 10 % do 25 % pada u toku kozmičkoga zračenja. No, intenzivna Forbusheva smanjenja su rijetka pa u toku jednog Sunčevog ciklusa ima prosječno manje od 10 događaja s intenzitetom većim od 10 % ([Cane, 2000](#)).

U širem smislu Forbusheva smanjenja se mogu povezati i s korotirajućim područjima interakcije, koja su zamjetnija u doba manje Sunčeve aktivnosti i uzrokuju manji (0.5 % - 2 %) i simetričniji pad toka kozmičkoga zračenja ([Dumbović i sur., 2012a](#), sljedeće poglavlje). Obzirom da u doba Sunčeva maksimuma korotirajuća područja interakcije često slijede koronine izbačaje ili im prethode, često ih je vrlo teško identificirati ([Belov i sur., 2001](#)).


3.7. Modulacija kozmičkoga zračenja korotirajućim interakcijskim područjima

Korotirajuća interakcijska područja (CIR)²¹ se definiraju kao područja sabijene plazme koja se stvaraju na vodećim rubovima korotirajućih struja brzog Sunčevog vjetra. Brzi Sunčev vjetar s podrijetlom u koroninim šupljinama²² i s tipičnim brzinama od 500-800 kms^{-1} međudjeluje odnosno "gura" sporiji Sunčev vjetar, koji se kreće ispred njega brzinom od oko 400 km^{-1} . CIR-evi i brze struje Sunčevog vjetra²³ moduliraju galaktičko kozmičko zračenje ([Richardson, 2004](#)), a takve modulacije su povezane s periodom Sunčeve rotacije od 27 dana. Karakteristika CIR-eva su povećana gustoća i jakost magnetskog polja, a potom brza i vruća struja Sunčevog vjetra. Točan mehanizam modulacije kozmičkoga zračenja na Zemlji još nije u potpunosti istražen. U ovom radu načinjena je statistička studija povezanosti CIR događaja i varijacija u toku kozmičkoga zračenja na Zemlji.

²¹eng. *corotating interaction regions*

²²eng. *coronal holes*

²³eng. *high speed streams*



Slika 3.10.: Položaj korištenih NM postaja na karti svijeta. Crvenom bojom su označene postaje na visokim geografskim širinama, žutom na srednjim, a plavom na niskim geografskim širinama. Ispod imena postaja je naznačen VGGR (R_c) i točna geografska širina i dužina.

3.7.1. Podaci i metoda

Korištene su dnevne srednje vrijednosti toka kozmičkog zračenja izmjerene u osam postaja s neutronske monitorima (NM), a podaci su uzeti sa SPIDR²⁴ web stranice²⁵. Obzirom da VGGR ovisi o geografskoj lokaciji, a poglavito o geografskoj širini, NM postaje su izabrane tako da pokrivaju sve geografske širine i dužine. Tri postaje su odabrane za visoke, tri postaje za srednje i dvije postaje za niske geografske širine. VGGR je iznosio $P_c = 0 - 12.91$ GeV (slika 3.10).

U analizi je izbjegnuto period u kojem ima mnogo koroninih izbačaja budući da jaka Sunčeva aktivnost i koronini izbačaji također snažno utječu na kozmičko zračenje. Odabran je period blizu silazne faze Sunčevog ciklusa 23. od 25. siječnja do 5. svibnja 2005²⁶ jer je u tom periodu učestalost koroninih izbačaja bila vrlo mala (Vršnak i sur., 2007b).

Podaci o gustoći protona, n , brzini protona, v i jakosti magnetskoga polja, B su uzeti iz baze podataka s Advanced Composition Explorer (ACE) satelita (Stone i sur., 1998). Dnevni podaci o veličini područja koroninih šupljina na Suncu su određeni iz slika Solar X-Ray Imager-a (SXI), instrumenta koji se nalazi na GOES-12 satelitu. Koronine šupljine su vidljive kao tamnija područja na rendgenskim slikama Sunca (Hill i sur., 2005; Pizzo i sur., 2005). Koristeći jednu SXI level-2 sliku po danu, udjeli područja koroninih šupljina

²⁴Space Physics Interactive Data Resource

²⁵<http://spidr.ngdc.noaa.gov/spidr>

²⁶dani u godini, DOY: 25-125

su izdvojene za tri meridijanska odsječka za heliografske širine: CH E $[-40^\circ -20^\circ]$, CH M $[-10^\circ 10^\circ]$ (slika 3.11) i CH W $[20^\circ 40^\circ]$ (Vršnak i sur., 2007c).

Budući da su promatrane dnevne varijacije u kozmičkom zračenju, podacima mjerenja NM-ima je oduzet srednjak sa svrhom uklanjanja linearnog trenda. Ti podaci su onda korelirani s udjelima površina koroninih šupljina i ACE podacima, omogućujući posmak²⁷ od 10 dana. Statistička značajnost je testirana jednostranim t-testom na 95 % razini pouzdanosti.

Kako bi se odredili periodi koji prevladavaju u podacima kozmičkog zračenja kao i njihova vremena pojavljivanja, korišteni su spektar snage valića²⁸ i globalni spektar snage²⁹ (Torrence i Compo, 1998; Temmer i sur., 2007).

3.7.2. Diskusija i rezultati

Na slici 3.11a prikazan je udio područja koronine šupljine koja se nalazila u središnjem (CH M) odsječku kao funkcija dana u godini 2005 (DOY). Varijacije u zastupljenosti koroninih šupljina pokazuju istaknuti period od oko 9 dana (Temmer i sur., 2007). On se može objasniti položajem velikih koroninih šupljina razmaknutih oko 120° u heliografskoj širini. Slični periodi su pronađeni u mjerenjima Climax NM-a (slika 3.11b) te također u parametrima Sunčevog vjetra izmjerenim ACE satelitom (brzina protona v , slika 3.11c i magnetsko polje B , slika 3.11d). Za vrijeme prolaska korotirajućih interakcijskih područja kozmičko zračenje je imalo tipično smanjen tok za 0.5 % do 2 % (slika 3.11b). Slika 3.12 prikazuje detektirane periode u kozmičkom zračenju koristeći Morlet valić (wavelet), gdje najizraženiji period također iznosi 9 dana (DOY 30-125) sa statističkom pouzdanošću na 95 % razini. Nešto slabiji izraženi periodi se mogu uočiti u području 13.5 dana (DOY 20-65) te 12 i 15 dana (DOY 65-115), što otprilike iznosi pola perioda rotacije Sunca.


Rezultati korelacijske analize za svaku od NM postaja su prikazani u tablici 3.2. U tablici je uočljivo da postoje antikorelacije (srednja vrijednost $r = -0.29$) između udjela površine koroninih šupljina povezanih s CIR i promjena u kozmičkome zračenju. Najveći koeficijenti korelacije su nađeni za posmake od 7, 5 odnosno 3 dana za istočni (CH E), središnji (CH M) odnosno zapadni odsječak (CH W) koroninih šupljina. Značajna povezanost je također uočena u slučaju parametara Sunčevog vjetra: v , B i n (3.2). Najbolja koreliranost s kozmičkim zračenjem je pronađena u slučaju magnetskog polja, B s posmakom od 2 do 3 dana, a potom slijedi gustoća protona, n s karakterističnim posmakom od 4 dana te brzina protona, v s posmakom od 0 do 1 dana.

Iz dobivenih rezultata može se zaključiti da pojačano magnetsko polje, koje se formira

²⁷eng. *lag*


²⁸eng. *Wavelet Power Spectra*

²⁹eng. *Global Wavelet Power Spectra*



Slika 3.11.: a) dnevni udio područja koronine šupljine koja se nalazila u središnjem (M) odsječku, b) relativne promjene u kozmičkome zračenju izmjerene Climax NM-om ($P_c = 3,03$ GeV), c) dnevni srednjaci ACE satelita za brzinu protona v i d) jakost magnetskog polja B . X-os predstavlja dane u 2005. godini (DOY).

na prednjim rubovima brzih struja u Sunčevom vjetru, djeluje kao svojevrsni štit od galaktičkog kozmičkog zračenja smanjujući tok kozmičkog zračenja na Zemlji od 0.5 % do 2 %. Ta pojava je posebno izražena tijekom silazne faze Sunčevog ciklusa, kada su koronini izbačaji rijetki, a pojava koroninih šupljina učestala. Nakon prolaska maksimuma magnetskog polja pored Zemlje, posmak u odnosu na vrijeme najvećeg smanjenja u kozmičkom zračenju je 2 do 3 dana.



Slika 3.12.: Usrednjen spektar snage valića (lijevo) i globalni spektar snage valića (desno) za svih 8 NM postaja zajedno. Period analize podataka je 25.1. do 5.5.2005. (dan u godini, DOY 25-125). Konus utjecaja, pri kojem utjecaj rubova vremenskoga niza postaje značajan, je prikazan ukriženim linijama. Bijelim linijama su omeđena područja s razinom pouzdanosti od 70 % (tanka bijela linija), 80 % (deblja bijela linija) i 90 % (najdeblja bijela linija). Točkasta linija na globalnom spektru snage označava 95 % razinu pouzdanosti.

	CH E	CH M	CH W	v	B	n
NM South Pole	-0.33 (6)	-0.31 (4)	-0.30 (3)	-0.21 (0)	-0.31 (2)	-0.24 (4)
NM Thule	-0.16* (7)	-0.20 (4)	-0.14* (3)	-0.09* (0)	-0.37 (2)	-0.23 (4)
NM Magadan	-0.34 (7)	-0.33 (5)	-0.34 (3)	-0.24 (0)	-0.33 (2)	-0.20 (4)
NM Jungfrauoch	-0.31 (8)	-0.26 (5)	-0.32 (4)	-0.21 (2)	-0.35 (3)	-0.22 (4)
NM Climax	-0.34 (7)	-0.31 (5)	-0.31 (3)	-0.20 (1)	-0.38 (3)	-0.33 (4)
NM Hermanus	-0.27 (7)	-0.27 (5)	-0.27 (3)	-0.11* (1)	-0.38 (3)	-0.32 (4)
NM Haleakala	-0.23 (7)	-0.26 (5)	-0.32 (3)	-0.20 (1)	-0.34 (3)	-0.16* (4)
NM Tibet	-0.34 (7)	-0.39 (5)	-0.41 (3)	-0.27 (1)	-0.38 (3)	-0.18 (4)
average	-0.29 (7.00)	-0.29 (4.75)	-0.30 (3.13)	-0.19 (0.75)	-0.36 (2.63)	-0.24 (4.00)
σ	0.065	0.056	0.078	0.062	0.026	0.063

Tablica 3.2.: Korelacijski koeficijenti za ovisnost izmjerenih vrijednosti kozmičkoga zračenja u 8 NM postaja i područja koroninih šupljina (CH, tri meridonalna odsječka po geografskoj dužini: istočni - CH E, središnji CH M, zapadni CH W), magnetskog polja, B , brzine protona, v i gustoće, n . Prikazan je najveći koeficijent korelacije za vrijeme posmaka od 10 dana, a brojevi u zagradama pokazuju pripadajući posmak za svaki koeficijent korelacije. Vrijednosti koje nisu statistički značajne su obilježene zvjezdicom.

3.8. Kozmogeni radionuklidi i analiza ^{10}Be

Na temelju mjerenja kozmogenih radionuklida (^{10}Be , ^{14}C , ^{36}Cl) moguće je odrediti tok kozmičkoga zračenja i Sunčevu aktivnost u dalekoj prošlosti.

Kozmogeni radionuklidi nastaju kao posljedica nuklearnih međudjelovanja između galaktičkoga kozmičkoga zračenja³⁰ i atoma (N, O, Ar) u atmosferi (Masarik i Beer, 1999, 2009). Nastali izotopi se nakon određenoga vremena talože u prirodnim arhivima kao što je led (^{10}Be , ^{36}Cl) ili godovi u drvetu (^{14}C). Vrijeme zadržavanja u atmosferi ovisno je o geokemijskim svojstvima izotopa. Tako se ^{10}Be veže za aerosole u stratosferi i nakon prosječnog zadržavanja od 1 do 2 godine biva uklonjen iz atmosfere putem oborina te se arhivira u ledu (Heikkilä i sur., 2013). ^{14}C se u atmosferi oksidira u $^{14}\text{CO}_2$ i nakon toga se može zadržavati u različitim CO_2 spremnicima klimatskog sustava: atmosferi, biosferi i oceanima, pri čemu vrijeme zadržavanja varira³¹. Naposljetku $^{14}\text{CO}_2$ putem fotosinteze biva ugrađen u organski materijal (npr. drvo).

Mjerenja izotopa u prirodnim arhivima, koja mogu dosezati tisuće godina u prošlost, omogućavaju da se uz poznavanje procesa njihovog transporta u atmosferi i njihove depozicije odredi produkcija kozmogenih izotopa u atmosferi.

Uspoređivanjem podataka mjerenja ^{14}C i ^{10}Be u vremenu moguće je odvojiti procese utjecaja klimatskog sustava na transport i depoziciju tih izotopa u atmosferi (tzv. efekti sustava) od njihove produkcije koja je određena Sunčevom aktivnošću i geomagnetskim poljem (Beer, 2000). Naime, zbog različitih geokemijskih svojstava ti izotopi imaju sasvim različito ponašanje u atmosferi dok je produkcija oba izotopa na isti način modulirana Sunčevim i geomagnetskim promjenama. Smatra se da je oko 80 % izmjerenog signala izotopa ^{14}C i ^{10}Be određeno produkcijom dok ostatak signala, koji je različit za ^{14}C u odnosu na ^{10}Be , otpada na efekte sustava (Abreu i sur., 2013).

Mjerenjima ^{10}Be može se doseći više stotina tisuća godina u prošlost, a mjerenjima ^{14}C , koji ima kraće vrijeme poluraspada i manje trajne archive, oko 12 tisuća godina u prošlost. Pouzdano određivanje produkcije oba izotopa ograničeno je uvjetima koje nameće ^{14}C , tj. na vremenski period od desetak tisuća godina u prošlost. Osim toga klimatski sustav se prije desetak tisuća godina bitno promijenio pa je vrlo teško pouzdano odrediti efekte sustava prije tog perioda.

Produkcija izotopa određena je tokom kozmičkoga zračenja pa se stoga može smatrati svojevrsnim prirodnim neutronske monitorom. Sukladno tome mjerenja neutronske monitorima, dostupna od sredine prošloga stoljeća, mogu se produžiti na desetak tisuća godina u prošlost (Beer i sur., 2013).

³⁰utjecaj Sunčevoga kozmičkoga zračenja je zanemariv, jer ono posjeduje znatno niže energije

³¹atmosfera 10 godina, biosfera 60 godina, oceani 1000 godina

Za određivanje Sunčeve aktivnosti iz produkcije izotopa potrebni su podaci o geomagnetskom polju. Te podatke je moguće dobiti rekonstrukcijom geomagnetskoga polja pomoću paleo arhiva, kao što su sedimenti na oceanskom dnu (Laj i sur., 2000). Na taj način moguće je odrediti promjene Sunčeve aktivnosti do nekoliko desetaka tisuća godina u prošlosti (Vonmoos i sur., 2006; Steinhilber i sur., 2008), što je daleko veći period od direktnih mjerenja Sunčeve aktivnosti (Sunčeve pjege) koja su počela prije nešto više od dva stoljeća.

Steinhilber i sur. (2008) načinili su rekonstrukciju Sunčeve aktivnosti u posljednjih 9300 godina temeljenu na mjerenjima ^{10}Be izotopa iz ledenih jezgri na Grenlandu. Autori su Sunčevu aktivnost izrazili kao Sunčevu modulacijsku funkciju Φ , koja aproksimativno opisuje modulacijski efekt Sunčevog energetskog spektra na galaktičko kozmičko zračenje (Gleeson i Axford, 1967). Funkcija Φ se može opisati i kao prosječna energija koju izgubi proton galaktičkoga kozmičkog zračenja na putu do Zemlje.


Pomoću Φ moguće je rekonstruirati i druge parametre Sunčeve aktivnosti, kao što je ukupno Sunčevo zračenje (Steinhilber i sur., 2009) ili međuplanetarno magnetsko polje (Steinhilber i sur., 2010). Takvim rekonstrukcijama različitih parametara Sunčeve aktivnosti u dužim periodima nastaju čvršći temelji za predviđanje Sunčeve aktivnosti u budućnosti (Abreu i sur., 2008; Steinhilber i Beer, 2013). Nađena je povezanost Sunčeve aktivnosti s klimatskim oscilacijama u prošlosti (Beer i sur., 2000). Najnovija istraživanja pokazala su da bi gibanje planeta moglo utjecati na dugoročne promjene u Sunčevoj aktivnosti (Abreu i sur., 2012; McCracken i sur., 2014).

U ovome radu analizirani su podaci za Sunčevu modulacijsku funkciju Φ , dostupni u periodu od posljednjih 9300 godina. Podaci su uzeti iz rada Steinhilber i sur. (2008), a vremenska rezolucija podataka je bila 25 godina. Mjerenja ^{10}Be dostupna su i u vremenskim razmacima od 1-2 godine, međutim, usrednjavanjem ^{10}Be podataka na periode veće od 20 godina smanjuju se neželjeni efekti sustava (McCracken i sur., 2004; Beer i sur., 2013). No zbog usrednjavanja na duži vremenski period u podacima više nije moguće razlučiti pojedinačne Sunčeve cikluse već samo dugoročne (stoljetne) varijacije u Sunčevoj aktivnosti.

Na slici 3.13 je prikazan vremenski niz za Φ (plava linija) zajedno s nizom za Φ na koji je primijenjen 200-godišnji klizni srednjak.

Koristeći nefiltrirane podatke za Φ načinjena je spektralna analiza pomoću valića (Morlet) i primjenom metoda opisanih u Torrence i Compo (1998), kojima je moguće identificirati izražene kvazi-periode³². Slika 3.14 prikazuje rezultate spektralne analize. Prije spektralne analize, podaci za Φ su pretvoreni u anomalije na način da je oduzet srednjak cijeloga niza koji je potom normaliziran na njegovo standardno odstupanje (slika 3.14a).

³²kvazi-periodičnost je svojstvo sustava da pokazuje nepravilnu periodičnost




Slika 3.13.: Vremenski niz Sunčeve modulacijske funkcije (Φ) u zadnjih 9300 godina. Nefiltrirani Φ je prikazan plavom linijom, a Φ na koji je primijenjen 200-godišnji klizni srednjak crvenom debelom linijom.

Wavelet spektar snage je prikazan na slici 3.14b, a različite boje označavaju vrijednosti u spektru snage pri čemu su crvenom bojom označene najveće vrijednosti. Uočava se period od oko 1000 godina, koji se proteže kroz veći dio vremenskog niza za Φ . Nadalje je vrlo izražen period od oko 2000 godina, koji je prisutan u cijelom vremenskom periodu analize. Međutim, procjene valića (wavelet) za periode od 2000 godina i duže nisu pouzdane jer na njih utječu rubovi konačnoga vremenskog niza (tzv. konus utjecaja, crna linija na slici 3.14b). Od kraćih perioda prisutni su kvazi-periodi od 210 (Suess ciklus), 350 i 700 godina. Svi spomenuti periodi prikazani su za cijeli vremenski niz Φ u globalnom spektru valića na slici 3.14c. Slika 3.14d prikazuje spektar snage valića usrednjen za periode od 800 do 1200 godina. Uočljivo je da je period od 1000 godina nešto manje izražen između -2000 i 500 godine. Treba napomenuti da kraći periodi također mogu utjecati na veću izraženost dužih perioda.

Daljna analiza Φ niza načinjena je pomoću Period04 programa (Lenz i Breger, 2005). Deset najizraženijih perioda za Φ je prikazano u tablici 3.3. Nađeni periodi sukladni su s dobivenim periodima u analizi valića. Tako npr. drugi period u tablici 3.3 iznosi 976 godina. Treći period iznosi 2169 godina, što ugrubo odgovara tzv. Hallstatovom ciklusu (Vasiliev i Dergachev, 2002). Iz paleoklimatskih arhiva je poznato da klimatske oscilacije posjeduju slične periode (Dansgaard i sur., 1984; Pestiaux i sur., 1988).

podaci Φ su također analizirani pomoću modela prigušenog slučajnog hoda³³. Taj model temelji se na modelu slučajnog hoda koji je često korišten u fizici Sunca (npr. Leighton, 1964) i posjeduje dodatni korigirajući parametar koji sve devijacije usmjerava prema srednjaku na vremenskoj skali od τ (Kelly i sur., 2009). Pokazalo se da model

³³eng. *damped random walk*



Slika 3.14.: Spektralna analiza za Sunčevu modulacijsku funkciju (Φ) koristeći Morlet valice. a) Vremenski niz za Φ , bez primjene filtra, koji je izražen kao anomalija normirana na standardno odstupanje. b) Wavelet spektar snage: crvenom bojom su označene najveće vrijednosti u spektru snage; konus utjecaja, pri kojem utjecaj rubova vremenskoga niza postaje značajan, je prikazan crnom linijom. c) Globalni spektar snage valica (srednja vrijednost snage valica za cijelo razdoblje analize). d) Usrednjeni spektar snage valica za periode od 800 do 1200 godina u ovisnosti o vremenu. Crtkane crvene linije označavaju intervale pouzdnosti na 95 % razini, koji su izračunati na temelju autokorelacijske funkcije ($\alpha_1 = 0.96$) i crvenoga šuma.

Broj	Period (godine)
1	10970
2	976
3	2169
4	207
5	715
6	351
7	790
8	500
9	365
10	3454

Tablica 3.3.: Deset najizraženijih perioda u vremenskom nizu Φ izračunatih pomoću Period04 programa.

prigušenog slučajnog hoda najbolje reproducira niz Φ sa τ od 1000 godina ([Hanslmeier i sur., 2013](#)).

Period od 1000 godina pronašao je i [Ma \(2007\)](#) koristeći rekonstruirane podatke broja Sunčevih pjega za posljednjih 11400 godina temeljenih na mjerenjima ^{14}C .

Rekonstrukcija geomagnetskog polja Zemlje opterećena je pogreškama, a one su izvor mogućih pogrešaka u rekonstrukciji Sunčeve aktivnosti, tj. u ovom slučaju Φ . No te pogreške imaju utjecaj na dužim vremenskim skalama. Za pretpostaviti je da bi periodi duži od 3000 godina mogli biti rezultat sporih promjena u geomagnetskom polju dok su periodi reda veličine od 1000 godina Sunčevog podrijetla ([Usoskin i sur., 2009b](#)).

4. Sveza kozmičkoga zračenja i naoblake

4.1. Utjecaj Sunčeve aktivnosti na Zemljinu klimu

Ideja da Sunčeva aktivnost utječe na Zemljinu klimu postoji već preko dva stoljeća ([Herschel, 1801](#)), a od sredine druge polovice 20-og stoljeća nižu se radovi koji upućuju na tu povezanost ([Eddy, 1976](#); [Herman i Goldberg, 1978](#); [Hoyt i Schatten, 1997](#)). U novije vrijeme postalo je moguće naprednim tehnikama (npr. određivanje ^{10}Be radionuklida iz leda) i pomoću indirektnih podataka (npr. sedimenti, sige, ledene jezgre itd.) načiniti niz paleo-klimatoloških studija koje ukazuju na čvrstu povezanost Sunčeve aktivnosti i nekih klimatskih parametara ([Ram i Stolz, 1999](#); [Beer i sur., 2000](#); [Bond i sur., 2001](#); [Fleitmann i sur., 2003](#); [Versteegh, 2005](#)).

Obzirom da je Sunčevo zračenje glavni izvor i pokretač klimatskoga sustava na Zemlji, logično je smatrati da će promjene u zračenju uzrokovati i klimatske promjene. Od kada je započela operativna era satelita, u zadnjih 30-tak godina, moguće je točno mjeriti količinu ukupnoga Sunčeva zračenja (TSI) iznad atmosfere. Ta mjerenja su pokazala da TSI varira samo 0.1 % tijekom Sunčevih ciklusa ([Fröhlich, 2006](#)), što samo po sebi nije dovoljno da objasni značajniji utjecaj na klimu¹.

No ipak, mnoga opažanja ukazuju na značajne klimatske promjene uzrokovane Sunčevom aktivnošću, koje vrlo često imaju regionalni karakter ([White i sur., 1997](#); [Meehl i sur., 2008](#); [Tung i Camp, 2008](#)). To sugerira da moraju postojati kompliciraniji mehanizmi, koji nisu nužno linearni te koji određenim spregama uzrokuju promatrane promjene u klimi. Većina tih mehanizama je tek u fazi istraživanja i validacije, a često je teško razdvojiti određene utjecaje, koji mogu djelovati istovremeno na iste klimatske parametre.

Mehanizmi koji objašnjavaju utjecaj varijacija u Sunčevoj aktivnosti na klimatske promjene mogu se podijeliti u dvije grupe (slika 4.1): one koji kao uzrok klimatskih promjena razmatraju 1) promjene u Sunčevom zračenju (TSI, UV) i 2) promjene u toku energetskih čestica (SEP, GCR).

¹prema IPCC ([IPCC, 2013](#)) TSI uzrokuje promjene bilance energije klimatskog sustava od 0.05 W m^{-2} (eng. *radiative forcing*)

Zamislivo je da i male varijacije u TSI dugoročno utječu na oceane. Oceani posjeduju veliki toplinski kapacitet i u mogućnosti su dugoročno skladištiti male promjene u toplini (Meehl i sur., 2008; Roy i Haigh, 2010). To onda utječe na površinsku temperaturu oceana (SST)², a ona može uz određene unutarnje klimatske oscilacije (npr. ENSO, kvazi-desetljetna oscilacija, QDO³) i sprege imati značajan klimatski odziv (slika 4.1). Takav mehanizam se po smjeru propagacije naziva "odozdo prema gore"⁴ mehanizam.

Sunčevo UV zračenje, iako posjeduje samo jedan mali dio odaslane ukupne Sunčeve energije, ima tijekom 11-godišnjega Sunčeva ciklusa mnogo veće varijacije nego TSI. Varijacije do 6 % su prisutne u dijelu spektra pri 200 nm, gdje se događa disocijacija kisika i produkcija ozona, a do 4 % u području pri 240-320 nm, gdje je apsorpcijsko djelovanje ozona najveće. Te varijacije utječu na promjene zastupljenosti ozona stvarajući temperaturne anomalije ekvatorijalnih područja niže stratosfere (slika 4.1) u iznosu od otprilike 1 do 2 K tijekom Sunčeva ciklusa (Labitzke i van Loon, 1993; Haigh, 1996; Austin i sur., 2008). Anomalije dalje utječu na strujanja u stratosferi, pri čemu se mogu proširiti i pojačati (Kodera i Kuroda, 2002). Predloženo je više sprege koje pridonose da se ti poremećaji dalje šire iz stratosfere do troposfere, a one su povezane s kvazi-bijenalnom oscilacijom (QBO)⁵ te drugim klimatskim oscilacijama (slika 4.1). Ovakav mehanizam naziva se po smjeru propagacije "odozgo prema dolje"⁶ mehanizam.

Pretpostavlja se da bi oba spomenuta mehanizma mogla biti istovremeno aktivna, što u konačnici može još pojačati odziv u troposferi, ako se u obzir uzmu sve sprege i dinamički efekti u atmosferi (Meehl i sur., 2009). Klimatski modeli koji opisuju te mehanizme su za sada ograničeni na područje do vrha troposfere ili stratosfere. Za sada ne postoji cijelokupni model koji bi povezao sve sprege između oceana, troposfere i stratosfere.

Predložen je također mehanizam u kojem čestice kozmičkoga zračenja (posebice SEP), koje pospješuju ionizaciju i disocijaciju, utječu na kemijske sastojke (OH_x , NO_x i ozon) u srednjoj atmosferi (slika 4.1) u vremenskim skalama od nekoliko dana do nekoliko mjeseci (Jackman i sur., 2006). Takve promjene mogu utjecati na koncentraciju i strujanje ozona. No te su promjene uglavnom lokalizirane na stratosferu u polarnim područjima i za sada nema čvrstih dokaza da bi one mogle značajnije utjecati na troposferu.

Kozmičko zračenje također može djelovati na naoblaku (slika 4.1), a dva predložena mehanizma opisana su u sljedećem poglavlju.


²eng. *Sea Surface Temperature*

³ eng. *Quasi-Decadal Oscillation*

⁴eng. *bottom-up*

⁵eng. *Quasi-Biennial Oscillation*

⁶eng. *top-down*



Slika 4.1.: Dijagram utjecaja Sunčeve aktivnosti na Zemljinu klimu. Prikazani su mehanizmi utjecaja Sunčevoga zračenja (TSI i UV) i visoko-energetskih čestica (GCR i SEP). Dvije crtkane strelice označavaju spregu između stratosfere i troposfere te između oceana i atmosfere. T - temperatura, I - struja, AO (*Arctic Oscillation*) - Arktička oscilacija, NAO (*North Atlantic Oscillation*) Sjevernoatlanska oscilacija. (Kodera i Kuroda, 2002)

4.2. Mehanizmi i modeli utjecaja kozmičkoga zračenja na naoblaku

Iznos ukupne energije koju Zemljina atmosfera prima putem kozmičkoga zračenja je vrlo malen. Ta energija je 10^9 puta manja od energije TSI. Stoga je za očekivati da, u slučaju utjecaja kozmičkoga zračenja na naoblaku, mora postojati vrlo efikasan mehanizam koji tu energiju može povećati do vrijednosti koje mogu izazvati značajne klimatske promjene. Tako efikasan mehanizam se može objasniti utjecajem ionizacije atmosfere na oblačne kondenzacijske jezgre (CCN)⁷, koje onda utječu na promjene u naoblaci.

Činjenica da ionizacija može uzrokovati kondenziranje prezasićene⁸ vodene pare u zraku poznata je već preko 100 godina. To je otkrio škotski fizičar Charles Wilson proučavajući nastanak oblaka u posebnoj komori (Wilson, 1911). Wilsonova komora je kasnije korištena kao detektor za proučavanje nabijenih čestica i njihovih kondenzacijskih tragova, što je

⁷eng. *Cloud Condensating Nuclei*

⁸posjeduje relativnu vlažnost veću od 100 %

omogućilo otkriće nekih elementarnih čestica (npr. pozitrona i miona).

Prezasićenje vodenom parom u Wilsonovoj komori iznosi više stotina posto (tzv. homogena nukleacija), a iz iskustva je poznato da takva prezasićenja vodenom parom nikad nisu prisutna u Zemljinoj atmosferi (npr. [Mason, 1971](#)). Naoblaka se u atmosferi formira već pri prezasićenjima vodene pare od nekoliko postotaka, no za razliku od Wilsonove komore u atmosferi postoje sićušne čestice, aerosoli, koji igraju ključnu ulogu u formiranju oblaka kao kondenzacijske ili ledene jezgre (tzv. heterogena nukleacija).

Samo jedan dio čestica aerosola može djelovati kao oblačna kondenzacijska jezgra koja ima mogućnost formirati kapljice u zraku. Naime kapljice koje se formiraju oko čestica aerosola (kondenzacijske jezgre) mogu rasti spontano tek kada te čestice imaju dovoljno veliki promjer. Takav kritičan promjer CCN-a iznosi tipično oko 100 nm ([Henning i sur., 2002](#)). U nekim područjima atmosfere, gdje su izvori aerosola ograničeni, stvaranje i brzina rasta čestica u atmosferi je ključna za stvaranje naoblake. Svaka oborina uklanja čestice aerosola iz atmosfere.

Aerosoli nisu samo odgovorni za stvaranje oblaka već i za njihova svojstva pa tako promjene karakteristika aerosola mogu prouzročiti promjene u npr. gustoći ili životnom vijeku oblaka. Stoga možemo očekivati da svaka promjena svojstva ili broja čestica aerosola može imati za posljedicu promjenu u količini i svojstvima oblaka. Kako su oblaci jedan od najvažnijih čimbenika u bilanci energijskih tokova Zemljinog klimatskog sustava (poglavlje 1, slika 1.3), takve promjene imaju također i snažne klimatske posljedice.


Iako je atmosferska ionizacija putem kozmičkoga zračenja sveprisutna u atmosferi, prirodne radioaktivne tvari (kao npr. radon) mogu također biti važni izvori ionizacije u atmosferi iznad kopna. Stoga kozmičko zračenje doprinosi tek 20 % ionizaciji iznad kopna u planetarnom graničnom sloju⁹ ([Hoppel i sur., 1986](#)). Ionizacija atmosfere putem kozmičkoga zračenja dominira iznad planetarnog graničnog sloja i u područjima iznad mora i oceana.

4.2.1. Mehanizam kondenzacijskih jezgri

U mnogim područjima atmosfere nastanak naoblake ograničen je dostupnim koncentracijama čestica aerosola koje su potrebne za nastanak naoblake. To je naročito izraženo u područjima gdje se zbog nedostatka izvora aerosola (npr. iznad oceana) čestice aerosola formiraju nukleacijom iz dostupnih plinova u tragovima (slika 4.2). Smatra se da u tim područjima ionizacija (odnosno prisutnost iona) može ubrzati nastanak i rast finih¹⁰ čestica aerosola (slika 4.2, [Dickinson, 1975](#); [Yu i Turco, 2000, 2001](#)). Ovaj mehanizam se još

⁹u prosjeku ima visinu od oko 1 km

¹⁰imaju veličinu od nekoliko nm



Slika 4.2.: Shematski prikaz mehanizma oblačnih kondenzacijskih jezgri (CCN).

naziva i mehanizam "čistog zraka" zbog činjenice da u čistom zraku ima vrlo malo čestica aerosola koje mogu poslužiti kao CCN.

Tvar iz koje nukleacijom mogu nastati fine čestice aerosola je npr. sulfatna kiselina (H_2SO_4), a nalazi se u atmosferi kao plin u tragovima. Klasičan mehanizam nukleacije iz sulfatne kiseline ($\text{H}_2\text{SO}_4 - \text{H}_2\text{O}$) koji opisuje nastanak i rast čestica aerosola, nije u mogućnosti objasniti brzine nukleacije koje su prisutne u atmosferi. Problem je naime u tome, što fine čestice aerosola (veličine nekoliko nm) nisu stabilne i imaju tendenciju da opet ispare. Potrebni su dodatni čimbenici koji bi stabilizirali te čestice kako bi mogle dalje rasti do veličina CCN. Stoga su predloženi novi mehanizmi, kao terciarna nukleacija ($\text{H}_2\text{SO}_4 - \text{H}_2\text{O} - \text{NH}_3$) putem amina (Kulmala i sur., 2000), nukleacija inducirana ionima ($\text{H}_2\text{SO}_4 - \text{H}_2\text{O} - \text{ion}$, Raes i sur., 1986) ili nukleacija posredovana ionima $((\text{H}_2\text{SO}_4)_n - (\text{H}_2\text{O})_m$, Yu i Turco, 2000, 2001).

Rast čestica aerosola putem iona potvrdila su i neka direktna mjerenja u troposferi (Hörrak i sur., 1998; Eichkorn i sur., 2002). Budući da je stupanj ionizacije u atmosferi velikim dijelom¹¹ određen tokom kozmičkoga zračenja, za očekivati je da će promjene u intenzitetu kozmičkoga zračenja uzrokovati promjene u nastaku i brzini rasta čestica aerosola.

¹¹iznad planetarnoga graničnoga sloja u kopnenim područjima te iznad oceana i mora

Yu i Turco (2001) procijenili su na temelju modela da bi promjena stupnja ionizacije od 25 % trebala uzrokovati promjene u koncentraciji stabilnih čestica aerosola od najmanje 4 %, a utjecaj bi trebao biti najveći u nižoj troposferi jer tamo koncentracija H_2SO_4 nije ograničena. Prema modelu koji su predložili Lovejoy i sur. (2004), nukleacija putem iona u nižoj atmosferi trebala bi biti znatno manja od one procijenjene u radu Yu i Turco (2001). Kasnije su se obje grupe znanstvenika složile da se najveći efekt nukleacije čestica aerosola putem iona treba očekivati u srednjoj troposferi (Yu, 2002; Kazil i Lovejoy, 2004).

Ionizacijom se može objasniti brži nastanak i rast najfinijih čestica do stabilnih veličina od nekoliko nm, ali ne i daljnji rast tih čestica do veličina od oko 100 nm, kada te čestice mogu djelovati kao CCN. Taj proces ne ovisi o ionizaciji pa tako fine čestice aerosola mogu nastati već nakon nekoliko sati, a za daljnji rast do veličina CCN-a je nekad potrebno i više dana.

4.2.2. Mehanizam globalnoga električnog strujnog kruga

U uvjetima lijepoga vremena, kada nema oblaka, između ionosfere¹² i Zemljine površine teče struja (2 pA m^{-2}), što stvara globalni električni strujni krug (GEC)¹³ (slika 4.3, Wilson, 1906; Burke i Few, 1978; Rycroft i sur., 2000). Razlog tome je električni potencijal između ionosfere i Zemljine površine od otprilike 250 kV. Jedan izvor GEC-a potječe iz elektrificiranih oblaka i aktivnih grmljavinskih nevremena na Zemlji (Wilson, 1916; Rycroft i sur., 2008). Drugi izvor GEC-a je ionizacija u atmosferi putem kozmičkoga zračenja pa sve promjene u kozmičkome zračenju uzrokuju promjene u GEC-u (Tinsley i sur., 1989; Tinsley, 2000).


GEC mehanizam temelji se na opažanjima električnoga polja i vertikalne vodljivosti struje za vrijeme lijepoga vremena koja biva poremećena prisutnošću naoblake u atmosferi (slika 4.4, Tinsley, 2000; Harrison, 2001). Naime, unutar oblaka kapljice vrlo efikasno uklanjanju postojeće ione pa je stoga električna vodljivost u oblacima puno manja nego u područjima izvan oblaka. Zbog toga se u oblacima električno polje povećava toliko dugo dok se opet ne uspostavi električna vodljivost kroz oblake. Posljedica je nakupljanje naboja u prostoru iznad i ispod oblaka. Kapljice i aerosoli u tim područjima mogu imati velike naboje (slika 4.4, Nicoll i Harrison, 2010). Smatra se da električki nabijene kapljice i aerosoli mogu utjecati na različite procese u oblacima, a zbog navedenih specifičnosti mehanizam je također nazvan "uz-oblačni"¹⁴ mehanizam.

Veći naboj čestica aerosola može uzrokovati povećanje učinkovitosti sudara s kaplji-

¹²najviši dio atmosfere (>90 km) koji je ioniziran, a plinovi su u stanju plazme

¹³eng. *Global Electric Circuit*

¹⁴eng. *"near cloud" mechanism*




Slika 4.3.: Prikaz globalnoga električnog strujnog kruga (GEC) između ionosfere i Zemljine površine. Slika desno je pojednostavljeni prikaz GEC-a kao električne sheme. r označava globalni električni otpor između Zemljine površine i ionosfere, R_1 otpor između gornjega sloja oblaka i ionosfere, R_2 otpor unutar oblaka, a R_3 otpor između oblaka i Zemljine površine. (Makino i Ogawa, 1984)

cama¹⁵ (Tripathi i sur., 2006) ili mogućnost zamrzavanja kapljica u podhlađenim vodenim oblacima (Tinsley i sur., 2000). Povećani naboj također može utjecati na nastanak, difuzivni rast kapljica ili na povećanu koalescenciju između kapljica, što na kraju može rezultirati utjecajem na veličinu ili broj kapljica u oblaku (Harrison i Ambaum, 2008; Khain i sur., 2004).

Varijacije u toku kozmičkoga zračenja u ovisnosti o Sunčevoj aktivnosti mogu djelovati na naboj u prostoru uz oblake te tako utjecati na naoblaku. Uz direktni utjecaj na oblake moguć je i indirektni utjecaj, kao npr. na smanjenje oborine ili promjene u latentnoj toplini, koje djeluju na atmosfersku dinamiku i time mogu povećati energiju u sustavima jakih ciklona i oluja (Tinsley i Deen, 1991; Tinsley i sur., 2012).

GEC mehanizam može teorijski objasniti svezu Sunčeve aktivnosti i klime, no on je povezan s brojnim nepouzdanostima jer nedostaju eksperimentalna mjerenja, a detaljni mikrofizikalni procesi u naoblaci su još predmet intenzivnog istraživanja.

¹⁵eng. *electroscavenging*



Slika 4.4.: Shematski prikaz stvaranja nabijenih čestica aerosola na granicama oblaka pod utjecajem GEC-a. Desna strana slike prikazuje izmjerene vrijednosti električnog polja za prikazana područja na slici (iznad oblaka, u oblaku i ispod oblaka). Ionizacija putem kozmičkoga zračenja utječe na GEC i time na električnu nabijenost čestica oko oblaka. (Carslaw i sur., 2002)

4.3. Eksperimentalna istraživanja: ionizacija i nukleacija aerosola

U zadnjih nekoliko godina dva neovisna eksperimenta, SKY eksperiment i CERN-ov CLOUD¹⁶ eksperiment, potvrdila su postojanje brže nukleacije aerosola u prisutnosti iona u odnosu na binarnu neutralnu nukleaciju (Enghoff i sur., 2011; Kirkby i sur., 2011; Almeida i sur., 2013).

U SKY eksperimentu je korišten snop elektrona od 580 MeV za stvaranje iona u komori, a svi pokusi su provedeni na istoj temperaturi (294 K)¹⁷ uz primjenu dvije različite koncentracije sulfatne kiseline (H_2SO_4). Broj čestica većih od 4 nm određen je kondenzacijskim brojačem¹⁸, a nastanak manjih čestica, koncentracija iona i sulfatne kiseline su procijenjeni. Rezultati eksperimenta su pokazali da se je nastanak aerosola značajno povećao u periodima ionizacije proizvedene putem snopa elektrona te je zaključeno da se nukleacijom putem iona može objasniti brzina rasta čestica aerosola u atmosferi (Enghoff

¹⁶Cosmics Leaving Outdoor Droplets

¹⁷naime u troposferi su prisutne puno manje temperature od 294 K

¹⁸Condensation Particle Counter

i sur., 2011).

U eksperimentu CLOUD je mnogo detaljnije simuliran nastanak aerosola u atmosferi. Korišten je 3.5 GeV snop iz CERN-ovog sinkrotrona protona kojim se može postići maksimalna očekivana ionizacija u troposferi ($80 \text{ cm}^{-3} \text{ s}^{-1}$). Komora je bila opremljena visokonaponskom mrežom za uklanjanje iona kako bi se mogla usporediti nukleacija u prisutnosti i odsutnosti iona. Eksperimenti su provedeni pri različitim temperaturama (248 K - 293 K) i koncentracijama sulfatne kiseline. Posebna pažnja je posvećena kontaminaciji komore jer je poznato da i vrlo male koncentracije nekih supstancija mogu utjecati na nukleaciju. Mjerenja su načinjena uz pomoć niza najmodernijih instrumenata (Kirkby i sur., 2011).

Prvi rezultati eksperimenta CLOUD pokazali su da je u prisutnosti amonijaka koncentracije od 100 ppt¹⁹ nukleacija iz sulfatne kiseline 100 do 1000 puta brža od one posredovane ionizacijom, koja je pak 10 puta brža od neposredovane nukleacije (Kirkby i sur., 2011). No čak i u prisutnosti amonijaka ili drugih anorganskih tvari brzina nukleacije aerosola je još uvijek znatno manja od izmjerene brzine nukleacije aerosola u atmosferi. Daljnji eksperimenti su pokazali da dimetilamini u koncentracijama većim od 3 ppt mogu ubrzati nukleaciju za više od 1000 puta u odnosu na onu putem amonijaka, što je do 10^5 puta brže od nukleacije putem iona i odgovara brzinama nukleacije izmjerenim u atmosferi (Almeida i sur., 2013). Sukladno tim rezultatima je zaključeno da je utjecaj ionizacije na nukleaciju čestica aerosola u atmosferi općenito malen (Almeida i sur., 2013).

SKY i CLOUD eksperimenti se razlikuju u konačnim zaključcima o utjecaju ionizacije na nukleaciju aerosola u atmosferi. Moguće je, zbog pojednostavljenog dizajna eksperimenta u slučaju SKY komore, da je došlo do kontaminacije s organskim ili drugim tvarima, koje su mogle prouzročiti daleko veće brzine nukleacije nego što su izmjerene u CLOUD eksperimentu.

4.4. Procjene utjecaja kozmičkoga zračenja na klimu

Mehanizam oblačnih kondenzacijskih jezgri (CCN) temelji se na relativno dobro razvijenim teorijskim osnovama, što je potaknulo neke autore da atmosferskim modelima procijene utjecaj kozmičkoga zračenja na aerosole i naoblaku.

Pierce i Adams (2009) su bili prvi koji su koristili globalni klimatski model opće cirkulacije atmosfere²⁰ kako bi procijenili utjecaj nukleacije aerosola putem iona na koncentracije CCN-a tijekom 11-godišnjega Sunčeva ciklusa. Njihovi rezultati su pokazali da nema značajnih promjena u koncentracijama CCN od Sunčevoga minimuma do Sunčevoga maksimuma, iako se nastanak ultrafinih čestica aerosola povećao za 4 puta. Naime,

¹⁹parts per trillion

²⁰eng. *General Circulation Model*, GCM

kod većih brzina nukleacije mnogo ultrafinih čestica aerosola se natječe za dostupne plinove u tragovima, potrebne za rast do veličina CCN. Stoga čestice pri velikim brzinama nukleacije imaju sporiji rast do CCN veličina nego u slučaju manjih brzina nukleacija. Ako čestice sporo rastu, mogu biti uklonjene iz atmosfere prije nego što uspiju narasti do veličina CCN. Sukladno tome promjene u koncentraciji CCN-a nisu jako osjetljive na promjene u brzini nukleacije (Pierce i Adams, 2009)

Snow-Kropla i sur. (2011) su dobili slične rezultate koristeći globalni kemijski model transporta²¹ koji uključuje mikrofiziku aerosola. S tim modelom je testiran utjecaj promjena kozmičkoga zračenja tijekom Sunčeva ciklusa i tijekom Forbushevih smanjenja. Na temelju simulacija procijenjeno je da je promjena koncentracije CCN-a manja od 0.2 % za čestice veće od 80 nm. Promjene u koncentracijama manjih čestica aerosola (10 nm) su nešto veće, no još uvijek manje od 1 %. Stoga su ti rezultati također pokazali da bi utjecaj mehanizma CCN na naoblaku mogao biti zanemariv.

Nadalje, Dunne i sur. (2012) su u globalnim eksperimentima s mikrofizikalnim modelom aerosola provjeravali utjecaj velikih (15 %) promjena u brzini nukleacije aerosola na nastajanje CCN-a u periodu od 10 dana. Niti oni nisu uočili značajnije promjene u koncentracijama CCN-a u ovisnosti o brzini nukleacije.

Gore spomenutim modelima proučavao se utjecaj kozmičkoga zračenja na nastajanje CCN-a. Kazil i sur. (2012) su otišli korak dalje i pomoću globalnog klimatskog modela pokušali procijeniti utjecaj kozmičkoga zračenja na svojstva naoblake i klimu. Zaključili su da varijacije u kozmičkome zračenju tijekom Sunčeva ciklusa, uzrokujući promjene u česticama aerosola te naoblaci, utječu na bilancu klimatskih tokova energije za samo 0.05 Wm^{-2} (za usporedbu utjecaj CO_2 prema zadnjem IPCC (2013) izvješću je 1.68 Wm^{-2}).

Kao što simulacije pomoću različitih modela pokazuju, nukleacija čestica aerosola putem ionizacije u atmosferi ne utječe značajnije na CCN odnosno na svojstva naoblake na dugoročnim ili kratkoročnim skalama. Za mehanizam globalnoga električnoga kruga za sad ne postoje operativni modeli.

²¹eng. *Chemical Transport Model*, CTM

5. Analize dugoročnih utjecaja kozmičkoga zračenja na naoblaku

O naoblaci opažanoj sa Zemlje postoje podaci od početka prošloga stoljeća, no oni su ograničeni na područja meteoroloških mjernih postaja. Stoga su ti podaci prikladni samo za regionalne (npr. [Udelhofen i Cess, 2001](#); [Sun i Bradley, 2002](#)), ali ne i za globalne analize. Sveobuhvatna globalna motrenja naoblake postala su moguća početkom ere satelita, krajem 70-tih godina prošloga stoljeća.

Danas je dostupno više skupova satelitskih podataka o naoblaci ([Stubenrauch i sur., 2013](#)). Skup podataka međunarodnoga satelitskog projekta klimatologije naoblake (ISCCP)¹ jedan je od najopsežnijih i s najduljim periodom opažanja ([Rossow i Schiffer, 1991](#)). U okviru ovog projekta, započetog 1983. godine, nastala je velika baza podataka, temeljena na ukalibriranim mjerenjima zračenja u vidljivom (VIS) i infracrvenom (IR) području pomoću geostacionarnih² i polarnih³ satelita. ISCCP podaci imaju globalnu pokrivenost naoblake u prostornoj rezoluciji od $2.5^\circ \times 2.5^\circ$ ($280 \times 280 \text{ km}^2$) s vremenskom rezolucijom od 3 sata.

Budući da su dostupni za duža vremenske periode, ISCCP podaci se koriste u dugoročnim analizama globalne ovisnosti naoblake i kozmičkoga zračenja. Međutim mnogi ih autori neoprezno i nekritički upotrebljavaju, što je uzrok raznim pogreškama. U ovom dijelu rada diskutirane su moguće pogreške dugoročnih analiza.

Među prvim koji su koristili ISCCP podatke, bili su [Svensmark i Friis-Christensen \(1997\)](#). Oni su analizirali mjesečne ISCCP podatke o naoblaci tijekom jednog Sunčevog ciklusa (1983-1991) i zaključili da se globalna naoblaka mijenjala za 3-4 % u ovisnosti o promjenama u kozmičkome zračenju. Također su zaključili da se takav utjecaj kozmičkoga zračenja na klimu može usporediti s antropogenim utjecajem stakleničkih plinova na globalno zagrijavanje. Ovaj rad pobudio je u vrlo kratkom roku veliki interes i kontro-

¹eng. *International Satellite Cloud Climatology Project*


²geostacionarni sateliti se nalaze u orbiti na visini od oko 36000 km iznad Zemljinog ekvatora. Takva specifična orbita im omogućava da su smješteni uvijek iznad istog dijela Zemljine površine kojega promatraju.

³polarni sateliti se nalaze u nižim orbitama na visini od oko 850 km. Oni kruže oko Zemlje više puta dnevno po određenom meridijanu što omogućava da dobro pokriju polarna područja koja nisu pokrivena geostacionarnim satelitima.

verzu u znanstvenim i širim krugovima (Kerthaler i sur., 1999; Gierens i Ponater, 1999; Jørgensen i Hansen, 2000; Laut, 2003; Damon i Laut, 2004).

Ponovnom analizom nešto dužeg razdoblja (1983-1994) ISCCP mjesečnih (D2) podataka o naoblaci za različite visinske slojeve⁴, spomenuti autori su našli značajne korelacije između kozmičkoga zračenja i naoblake samo za niski oblačni sloj (0-3.2 km). Srednji i visoki oblačni sloj nisu pokazivali povezanost s kozmičkim zračenjem (Pallé i Butler, 2000; Marsh i Svensmark, 2000).

Ti rezultati nisu bili u skladu s očekivanim utjecajem kozmičkoga zračenja na naoblaku, budući da su tijekom Sunčeva ciklusa promjene u stupnju atmosferske ionizacije najmanje za niske geografske širine i male visine ($\sim 3\%$), a najveće ($\sim 53\%$) za visoke geografske širine i velike visine u atmosferi (slika 5.1, Kerthaler i sur., 1999; Gierens i Ponater, 1999; Jørgensen i Hansen, 2000; Wagner i sur., 2001).



Slika 5.1.: Relativne promjene u stupnju atmosferske ionizacije između Sunčevoga maksimuma i minimuma kao funkcija geografske širine i visine u atmosferi. (Wagner i sur., 2001)

5.1. Provjera korelacija kozmičkoga zračenja i naoblake u razdoblju 1983-1994

S ciljem da se provjeri značajnost korelacija ovisnosti kozmičkoga zračenja i naoblake u razdoblju od 1983 - 1994. (Pallé i Butler, 2000; Marsh i Svensmark, 2000) u ovome

⁴ISCCP D2 podaci o naoblaci razlikuju niski 0-3.2 km, srednji 3.2-6.5 km i visoki >6.5 km oblačni sloj

radu korišteni su istovjetni ISCCP D2 podaci o naoblaci. Slika 5.2a prikazuje mjesečne vrijednosti za nisku naoblaku i kozmičko zračenje i sukladna je rezultatima prikazanima u radu Marsha i Svensmarka (poglavlje 6, slika 6.1).


Marsh i Svensmark (2000) su izračunali pojedinačne koeficijente korelacije za svaki element globalne mreže $2.5^\circ \times 2.5^\circ$, a prethodno su podatke o naoblaci i o toku kozmičkoga zračenja filtrirali 12-mjesečnim kliznim srednjakom. Takva analiza je provedena i u ovome radu (slika 5.2b). Marsh i Svensmark (2000) su izračunali da je 15.8 % korelacija od ukupne globalne pokrivenosti pozitivno značajno te da je vjerojatnost da se ti rezultati dobiju slučajno manja od 0.001 %. Značajnost rezultata procijenili su na temelju izračuna stupnjeva slobode. Izračunali su da ima 160 stupnjeva slobode. Taj izračun je pogrešan obzirom da su analizirani podaci povezani s autokorelacijama (poglavlje 9.5), na što je upozorio i Kristjánsson i sur. (2002). U ovome radu izračunati su efektivna veličina uzorka i pripadajući stupnjevi slobode pomoću metoda, koje su opisali Ripley (1987) i Neal (1993). Izračun je pokazao da globalno usrednjeni mjesečni ISCCP D2 podaci za naoblaku imaju samo 7 stupnjeva slobode, što je u skladu s veličinom uzorka i velikim autokorelacijama.

Značajnost korelacija Marsha i Svensmarka (2000) povezana je s neprimjerenom procjenom efektivne veličine uzorka: autori su granicu značajnosti definirali kao $r \geq 0.6$, a to je premala vrijednost, ako se u obzir uzme da se radi o nizovima s autokorelacijama (poglavlje 9.5).

Problematično je i filtriranje 12-mjesečnim kliznim srednjakom, koje se koristi kako bi se umanjile kratkoročne varijacije. Marsh i Svensmark (2000) su taj postupak primijenili na oba niza, na taj način smanjili efektivnu veličinu uzorka i povećali iznos korelacija (slika 5.2b). Ako se podaci ne filtriraju, dobivene korelacije su očekivano mnogo manje (slika 5.2c). To ukazuje na povezanost korelacija s određenim trendovima u podacima naoblake, a te dugoročne varijacije su vezane za niz daljnjih problema opisanih u sljedećem poglavlju.

Treba napomenuti da Sun i Bradley (2002), koji su raspolagali ISCCP podacima i dugoročnim mjerenjima naoblake sa Zemljine površine (meteorološke postaje i brodovi), nisu dobili rezultate koji bi ukazivali na povezanost kozmičkoga zračenja i naoblake.

5. Analize dugoročnih utjecaja kozmičkog zračenja na naoblaku



Slika 5.2.: a) Globalno usrednjeni mjesečni ISCCP D2 IR podaci za nisku (0-3.2 km) naoblaku (plava linija) i podaci mjerenja kozmičkog zračenja NM-ima iz postaja Moskva i Climax (crvena linija) u razdoblju od lipnja 1983. do prosinca 1994. godine. b) koeficijenti korelacije (r) ovisnosti naoblake i kozmičkog zračenja (podaci iz a) prikazani na svjetskoj karti za sve elemente mreže ($2.5^\circ \times 2.5^\circ$). Oba niza su filtrirana 12-mjesečnim kliznim srednjakom prije korelacijske analize. c) prikazuje iste korelacije kao u b) ali bez filtriranja. Crni krugovi prikazani na slikama b) i c) označavaju područja mjerenja naoblake 3 geostacionarna satelita.

5.2. Pogreške u ISCCP podacima o naoblaci

ISCCP set se sastoji od interkalibriranih podataka dobivenih s različitih satelita, s time da pokrivenost geografskih područja varira u vremenu (slika 5.3). Taj nedostatak sveden je na minimum obradom podataka, no ipak postoje jasne indikacije da su određene detekcijske i kalibracijske pogreške i dalje prisutne.


Koristeći sve dostupne podatke ISCCP-a o naoblaci u razdoblju od 1983. do 2008. godine, moguće je izračunati linearne trendove za svaki element mreže u ISCCP D1 podacima. To je prikazano na slici 5.4. Uočljive su pravilne strukture, koje nisu povezane s dinamikom naoblake u atmosferi. One su posljedica pogrešaka detekcije naoblake pomoću satelita. Područja izraženih kružnih struktura odgovaraju vidnom polju geostacionarnih satelita (Evan i sur., 2007). Takve strukture utječu i na koeficijente korelacije, prikazane na slici 5.2b. Slika pokazuje da je dio izraženih korelacija između kozmičkoga zračenja i naoblake povezan s tim strukturama (označene crnim krugovima na slici 5.2b). To je posebno izraženo u slučaju istočnog dijela Afrike (slika 5.2b).

Na postojanje dugoročnih umjetnih trendova u ISCCP podacima naoblake upozorili su Norris (2000, 2005) i Campbell (2004). Takve trendove u ISCCP podacima su također istraživali Evan i sur. (2007). Oni su došli do zaključka da se detektirana naoblaka gotovo linearno povećava kad se povećava kut vidnog polja geostacionarnih satelita. Naime, instrumenti satelita koji opažaju naoblaku pod pravim kutem, detektiraju u pravilu samo najgornje slojeve naoblake. Kada se kut promatranja povećava, instrumenti satelita opažaju naoblaku više bočno, što omogućava detekciju više slojeva naoblake. Posljedica toga je da instrumenti satelita precjenjuju naoblaku na rubovima vidnoga polja satelita (slika 5.4).


Budući da se broj geostacionarnih satelita, koji su korišteni u ISCCP-u tijekom vremena povećavao (slika 5.3), spomenuta pristranost⁵, povezana s kutem opažanja satelita, se vremenom smanjivala. Kako je bilo sve više geostacionarnih satelita, koji su sve bolje pokrivali ukupnu Zemljinu površinu, mjerenja na rubovima vidnoga polja satelitskih instrumenata su isključivana, što je dovelo do dugoročnoga prividnog smanjivanja naoblake u tim područjima. Zbog toga je porast broja satelita (slika 5.3) tijekom vremena uvjetovao umjetni pad niskog sloja naoblake (slika 5.7a, Norris, 2000, 2005; Campbell, 2004; Evan i sur., 2007).

Daljnji problem, u analizi ovisnosti kozmičkoga zračenja i naoblake su pogreške detekcije niskoga oblačnog sloja uzrokovane prisutnošću visoke naoblake. Na taj problem je već upozorio Pallé (2005). Na slici 5.5 su prikazani mjesečni ISCCP D2 podaci o naoblaci za razdoblje od 1983. do 2008. godine. Može se lako uočiti da niski (plava linija) i srednji

⁵eng. textitbias



Slika 5.3.: Vremenska linija upotrebe geostacionarnih satelita u opažачkom razdoblju ISCCP-a u ovisnosti pokrivenosti geografske dužine. Različite boje označavaju pokrivenost i životni vijek različitih satelita, koji su korišćeni kao izvori podataka za ISCCP. (iz NOAA/NCDC)



Slika 5.4.: Linearni trend svakoga pojedinačnog elementa mreže za ISCCP D1 VIS-IR podatke o naoblaci u razdoblju od 1983. do 2008. godine. Nastala struktura odgovara položaju područja mjerenja naoblake za 3 geostacionarna satelita.


do visoki sloj (crvena linija) naoblake vrlo dobro anti-koreliraju ($r = -0.66$).

Koeficijenti korelacije za ovisnost između niske i srednje do visoke naoblake, izračunati u ovome radu za svaki element mreže, prikazani su na slikama 5.6a (ISCCP IR) i 5.6b (MODIS)⁶. Uočavaju se područja značajnih negativnih korelacija (na 95 % razini, plavo), posebice izraženih na slici 5.6a. One su nastale zbog nedetektirane niske naoblake, jer je bila prekrivena netransparentnim visokim oblačnim slojem. Za MODIS (poglavlje 5.3) podatke o naoblaci (5.6b) su, zbog pouzdanije detekcije, područja negativnih korelacija mnogo manja. Područja s pozitivnim korelacijama, koja su prisutna samo u slučaju ISCCP podataka (5.6a), moguće su uvjetovana pogrešnim izračunom visine naoblake, s posljedicom da su dijelovi visokog transparentnog oblačnog sloja detektirani kao niski (Stubenrauch i sur., 1999).


Nadalje, u ISCCP IR podacima je precijenjena ili podcijenjena količina nekih oblačnih slojeva u područjima gdje je kontrast površine malen u odnosu na naoblaku (Rossow i Schiffer, 1999; Stubenrauch i sur., 1999). Tako je na primjer visoka tanka naoblaka u ISCCP podacima podcijenjena i do 40 %, jer je ISCCP ne može pouzdano detektirati obzirom na mali kontrast u odnosu na površinu pokrivenu snijegom (Stubenrauch i sur., 1999).

⁶MODERate Resolution Imaging Spectroradiometer

5. Analize dugoročnih utjecaja kozmičkoga zračenja na naoblaku



Slika 5.5.: ISCCP D2 VIS-IR podaci o naoblaci za niski sloj (0-3.2 km, plava linija) i srednji do visoki sloj (> 3.2km, crvena linija) u razdoblju od 1983. do 2008. godine. Nizovima su uklonjene sezonske varijacije.



Slika 5.6.: Koeficijenti korelacije ovisnosti niskog (0-3.2 km) i srednjeg do visokog (> 3.2 km) sloja naoblake za svaki element mreže prikazani na svjetskoj karti. a) ISCCP IR, b) MODIS podaci o naoblaci. Prikazane su samo značajne korelacije na 95 % razini, a područja gdje nema značajnih korelacija su prikazana sivom bojom.

Na slici 5.5 su uočljive nagle promjene u naoblaci za oba prikazana oblačna sloja, koje uglavnom nisu vezane za stvarne promjene naoblake. Takvi nagli skokovi u količini naoblake (npr. u listopadu 2001) povezani su s promjenama u konstelaciji opažачkih satelita kao što su lansiranja novih satelita, premještanja satelita, kvarova na satelitima [Evan i sur. \(2007\)](#) ili promjena referentnog satelita zaduženog za međukalibraciju podataka ([Knapp, 2008](#)).

Treba napomenuti da i sami autori ISCCP podataka, [Brest i sur. \(1997\)](#) ističu da ti podaci nisu dovoljno precizni, da bi vrijednosti malih promjena u naoblaci na dugoročnim vremenskim skalama bile pouzdane. Ukupne relativne pogreške u kalibracijama zračenja, izmjerenog instrumentima različitih satelita, iznose $\leq 5\%$ za VIS $\leq 2\%$ za IR podatke, dok su apsolutne pogreške nešto veće i iznose $\leq 10\%$ za VIS i $\leq 3\%$ za IR ([Brest i sur., 1997](#)).

5.3. Korelacije i satelitski podaci o naoblaci u posljednje 3 dekade

Na temelju ISCCP podataka dostupnih nakon 1994. godine ustanovljeno je da značajne korelacije između niske naoblake i kozmičkoga zračenja više ne postoje ([Kristjánsson i sur., 2002, 2004](#); [Agee i sur., 2012](#); [Laken i sur., 2012a](#)).

Međutim [Marsh i Svensmark \(2003\)](#) su objavili rad u kojem su uz određene kalibracije dugoročnih ISCCP podataka pokazali da je korelacija između niske naoblake i kozmičkoga zračenja značajna i za razdoblje nakon 1994. godine. Autori su tvrdili da je, zbog problema u kalibraciji ISCCP satelita 1994. godine, nastala pogreška u trendu ISCCP podataka. Stoga su uzeli podatke naoblake iz drugih satelitskih mjerenja (SSMI⁷, zanemarujući činjenicu da SSMI podaci mogu također posjedovati umjetne trendove) i pomoću njih korigirali trendove u ISCCP podacima nakon 1994. godine. Korekcije, međutim, nisu sustavno provedene. Korigiran je samo dio podataka koji nije podupirao hipotezu o ovisnosti kozmičkoga zračenja i naoblake. Sve ostale kalibracijske i detekcijske pogreške autori nisu uzeli u obzir (poglavlje 5.2).

[Svensmark \(2007\)](#) je svoje rezultate smatrao dovoljno dobrima da na temelju njih razvije teoriju "kozmozaklimatologije", koja kozmičkom zračenju pripisuje ključnu ulogu u globalnom zagrijavanju i u velikim klimatskim promjenama u prošlosti. Tu teoriju su oduševljeno poduprijeli skeptici klimatskih promjena i pripadnici interesnih skupina koje negiraju čovjekov utjecaj na klimatske promjene.

Na slici 5.7 su prikazane relativne promjene u globalnoj ISCCP IR naoblaci (plave linije)

⁷Special Sounder Microwave Instrument

i u toku kozmičkoga zračenja (crvene linije) u razdoblju od 1983. do 2010. godine. Na slici 5.7a je vidljivo da ne postoji podudarnost između varijacija u kozmičkome zračenju i niske naoblake. Nakon 1994. godine naoblaka se kontinuirano smanjuje, a kozmičko zračenje pokazuje vrlo izraženi maksimum⁸. Koeficijent korelacije tih dvaju nizova iznosi $r = -0.15$, ukazujući na neznčajnu anti-korelaciju, koja nije u skladu s rezultatima Marsha i Svensmarka (2003). Slika 5.7b prikazuje rezultate analize srednje i visoke naoblake. Satelitska detekcija ovih oblačnih slojeva je nešto pouzdanija, ali ni ovdje nije vidljiva veza dugoročnih promjena naoblake i kozmičkoga zračenja.

Od 2000. godine dostupni su satelitski podaci za naoblaku projekta MODIS (King i sur., 1992). Postoje dva MODIS instrumenta, koji se nalaze na dva NASA-ina⁹ polarna satelita (Aqua i Terra). Oni snimaju u 36 kanala vidljivog (VIS) i infracrvenog (IR) spektra s prostornom rezolucijom od $1^\circ \times 1^\circ$ i vremenskom rezolucijom od 12 sati. Stoga MODIS predstavlja dobar komplementarni dugoročni niz mjerenja naoblake. MODIS instrumenti mjere čitav niz dodatnih atmosferskih parametara pa su ti podaci povezani s nešto manjim pogreškama u odnosu na ISCCP (Pincus i sur., 2012).

Na slici 5.7 su prikazani MODIS podaci za za niski (5.7a) i za srednji do visoki sloj (5.7b) naoblake u razdoblju od 2000. do 2010. godine. Za oba oblačna sloja je uočljivo nepodudaranje dugoročnih ISCCP i MODIS mjerenja. Takve razlike su objašnjive činjenicom da ISCCP i MODIS koriste različite podatke i metode za određivanje parametara oblaka¹⁰ (Pincus i sur., 2012). Dio razlika se također može objasniti već spomenutim pogreškama u detekciji i kalibraciji ISCCP naoblake.


Laken i sur. (2012a) je analizirao utjecaj Sunčeve aktivnosti na naoblaku u protekloj dekadi (2000-2011) koristeći podatke MODIS-a. Uspoređivao je promjene naoblake u ovisnosti o parametrima Sunčeve aktivnosti (CR, UV, TSI). Statistički značajne korelacije nisu pronađene ni za jedan oblačni sloj niti na globalnoj ili niti na regionalnoj skali. Jedino su za mala regionalna područja dobivene izraženije korelacije naoblake s TSI (poglavlje 7), no ustanovljeno je su te korelacije bolje povezane s ENSO-m (Laken i sur., 2012a).

Spomenuti rad pokazuje da dugoročne analize nisu opterećene jedino pogreškama s izvorom u podacima. Pogreške mogu nastati i zato, što u dužim vremenskim periodima na naoblaku, osim kozmičkoga zračenja, mogu utjecati i drugi čimbenici. To mogu biti unutarnje klimatske oscilacije, npr. ENSO (Kuang i sur., 1998; Farrar, 2000; Marsh i Svensmark, 2003; Roy i Haigh, 2010; Laken i sur., 2012a) ili vulkanske erupcije (Luo i sur., 2002). Stoga su za praćenje ovisnosti kozmičkoga zračenja i naoblake mnogo prikladnije kratkoročne analize.

⁸uzrok tome je zadnji vrlo slabi Sunčev ciklus (Nandy i sur., 2011)

⁹National Aeronautics and Space Administration

¹⁰kao što je npr. visina oblaka



Slika 5.7.: Relativne promjene u globalnoj naoblaci za a) niski (0-3.2 km) i b) srednji do visoki sloj naoblake (>3.2 km). Korišteni su ISCCP IR podaci (plave linije) u razdoblju od 1984. do 2010. i MODIS podaci (zelene linije) u razdoblju od 2000. do 2010. godine. Relativne promjene u naoblaci su izračunate u odnosu na srednjak u cijelom periodu mjerenja. Podaci za kozmičko zračenje izmjereni su pomoću NM-a iz postaja Moskva i Climax (crvene linije).

6. Utjecaj kozmičkoga zračenja na naoblaku tijekom Forbushevih smanjenja

Pogreške karakteristične za dugoročne analize mogu se izbjeći u kratkoročnim analizama koje koriste Forbusheva smanjenja (slika 6.1b). Za veća Forbusheva smanjenja amplituda varijacija u toku kozmičkoga zračenja je slična kao i za vrijeme 11-godišnjeg Sunčevoga ciklusa (slika 6.1).


Grupa ruskih znanstvenika (Pudovkin i Veretenenko, 1995; Pudovkin i sur., 1996) među prvima je istraživala utjecaj Forbushevih smanjenja na promjene u naoblaci. Autori su na temelju opažanja meteroloških postaja na području Rusije i pomoću kompozitne analize (poglavlje 9.1) pronašli značajna smanjenja u naoblaci u područjima visokih geografskih širina (60° - 64°). No gustoća i kvaliteta podataka kojima su se služili bila je ograničena, a rezultat je bio regionalnog karaktera, jer su bila obuhvaćena samo neka područja Rusije.

Satelitski podaci o naoblaci su omogućili sveobuhvatniju i pouzdaniju kratkoročnu analizu (Todd i Kniveton, 2001, 2004). Todd i Kniveton su koristeći 32 Forbusheva događaja i ISCCP D1 podatke zaključili da značajne promjene u naoblaci postoje samo u polarnim područjima i pri visokim geografskim širinama. Iako takvi rezultati imaju smisla, obzirom da su u tim područjima promjene u atmosferskoj ionizaciji putem kozmičkoga zračenja najveće, upitna je kvaliteta satelitskih podataka naoblake (poglavlje 5.2, Rossow i Schiffer, 1999; Stubenrauch i sur., 1999).

Kristjánsson i sur. (2008) su analizirali 22 Forbusheva smanjenja i MODIS satelitske podatke o naoblaci te nisu dobili značajne korelacije između kozmičkoga zračenja i naoblake. Svensmark i sur. (2009, 2012) su uspoređivali podatke o naoblaci (ISCCP, MODIS) i koncentracije aerosola u atmosferi (AERONET) za vrijeme 26 Forbushevih smanjenja te došli do zaključka da postoje značajne promjene u svim analiziranim parametrima za vrijeme Forbushevih smanjenja.

Navedeni primjeri ilustriraju da i pri kratkoročnim analizama rezultati variraju od rada do rada, onemogućavajući pouzdane zaključke.

Važno je da se u analizi uzmu u obzir varijacije kozmičkoga zračenja u ovisnosti o



Slika 6.1.: Usporeba dugoročnih i kratkoročnih analiza utjecaja kozmičkoga zračenja na naoblaku. a) primjer dugoročne analize (Marsh i Svensmark, 2000), tok kozmičkoga zračenja (crvena linija, Huancayo NM) i naoblaka (plava linija, ISCCP D2 podaci za niske oblake) su prikazani u periodu od jednog 11-godišnjeg Sunčevog ciklusa. b) primjer kratkoročne analize s Forbushevima smanjenjima, tok kozmičkoga zračenja (crvena linija, Jungfraujoch NM) i izračunata efektivna ionizacija atmosfere (zelena linija) su prikazani u periodu od 20 dana te prikazuju Forbushevo smanjenje koje se dogodilo 27.11.1989. (4 događaj iz tablice 6.1).

geografskoj lokaciji i visini. No u većini radova ovaj uvjet nije ispunjen, jer su korišteni podaci kozmičkoga zračenja sa samo nekoliko lokacija (npr. Pudovkin i Veretenenko, 1995; Pudovkin i sur., 1996; Todd i Kniveton, 2001, 2004; Kristjánsson i sur., 2008).

Dva daljnja problema prate kratkoročne analize s Forbushevima smanjenjima. Prvi problem je vezan za jako izražen šum i autokorelaciju u naoblaci (poglavlje 9). On se može donekle riješiti ako se usrednji veća količina podataka (npr. prostorno), ili ako se koristi veći broj Forbushevih smanjenja. No treba napomenuti da je broj većih Forbushevih smanjenja u periodu analize ograničen.

Drugi problem je u činjenici da odziv naoblake na promjene u atmosferskoj ionizaciji mora biti u vremenskom periodu kratkoročne analize, a to je u većini slučajeva period do 10-ak dana. Najmanji promjer čestice aerosola koja djeluje kao CCN je ovisan o higroskopnosti čestice i relativnoj vlažnosti u atmosferi. Na primjer, čestica aerosola koja sadrži vrlo higroskopnu sulfatnu kiselinu (H_2SO_4) može već s promjerom od 30 nm djelovati kao CCN pri relativnoj vlažnosti od 100.05 %. Vrijeme rasta novonastalih čestica do te veličine ovisi o koncentraciji plinovitih molekula za kondenzaciju. Za H_2SO_4 vrijeme rasta do veličine CCN iznosi od 3 do 6 dana (Arnold, 2006). Ionizacija u atmosferi je značajno smanjena 1 do 2 dana nakon početka Forbushevog smanjenja pa se stoga može očekivati da će najveće promjene u naoblaci kasniti za Forbushevima događajem u iznosu vremena trajanja rasta čestica povećano za period od 1 do 2 dana. Sukladno tome, pad naoblake se očekuje 4 do 8 dana nakon početka Forbushevog smanjenja (Arnold, 2006,

2008). Nastojeći pažljivim odabirom eksperimentalnih uvjeta ukloniti što više čimbenika koji bi mogli utjecati na pouzdanost rezultata, analiza ovisnosti naoblake o kozmičkome zračenju načinjena je i u ovome radu.

6.1. Podaci i metode

Provedena je detaljna korelacijska analiza ovisnosti naoblake i atmosferske ionizacije za šest najvećih Forbushevih smanjenja u razdoblju od 1989. do 2001. godine (tablica 6.1). Forbusheva smanjenja su odabrana pomoću tri kriterija: 1) tok kozmičkoga zračenja je bio konstantan u periodu prije Forbushevog smanjenja kako bi se mogao koristiti kao referentna razina, 2) Forbushevo smanjenje je pokazivalo glatki i pravilan oporavak bez utjecaja daljnjih Forbushevih smanjenja na tok kozmičkoga zračenja u tom periodu, 3) sva Forbusheva smanjenja povezana sa SEP događajima, koji bi mogli sa suprotnim predznakom utjecati na ionizaciju, su uklonjeni iz analize. Na taj način je uz pomoć podataka izmjerenih s 18 NM-a između 14 najvećih Forbushevih smanjenja u razdoblju od 1989. do 2001. odabrano šest događaja (tablica 6.1).

Događaj	Datum	Vrijeme	Jačina Fd (%)	Razdoblje analize
1	24.03.1991	03:41	21.3	19.03 - 07.04.1991
2	28.10.1991	15:37	17.4	23.10 - 11.11.1991
3	13.03.1989	01:27	16.6	08.03 - 27.03.1989
4	27.11.1989	21:39	15.4	22.11 - 11.12.1989
5	26.02.1992	16:57	9.7	21.02 - 11.03.1992
6	24.09.1998	23:45	9.2	19.09 - 08.10.1998

Tablica 6.1.: Lista Forbushevih događaja korištenih u analizi. Datum i vrijeme označavaju dolazak udarnog vala, koji se smatra početkom Forbushevog smanjenja. Sva vremena su izražena u UTC (srednje vrijeme po Greenwichu), a period analize počinje prvi dan u 00:00 sati i završava zadnjeg dana u 23:59 sati. Jačina Forbushevog smanjenja (Fd) opisuje pad toka kozmičkoga zračenja pri 10 GeV izvan Zemljine magnetosfere (Belov i sur., 1995).

Za analizu je odabran period od 21 dan, koji je počinjao pet dana prije početka Forbushevog smanjenja. Ovom periodu dodano je još 10 dana, kako bi se omogućile korelacije s posmakom¹. Svi korišteni podaci bili su normalizirani (tj. pretvoreni u anomalije) pomoću srednjaka od prva četiri dana prije Forbushevog smanjenja (period normalizacije), koji je potom oduzet od svih vrijednosti u periodu analize.

Za svaki događaj Forbushevog smanjenja korišteni su podaci NM-a uzeti sa SPIDR web stranice (<http://spidr.ngdc.noaa.gov/spidr>) iz kojih je izračunat diferencijalni spek-


¹eng. *lag*

tar energije za primarno galaktičko kozmičko zračenje. S tim podacima je uz pomoć PLANETOCOSMIC programa (poglavlje 6.1.1) izračunata efektivna ionizacija atmosfere u rezoluciji od $5^\circ \times 5^\circ$ kao funkcija geografske širine, dužine i visine u atmosferi te geomagnetskog polja. Slika 6.4 prikazuje primjer stupnja atmosferske ionizacije uzrokovane kozmičkim zračenjem za 19.3.1991. Uočljiva je velika ovisnost ionizacije o geografskoj širini i mala ovisnost o geografskoj dužini, što je posljedica djelovanja geomagnetskog polja (poglavlje 3.3).

Za podatke o naoblaci je korišten infracrveni (IR) udio naoblake u trosatnoj vremenskoj rezoluciji i $2.5^\circ \times 2.5^\circ$ prostornoj rezoluciji iz D1 skupa podataka međunarodnog satelitskog projekta klimatologije naoblake (ISCCP, Rossow i Schiffer, 1991). Takav je odabir podataka imao prednosti obzirom na prijašnje radove u kojima su za naoblaku korišteni ISCCP D2 podaci (npr. Svensmark i Friis-Christensen, 1997; Marsh i Svensmark, 2000, 2003; Kerthaler i sur., 1999; Kristjánsson i sur., 2002, 2004; Sun i Bradley, 2002). Skup ISCCP D2 podataka je za razliku od D1 podataka usrednjen na mjesečne vrijednosti.

Obzirom da su satelitski podaci bili nepotpuni, a naoblaka je imala velike dnevne oscilacije, oni su adekvatno obrađeni prije korelacijske analize. Elementi mreže, u kojima je nedostajalo više od 3 uzastopna mjerenja (>9 h), nisu uzeti u obzir, a ostali elementi su linearno interpolirani. Dnevne oscilacije su uklonjene na način da su svi podaci filtrirani dnevnim kliznim srednjakom. Određena područja na Zemlji pokazuju vrlo rijetku učestalost naoblake, što je u ovim podacima bilo najizraženije za visoku naoblaku. Stoga su svi elementi mreže s više od 44 % mjerenja bez detektirane naoblake u normalizacijskom periodu također uklonjeni iz daljnje analize. Prag od 44 % je izračunat iz minimuma funkcije između mjerenja koja su uklonjena ili nedostaju i broja mjerenja koja nisu detektirala naoblaku.

Kako je ilustrirano na slici 6.2, za svaki element mreže izračunat je koeficijent korelacije i to za svaki visinski sloj oblaka (niski 0-3.2 km, srednji 3.2-6.5 km, visoki oblaci >6.5 km i ukupni sloj naoblake), Forbushevo smanjenje i posmak od 10 dana. Zatim je napravljena detaljna statistička analiza dobivenih koeficijenata korelacije, koja je opisana u poglavlju 6.1.2. Za sve elemente analizirane mreže $2.5^\circ \times 2.5^\circ$, šest Forbushevih smanjenja i različite visinske slojeve naoblake izračunato je ukupno 107073 koeficijenata korelacije za svaki posmak s korakom od 3 h u rasponu od 0 do 10 dana, što sveukupno odgovara broju od 8672913 izračunatih korelacija. Takav veliki broj analiziranih korelacija omogućio je dobru statističku osnovu za prevladavanje izraženoga šuma u podacima naoblake te dovoljno dobru osjetljivost metode (poglavlje 6.1.3). Zbog izraženog šuma i autokorelacije u naoblaci, značajnost dobivenih rezultata je određena pomoću kontrolnih događaja i provjera osjetljivosti (poglavlje 6.1.3).



Slika 6.2.: Ilustracija korelacijske analize. Svaki element mreže s podacima o efektivnoj ionizaciji u atmosferi je koreliran s posmacima do 10 dana s ISCCP D1 podacima za naoblaku koji su posjedovali istu gustoću mreže od 2.5° x 2.5°. Prikazan je primjer za srednju visinu oblaka (3.2-4.7 km) i datum 25.3.1991. u 00:00 sati (UTC).

6.1.1. Izračun efektivne ionizacije u atmosferi

Jedan od važnih produkata atmosferskih čestičnih pljuskova je ionizacija atmosfere (poglavlje 3.4). Današnja era brzih računala omogućava točno simuliranje interakcija između kozmičkoga zračenja i Zemljine atmosfere. Takav izračun je moguće provesti s programima koji koriste Monte Carlo simulacije i baziraju se na GEANT4 programskom paketu (Agostinelli i sur., 2003), izvorno razvijenom za istraživanja s ubrzivačima čestica (CERN). Program PLANETOCOSMIC koristi GEANT4 programski paket i pomoću Monte Carlo tehnika, uzimajući u obzir hadronske i elektromagnetske interakcije kozmičkoga zračenja sa česticama u Zemljinoj atmosferi, računa efektivnu atmosfersku ionizaciju (Desorgher i sur., 2005; Bütikofer i sur., 2008). Program također simulira propagaciju kozmičkoga zračenja kroz geomagnetsko polje pomoću različitih modela.

PLANETOCOSMIC programom se mogu izračunati prinosne funkcije $E_{dep}(P_i, P_{i+1}, d)$, koje predstavljaju energiju pohranjenu u atmosferi po gcm^{-2} za neku atmosfersku dubinu²

²atmosferska dubina je definirana gustoćom stupa zraka u atmosferi i izražena je u gcm^{-2} ($1 \text{ gcm}^{-2} =$

d i proizlaze iz izotropnog toka protona iznad atmosfere te posjeduju ravan spektar za intervale rigiditeta $[P_i, P_{i+1}]$. Ti intervali su logaritamski raspoređeni u rasponu energija od 10 MeV do 1 TeV. Prinosne funkcije su normalizirane na jedan slučajni proton i izražene su u MeV/proton/(gcm⁻²). Vrijednost za ionizaciju u Zemljinoj atmosferi $Q(d)$ kao funkcija atmosferske dubine se onda dobiva iz prinosnih funkcija pomoću jednadžbe:

$$Q(d) = \frac{f_\alpha \rho(d) \sum_i E_{dep}(P_i, P_{i+1}, d) \pi \int_{P_i}^{P_{i+1}} j_p(P) dP}{E_{ion}}, \quad (6.1)$$

gdje je $j_p(P)$ usmjereni tok protona kozmičkoga zračenja na vrhu atmosfere, $\rho(d)$ predstavlja gustoću atmosfere, a E_{ion} srednju energiju potrebnu da bi nastao ionski par (~ 35 eV). Pri tome je uzet u obzir atmosferski sastav i gustoća, koji su izračunati pomoću empiričkog modela NRMLSISE 2000 (Picone i sur., 2002). Faktor f_α u (6.1) je uveden kako bi se uzeo u obzir utjecaj α čestica kozmičkoga zračenja, a predstavlja omjer između toka energija u α i protonskom spektru kozmičkoga zračenja i toka energija u protonskom spektru kozmičkoga zračenja ($f_\alpha = 1.33$).

Ovakav ionizacijski model je detaljno opisan i provjeren eksperimentalnim podacima u radu Usoskin i sur. (2009a). Na ovaj način, uz korištenje prinosnih funkcija, ionizacija Zemljine atmosfere može se brzo i jednostavno izračunati za bilo koji tip spektra Sunčevoga ili galaktičkoga kozmičkoga zračenja.

Kako bi se uzela u obzir propagacija kozmičkog zračenja kroz Zemljino geomagnetsko polje, $j_p(P)$ je postavljen kao nula za sve rigiditete P manje od vertikalnog graničnog geomagnetskog rigiditeta P_c (Cooke i sur., 1991; Smart i sur., 2000, poglavlje 3.3). Za rigiditete P veće od P_c , tok $j_p(P)$ je postavljen tako da je jednak toku protona izvan Zemljine magnetosfere. Spektar protona kozmičkog zračenja izvan Zemljine magnetosfere za vrijeme Forbushevih smanjenja je uzet kao izotropan i određen je pomoću jednadžbe:

$$\psi(P) = \psi_0(P)M(P, t), \quad (6.2)$$

gdje je $\psi_0(P)$ diferencijalni spektar protona kozmičkoga zračenja prije Forbushevoga smanjenja, a $M(P)$ predstavlja modulacijsku funkciju Forbushevog smanjenja. Referentni spektar, koji bi kozmičko zračenje imalo bez utjecaja Forbushevog smanjenja $\psi_0(P)$, može se odrediti pomoću modela opisanog u Gleeson i Axford (1968). Taj model uvažava protonski međuzvjezdani spektar galaktičkoga kozmičkog zračenja, koji je parametriziran po Garcia-Munoz i sur. (1975) i na njega je primijenjen Sunčev modulacijski parametar ϕ , koji je ovisan o Sunčevoj aktivnosti te parametrizira oblik moduliranog spektra galaktičkoga kozmičkog zračenja (poglavlje 3.2). Obzirom da se geomagnetsko polje mijenja pod

utjecanjem koroninoga izbačaja i međuplanetarnoga udarnog vala za vrijeme Forbushevih smanjenja (poglavlje 3.6), na spektar kozmičkoga zračenja potrebno je primijeniti modulacijsku funkciju $M(P)$. U nešto izmijenjenom obliku od opisanog u Lockwood i sur. (1991) funkcija modulacije se određuje pomoću:

$$M(P, t) = (P + 1)^{-\gamma(t)}, \quad (6.3)$$

te ovisi o modulacijskom parametru $\gamma(t)$ tijekom Forbushevog smanjenja. Metoda kojom se računa parametar $\gamma(t)$ je prikazana na slici 6.3 za vrijeme Forbusheva smanjenja za 15.03.1989. u 00:00 sati po UTC³ (događaj broj 3, tablica 6.1). Nadalje, $\delta N(t)$ je definiran kao relativna promjena u toku kozmičkoga zračenja u odnosu na vrijednost N_0 prije početka Forbusheva smanjenja. Funkcija $\delta N(t)$ u ovisnosti o vertikalnom graničnom geomagnetskom rigiditetu P_c može se teorijski procijeniti pomoću:

$$\delta N(t) = \frac{N(t) - N_0}{N_0} = \int_{P_c} \frac{[\psi(P) - \psi_0(P)S(P)]}{\psi_0(P)S(P)} dP, \quad (6.4)$$


gdje $S(P)$ označava specifične prinosne funkcije uzete iz rada Debrunner i sur. (1984). Uspoređujući funkcije $\delta N(t)$ izračunate različitim modulacijskim parametrima γ (plave puno crtkane linije na slici 6.3) i mjerenja neutronske monitorima (crvene točke na slici 6.3), može se odrediti γ za neko specifično vrijeme. Najbolja prilagodba jednadžbe (6.4) NM mjerenjima daje traženi γ za vrijeme t . Za tu svrhu su za svako korišteno Forbushevo smanjenje u analizi uzeta mjerenja toka kozmičkoga zračenja s desetak NM postaja (SPIDR web stranica: <http://spidr.ngdc.noaa.gov/spidr>), raspoređenih po različitim geografskim širinama s različitim vrijednostima za P_c .

Opisanom metodom je za svih šest Forbushevih smanjenja i period analize od 20 dana izračunat modulacijski parametar γ koji je definirao tok kozmičkoga zračenja iznad Zemljine magnetosfere u vremenskim koracima od tri sata. Efektivni vertikalni granični geomagnetski rigiditet (P_c) je izračunat u rezoluciji od $5^\circ \times 5^\circ$ (poglavlje 3.3, slika 3.5) uz pomoć geomagnetskog modela Tsyganenko89c (Tsyganenko, 1989), što je omogućilo izračun toka kozmičkoga zračenja iznad atmosfere. Naposljetku je izračunata efektivna ionizacija u atmosferi tijekom Forbushevih smanjenja za polje $5^\circ \times 5^\circ$ pomoću jednadžbe (6.1) preko cijele Zemljine površine (slika 6.4).

6.1.2. Statistička analiza korelacija

Za vrijeme perioda analize od 20 dana koeficijenti korelacije, $\hat{P}_j(l)$, su izračunati za svaki element (x_j) $2.5^\circ \times 2.5^\circ$ mreže i posmak l od 0 do 10 dana s vremenskim korakom od tri

³srednje vrijeme po Greenwichu



Slika 6.3.: Ilustracija metode koja je korištena kako bi se dobio modulacijski parametar γ tijekom Forbushevih smanjenja. Plave točkasto crtkane linije označavaju izračunate teorijske funkcije relativnih vrijednosti mjerena putem NM-a u ovisnosti o vertikalnom graničnom geomagnetskom rigiditetu P_c , a dobivene su za različite vrijednosti parametra γ . Crvene točke označavaju izmjerene relativne vrijednosti toka kozmičkoga zračenja putem NM-a. Modulacijski parametar γ je određen kao najbolja prilagodba teorijskoj funkciji (označena crvenom debelom linijom). Slika odgovara vremenu 15.03.1989 u 00:00 sati (UTC).

sata. Prostorne razdiobe koeficijenata korelacije na karti svijeta kao i histogrami (npr. slika 6.6b-c) pokazali su da vrijedi pretpostavka da koeficijenti korelacije, $\hat{P}_j(l)$, imaju istu očekivanu vrijednost, $\mu(l)$, za svaki posmak. Stoga je uveden globalni srednjak korelacija:


$$\hat{P}_{avg}(l) = \frac{1}{N} \sum_j \hat{P}_j(l), \quad (6.5)$$

gdje N označava ukupni broj elemenata mreže za koju je rađena korelacija.

Kako bi se procijenilo standardno odstupanje σ globalnog srednjaka korelacija $\hat{P}_{avg}(l)$, potrebne su neke pretpostavke o prostornim korelacijama za $\hat{P}(l)$. Prostorne karte korelacija (slika 6.6b) su pokazale da postoje homogene izotropne korelacije:

$$Cor(\hat{P}_i(l), \hat{P}_j(l)) = \rho(|\mathbf{x}_i - \mathbf{x}_j|), \quad (6.6)$$

ali da postaju zanemarive nakon neke radijalne udaljenosti r (x_i i x_j označavaju elemente



Slika 6.4.: Primjer izračunate ionizacije u Zemljinoj atmosferi uzrokovane kozmičkim zračenjem za 19.3.1991. u 00:00 sati UTC (1 događaj). Isječak profila vrijednosti ionizacije na istočnom meridijanu od 2.5° prikazan je kao funkcija geografske širine i atmosferske dubine (predstavlja visinu u atmosferi). Slika ubačena na desnoj strani prikazuje ionizaciju za atmosfersku dubinu od 180 g/cm² (13.2 km) u ovisnosti o geografskom položaju.

mreže $X(i, j)$). Sukladno tome, procjena varijance $P_{avg}(l)$ se dobiva jednadžbom:

$$\widehat{Var}(P_{avg}(l)) = \frac{1}{N(N-L)} \sum_{|\mathbf{x}_i - \mathbf{x}_j| \leq r} (\hat{P}_i(l) - P_{avg}(l))(\hat{P}_j(l) - P_{avg}(l)), \quad (6.7)$$

gdje su svi elementi mreže $X(i, j)$ unutar radijusa r zbrojeni, a pri tome je L broj elemenata unutar polumjera r . Očekivana vrijednost od (6.7) je određena pomoću:

$$\mathbb{E}(\widehat{Var}(P_{avg}(l))) = Var(P_{avg}(l)) - \frac{1}{N-L} \sum_{|\mathbf{x}_j - \mathbf{x}_k| > r} \sigma_j \sigma_k \rho(|\mathbf{x}_j - \mathbf{x}_k|). \quad (6.8)$$

Izračun u kojem je variran radijus r doista je pokazao da se varijanca u (6.7) stabilizira za radijus r od oko 15°, što omogućava da se prostorne korelacije izvan radijusa $r = 15^\circ$ zanemare. Pod pretpostavkom da ρ nestaje izvan polumjera r , procjena u (6.7) nema više

pristranost⁴. Izuzetak je u slučaju kada broj elementata L unutar polumjera r znatno varira (npr. u slučaju visokih oblaka gdje nedostaje dosta podataka), kada je pristranost veličine $\mathcal{O}(L/N)$. Ova pristranost se može smanjiti ubacivanjem određene korekcije za L , no izračuni su pokazali da ta korekcija ima neznatni utjecaj na procjenu pomoću jednadžbe (6.7).

Budući da autokorelacije naoblake i ionizacije ne ovise znatno o elementu mreže, za pretpostaviti je da ni varijance $\hat{P}_i(l)$ ne ovise o elementu mreže. Iako postoji prostorna korelacija između $\hat{P}_i(l)$, broj efektivnih stupnjeva slobode je i dalje velik. Stoga se može pretpostaviti da $P_{avg}(l)$ ima normalnu razdiobu što je i dokazano oblikom histograma na slici 6.6c. Omjer T , koji je definiran jednadžbom:

$$T = \frac{P_{avg}(l) - \mu(l)}{\sqrt{\widehat{Var}(P_{avg}(l))}} \quad (6.9)$$

ima onda normalnu razdiobu s očekivanom vrijednošću 0 i varijancom 1, što omogućava jednostavan izračun intervala pouzdanosti na 95 % razini značajnosti.

6.1.3. Kontrolni događaji i provjere osjetljivosti


Kako bi se provjerila ispravnost postupaka analize, primijenjene su dvije različite metode. U prvoj metodi su odabrana dva perioda za vrijeme Sunčevog minimuma, koji su trajali 20 dana⁵ i imali manje varijacije od 2 % u toku kozmičkoga zračenja. Ti periodi su nazvani kontrolni događaji (kontrolni događaj 1: 2.07.-21.07.1986, kontrolni događaj 2: 2.04.-21.04.1996). U tim periodima podaci naoblake su obrađeni na isti način kao i u stvarnoj analizi, tj. korelirani su s posmakom od 10 dana s podacima atmosferske ionizacije za vrijeme Forbushevih smanjenja. Svrha je bila odrediti utjecaj autokorelacije u naoblaci (Kristjánsson i sur., 2002). Korelacije dobivene u kontrolnim događajima su potom uspoređene s korelacijama izračunatim u analizi naoblake za vrijeme Forbushevih smanjenja. Primjer takve usporedbe je na slici 6.5, gdje je prikazan globalni srednjak (P_{avg}) kontrolnog događaja 1 (plava točkasta linija) i Forbushevog događaja 1 (zelena crtano točkasta linija) za posmak od 10 dana. Oba kontrolna događaja pokazala su slične varijacije tijekom 10 dana posmaka kao i svi Forbushevi događaji pojedinačno.

Druga metoda imala je za cilj provjeriti osjetljivost analize. Dok naoblaka u pravilu varira između 0 % i 100 %, promjene u kozmičkom zračenju su puno manje i iznose od 10 % do 20 % (vrijedi samo za najveća Forbusheva smanjenja). Stoga je bitno znati da li su primijenjene metode dovoljno osjetljive da mogu detektirati vrlo male promjene u

⁴eng. textitbias

⁵identičan period analize kao i kod analize Forbushevih događaja

naoblaci koje bi trebale biti uzrokovane promjenama u atmosferskoj ionizaciji odnosno kozmičkom zračenju. Kako bi se to provjerilo, promjene u atmosferskoj ionizaciji tijekom prvog Forbushevog događaja su pridodane kontrolnom događaju s posmakom od 5 dana. Prema dugoročnoj studiji utjecaja kozmičkog zračenja na naoblaku u kojoj je nađena značajna korelacija [Marsh i Svensmark \(2000\)](#) tijekom jednog Sunčevog ciklusa (1983-1995), 8 % promjena u toku kozmičkoga zračenja je pratila promjena u naoblaci od 2 %. Iako je taj rezultat upitan, jer korelacija kozmičkoga zračenja s oblacima nije više prisutna iza 1994. godine (poglavlje 5), u nedostatku bolje procjene može se pretpostaviti da kozmičko zračenje utječe na naoblaku s efikasnošću od 25 % (2 %/8 %). Efikasnost od 25 % je simulirana na način da su ionizacijske vrijednosti smanjene na 25 % prvotnih vrijednosti te je potom naoblaka umanjena za taj iznos. Takvi modificirani podaci naoblake su onda korelirani s podacima za ionizaciju istoga događaja. Na slici 6.5 je prikazan globalni srednjak korelacija (P_{avg}) u provjeri osjetljivosti (crvena puna linija), koji pokazuje značajni maksimum za posmak od 5 dana u odnosu na kontrolni i Forbushev događaj. P_{avg} u provjeri osjetljivosti bio je značajno veći (0.11) u odnosu na kontrolne događaje, što potvrđuje da je provedena analiza dovoljno osjetljiva da detektira povezanost između kozmičkoga zračenja i naoblake na globalnoj razini.



Slika 6.5.: Usporedba globalnog srednjaka korelacija (P_{avg}) za test osjetljivosti (crvena puna linija), kontrolni događaj 1 (točkasta plava linija) i Forbushev događaj 1 (zelena crtano točkasta linija). P_{avg} je izračunat iz podataka za ukupnu naoblaku, a izražen je kao funkcija posmaka od 10 dana. Standardno odstupanje (σ) je izračunato za svaku veličinu i posmak pojedinačno. Sjenčane površine predstavljaju intervale pouzdanosti na 95 % razini ($\pm 1.96 \sigma$).

6.2. Rezultati i diskusija

Slika 6.6, koja se sastoji od tri dijela, sažimlje rezultate globalne analize. Globalni srednjaci koeficijenata korelacije P_{avg} , dobiveni usrednjavanjem svih analiziranih elemenata globalne mreže ($2.5^\circ \times 2.5^\circ$) i šest Forbushevih događaja zajedno, prikazani su na slici 6.6a. Srednjaci korelacija P_{avg} u ovisnosti o posmaku prikazani su za niski (plava točkasta linija), srednji (žuta crtkano točkasta linija) i visoki (plava točkasta linija) oblačni sloj. Nedostatak bilo kakvog značajnijeg maksimuma za P_{avg} u periodu posmaka od 10 dana za sva tri sloja naoblake jasno pokazuje da naoblaka u troposferi nema globalni odziv na Forbusheva smanjenja. Dodatne argumente pruža analiza kontrolnih događaja, u kojoj su srednjaci korelacija P_{avg} pokazivali usporedive varijacije i standardna odstupanja u naoblaci kao i u slučaju Forbushevih smanjenja. Za razliku od Forbushevih smanjenja, gdje su promjene u toku kozmičkoga zračenja bile do 25 %, za kontrolne događaje one su bile neznatne, iznoseći manje od 2 % (slika 6.5, poglavlje 6.1.3).

Visoka naoblaka (>6.5 km) pokazuje najveće varijacije i šire intervale pouzdanosti (sjenčano plavo područje) u periodu posmaka od 10 dana u odnosu na druge slojeve naoblake (slika 6.6). Objašnjenje za veću varijabilnost koeficijenata korelacije za visoku naoblaku je neposredno povezano s usrednjavanjem podataka i utjecajem šuma. Naime zbog činjenice da visoka naoblaka u određenim područjima često nije prisutna (poglavlje 6.1), dosta je elemenata mreže za visoke oblake uklonjeno iz analize pa je stoga korišteno svega 29 % podataka u odnosu na globalnu (100 %) pokrivenost Zemlje. U slučaju srednjeg sloja naoblake problem s nedostatkom naoblake nije bio toliko izražen pa je pokrivenost podacima bila 69 %. U slučaju niske naoblake pokrivenost podacima je iznosila 90 %, a uzrok manjku podataka bio je isključivo manjak satelitskih mjerenja. Navedene brojke pokazuju da nije moguće direktno uspoređivati amplitude P_{avg} za različite slojeve naoblake bez razmatranja količine usrednjenih podataka koji smanjuju šum. Za kontrolne događaje dobiveni su slični rezultati kao i za Forbusheva smanjenja: najveće varijacije i širi interвали pouzdanosti uočeni su za visoku naoblaku (poglavlje 6.1.3).

Mala pozitivna pristranost u srednjacima koeficijenata od 0.02 je dobivena za sve Forbusheve događaje, slojeve naoblake i posmake. U kontrolnim događajima dobivena je slična pristranost. Takva pristranost je i očekivana s obzirom da se radi o relativno kratkim periodima analize od 20 dana i jakim autokorelacijama u podacima naoblake.

Provjere osjetljivosti prikazanih metoda (poglavlje 6.1.3, slika 6.5) su pokazale da u slučaju efikasnosti od 25 % za mehanizam utjecaja kozmičkoga zračenja na naoblaku (Marsh i Svensmark, 2000) usrednjavanje prikazanim metodama posjeduje dovoljnu osjetljivost da smanji šum i detektira promjene u naoblaci. Međutim, pri manjim efikasnostima mehanizma kao i pri analizama manjih prostornih područja, moguće je da šum onemogućí

jasnu detekciju signala.

Slika 6.6b prikazuje primjer usrednjenih koeficijenata korelacije za niski sloj naoblake (0-3.2 km) na globalnoj svjetskoj karti. Koeficijenti korelacije su usrednjeni za svih šest Forbushevih smanjenja zajedno, u svakom elementu mreže te za sve posmake u vremenu između 5 i 6 dana kada je očekivan odziv u naoblaci. Elementi mreže, koji su usrednjeni s manje od četiri Forbusheva smanjenja, nisu prikazani zbog manjka podataka (siva područja na karti). Negativne korelacije su označene kao plava, a pozitivne korelacije su prikazane kao crvena područja. Na slici 6.6b može se jasno vidjeti da prostorni raspored korelacija nije homogen i ne pokazuje veća područja s istim predznakom, što također upućuje na stohastična svojstva izračunatih korelacija. Slične raspodjele koeficijenata korelacije dobivene su i u slučaju ostalih slojeva naoblake te za ostale posmake.

Histogrami koeficijenata korelacije pokazuju normalnu raspodjelu vrijednosti koeficijenata, što ukazuje na odsutnost korelacije između kozmičkoga zračenja i naoblake. Primjer jednoga takvog histograma je na slici 6.6c.


Rezultati predstavljene analize su u skladu s rezultatima koje su dobili [Kristjánsson i sur. \(2008\)](#) pomoću MODIS podataka o naoblaci. Na temelju kompozitne analize tijekom 18-dnevnog perioda oni su zaključili da kozmičko zračenje ne utječe značajno na naoblaku, kao ni na određena svojstva oblaka (npr. optička gustoća oblaka, veličina kapljica u oblacima). Suprotno tome, [Svensmark i sur. \(2009, 2012\)](#), analizirajući oba niza podataka za naoblaku, ISCCP i MODIS te podatke za aerosole, uočili su značajne promjene uzrokovane Forbushevima smanjenjima za sve analizirane parametre. Osvrt na te rezultate se nalazi u poglavlju 9.7.1, u kojem je diskutirana prikladnost metoda i procjena statističke značajnosti.

U nekim regionalnim analizama temeljenim na podacima opažanima sa Zemlje nađena je sveza između kozmičkoga zračenja i određenih svojstava oblaka ([Harrison i Stephenson, 2006](#); [Harrison i Ambaum, 2010](#); [Harrison i sur., 2011](#)). [Harrison i Stephenson \(2006\)](#) istraživali su omjer difuznog i direktnog Sunčevog zračenja⁶ mjerenih iz postaja na području Velike Britanije u odnosu na promjene u kozmičkome zračenju. Njihovi rezultati su pokazali da postoji nelinearna sveza kozmičkoga zračenja i lokalne naoblake, koja se očituje u povećanju oblačnosti za 19 % u danima s povećanim tokom kozmičkoga zračenja. Udio difuznog zračenja je dalje analiziran za vrijeme Forbushevih smanjenja pomoću podataka opservatorija Lerwick u Engleskoj. Zaključeno je da za vrijeme najvećih⁷ Forbushevih smanjenja postoji brzi odziv (nakon jednog dana) u naoblaci ([Harrison i Ambaum, 2010](#)). Nadalje, [Harrison i sur. \(2011\)](#) su pronašli korelaciju između kozmičkoga zračenja i visine naoblake na temelju mjerenja opservatorija Lerwick. Prema spomenutim autorima visina

⁶takav odnos se može koristiti kao indirektan podatak za naoblaku

⁷s padom toka kozmičkoga zračenja većim od 10 %

6. Utjecaj kozmičkoga zračenja na naoblaku tijekom Forbushevih smanjenja



Slika 6.6.: a) Globalni srednjaci koeficijena korelacije, P_{avg} , izračunati iz svih elemenata mreže i 6 Forbushevih smanjenja zajedno prikazani kao funkcija posmaka od 10 dana. P_{avg} je prikazan za visoki (plava točkasta linija), srednji (žuta crtkano točkasta linija) te niski (zelena puna linija) sloj naoblake. Standardno odstupanje (σ) je izračunato za svaki posmak posebno, a obojana sjenčana područja predstavljaju intervale pouzdanosti na 95 % razini ($\pm 1.96 \sigma$). b) Korelacijski koeficijenti (negativne vrijednosti: plavo, pozitivne vrijednosti: crveno) za niski sloj naoblake (0-3.2 km) za posmak od 5-6 dana prikazani na globalnoj svjetskoj karti. Korelacijski koeficijenti su izračunati kao srednjaci 6 Forbushevih događaja za svaki element globalne mreže, a siva područja odgovaraju podacima koji nedostaju. c) Histogram za iste koeficijente korelacije koji su prikazani u b). X-os prikazuje vrijednost koeficijena korelacije, a y-os broj koeficijena korelacije u specifičnom razredu.

baze niskog sloja naoblake bila je manja za 7 m u danima s visokim tokom kozmičkoga zračenja. Nađene promjene su najvjerojatnije povezane s mehanizmom GEC-a. Autori su također tvrdili da su pronašli periode od 27 dana i 1.68 godina u podacima o visini naoblake, koji odgovaraju periodima promjena u kozmičkome zračenju. Ako postoji veza između kozmičkoga zračenja i naoblake, kao što sugeriraju rezultati Harrisona i suradnika, utjecaj je malen i lokalna pa se sukladno tome ne očekuje značajniji utjecaj na klimu.

6.2.1. Regionalna analiza


Relativne promjene u stupnju atmosferske ionizacije su mnogo veće u područjima oko polova nego oko ekvatora (poglavlje 5, slika 5.1). Stoga se, ako je ionizacija dominirajući čimbenik koji utječe na naoblaku, manji odziv naoblake očekuje pri niskim nego pri visokim geografskim širinama. To podupire rezultate prikazane u Todd i Kniveton (2001, 2004) koji su za vrijeme Forbushevih smanjenja uočili značajne promjene u visokoj naoblaci u polarnim područjima. Suprotno očekivanjima, Marsh i Svensmark (2000, 2003) su u dugoročnim analizama opazili odziv niske naoblake samo pri niskim geografskim širinama.

Kako bi se istražila eventualna povezanost promjene naoblake i geografske širine, elementi mreže ispod i iznad 45° geografske širine su zasebno korelirani za sve događaje i sve slojeve naoblake. Na slici 6.7 su prikazani rezultati regionalne analize za niske i visoke geografske širine. Pri geografskim širinama iznad 45° (slika 6.7a i 6.7b) ni jedan od prikazanih slojeva naoblake ne pokazuje značajnu korelaciju s atmosferskom ionizacijom. Područje visoke i srednje naoblake, gdje se i očekuju najveće promjene u ionizaciji, pokazuje malo povećanje za srednjak koeficijentata korelacije, P_{avg} , no to se povećanje nalazi unutar granica intervala pouzdanosti (95 %). Niti povećanje koje pokazuje ukupni oblačni sloj nije značajno (slika 6.7b). Pri niskim geografskim širinama (slika 6.7c i 6.7d) također nema značajne korelacije.

Prema Yu i Turco (2001) iznad oceana se očekuje veći utjecaj kozmičkoga zračenja na naoblaku nego iznad kopna. Iznad kopna se očekuje manji učinak ionizacije na naoblaku budući da su u tim područjima obično dostupne dovoljne koncentracije aerosola koje mogu služiti kao oblačne kondenzacijske jezgre. Stoga bi promjene u ionizaciji u područjima iznad kopna i oceana trebale imati različiti učinak na naoblaku. Marsh i Svensmark (2000, 2003) su u dugoročnim analizama dobili značajne korelacije za nisku naoblaku iznad oceana.

Suprotno rezultatima prikazanim u Marsh i Svensmark (2000, 2003) u ovome radu nije uočena povezanost kozmičkoga zračenja i naoblake iznad oceana. Slika 6.8 prikazuje usporedbu rezultata (P_{avg}) u područjima kopna (slika 6.8a i 6.7b) i oceana (slika 6.8c i


6. Utjecaj kozmičkoga zračenja na naoblaku tijekom Forbushevih smanjenja



Slika 6.7.: Usporedba srednjaka koeficijenata korelacije, P_{avg} , za visoke (lijevo: a,b) i niske (desno: c,d) geografske širine. P_{avg} kao funkcija posmaka od 10 dana je izračunata za šest Forbushevih smanjenja. a i c) P_{avg} za visoki (plava točkasta linija), srednji (žuta crtkano točkasta linija) i niski (zelena puna linija) sloj naoblake. b i d) P_{avg} za ukupnu naoblaku (crvena puna linija). Standardno odstupanje (σ) je izračunato za svaki posmak posebno, a obojana sjenčana područja predstavljaju intervale pouzdanosti na 95 % razini ($\pm 1.96 \sigma$). U tablicama na slikama (a i c) je prikazan broj elemenata mreže iz kojeg je izračunat P_{avg} za svaki oblačni sloj u svakom posmaku.

6.7d). Ni u jednom području nisu dobivene značajne korelacije. P_{avg} ima maksimum pri posmaku od 6 dana za ukupnu naoblaku iznad kopna (slika 6.8b), no za pretpostaviti je da se radi o šumu budući da za nijedan pojedinačni oblačni sloj nije uočen maksimum u tom periodu.

Na slikama 6.7 i 6.8 prikazani su podaci o broju analiziranih elemenata mreže po određenom posmaku za svaki oblačni sloj. Taj broj ujedno označava i količinu usrednjenih podataka (tj. pokrivenost, %) i iz njega se može procijeniti utjecaj šuma. Uočljivo je da je pokrivenost područja visokih geografskih širina i područja iznad kopna znatno manja u odnosu na područja niskih geografskih širina i područja iznad oceana, što znači da ona imaju veće varijacije u P_{avg} i veći šum.



Slika 6.8.: Usporedba srednjaka koeficijenta korelacije, P_{avg} , za elemente mreže iznad kopna (lijevo: a,b) i oceana (desno: c, d). P_{avg} kao funkcija posmaka od 10 dana je izračunata za 6 Forbushevih smanjenja. a i c) P_{avg} za visoki (plava točkasta linija), srednji (žuta crtkano točkasta linija) i niski (zelena puna linija) sloj naoblake. b i d) P_{avg} za ukupnu naoblaku (crvena puna linija). Standardno odstupanje (σ) je izračunato za svaki posmak posebno, a obojana sjenčana područja predstavljaju intervale pouzdanosti na 95 % razini ($\pm 1.96 \sigma$). U tablicama na slikama (a i c) je prikazan broj elemenata mreže iz kojeg je izračunat P_{avg} za svaki oblačni sloj u svakom posmaku.

Posebice izražen šum u naoblaci (poglavlje 9.4) imaju mala i ograničena geografska područja (manja od $15^\circ \times 15^\circ$) pa na temelju satelitskih podataka i malog broja Forbushevih događaja (< 10) nije moguće zaključiti o utjecaju kozmičkoga zračenja na naoblaku u tim područjima.

7. Utjecaj ukupnoga Sunčevog zračenja na naoblaku

Analiza naoblake i toka kozmičkoga zračenja za vrijeme Forbushevih smanjenja, predstavljena u prethodnom poglavlju, nije dala korelacije koje bi ukazivale na povezanost ova dva parametra. Slične rezultate dobili su i drugi autori (npr. [Pallé i Butler, 2001](#); [Kristjánsson i sur., 2008](#); [Laken i sur., 2009](#)). Međutim, ima autora, koji su primjenom kratkoročne analize za vrijeme Forbushevih smanjenja dobili značajne pozitivne (npr. [Pudovkin i Veretenenko, 1995](#); [Todd i Kniveton, 2004](#); [Svensmark i sur., 2009](#)), ili pak negativne korelacije (npr. [Wang i sur., 2006](#); [Troshichev i sur., 2008](#)).

Nekoliko je razloga zbog kojih su mogući proturječni rezultati: 1) ne postoji povezanost između kozmičkoga zračenja i naoblake; 2) takva sveza postoji, ali je ograničena atmosferskim prilikama u određeno doba, tj. nije sveza prvog reda; 3) korišten je premali uzorak, ili su razmatrana premala geografska područja; 4) ostali Sunčevi parametri kao što je ukupno Sunčevo zračenje (TSI) mogu također utjecati na rezultate, a većina autora ih nije izolirala.

Na mogućnost da bi TSI mogao djelovati na naoblaku upozorili su već autori dugoročnih analiza. [Kristjánsson i sur. \(2002\)](#) dobili su jaču korelaciju između TSI-a i naoblake nego u slučaju kozmičkoga zračenja i naoblake. Njihova daljnja analiza upućivala je na povezanost TSI s površinskom temperaturom oceana (SST), što ide u prilog "odozdo prema gore" mehanizmu (poglavlje 4.1, [Meehl i sur., 2009](#)). Naime, čak i malo zagrijavanje oceana može uzrokovati znatnije isparavanje vodene pare, koje onda može utjecati na povećanje naoblake. [Laken i sur. \(2011\)](#) su analizirali 123 Forbusheva smanjenja u razdoblju od 1978. do 2006. godine. Oni su pomoću 20-dnevne kompozitne analize detektirali pad naoblake 3 dana prije najvećeg pada kozmičkoga zračenja. Dobiveni odziv naoblake povezali su s promjenama u TSI-u, budući da pad u TSI-u prethodi za nekoliko dana padu u kozmičkome zračenju.

Promjene u TSI-u su uzrokovane pojavama na površini Sunca, kao što su Sunčeve pjege i fakule. Na mjestima gdje se pojavljuju Sunčeve pjege, odaslana Sunčeva energija je drugačija u odnosu na ostatak Sunčeve površine, što kumulativno doprinosi varijacijama u TSI-u. Promjene u Sunčevom UV zračenju su najčešće povezane s pojavom fakula, velikih

svjetlih područja u atmosferi Sunca, koji se najčešće nalaze u aktivnim područjima oko Sunčevih pjega. Budući da koronini izbačaji i Sunčev vjetar putuju supermagnetosoničnim brzinama, promjene u toku kozmičkoga zračenja se na Zemlji mogu očekivati za 2 do 4 dana dok se promjene u Sunčevom zračenju opažaju na Zemlji gotovo trenutačno¹.

Utjecaj TSI-a na naoblaku kao mogući izvor pogrešaka na kratkoročnim vremenskim skalama istražen je u ovome radu pomoću kompozitne analize. Pažljivim odabirom događaja moguće je odvojiti parametre TSI i kozmičko zračenje te provjeriti njihovo djelovanje na naoblaku za različita područja i visine u atmosferi.

7.1. Podaci i metode

Dnevni podaci u razdoblju od 1978. do 2010. godine za TSI su uzeti iz baze podataka satelitskih mjerenja *Active Cavity Radiometer Irradiance Monitor*, ACRIM (Willson i Mordvinov, 2003).

Za naoblaku su korišteni ISCCP IR D1 podaci iz perioda od 1983. do 2008. godine (poglavlje 5). Analizirana su tri sloja naoblake: visoki (>6.5 km), srednji (3.2-6.5 km) i niski (0-3.2 km). Nadalje, podaci su podijeljeni obzirom na geografsko područje: visoke ($>45^\circ$) i niske ($<45^\circ$) geografske širine te područja iznad kopna i oceana (poglavlje 6.2.1). Za sve navedene visine oblaka i sva geografska područja podaci su usrednjeni kako bi se smanjio vrlo izražen meteorološki šum u naoblaci te uklonile dnevne varijacije naoblake.

Podaci za tok kozmičkoga zračenja (CR) su izmjereni NM-om postaje Climax (39.37°N, -106.18°W, 3400 m n.v., $P_c=2.99$ GeV). Budući da podaci za Sunčevo UV zračenje² nisu bili dostupni za cijeli period analize, mjerenja Sunčeva zračenja u radio spektru pri 2800 Mhz (F10.7) korištena su kao indirektni podaci (Rich i sur., 2003).

Svi podaci (osim F10.7) su normalizirani 10-dnevnim srednjakom u periodu od -20 do -10 dana (tzv. period normalizacije) prije ključnog dana³ po kojemu je načinjen kompozit (poglavlje 9.1). Tako dobivene vrijednosti definirane su kao anomalije s oduzetim 10-dnevnim srednjakom perioda normalizacije.

Pripremljene su tri grupe kompozitnih uzoraka. U prvome uzorku, koji je nazvan *In-cTSI*, su odabrani događaji u kojima su zabilježeni najveći porasti u intenzitetu TSI-a tijekom nekoliko dana. U drugome, *DecTSI-A*, odabrani su događaji s najvećim smanjenjima u intenzitetu TSI. Treći uzorak, *DecTSI-B*, je dobiven uklanjanjem svih događaja sa značajnim promjenama u toku kozmičkoga zračenja obzirom na period ± 10 dana od ključnog datuma iz uzorka *DecTSI-A* (slika 7.2). Najveći porast odnosno smanjenje u

¹putuju brzinom svjetlosti, tj. 8 minuta do Zemlje

²potrebna su satelitska mjerenja

³definiran kao dan 0 u vremenskoj skali analize i odgovara trenutku kada se dogodio poremećaj u TSI

intenzitetu TSI-a je odabrano kao ključni datum za konstrukciju kompozita.


Najveće promjene u TSI-u identificirane su pomoću visoko-propusnog filtra i to tako da je iz ACRIM podataka u dnevnoj vremenskoj rezoluciji izračunat referentni niz s mjesečnim kliznim srednjakom (31 dan), koji je potom oduzet od niza s tjednim kliznim srednjakom (7 dana). Iz tih podataka je uz pomoć 95-og percentila odabrana populacija najvećih povećanja i smanjenja u TSI-u. Naposljetku su izbačeni događaji u kojima su zabilježene uzastopne značajnije promjene u TSI-u u periodu od ± 10 dana od ključnog datuma. Na ovaj način je dobijen čišći signal, no smanjen je i broj događaja pa je tako kompozit za uzorak *IncTSI* imao 19, kompozit za *DecTSI-A* 48, a kompozit za *DecTSI-B* 37 događaja. Lista svih događaja za sve uzorke je prikazana u tablici A.1.

Koeficijenti (r) korelacija između TSI-a, CR-a, F10.7 i pripadajućih ISCCP podataka o naoblaci izračunati su posebno za svaki od tri uzorka (kompozita) u periodu od ± 20 dana. Period podataka o naoblaci je produžen za dodatnih 20 dana (-20 do +40 dana) kako bi se omogućila korelacija s posmakom od 20 dana.

Granične vrijednosti značajnosti za svaki dobiveni koeficijent korelacije određene su pomoću Monte Carlo simulacija. U čitavom dostupnom ISCCP setu podataka s dnevnim vrijednostima o naoblaci (1983-2008) su nasumce odabrani datumi te načinjeni kompoziti s jednakim brojem događaja kao i u uzorcima (npr. za *IncTSI* je napravljen kompozit od 19 događaja). Takvi kompoziti sa slijepim događajima su onda korelirani na isti način kao i stvarni uzorci sa svakim parametrom (TSI, CR, F10.7) te je taj proces ponavljen 100000 puta. Iz dobivenih koeficijenata korelacije su izračunate razdiobe. Jedan primjer je prikazan na slici 7.1. Pomoću Shapiro-Wilk testa (Shapiro i Wilk, 1965) ustanovljeno je da su razdiobe koeficijenata korelacije normalne ($W=0.996$, $p=4.8 \cdot 10^{-10}$). Iz dobivenih razdioba određene su granične vrijednosti značajnosti koeficijenata kao 2.5-i i 97.5-i percentili. Takav pristup pokazuje koji je raspon korelacije u slučaju nasumce odabranih slijepih događaja. Kada bi Sunčevi parametri utjecali na naoblaku, tada bi korelacije izračunate za uzorke trebale biti veće od onih, koje su dobivene za slijepe događaje.

Signal u naoblaci, koji bi bio uzrokovan nekim od Sunčevih parametara (TSI, CR, F10.7), mora imati visoku efikasnost mehanizma utjecaja na naoblaku da bi ga se uopće moglo detektirati. Na primjer promjena od 1 % u toku kozmičkoga zračenja koja bi uzrokovala promjene od 1 % u naoblaci, značila bi efikasnost od 100 %. U slučaju niske naoblake iznad oceana nađeno je da 100000 kompozita s 19 nasumce odabranih događaja (*IncTSI*) daje $1.96 \sigma^4$ standardnih odstupanja, tj. šum od $1.33(\pm 0.24)$ % za vrijeme perioda od 41 dan (tablica 7.1). Jednostavan račun otkriva da detekcija korelacije između niske naoblake iznad oceana i Sunčevih parametara (TSI, CR, F10.7) na toj razini šuma u *IncTSI* uzorku (TSI povećanje od 0.08 %) zahtijeva mehanizam s efikasnošću većom

⁴odgovara 95 % razini pouzdanosti




Slika 7.1.: Histogram koeficijenata korelacije dobiven Monte Carlo simulacijama pomoću 100000 kompozita s 19 nasumce odabranih događaja (*IncTSI* uzorak). Korelirani su TSI i visoki sloj naoblake pri visokim geografskim širinama. Na slici su crveno naznačeni 2.5-i i 97.5-i percentili.

od 1662 % ($[1.33/0.08] * 100$). U slučaju *DecTSI-A* uzorka s 48 događaja i šumom od $0.83(\pm 0.15)$ %, za iste podatke naoblake i prosječno smanjenje toka kozmičkoga zračenja od 2.8 %, potrebna je efikasnost mehanizma od 30 % kako bi korelacija bila značajna (tablica 7.1).

Područje	n=48 (DecTSI-A)	n=37 (DecTSI-B)	n=19 (IncTSI)
LC <45°	0.95(±0.18)	1.09(±0.21)	1.51(±0.29)
LC >45°	1.75(±0.35)	1.99(±0.40)	2.78(±0.56)
MC <45°	1.22(±0.23)	1.38(±0.26)	1.93(±0.38)
MC >45°	1.44(±0.32)	1.63(±0.36)	2.27(±0.50)
HC <45°	1.51(±0.28)	1.72(±0.33)	2.40(±0.46)
HC >45°	3.30(±0.62)	3.75(±0.72)	5.20(±1.03)
LC - kopno	2.57(±0.60)	2.92(±0.68)	4.04(±0.95)
LC - ocean	0.83(±0.15)	0.95(±0.17)	1.33(±0.24)
MC - kopno	1.59(±0.37)	1.80(±0.41)	2.50(±0.57)
MC- ocean	1.11(±0.20)	1.26(±0.23)	1.75(±0.33)
HC - kopno	2.50(±0.47)	2.84(±0.53)	3.95(±0.75)
HC- ocean	1.83(±0.34)	2.09(±0.39)	2.90(±0.57)

Tablica 7.1.: Standardno odstupanje (1.96σ) za različite veličine kompozita (*DecTSI-A*: $n = 48$, *DecTSI-B*: $n = 37$, *IncTSI*: $n = 19$), za različite visine oblaka (LC - niski oblaci, MC - srednji oblaci, HC - visoki oblaci), geografske širine (<45° - niske geogr. širine, >45° - visoke geogr. širine) i područja iznad kopna i oceana. Standardna odstupanja su izračunata pomoću 100000 Monte Carlo simulacija nasumce odabranih kompozita koristeći ukupni ISCCP set podataka o naoblaci (1983-2008). Raspon odstupanja je prikazan u zagradama. Ove vrijednosti se mogu koristiti za procjenu šuma koji posjeduju podaci o naoblaci nakon usrednjavanja po određenim područjima i kompozitima.

7. Utjecaj ukupnoga Sunčevog zračenja na naoblaku



Slika 7.2.: Promjene Sunčevih parametara za kompozitne uzorke *IncTSI* ($n=19$, plave pune linije), *DecTSI-A* ($n=48$, crvene isprekidane linije) i *DecTSI-B* ($n=37$, zelene točkaste linije) u periodu od ± 20 dana u odnosu na najveća smanjenja ili povećanja ukupnog Sunčevog zračenja (definirani kao 0-dan). a) ukupno Sunčevo zračenje (TSI), b) tok kozmičkoga zračenja (GCR), c) Sunčevo radio zračenje (F10.7). Osjenčana područja označavaju standardna odstupanja srednjaka (kompozita) na dvostranoj 95 % razini pouzdanosti.

7.2. Rezultati i diskusija

Na slici 7.2 prikazane su promjene u TSI-u, CR-u i F10.7 za tri različita kompozitna uzorka *DecTSI-A*, *DecTSI-B* i *IncTSI*.

Za uzorak *IncTSI* (označen plavim punim linijama) uočljiv je porast u TSI-u s maksimumom od +0.076 % na dan 0 (slika 7.2a). Za ovaj uzorak nije bilo većih promjena u CR-u do dana +8, kada počinje pad u CR-u, koji doseže minimum od 1.5 % na dan +10 (slika 7.2b). Detaljnija analiza pojedinih događaja je pokazala da je samo nekoliko događaja odgovorno za pad u CR-u (npr. 26.08.1989, 6.03.1991, 19.05.1991). Te događaje nije bilo potrebno uklanjati iz uzorka *IncTSI* obzirom da su promjene u TSI-u i CR-u vremenski dovoljno razmaknute. Za F10.7 uočljiv je široki maksimum od 20 % na dan +9 (slika 7.2c). Ovaj maksimum kasni oko tjedan dana za maksimumom u TSI-u, što približno odgovara vremenu da aktivna područja na Suncu zbog Sunčeve rotacije dođu od centra do ruba Sunčeva diska (Lean i Woods, 2010). Fakule koje su odgovorne za promjene u TSI-u, imaju najveći utjecaj na rubu Sunčeva diska (Carlsson i sur., 2004) dok su promjene u UV zračenju Sunca (F10.7) najveće kada su aktivna područja u centru Sunčeva diska. Detaljna analiza pojedinih događaja je pokazala da su samo 4 događaja (7.06.1989, 13.5.1990, 22.01.1990. i 9.08.1991) doprinijela povećanju F10.7.

Za uzorak *DecTSI-A* (označen crvenim isprekidanim linijama) je uočljiv pad u TSI-u s minimumom od -0.13 % na dan 0 (slika 7.2a) i pad u CR-u s minimumom od 2.8 % na dan +3 (slika 7.2b). Kašnjenje CR minimuma objašnjava se prosječnim vremenom putovanja udarnog vala i koroninog izbačaja do Zemlje. Porast u F10.7 karakterizira maksimum od 40 % na dan 0 (slika 7.2c).

Promjene u TSI-u i F10.7 za uzorak *DecTSI-B* (označen zelenim točkastim linijama) su vrlo slične onima za *DecTSI-A* (slika 7.2a i 7.2c), što je i logično budući da je *DecTSI-B* podskup događaja iz *DecTSI-A*. Jedina razlika između ova dva uzorka je nedostatak izraženog CR minimuma za uzorak *DecTSI-B* u odnosu na *DecTSI-A* (slika 7.2b). To znači da je u uzorku *DecTSI-B* moguće analizirati Sunčeve parametre (F10.7 i TSI) bez utjecaja CR-a.

Na slici 7.3 su prikazani ISCCP podaci za naoblaku izraženi kao anomalije (%) za uzorke *IncTSI* (plave linije), *DecTSI-A* (crvene linije) i *DecTSI-B* (zelene linije), za područja niskih ($<45^\circ$, lijevo) i visokih geografskih širina ($>45^\circ$, desno) te za različite visine naoblake (niski, srednji i visoki sloj naoblake). Vidljivo je da su pri visokim geografskim širinama promjene u naoblaci nešto veće. Razlog tome je u činjenici da su područja po kojima su podaci usrednjeni manja pa je proporcionalno tome i šum u podacima veći. Na slici 7.4 su prikazani podaci za područja iznad oceana (lijevo) i kopna (desno). Ovdje se mogu uočiti veće promjene u naoblaci za područja iznad kopna, što je također rezultat

šuma jer su globalno gledajući ta područja daleko manja od područja iznad oceana.


Niti za jedan od navedenih uzoraka nisu dobivene značajne korelacije između naoblake i TSI-a, CR-a odnosno F10.7 ni za jedno od analiziranih područja (visoke ili niske geografske širine, područja iznad oceana ili kopna) niti za jednu visinu naoblake u periodu posmaka od 20 dana. Međutim, treba napomenuti da su za TSI dobiveni nešto veći koeficijenti korelacije u odnosu na CR ili F10.7. Nešto bolje, ali još uvijek neznačajne korelacije uočene su u slučaju *DecTSI-B* uzorka u područjima iznad oceana u usporedbi s područjima iznad kopna, što ide u prilog mehanizmu koji je predložio [Meehl i sur. \(2009\)](#). No, detaljna analiza koeficijenata korelacije za svaki element ISCCP mreže i za svaki Sunčev parametar (TSI, CR i F10.7) pokazala je nehomogene sporadične korelacije bez većih statistički značajnih geografskih područja.

U slučaju globalno usrednjenih podataka o naoblaci također nisu uočene značajne korelacije ni za jedan Sunčev parametar (TSI, CR, F10.7). Ove su korelacije bile nešto slabije u odnosu na regionalnu analizu, što je posljedica usrednjavanja pozitivnih i negativnih korelacija u globalnoj analizi.

Moguće je da postoji korelacija između Sunčevih parametara (Sunčeve aktivnosti) i naoblake na manjim područjima nego što su ona istražena u ovome radu. Međutim, u malim geografskim područjima je vrlo teško pouzdano detektirati signale malih amplituda. Razlog tome je velika varijabilnost naoblake, a ona to više utječe na rezultate što je veća prostorna rezolucija eksperimenta. To je evidentno i u tablici [7.1](#) koja prikazuje standardne devijacije dobivene Monte Carlo simulacijama kompozita različitih veličina i za različita područja (visina naoblake, geografske širine, oceani, kopno). Vidljivo je da su varijacije naoblake veće na manjim područjima analize i obrnuto.


Ako se usporede rezultati dobiveni s *DecTSI-A* i *DecTSI-B* uzorkom (smanjenja u TSI sa ili bez značajnih smanjenja u CR-u), vidljivo je da nema značajnijih razlika u promjenama naoblake. Razlike u promjeni naoblake nisu registrirane niti za područja iznad oceana i kopna (slika [7.4](#)), iako bi oblaci iznad oceana, prema ([Yu i Turco, 2001](#)) trebali biti osjetljivi na promjene u ionizaciji (poglavlje [4.2.1](#)). Također ne postoje razlike u promjeni naoblake između područja visokih i niskih geografske širina (slika [7.3](#)).

Sukladno provedenoj analizi, u kojoj su parametri TSI i F10.7 pažljivo odvojeni od CR-a, niti jedan od ispitivanih parametara (TSI, CR, F10.7) nije značajno povezan s promjenama u naoblaci.



Slika 7.3.: Normalizirane promjene naoblake (ISCCP) za niske ($<45^\circ$) i visoke ($>45^\circ$) geografske širine te za različite visine naoblake: A-B niski oblaci (0-3.2 km), C-D srednji oblaci (3.2-6.5 km) te E-F visoki oblaci (>6.5 km). Prikazan je cijeli period analize, tj. -20 do +40 dana od najvećih promjena u TSI. Plavim linijama je označen *IncTSI*, crvenim *DecTSI-A* i zelenim *DecTSI-B* uzorak.

7. Utjecaj ukupnoga Sunčevog zračenja na naoblaku



Slika 7.4.: Normalizirane promjene naoblake (ISCCP) za područja iznad oceana i kopna te za različite visine naoblake: A-B niski oblaci (0-3.2 km), C-D srednji oblaci (3.2-6.5 km) te E-F visoki oblaci (>6.5 km). Prikazan je cijeli period analize -20 do +40 dana od najvećih promjena u TSI. Plavim linijama je označen *IncTSI*, crvenim *DecTSI-A* i zelenim *DecTSI-B* uzorak.

8. Indirektni podaci za naoblaku - dnevni raspon temperatura

Dnevni raspon temperatura (DTR)¹ zraka na površini Zemlje može poslužiti kao indirektan podatak, kojime se može provjeriti sveza između kozmičkoga zračenja i naoblake (Dragić i sur., 2011).

Analize dostupnih podataka tijekom 20-og stoljeća pokazuju da se do 80 % dugoročnih globalnih varijacija u DTR-u može objasniti promjenama naoblake i oborina (Dai i sur., 1999). U prisutnosti oblaka, oborina i sekundarnih efekata kao što je vlažnost tla, DTR iznad kopna može biti smanjen za 25-50 % u odnosu na vedre dane (Dai i sur., 1999).

DTR je obrnuto proporcionalan naoblaci, jer oblaci reflektiraju dolazeće kratkovalno Sunčevo zračenje s posljedicom smanjivanja maksimalne dnevne temperature (poglavlje 1, slika 1.3). Taj efekt se smanjuje kako raste visina oblaka, a najmanji je za visoke i tanke slojeve oblaka male gustoće. Prisutnost oblaka u atmosferi također je uzrok apsorpciji i ponovnom emitiranju Zemljinoga dugovalnog zračenja (poglavlje 1, slika 1.3), što je posebno izraženo kod visoke naoblake. Stoga su temperature na Zemlji tijekom oblačnih noći veće nego u vedrim noćima. Općenito je efekt reflektiranja zračenja niskom naoblakom nešto veći nego efekt zadržavanja topline visokom naoblakom pa je DTR nešto osjetljiviji za nisku naoblaku nego za visoku (Dai i sur., 1999).

Efikasnost DTR-a u detekciji malih promjena u naoblaci dobro ilustrira sljedeći primjer: uslijed kondenzacijskih tragova zrakoplova, DTR na području Sjedinjenih Američkih Država promijenio se je za 1.8°C (Travis i sur., 2002).

DTR je dobra alternativa satelitskim podacima o naoblaci iz više razloga. Satelitski podaci o naoblaci dostupni su samo u relativno kratkom vremenskom periodu (~30 godina) i povezani s brojnim pogreškama (poglavlje 5.2). Mjerenja temperature zraka dostupna su za duži vremenski period i mnogo su jednostavnija u odnosu na neposredno određivanje naoblake, za koja su potrebna mjerenja više fizikalnih parametara.

U ovome dijelu rada korišteni su DTR podaci kako bi se ispitaio utjecaj kozmičkoga zračenja na naoblaku tijekom Forbushevih događaja. Ujedno su provjereni rezultati analize Dragić i sur. (2011), prema kojima Forbusheva smanjenja uzrokuju značajne promjene u

¹eng. *Diurnal Temperature Range*

DTR-u tj. naoblaci.

8.1. Podaci

Dva su nezavisna izvora podataka za DTR korištena u ovome radu: 1) DTR izračunat iz podataka mjerenja površinske temperature zraka pomoću 210 meteoroloških postaja² i 2) DTR dobiven pomoću podataka NCEP/NCAR³ reanalize za površinsku temperaturu zraka (Kalnay i sur., 1996).

Sve korištene meteorološke postaje su se nalazile na području sjeverne hemisfere (područje: 77.7°N - 34.7°N, 179.4°W - 170.4°E), a njihovi podaci preuzeti su iz Svjetskog centra za meteorologiju⁴ (<http://www.ncdc.noaa.gov/CDO/cdo>).

DTR dobiven iz NCEP/NCAR reanalize je izračunat za područje kopna za geografske širine 60°N - 60°S i sve geografske dužine. NCEP/NCAR podaci reanalize su dostupni globalno u mreži od 2.5° x 2.5° s vremenskom rezolucijom od 6 sati u razdoblju od 1950. do 2012. godine (Kalnay i sur., 1996).

Kod oba niza podataka DTR je izračunat kao razlika u dnevnoj minimalnoj i maksimalnoj temperaturi zraka.

Na slici 8.1 prikazane su sezonske varijacije za oba niza DTR podataka (iz meteoroloških postaja: puna linija, iz reanalize: točkasta linija) u razdoblju od 1951. do 2010. godine. Poklapanje između ta dva skupa podataka je vrlo dobro s koeficijentom korelacije $r = 0.92$. Uočljivo je da DTR podaci iz meteoroloških postaja pokazuju nešto raniji maksimum (u lipnju) nego podaci iz reanalize (u rujnu). Osim toga, DTR podaci temeljeni na reanalizi pokazuju nešto manji raspon vrijednosti u odnosu na DTR podatke dobivene iz meteoroloških postaja. Usporedba vrijednosti za zimske i ljetne mjesece⁵ u oba niza podataka je pokazala da je vrijednost DTR-a u podacima iz reanalize podcijenjena za najmanje 19 %. Lošije vremensko razlučivanje podataka reanalize mogući je razlog spomenutim razlikama.


Podaci iz reanalize imaju neke prednosti u odnosu na podatke dobivene iz meteoroloških postaja: dostupni su za veća geografska područja u pravilnoj mreži s pravilnim vremenskim i prostornim razlučivanjem i ne posjeduju razdoblja bez mjerenja. No nedostatak tih podataka je lošija vremenska rezolucija sa samo četiri vremenska mjerenja dnevno. Daljnji značajan nedostatak je da su podaci iz reanalize temeljeni na modelima, koji ne uzimaju u obzir svezu između kozmičkoga zračenja i naoblake. Stoga je moguće da je

²ovdje je bilo uključeno i 189 meteoroloških postaja, koje su korištene u Dragić i sur. (2011) radu

³National Centers for Environmental Prediction/National Center for Atmospheric Research

⁴World Data Center for Meteorology

⁵zimski mjeseci su definirani kao period prosinac-veljača, a ljetni kao lipanj-august



Slika 8.1.: Sezonske varijacije u DTR-u ($^{\circ}\text{C}$) izračunate uz pomoć 210 meteoroloških postaja (puna linija) i podataka reanalize (točkasta linija) na području Europe u razdoblju od 1951. do 2010. godine. Radi usporedbe DTR podaci iz reanalize su bili ograničeni na isto geografsko područje u kojem su bili dostupni DTR podaci iz meteoroloških postaja.

utjecaj Sunčeve aktivnosti u podacima reanalize djelomično ili potpuno uklonjen. Unatoč tome indirektni efekti bi trebali ostati prisutni u tim podacima.

Treba napomenuti da su u analizi provedenoj u ovome radu uzeta u obzir samo područja iznad kopna, jer su gotovo sve meteorološke postaje koje su korištene kao izvor podataka za DTR smještene u tim područjima.

Za provjeru povezanosti između Sunčeve aktivnosti i DTR-a korišteni su podaci ukupnoga Sunčeva zračenja (TSI) i toka kozmičkoga zračenja (CR). TSI podaci u razdoblju od 1978. do 2012. godine su uzeti iz PMOD/WRC⁶ združenih mjerenja (Fröhlich i Lean, 1998; Fröhlich, 2000). Za podatke toka kozmičkoga zračenja korištena su mjerenja NM-ima postaja Climax (39.37°N , -106.18°W , 3400 m n.v., $P_c=2.99$ GeV) i Moskva (55.47°N , 37.32°E , 200 m n.v., $P_c=2.46$ GeV) u razdoblju od 1951. do 2012. godine.

Korišten je uzorak od 267 Forbushevih događaja u razdoblju od 1955. do 2010. godine (uzorak $N267$), temeljen na podacima Mt. Washington NM-a⁷ i radu Laken i sur. (2011)⁸, a uključivao je sve događaje s promjenama kozmičkoga zračenja većim od 3 %. Kao ključna točka svih izračunatih kompozita odabran je datum najvećeg pada u toku kozmičkoga zračenja tijekom Forbusheva smanjenja (Laken i sur., 2011).

Neki od autora, koji su u kratkoročnim analizama detektirali povezanost naoblake i kozmičkoga zračenja, koristili su samo najveća Forbusheva smanjenja (Harrison i Step-

⁶Physikalisch-Meteorologisches Observatorium Davos / World Radiation Centre

⁷dostupni na web adresi: <http://www.ngdc.noaa.gov/stp/solar/cosmic.html>

⁸ovaj uzorak je također sadržavao i sve Forbusheve događaje koje je koristio Dragić i sur. (2011)

henson, 2006; Svensmark i sur., 2009; Dragić i sur., 2011). Stoga su iz $N267$ uzorka sa svim Forbushevima događajima odabrani samo oni događaji koji su imali pad toka kozmičkoga zračenja veći od 7 % (uzorak $N29$). Budući da je većina Forbushevih događaja povezana s manjim padom u kozmičkome zračenju, uzorak najvećih Forbushevih smanjenja je bio znatno manji i sastojao se od ukupno 29 događaja.

Svi kompoziti u ovoj analizi načinjeni su pomoću anomalija, kojima je prethodno oduzet 21-dnevni klizni srednjak. Intervali pouzdanosti su izračunati pomoću Monte Carlo metode pojedinačno za svaku vremensku točku kompozita, što je omogućilo pouzdanu statističku provjeru bez obzira na svojstva podataka (npr. autokorelacije). Ove metode su detaljno opisane u poglavlju 9.

8.2. Rezultati i diskusija


Na slici 8.2 prikazani su kompoziti za DTR, TSI i CR, sastavljeni od Forbushevih događaja praćenih u periodu analize od ± 40 dana. Na lijevoj strani slike 8.2 (a,c,g,e) su prikazani kompoziti načinjeni iz uzorka $N267$ (svi Forbushevi događaji, $n = 267$), a na desnoj strani slike 8.2 (b,d,f,h) kompoziti uzorka $N29$ (najveća Forbusheva smanjenja, $n = 29$).

Za oba analizirana parametra, CR (slika 8.2g-h) i TSI (slika 8.2e-f), uočljivo je da kompoziti imaju izrazito značajan minimum (t_0 za CR i t_{-3} za TSI). Intervali pouzdanosti (crtkane i točkaste linije za 95 % i 99 % razinu pouzdanosti) i raspon vrijednosti DTR-a su nešto veći za uzorak $N29$, što je posljedica manjeg broja događaja ($n = 29$).

Za kompozite DTR-a (iz meteoroloških postaja, slika 8.2c-d i iz NCEP/NCAR reanalize, slika 8.2a-b) nisu vidljivi značajni maksimumi ili minimumi u periodu do 20 dana nakon poremećaja u kozmičkome zračenju ili TSI-u. Ako postoji povezanost između Sunčevih parametara i naoblake, odziv u DTR-u bi trebao biti detektiran u periodu od 10 dana nakon poremećaja u Sunčevim parametrima (CR i TSI). Nadalje, u DTR kompozitima se značajni maksimumi uočavaju prije samih poremećaja u Sunčevim parametrima, što je jasan dokaz da nisu vezani za njih (slika 8.2a-b). Takvi maksimumi ili minimumi su posljedica šuma: u intervalu od 80 točaka možemo očekivati u prosjeku oko 4 takve značajne vrijednosti ($0.05 \cdot 80$) ako koristimo 95 % razinu pouzdanosti.

Na temelju postojećih istraživanja moguće je procijeniti hipotetski odziv DTR-a na promjene u kozmičkome zračenju. Za tu svrhu je uzet podatak iz rada Dai i sur. (1999) da porast naoblake od 70 % uzrokuje pad DTR-a za 3.6°C u ljetnim mjesecima te podatak iz rada Svensmark i sur. (2009) da pad toka kozmičkoga zračenja od 18 % uzrokuje pad u naoblaci od 1.7 %. Jednostavan račun pokazuje da bi promjena od 1 % u kozmičkome zračenju trebala biti popraćena s promjenom od 0.005°C u DTR-u ($\frac{3.6^\circ\text{C}}{70\%} \cdot \frac{1.7\%}{18\%} = 0.0048^\circ\text{C}$).

Obzirom da prosječno smanjenje u kozmičkome zračenju za uzorak $N267$ iznosi 3.4 %



Slika 8.2.: Prikaz svih izračunatih kompozita u periodu analize od ± 40 dana. (a-b) globalni DTR dobiven iz NCEP/NCAR reanalize za područje $60^{\circ}\text{N} - 60^{\circ}\text{S}$ i sve geografske dužine, (c-d) DTR dobiven iz meteoroloških postaja za područje $77.7^{\circ}\text{N} - 34.7^{\circ}\text{N}$, $179.4^{\circ}\text{W} - 170.4^{\circ}\text{E}$, (e-f) TSI (g-h), tok kozmičkoga zračenja (Climax i Moskva NM-i). Lijevo (a,c,e,g) su prikazani kompoziti za uzorak $N267$, a desno (b,d,f,h) za $N29$. Horizontalne crtkane i točkaste line predstavljaju intervale pouzdanosti na 95 % i 99 % razini značajnosti izračunate pomoću 100000 Monte Carlo simulacija. DTR je izračunat samo za područja iznad kopna. Sve prikazane vrijednosti su izražene kao anomalije dobivene s 21-dnevnim kliznim srednjakom.


(slika 8.2g), a za uzorak *N29* 8.4 % (slika 8.2h), očekivana promjena u DTR-u bi trebala biti 0.017°C za *N267* i 0.042°C za *N29*.

Koristeći intervale pouzdanosti za DTR na slici 8.2a-d (za npr. 95 % razinu pouzdanosti), može se odrediti granica detekcije koja je potrebna da bi se uočile značajne promjene u DTR-u uzrokovane smanjenjem u CR-u (poglavlje 9.6). U slučaju uzorka *N267* intervale pouzdanosti iznose $\pm 0.022^{\circ}\text{C}$ za DTR iz NCEP/NCAR reanalize (8.2a) i $\pm 0.07^{\circ}\text{C}$ za DTR iz meteoroloških postaja (8.2c). Unatoč velikoga uzorka od 267 Forbushevih smanjenja, granica detekcije za oba tipa DTR podataka je veća od mogućega odziva u DTR-u (0.017°C). Za uzorak *N29* dobiva se na isti način granica detekcije od $\pm 0.07^{\circ}\text{C}$ za DTR iz NCEP/NCAR reanalize (8.2b) i $\pm 0.22^{\circ}\text{C}$ za DTR iz meteoroloških postaja (8.2d), što je daleko veće od očekivanoga signala (0.042°C).

Slika 8.3 prikazuje DTR varijacije u ovisnosti o geografskom položaju s rezolucijom mreže od $2.5^{\circ} \times 2.5^{\circ}$ za uzorak *N29* te dane t_{+3} (8.3a) i t_{+6} (8.3b). Na manjim područjima, lokalno, uočljive su promjene u DTR-u i do $\pm 2.5^{\circ}\text{C}$. Prostorna raspodjela i iznos pozitivnih i negativnih varijacija u DTR-u su globalno ujednačeni bez većih područja s varijacijama istog predznaka ili iznosa. Varijacije u vremenu su vrlo izražene, što se vidi usporedbom DTR-a za t_{+3} i t_{+6} (8.3a-b). Sve to ukazuje da su DTR varijacije povezane sa stohastičnim promjenama. Kako bi se procijenila značajnost anomalija DTR-a za sve elemente mreže (geografske lokacije) načinjena je statistička provjera temeljena na Monte Carlo simulacijama. Za svaki element mreže konstruirano je 10000 kompozita s nasumce odabranim događajima te je iz pripadnih razdioba određena značajnost na dvostranoj 95 % razini. Na slici 8.3c je prikazan udio elemenata mreže sa značajnim vrijednostima DTR-a tijekom perioda analize od ± 40 dana. Vidljivo je da ne postoje istaknute varijacije u udjelu značajnih vrijednosti nakon ključnog datuma, koje bi mogle biti povezane s promjenama u Sunčevim parametrima. Varijacije su sličnog trajanja i amplitude tijekom cijelog perioda analize.

Dugoročna analiza (1951-2010) za oba niza DTR podataka (iz NCEP/NCAR reanalize i iz metroloških postaja) pomoću Lomb-Scargle periodograma pokazala je također da varijacije u DTR-u i CR-u ne posjeduju iste periode (Laken i sur., 2012b).


Predstavljeni rezultati nisu u skladu s rezultatima Dragić i sur. (2011). Oni su koristeći DTR podatke iz 189 meteoroloških postaja na području Europe primjenom kompozitne analize našli značajne promjene u DTR-u (0.38°C) povezane s 35 najvećih Forbushevih smanjenja ($I_{Fd} > 7\%$) u razdoblju od 1951. do 1991. godine (slika 8.4a). Autori su zaključili da je odziv u DTR-u veći u slučaju većih Forbushevih smanjenja. Do istih zaključaka došli su u kasnije objavljenom radu, u kojem su analizom obuhvatili i SEP događaje (Dragić i sur., 2013). Može se pokazati da je povećanje odziva u DTR-u, koji su uočili Dragić i sur. (2011, 2013) koristeći uzorak konstruiran od samo najvećih Forbushevih



Slika 8.3.: Promjene u DTR-u za uzorak $N29$ ($I_{Fd} \geq 7\%$) prikazane na svjetskoj karti za a) t_{+3} i b) t_{+6} . c) Udio (%) značajnih elemenata u odnosu na ukupan broj elemenata mreže u periodu analize od ± 40 dana. Podaci za DTR su iz NCEP/NCAR reanalize podataka i prikazani su samo iznad kopna. Crvene točkice označavaju udio značajnih elemenata za t_{+3} i t_{+6} . Statistička značajnost je izračunata za svaki element mreže na temelju 10000 DTR kompozita s nasumce odabranim događajima.

smanjenja, zapravo uzrokovano šumom, jer se odabirom najvećih Forbushevih smanjenja smanjuje broj događaja, pri čemu se povećava šum (Laken i Čalogović, 2013).

Koristeći iste DTR podatke kao i Dragić i sur. (2011) napravljena je reanaliza njihovih rezultata, koja je prikazana na slici 8.4b. DTR je u reanalizi preračunat u anomalije s oduzetim 21-dnevnim kliznim srednjakom. Intervali pouzdanosti za 95 % (crtkane linije) i 99 % (točkaste linije) razinu pouzdanosti izračunati su pomoću 10000 Monte Carlo simulacija iz razdioba kompozita s nasumce odabranim događajima. Ustanovljeno je da DTR doista, sukladno rezultatima Dragić i sur. (2011), pokazuje značajan maksimum za dan t_{+3} na 95 % razini pouzdanosti (slika 8.4b). No, ako se koristi period analize od ± 40 dana, umjesto ± 10 dana (slika 8.4a), uočava se da takav značajan maksimum nije neuobičajena pojava u dužem periodu analize. Naime, sveukupno postoje četiri značajna minimuma ili maksimuma u DTR-u za 95 % razinu pouzdanosti u periodu od 80 dana, što je u skladu sa statističkim očekivanjima ($80 \cdot 0.05 = 4$). Stoga se može zaključiti da maksimum u DTR-u za dan t_{+3} , iako je statistički značajan, nije robustan rezultat koji bi potvrdio vezu između DTR-a i kozmičkoga zračenja. Štoviše, upitna je tvrdnja Dragić i sur. (2011) da su njihovi rezultati značajni na 99 % razini pouzdanosti jer su oni statističku značajnost procijenili pomoću klasičnoga t-testa, koji nije uzimao u obzir autokorelacije u naoblaci.



Slika 8.4.: a) slika 3 iz [Dragić i sur. \(2011\)](#) b) DTR kompozit za najveća Forbusheva smanjenja ($I_{Fd} \geq 7\%$, $n = 37$) temeljen na mjerenjima 210 meteoroloških postaja u periodu analize od ± 40 dana. Crtkane i točkaste linije predstavljaju intervale pouzdanosti na 95 % i 99 % razini značajnosti izračunate pomoću 100000 Monte Carlo simulacija. Vrijednosti za DTR su izražene kao anomalije izračunate sa 21-dnevnim kliznim srednjakom.

9. Kompoziti i Monte Carlo simulacije kao ključ interpretacije hipoteze

9.1. Metoda kompozitne analize

Tehnika kompozita je korisna za odvajanje signala malih amplituda u podacima velike varijabilnosti (Chree, 1913, 1914). Analiza se bazira na odabiru podskupova podataka, koji sadrže ključnu točku u vremenskom nizu odabranu po nekom kriteriju, npr. pojavi nekog ekstremnog događaja u jednom ili više uzoraka podataka (Chree, 1913, 1914; Forbush i sur., 1983). Na taj način, gomilanjem i usrednjavanjem događaja koji su vremenski spojeni po ključnim datumima, pozadinski šum može biti smanjen do te mjere da se neki slabi signal može detektirati.

Ova metoda, koja se još naziva superponirajuća analiza epoha¹ ili kondicionalno uzorkovanje, se često koristi za provjeru hipotetske povezanosti između kozmičkog zračenja i naoblake za vrijeme Forbushevih smanjenja.


Slika 9.1 ilustrira primjer kompozitne analize i način na koji se koristi u indentifikaciji signala malih amplituda. Na slici 9.1a prikazan je hipotetski vremenski niz X_i s ukupno 400 vremenskih jedinica (npr. dani), uzorkovan u pravilnim vremenskim razmacima. Niz se sastoji od stohastične komponente ili šuma (N_i , definiran kao bijeli šum), deterministički određene komponente (D_i , dobiven zbrajanjem dvaju oscilacija različitih perioda) i komponente slabog signala (S_i). N_i i D_i komponente variraju u rasponu između 0 i 1, a S_i ima amplitudu od 0.3, koja pokazuje poremećaj u periodu od 5 dana i ponavlja se svakih 40 dana tijekom cijelog vremenskog niza. Dakle, vremenski niz X_i , je definiran kao:

$$X_i = D_i + N_i + S_i. \quad (9.1)$$

Prije nego što se započne s usrednjavanjem događaja, važno je da se uklone sve varijacije u X_i , koje nisu povezane s periodom signala S_i komponente i mogu smanjiti odnos signala i šuma². U praksi je često dosta teško znati točne osobine signala koji se traži, no ponekad

¹eng. *superposed epoch analysis*

²eng. *signal-to-noise ratio*



Slika 9.1.: a) Hipotetski niz X_i koji se sastoji od determinističke komponente (D_i), stohastičke komponente (N_i) i ponavljajućeg signala male amplitude (S_i). D_i i N_i su u rasponu od 0 do 1, a S_i ima amplitudu od 0.3. b) niz X_i (tanja linija) i niz F_i (debelija linija), koji je dobiven primjenom kliznog 21-dnevnog kliznog srednjaka na X_i . c) kompozitna matrica anomalija, A_{jt} , dobivena oduzimanjem X_i od F_i . Ona se sastoji od svih događaja centriranih oko ključne vremenske točke u kojoj se nalazi signal. d) kompozit C_t i standardno odstupanje srednjaka (SEM).

se može odrediti gornja granica duljine traženoga signala. U primjeru 9.1a ona iznosi manje od tjedan dana. Ako se upotrijebi visoko propustan filter duljine prozora tri puta veće od maksimalne duljine očekivanog signala (npr. 21 dan), to će smanjiti šum pri detekciji, a neće značajnije utjecati na signal koji se traži. Na slici 9.1b prikazani su niz X_i i filtrirani niz F_i , pri čemu je F_i dobiven primjenom 21-dnevnog kliznog srednjaka na X_i .

Kada se F_i oduzme od X_i dobiva se A_i , tj. niz nakon primjene visoko propusnog filtra, koji se može definirati kao anomalije. Ako su poznata vremena kada se dogodio signal u nizu S_i , onda se ta vremenska točka može odrediti kao ključno vrijeme po kojemu će se složiti kompozitna matrica A_{jt} , gdje je $j = 1, \dots, n$ broj događaja koji se usrednjava, a t je vrijeme. Pojedini događaji u periodu ± 20 dana su prikazani na slici 9.1c (matrica A_{jt}) na kojoj je teško procijeniti traženi signal. No ako se usrednji 10 događaja zajedno dobiva se kompozit:

$$C_t = \frac{1}{n} \sum_{j=0}^n M_{jt}, \quad (9.2)$$

a šum je smanjen za iznos drugog korijena od broja događaja koji su u kompozitu:

$$\Delta C_t = \frac{\sigma}{\sqrt{n}}, \quad (9.3)$$

gdje ΔC_t označava standardno odstupanje srednjaka³ za vrijeme t i σ je standardno odstupanje uzoraka od C_t . Na taj način se za svaki vremenski korak može izračunati srednjak svih događaja i standardno odstupanje srednjaka kako je prikazano na slici 9.1d. Na slici je uočljivo da se dobiva jasan signal, koji je centriran za dan 0 po ključnoj vremenskoj točki.

Neprikladna konstrukcija i evaluacija kompozita može znatno utjecati na rezultate i zaključke radova. Tako je npr. na području fizike Sunca i Zemlje objavljen veliki broj radova, koji se koriste analizom kompozita i povezuju relativno male promjene u Sunčevoj aktivnosti sa Zemljinom atmosferom. No rezultati tih radova su, iako su u njima korišteni slični ili isti podaci, vrlo često proturječni. Pregledom literature koja se odnosi na povezanost kozmičkog zračenja i naoblake može se naći cijeli spektar različitih rezultata. Jedna grupa autora nalazi pozitivne korelacije (npr. Tinsley i Deen, 1991; Pudovkin i Veretenenko, 1995; Todd i Kniveton, 2001, 2004; Harrison i Stephenson, 2006; Svensmark i sur., 2009; Dragić i sur., 2011; Harrison i sur., 2011; Okike i Collier, 2011), druga grupa autora ne nalazi nikakvu povezanost (npr. Lam i Rodger, 2002; Kristjánsson i sur., 2008; Sloan i Wolfendale, 2008; Laken i sur., 2011; Laken i Čalogović, 2011; Laken i sur., 2012b), a treća grupa nalazi negativne korelacije (npr. Wang i sur., 2006; Troshichev i sur., 2008). Razlog ovakvoj raznolikosti rezultata mogle bi biti metodološke razlike u analizi kompozita (npr. povezane s filtriranjem ili normalizacijom podataka), ili neprimjerene statističke provjere (npr. neki tipovi podataka nisu podobni za određene statističke provjere).

U ovome radu analizirani su slučajevi neprikladne primjene kompozitne analize i predložena je robustna metoda za procjenu statističke značajnosti, koja se bazira na Monte Carlo simulacijama. Ta metoda je razrađena na primjeru provjere hipoteze povezanosti kozmičkoga zračenja i naoblake te detaljno opisana u sljedećim poglavljima.

9.2. Podaci


Odabrano je ukupno 44 Forbusheva smanjenja koja su registrirana pomoću mjerenja NM-om Mt. Washington Opservatorija (44.30°N, 288.70°E, 1900 m n.v., $P_c=1.24$ GeV) u razdoblju od 1984. do 1995. godine⁴. Podaci o toku kozmičkoga zračenja su izmjereni NM-ima postaja Climax Colorado (39.37°N, -106.18°W, 3400 m n.v., $P_c=2.99$ GeV) i

³eng. *standard error of the mean*

⁴lista Forbushevih smanjenja je uzeta s web adrese <http://www.ngdc.noaa.gov/stp/solar/cosmic.html>

Moskva (55.47°N , 37.32°E , 200 m n.v., $P_c=2.46$ GeV). Podaci su normalizirani na srednjak mjerenja u razdoblju 1950-2010, te izraženi kao dnevni srednjaci (slika 9.2a). Kao ključni datum za konstrukciju kompozita odabrana je točka najvećeg smanjenja toka kozmičkoga zračenja tijekom Forbushevih smanjenja. Oni događaji koji su bili povezani s većim SEP događajima (>500 MeV) u razdoblju ± 7 dana od ključnog datuma, nisu korišteni u analizi.

Globalni dnevni podaci ukupne naoblake⁵ uzeti su iz ISCCP IR D1 u razdoblju od 1.7.1983. do 31.12.2009. (slika 9.2b).



Slika 9.2.: a) Dnevno usrednjeni i normalizirani tok kozmičkoga zračenja (%) izračunat iz mjerenja NM-ima postaja Climax Colorado i Moskva. b) globalna dnevna naoblaka (%) iz ISCCP IR D1.

9.3. Filtriranje podataka

Obzirom da Forbusheva smanjenja traju po nekoliko dana, logično je za očekivati da će promjene u naoblaci imati isti ili sličan period. Kako bi se pretpostavka o povezanosti kozmičkoga zračenja i naoblake mogla provjeriti na kratkoročnim vremenskim skalama,


⁵total cloud fraction (1000-50 mb)

potrebno je sve ostale duže periode koji nisu povezani s hipotezom ukloniti iz podataka. Forbush i sur. (1982, 1983) su pokazali da se u tradicionalna statistička ispitivanja može unijeti pristranost⁶ (npr. t-testom) ako varijacije s dužim periodima nisu uklonjene. Uklanjanje linearnih trendova odnosno godišnjih varijacija, koje najčešće dominiraju u geofizičkim podacima, obično nije dovoljno da bi se uklonile i srednjoročne varijacije koje su prisutne u naoblaci, a povezane su sa sinoptičkim uvjetima. Sustavi naoblake mogu se protezati po nekoliko tisuća kilometara te mogu trajati od nekoliko dana do nekoliko tjedana, a u ovom slučaju to su vremenske skale koje su kraće od godišnjih varijacija, ali duže od varijacija koje se traže u provjeri hipoteze. Uključivanje takvih srednjoročnih varijacija u kompozite može rezultirati s pomaknutim srednjim vrijednostima i autokorelacijskim efektima. Stoga je poželjno koristiti prikladne filtre, kako bi se zadržao samo onaj dio varijacija u podacima koje se tiču provjere hipoteze. U slučaju hipoteze povezanosti kozmičkoga zračenja i naoblake prikladan je filtar s 21-dnevnim kliznim srednjakom budući da bi se efekti ionizacije na mikrofiziku aerosola i oblaka trebali događati na vremenskim skalama manjim od tjedan dana (Arnold, 2006).

Filtriranje je potrebno provesti s pažnjom jer u nekim slučajevima može unijeti značajne artefakte ili potpuno uništiti traženi signal. Na slici 9.3 prikazane su pogreške i artefakti filtriranja za tri različita hipotetska poremećaja (plave linije) u trajanju od 3 dana (9.3a), 7 dana (9.3b) i 11 dana (9.3c). Oduzimanjem 21-dnevnog kliznog srednjaka (crne linije) od originalnih nizova dobije se filtrirani niz, koji se može definirati kao anomalije (crvene linije). Na slikama 9.3a-c lako je uočiti da se pogreška filtra povećava s porastom vremena trajanja poremećaja, što ima za posljedicu da anomalije pokazuju sve veće i veće vrijednosti u odnosu na originalni niz (9.3a: +9.6 %, 9.3b: +19 %, 9.3c: +27.8 %), a amplitude se smanjuju (9.3c: 0.8 %, za poremećaj trajanja 15 dana: 9 %). Pogreške rastu kada se duljina poremećaja približava duljini prozora kliznog srednjaka. Iz ovoga se može zaključiti da duljina prozora filtra (kliznog srednjaka) mora biti oko 3 puta duža nego najduži period signala koji se želi detektirati.

Na slici 9.3d je prikazan stvaran primjer pogrešaka filtriranja za tok kozmičkoga zračenja (plava linija), koji je dobiven pomoću kompozita od 44 događaja. Na istoj slici je prikazan 21-dnevni klizni srednjak kozmičkoga zračenja (crna linija) te pripadajuće anomalije (crvena linija) nakon oduzimanja kliznog srednjaka. Korištenje 21-dnevnog kliznog srednjaka je u ovom slučaju smanjilo amplitudu Forbusheve promjene toka kozmičkoga zračenja za oko 4 %. Mala pristranost je također prisutna: vrijednosti za tok kozmičkoga zračenja neposredno prije i nakon Forbushevih događaja su nešto veće od stvarnih. Efekt pristranosti je neznatan ako se koristi dovoljno dugačak prozor visoko propusnog filtra (kliznog srednjaka).


⁶eng. textitbias



Slika 9.3.: Prikaz pogrešaka filtriranja visoko propusnim filtrom tj. 21-dnevnim kliznim srednjakom. (a-c) simetrični poremećaji u signalu centrirani na t_0 u trajanju od a) 3 dana b) 7 dana i c) 11 dana s amplitudom od 100 jedinica (plave linije). Crna linija prikazuje poremećaje nakon primjene kliznog srednjaka, a crvenim linijama su prikazane anomalije koje se dobiju oduzimanjem kliznog srednjaka od originalnih podataka (filtrirani niz). (d) analogno prikazan kompozit toka kozmičkoga zračenja sastavljen od 44 Forbusheva smanjenja (plava linija), klizni srednjak (crna linija) i anomalije (crvena linija) koje su zbog bolje preglednosti prikazane s posmakom od -5.

Unatoč ograničenjima, prednosti u uklanjanju šuma filtriranjem su velike, jer šum može pridonijeti autokorelaciji u podacima i to može imati značajan utjecaj na statističke provjere i rezultate. Kako bi se odredio utjecaj i prednosti uklanjanja srednjoročnih varijacija, generirani su kompoziti naoblake, sastavljeni od 20 nasumce odabranih slijepih događaja (datuma) tijekom perioda analize od ± 40 dana. Svaki datum odabran je pomoću generatora slučajnih brojeva i svih dostupnih podataka o naoblaci u razdoblju od 1983. do 2010. godine. Jedan primjer takvoga kompozita prikazan je na slici 9.4a. Anomalije naoblake su izračunate pomoću dvije različite metode. U prvoj metodi je podacima samo uklonjen linearni trend (crne linije), a u drugoj je primijenjen već opisani filtar s 21-dnevnim kliznim srednjakom (plave linije) i na taj način su uklonjene i srednjoročne varijacije u podacima. Slika 9.4a daje predodžbu o tome na koji način srednjoročne vari-

jacije utječu na kompozite. Kako bi se objektivno mogle odrediti razlike između metoda, one su izračunate 100000 puta (Monte Carlo simulacije) te su prikazane u histogramu na slici 9.4b. Apsolutno standardno odstupanje (σ) razlika između dvije metode iznosi 0.1 %, što kasnijim zanemarivanjem može imati utjecaj na određivanje statističke značajnosti dobivenih varijacija u kompozitima. Treba napomenuti da razlika između navedene dvije metode također varira za pojedine podatke, za različiti broj događaja u kompozitu te za duljinu analiziranog niza. Jedan mali dio pristranosti također dolazi od već spomenutih pogrešaka filtriranja.



Slika 9.4.: Usporedba dviju metoda za računanje anomalija u naoblaci. a) primjer kompozita s 20 nasumce odabranih događaja: primjenom prve metode uklonjen je samo linearni trend (crna linija), a primjenom druge metode su podaci filtrirani 21-dnevnim kliznim srednjakom (plava linija). b) razlike između metoda izračunate pomoću 100000 kompozita s 20 nasumce odabranih slijepih događaja. Naznačeno je također apsolutno standardno odstupanje σ između te dvije metode.

9.4. Omjer signala i šuma kao ograničavajući faktor u konstrukciji kompozita

Kompozitnom analizom su često ispitivana ograničena područja i to ona u kojima je očekivan najveći efekt utjecaja nekoga Sunčeva parametra. Interes autora usmjeren je npr. na: više slojeve atmosfere iznad Antartike (Todd i Kniveton, 2001, 2004; Laken i Kniveton, 2011); područja južne hemisfere iznad oceana na različitim visinama (Kristjánsson i sur.,

2008); nisku naoblaku iznad tropskih i subtropskih područja (Svensmark i sur., 2009); indikatore intenziteta ciklona i anticiklona⁷ iznad sjeverne hemisfere i srednjih geografskih širina (Tinsley i sur., 1989; Tinsley i Deen, 1991); iznos ukupnog ozona na područjima geografskih širina između 40°N i 50°N za vrijeme perioda jake Sunčeve aktivnosti i istočne faze kvazi-bijenalne oscilacije⁸ (Fedulina i Laštovička, 2001); varijacije u atmosferskom tlaku i nastanku ciklonalnih te anticiklonalnih područja iznad sjevernog Atlantika (Arta-monova i Veretenenko, 2011) i dnevne raspone temperature iznad Europe (Dragić i sur., 2011; Laken i sur., 2012b).

Neki autori smatraju da je odziv u naoblaci, zbog šuma, moguće detektirati samo za vrijeme najvećih Forbushevih smanjenja (Harrison i Stephenson, 2006; Svensmark i sur., 2009; Dragić i sur., 2011). Iako je takvo razmišljanje racionalno, učestalost jakih Forbushevih smanjenja je vrlo rijetka. Ukupno 55 Forbushevih smanjenja iz razdoblja od 1984. do 1995. godine imala su sljedeći intenzitet, I_{Fd} ⁹: 28 slabijih Forbushevih smanjenja ($I_{Fd} < 5 \%$), 21 Forbushevo smanjenje srednje jačine ($5 \% \leq I_{Fd} < 10 \%$) i 6 vrlo jakih Forbushevih smanjenja ($I_{Fd} \geq 10 \%$). Periodi analize često su ograničeni dostupnošću i kvalitetom podataka, a većina podataka je dostupna samo za periode od nekoliko dekada ili manje. Iz toga se može zaključiti da kompoziti koji se temelje samo na većim ili najvećim Forbushevim smanjenjima imaju mali broj događaja i stoga su ograničeni šumom (Laken i sur., 2009; Harrison i Ambaum, 2010). No veći broj malih Forbushevih smanjenja u kompozitima također ne daje puno bolji omjer signala i šuma, jer je i signal puno slabiji.

Slika 9.5 pokazuje da se ograničavanjem prostornih područja analize ili broja događaja povećava šum. Primjenom Monte Carlo simulacija iz cjelokupnog ISCCP D1 niza podataka u razdoblju od 1983. do 2010. godine nasumce su odabrani datumi slijepih događaja, iz kojih su potom pomoću anomalija s 21-dnevnim srednjakom izračunati kompoziti. Pri tome je broj događaja n u kompozitima variran od 10 do 10000, a veličina područja analize, a je varirana od 0.1 % do 100 % pokrivenosti Zemljine površine¹⁰. Prilikom odabira manjih područja analize vodilo se također računa o tome da su lokacije odabrane nasumce. Svaki korak je ponovljen 10000 puta te je za svaku kombinaciju varijabli a i n dobivena razdioba od 10000 srednjaka kompozita za t_0 . Na slici 9.5 prikazani su 97.5-i percentili razdioba u ovisnosti o a i n . Kako bi se pouzdano mogao detektirati neki signal u naoblaci za određeni broj događaja, n i određenu veličinu područja analize, a , taj signal mora biti veći od vrijednosti na slici 9.5. Stoga vrijednosti na slici 9.5 prikazuju gornji


⁷eng. *vorticity area index*

⁸ eng. *quasi-biennial oscillation*, QBO

⁹definiran kao dnevna apsolutna promjena u toku kozmičkoga zračenja

¹⁰ISCCP satelitski podaci imaju globalnu pokrivenost cijele Zemljine površine, no ta pokrivenost je manja od 100 % (za nekoliko % do $\approx 20 \%$) jer neka mjerenja nedostaju, što se mijenja u vremenu

interval pouzdanosti. Donji interval pouzdanosti (2.5-i percentil), koji nije prikazan, ima gotovo iste vrijednosti¹¹ u negativnom području.



Slika 9.5.: Povezanost između veličine područja analize, a (izražene kao udio globalne Zemljine površine u %, x-os), broja događaja, n u kompozitima (y-os) i iznosa šuma podataka, koji je izražen kao 97.5-i percentil anomalija naoblake (z-os, u %) izračunat iz pripadajućih razdioba. Razdiobe su izračunate za svaku točku posebno pomoću 10000 Monte Carlo simulacija s kompozitima konstruiranim od anomalija naoblake filtriranih 21-dnevnim kliznim srednjakom. Sve osi su logaritamske.

Šum, koji je funkcija parametara a i n , definira granicu detekcije signala na nekoj razini pouzdanosti. Npr. ako su kompoziti načinjeni od 10 događaja i pokrivaju samo 1% Zemljine površine, tada bi promjene u naoblaci trebale biti veće od ± 6.3 % da bi bile statistički značajne na dvostranoj 95 % razini pouzdanosti.

Ako se pretpostavi neka vrijednost za efikasnost hipotetskog utjecaja kozmičkoga zračenja na naoblaku, tada je za svaku promjenu kozmičkoga zračenja moguće izračunati pripadnu promjenu u naoblaci, tj. veličinu traženoga signala. Polazeći od takvih izračuna, kompoziti se mogu konstruirati na način da se signal, ako postoji, pouzdano detektira uz određeni šum.

Svensmark i sur. (2009) su koristeći 5 Forbushevih događaja zaključili da smanjenje u toku kozmičkoga zračenja od 18 % prati smanjenje u naoblaci od 1.7 %. Ako vrijednost efikasnosti iznosi 9.4 % (1.7 %/18 %) i ako je šum jednak onome prikazanome na slici 9.5 i

¹¹razdiobe imaju skoro idealnu normalnu razdjelu oko 0

kompozit je konstruiran od 10 Forbushevih događaja s prosječnim smanjenjem kozmičkoga zračenja od 3 %¹², tada se u slučaju linearne povezanosti može očekivati signal od 0.28 % ($9.4 \% \cdot 3 \%$). Čak i u slučaju globalne analize, gdje bi bili korišteni svi podaci o naoblaci s globalnom pokrivenošću od 100 %, signal odziva naoblake bi bio 2 puta manji od šuma budući da gornji interval značajnosti za $n = 10$ nikada ne pada ispod 0.6 % (slika 9.5). Potrebno je više od 50 Forbushevih događaja da bi se u globalnoj analizi mogao detektirati signal od 0.28 %.

9.5. Procjena statističke značajnosti primjenom Monte Carlo simulacija

U fizici Sunca i Zemlje se tijekom perioda analize kompozita srednjaci uspoređuju u vremenu, npr. period prije i poslije Forbushevih smanjenja (Pudovkin i Veretenenko, 1995; Todd i Kniveton, 2001, 2004; Svensmark i sur., 2009; Dragić i sur., 2011; Okike i Collier, 2011). No neki autori zaboravljaju da se mjerenja u vremenu ne mogu promatrati kao neovisna (jer su kompoziti sastavljeni od geofizičkih podataka, koji su poznati kao nizovi s relativno velikim autokorelacijama) i da ih se ne može neposredno uspoređivati bez informacija o iznosu i posljedicama autokorelacija.

Metode statističke obrade geofizičkih podataka u analizama kompozita opisane su u radovima Forbush i sur. (1982, 1983); Singh i Badruddin (2006). Takvim metodama može se pouzdano odrediti statistička značajnost u nizovima s autokorelacijama.

Autokorelacije se pojavljuju u tzv. nizovima s pamćenjem, koji imaju svojstvo da na svako mjerenje u vremenu utječu prethodna mjerenja. To se odražava na varijanci i standardnom odstupanju niza, koja je, ako je procijenjena na standardni način, manja od stvarne. Kako bi se varijanca niza pravilno skalirala, potrebno je izračunati efektivnu veličinu uzorka, koja je određena procijenjenim brojem neovisnih mjerenja (npr. Wilks, 1997). Takav postupak rezultira u nešto širim intervalima pouzdanosti nego kad bi autokorelacije bile zanemarene, no vjerojatnost da se neka varijacija interpretira kao statistički značajna je manja i odgovara statističkoj razini pouzdanosti (npr. 95 %). Efektivne veličine uzoraka se mogu izračunati metodama koje su opisane u radovima Ripley (1987); Neal (1993).

Među prvim koji su koristili metodu procjene statističke pouzdanosti pomoću nasumce odabranih uzoraka u obradi geofizičkih podataka bili su Schuurmans i Oort (1969). Oni su proučavali utjecaj Sunčevih bljeskova na troposferski tlak sjeverne hemisfere pomoću kompozita koji se sastojao od 81 događaja. Budući da su znali da je atmosferski tlak (kao

¹²vrijednost od 3 % se često uzima kao granica koja definira Forbushevo smanjenje

i u slučaju naoblake) autokorelirani podatak, očekivali su da će broj statistički značajnih vrijednosti premašivati razinu pouzdanosti od 95 %¹³ iako nema povezanosti sa Sunčevim bljeskovima. Kako u to doba još nije bilo modernih računala, [Schuurmans i Oort \(1969\)](#) su načinili 3 kompozita s istim brojem nasumce odabranih slijepih događaja te ih usporedili s kompozitom stvarnih podataka kako bi procijenili utjecaj autokorelacije.


Postupak je u slučaju naoblake sličan onome koji su opisali [Schuurmans i Oort \(1969\)](#). Konstruirao se kompozit s nasumce odabranim "slijepim" događajima, taj postupak se ponovi mnogo puta pomoću Monte Carlo simulacije te se na temelju vrijednosti kompozita izračunaju funkcije gustoće vjerojatnosti (razdiobe). Iz razdioba se tada može precizno odrediti statistička značajnost varijacija srednjaka kompozita za neko vrijeme t , tj. može se neposredno provjeriti koja je vjerojatnost da se određena varijacija u kompozitu pojavi slučajno.

Ta metoda je u ovome radu korištena u slučaju procjene šuma u naoblaci (slika 9.5). "Slijepi" događaji za konstrukciju kompozita odabiru se pomoću metode slučajnih brojeva koristeći cijeli skup podataka, pri čemu broj događaja, n u kompozitima i veličina područja analize, a moraju odgovarati onima u stvarnoj analizi. Prije računanja kompozita i funkcija gustoće vjerojatnosti Monte Carlo simulacijama, podaci moraju biti obrađeni na isti način (npr. filtriranje 21 dnevnim srednjakom) na koji je provedena kompozitna analiza stvarnih uzoraka. Ovim postupkom može se izračunati funkcija gustoće vjerojatnosti za svaku vremensku točku, t tijekom perioda kompozitne analize. Naime, ponekad se događa da, npr. zbog postupaka normalizacije, kompoziti ne posjeduju istu varijancu u vremenu nego se ona mijenja (poglavlje 9.7, slika 9.9). Na temelju funkcija gustoće vjerojatnosti mogu se lako izračunati intervali pouzdanosti za neku statističku razinu α (npr. 5 %) kao percentili: npr. kao 95-i percentil za jednostranu statističku značajnost ili 2.5-i i 97.5-i percentil za dvostranu statističku značajnost. Takav postupak je točan samo u slučaju ako dobivene razdiobe dobro reprezentiraju populaciju podataka iz koje su izračunate.

Statistička značajnost se može procijeniti i iz standardnog odstupanja odnosno $\pm 1.96 \sigma$ (razina 95 %) ako se radi o normalnoj razdiobi, što koriste mnogi klasični statistički testovi (npr. t-test). U tom slučaju se pri normalnoj razdiobi 2.5-i i 97.5-i percentil poklapaju s $\pm 1.96 \sigma$ vrijednostima. No, geofizički nizovi često ne slijede idealne normalne razdiobe pa je procjena percentilima točnija od one standardnim odstupanjem (σ). To je prikazano na slici 9.6, koja pokazuje histograme anomalija za tok kozmičkoga zračenja i naoblaku s dnevnim podacima u razdoblju od 1983. do 2010. godine. Uočljivo je da u

¹³statistička razina pouzdanosti je definirana vjerojatnošću da se određeni rezultat nalazi na određenom dijelu razdiobe rezultata; npr. za razinu pouzdanosti od 95 %, ako imamo nizove koji nemaju pamćenje (tj. nisu autokorelirani), očekuje se da će 5 od 100 rezultata biti statistički značajno ako nisu prisutni deterministički efekti


slučaju toka kozmičkoga zračenja (slika 9.6a) histogram ne prati normalnu razdiobu (crne linije) i pomaknut je prema pozitivim vrijednostima. U prikazanom primjeru su razlike u razdiobama relativno malene, no one mogu biti i znatno veće.



Slika 9.6.: Histogrami razdioba dnevnih anomalija u cijelom periodu dostupnih podataka (1983-2010) za: a) tok kozmičkog zračenja (%) i b) naoblaku (%). Za usporedbu je crnim linijama prikazana normalna razdioba. Srednje standardno odstupanje $\pm 1.96\sigma$ je označeno crvenim točkastim linijama, a 2.5/97.5-i percentili plavim punim linijama, a njihova razlika je označena sa "Diff:" (eng. *difference*).

Pod uvjetom da se raspolaže kvalitetnim podacima, više iteracija Monte Carlo simulacijama značit će pouzdaniji rezultat. U postupku simulacija razdiobe konvergiraju prema točnim vrijednostima. U slučaju premalo napravljenih iteracija može nastati prevelika pogreška, a previše iteracija uzima previše računalnog vremena. Konvergencija rezultata Monte Carlo simulacija za kompozit od 40 događaja ($n = 40$) je prikazana na slici 9.7, a izražena je kao standardno odstupanje (σ) srednjih vrijednosti od 100 pojedinačnih Monte Carlo simulacija u ovisnosti o broju iteracija u svakoj simulaciji. Uočljivo je da s brojem

iteracija odstupanje eksponencijalno pada. Obzirom da odstupanje brzo konvergira, po pravilu 80:20 (Paretovo pravilo), ono se smanjuje na 20 % već pri 22. Monte Carlo iteraciji. Potpuna konvergencija se dobiva nakon nekoliko tisuća iteracija i to je optimalan broj u skladu s brzinom današnjih prosječnih računala.



Slika 9.7.: Konvergencija rezultata Monte Carlo simulacija prikazana kao standardno odstupanje (σ , y-os) između 100 pojedinačnih Monte Carlo simulacija koristeći kompozite od 40 nasumce odabranih događaja ovisno o broju iteracija u svakoj simulaciji (x-os). Vrijednosti iteracija su varirane od 5 do 200000. Puna linija prikazuje eksponencijalnu prilagodbu (fit) u prikazanim točkama, naznačeni su parametri i kvaliteta prilagodbe, a zvjezdica prikazuje vrijednost za koju je standardno odstupanje konvergiralo na 20 % od početnih vrijednosti.

9.6. Procjena statističke značajnosti na primjeru kozmičkoga zračenja i naoblake

Slika 9.8 prikazuje primjer procjene statističke značajnosti Monte Carlo simulacijama koristeći podatke za tok kozmičkoga zračenja (slika 9.8a) i naoblaku (9.8b). Kompoziti su konstruirani s ukupno 44 Forbusheva događaja u kojima nije bilo promjena u SEP-u, a prikazani su u periodu od ± 40 dana (crne pune linije) s pripadnim standardnim odstupanjima ($\pm 1.96 \sigma$, plave točkaste linije). Intervali pouzdanosti s dvostranom razinom pouzdanosti od 95 % i 99 % (crvene iscrtkane i točkaste linije) su izračunati pomoću Monte Carlo simulacija.

Srednjaci dnevnih anomalija u toku kozmičkoga zračenja su prikazani na slici 9.8a i pokazuju najveći poremećaj za t_0 od $(-3.01 \pm 0.53) \%$, što odgovara odstupanjima od (18 ± 3.2)

σ (statistička vjerojatnost, $p \ll 0.01$). Statistički značajne anomalije od $(0.89 \pm 0.37) \%$ (6.3 ± 2.1) σ su prisutne i prije Forbushevog smanjenja, za t_{-3} . Takva povećanja u toku kozmičkoga zračenja neposredno prije Forbushevih smanjenja su tipična i odgovaraju utjecaju udarnog vala na čestice kozmičkoga zračenja (poglavlje 3.6). Povećanju toka kozmičkoga zračenja neposredno prije Forbusheva smanjenja pridonose i artefakti filtra kliznog srednjaka. Preostala dva statistički značajna poremećaja u toku kozmičkoga zračenja za t_{+10} i t_{+23} su uzrokovana SEP događajima.

Anomalije naoblake ne pokazuju značajniji odaziv na promjene u kozmičkome zračenju u periodu analize kompozita, što je vidljivo na slici 9.8b. Najveća pozitivna ili negativna odstupanja su se dogodila prije statistički značajnog odstupanja u kozmičkome zračenju i to za t_{-26} $(-0.39 \pm 0.38) \%$ i t_{-18} $(0.33 \pm 0.32) \%$ što odgovara standardnim devijacijama od $(2.5 \pm 2.4) \sigma$ i $(2.1 \pm 2.1) \sigma$ te statističkim vjerojatnostima od $p = 0.01$ i $p = 0.04$. Sve ostale anomalije na slici 9.8b su manje veličine. Iznimka je anomalija na t_{+5} s vrijednošću od $(-0.37 \pm 0.41) \%$ odnosno $(2.4 \pm 2.6) \sigma$ i statističkom vjerojatnošću od $p = 0.02$. Iako bi neki tu anomaliju pripisali signalu u naoblaci, jer odgovara po predznaku i smještena je u vremenski period kada možemo očekivati odziv naoblake, treba pažljivo razmotriti taj rezultat prije nego što se zaključi da je statistički značajan.

Ako se analizira 81 točka u vremenu ($t_{\pm 40}$), može se očekivati da će se za statističku razinu od 95 % dobiti oko 4 statistički značajne anomalije ($81 \cdot 0.05 = 4.05$). Na slici 9.8b ima 6 dana za koje je srednja vrijednost anomalije naoblake $p < 0.05$. Za usporedbu, u slučaju toka kozmičkoga zračenja (slika 9.8a) ima 26 dana sa značajnim anomalijama $p < 0.05$, što je posljedica utjecaja Forbushevih smanjenja i SEP-a. Procjena statističke značajnosti bit će pouzdanija ako se srednje vrijednosti evaluiraju zajedno s njihovim standardnim odstupanjima nego kada su evaluirane samo srednje vrijednosti. Na primjer za anomaliju kozmičkoga zračenja pri t_{-3} i gornji i donji interval je u području $p < 0.05$. No za anomaliju naoblake pri t_5 , gornji interval ima $p > 0.05$ i nalazi se daleko od intervala pouzdanosti zbog čega ta anomalija nije pouzdano statistički značajna.

Uzimajući u obzir sve rezultate ove analize, zaključak je da statistički značajne varijacije u toku kozmičkoga zračenja ne uzrokuju statistički značajne varijacije u naoblaci.

Iz ovih rezultata može se izračunati efikasnost koju bi mehanizam hipotetskog utjecaja kozmičkoga zračenja na naoblaku morao imati da bi ovom analizom bio detektiran signal u naoblaci. Ako je prosječno smanjenje toka kozmičkoga zračenja tijekom Forbushevih događaja 3 % (slika 9.8a), a granica pouzdanosti podataka naoblake iznosi 0.40 % (slika 9.8b), tada efikasnost mehanizma mora biti veća od 13 % ($0.40\% / 3\%$) da bi bila detektirana značajna anomalija u naoblaci. To je veća efikasnost utjecaja kozmičkoga zračenja na naoblaku od one koju su procijenili neki autori (npr. Svensmark i sur., 2009, 9.4 %). Uz efikasnost od 9.4 % i eksperimentalne uvjete ovdje prikazanoga primjera (slika 9.8)

odziv naoblake ne bi mogao biti detektiran, ako i postoji.

Iako prikazana metoda procjene statističke značajnosti Monte Carlo simulacijama ima mnoge prednosti u usporedbi s klasičnim statističkim provjerama (npr. t-test), postoje situacije kada ova metoda može dati krive procjene. To se, na primjer, događa kada je količina podataka iz kojih se mogu napraviti jedinstveni nasumce odabrani uzorci ograničena. Ukupan broj jedinstvenih uzoraka¹⁴, koji se mogu uzeti iz nekoga niza može se izračunati pomoću:

$$I_{MC} = \frac{m!}{n!(m-n)!}, \quad (9.4)$$


gdje je I_{MC} broj jedinstvenih uzoraka, n je veličina uzorka (tj. veličina kompozita) i m je veličina niza iz kojega se uzimaju uzorci. Ako je broj jedinstvenih uzoraka manji od broja Monte Carlo simulacija s konvergiranim vrijednostima, tada će točnost metode biti ograničena.

Krive procjene nastaju i kada je broj Monte Carlo iteracija (odnosno simulacija) malen pa dobivene vrijednosti ne konvergiraju.¹⁵

Naposlijetku, prikazana metoda nije prikladna za nizove sa značajnim netipičnim vrijednostima. No utjecaj netipičnih vrijednosti je malen ako one nisu učestale, ako je broj ukupnih jedinstvenih uzoraka dovoljno velik i ako se može se provesti dovoljno velik broj Monte Carlo simulacija.

¹⁴određuje broj Monte Carlo simulacija

¹⁵razlog tome može biti ograničena količina podataka ili dizajn analize



Slika 9.8.: Kompoziti od 44 događaja Forbushevih smanjenja u periodu od ± 40 dana za a) tok kozmičkoga zračenja (%) i b) naoblaku (%). Usrednjene anomalije (crna puna linija) su prikazane zajedno sa standardnim odstupanjima od $\pm 1.96 \sigma$ (plave točkaste linije). Na temelju funkcija gustoće vjerojatnosti dobivenih iz 10000 Monte Carlo simulacija za svaku vremensku točku, t izračunati su dvostrani intervali pouzdanosti na razini od 95 % i 99 % (crvene iscrtkane i točkaste linije).


9.7. Neki primjeri loših procjena statističke značajnosti

Sukladno varijacijama anomalija i intervalima pouzdanosti prikazanim na slici 9.6, kozmičko zračenje ne utječe na naoblaku. No malo drugačija konstrukcija kompozita, može dati potpuno drugačije rezultate.

Česta praksa autora koji su provjeravali utjecaj kozmičkoga zračenja na naoblaku (npr. Todd i Kniveton, 2004; Svensmark i sur., 2009, 2012; Dragić i sur., 2011) je uspoređivanje svojstava naoblake prije i poslije Forbushevih smanjenja. Temeljem takvoga eksperimenta se mogu izračunati anomalije koje su normirane na period u kojem nije bilo poremećaja u toku kozmičkoga zračenja, npr. usrednjeni period od 5 dana (tzv. period normalizacije) prije Forbushevog smanjenja je oduzet od cijeloga vremenskoga niza. Potom se promjene u naoblaci prije Forbushevog događaja statistički uspoređuju s onima, koje su se dogodile nakon poremećaja očekujući da će, u slučaju sveze kozmičkoga zračenja i naoblake, promjene u naoblaci biti veće nego u periodu prije poremećaja u toku kozmičkoga zračenja. Takav pristup može imati znatan utjecaj na određivanje statističke značajnosti anomalija.

Na slici 9.9 je prikazan kompozit anomalija naoblake (crna puna linija) konstruiran od

44 Forbusheva smanjenja i istih ISCCP podataka o naoblaci kao i u primjeru na slici 9.8. U ovom slučaju anomalije su izračunate tako da je srednjak od 5 dana, počevši od dana -10 prije Forbushevog smanjenja (normalizacijski period), oduzet od cijelog niza. U ovom primjeru nije korišten 21-dnevni klizni srednjak kako bi se uklonile srednjoročne varijacije. Intervali pouzdanosti su izračunati samo za vrijeme normalizacijskog perioda i prošireni su na cijeli vremenski period kompozita na temelju 10000 Monte Carlo simulacija za razine pouzdanosti od 95 % i 99 % (crvene crtkane i točkaste linije na slici 9.9). U odnosu na period u kojem nije bilo poremećaja u toku kozmičkoga zračenja, dobiven je pad naoblake od -0.42 % za t_{+5} , koji odgovara 3.5σ devijaciji sa statističkom značajnošću od $p < 0.01$. Kada bi se anomalije naoblake u normalizacijskom periodu statistički uspoređivale s onom u t_{+5} , klasična statistička provjera bi pokazala da anomalija u naoblaci za t_{+5} ima veliku značajnost, koja npr. za t-test odgovara vjerojatnosti od $p=0.004$.



Slika 9.9.: Srednjaci kompozita anomalija naoblake (% , crna puna linija, lijeva y-os) i pripadajuće anomalije toka kozmičkoga zračenja (% , crna crtkana linija, desna y-os). Anomalije za oba parametra su izračunate oduzimanjem srednjaka u periodu od 5 dana počevši od dana -10 (tzv. period normalizacije). Na temelju 100000 Monte Carlo simulacija izračunate su dvije grupe intervala pouzdanosti na 95 % (crtkane linije) i 99 % (točkaste linije) razini pouzdanosti. Intervali pouzdanosti prikazani crvenim linijama su izračunati pomoću funkcija gustoće vjerojatnosti dobivenim za vrijeme perioda normalizacije, dok su intervali pouzdanosti prikazani plavim linijama izračunati pomoću funkcija gustoće vjerojatnosti za svaku vremensku točku, t zasebno.

Može se pokazati da statistička značajnost gornjeg rezultata nije ispravna. Ako se istom metodom pomoću 10000 Monte Carlo simulacija izračunaju razdiobe vjerojatnosti anomalija za svaku vremensku točku, t kompozita, dobiva se sasvim drugačiji rezultat (slika 9.9). Obzirom na nove (ispravne) intervale pouzdanosti za razine pouzdanosti od 95 % i 99 % (plave crtkane i točkaste linije), anomalija u naoblaci za t_{+5} nije više statistički značajna ($p = 0.06$) te ima sličnu značajnost onoj, koja je prikazana na slici 9.8b. Neispravna procjena statističke značajnosti u ovome primjeru je posljedica pretpostavke da podaci nemaju pamćenje, tj. da nisu autokorelirani. Ta pretpostavka u pravilu ne vrijedi za geofizičke podatke. Daljnja posljedica krivo procijenjene značajnosti nastaje postupkom normalizacije, koji značajno smanjuje varijancu kompozita oko perioda normalizacije. Kada bi se analizirani niz naoblake čak i zamijenio nizom bez pamćenja (npr. bijeli šum), pravilno procijenjeni intervali pouzdanosti bi i dalje pokazivali uže intervale u periodu normalizacije nego u ostalim periodima analize.

Svaka statistička provjera kojom se uspoređuju autokorelirane vrijednosti u periodu normalizacije s nekom anomalijom koja ih slijedi (npr. t_{+5}) imat će pristranost i postoji vjerojatnost da će vrijednosti koje nisu značajne biti procijenjene kao značajne, što je slučaj i kod t-testa. Problem je moguće riješiti uz pomoć Monte Carlo metode, kojom se intervali pouzdanosti računaju za svaku točku u vremenu t posebno. Slika 9.9 pokazuje da anomalija za t_{+5} nije značajna.

Male metodološke razlike u izračunu anomalija na slikama 9.8b i 9.9 imaju kao ishod razliku u amplitudi anomalije za t_{+5} od 0.05 %. Unatoč tome, ova anomalija na slici 9.9 nije značajna ($p = 0.06$). Uzrok su autokorelacijski efekti u kombinaciji s postupkom normalizacije, koji su rezultirali u povećanju intervala pouzdanosti. Može se zaključiti da su oba rezultata ispravna: oni su nezavisna procjena vjerojatnosti da se slučajno dobije određena vrijednost na temelju obrade podataka na određeni način, uključujući, isključujući ili ignorirajući određene efekte. Kada se svi dostupni parametri uzmu u obzir, što znači da se razmatra srednjak, njegovo odstupanje, dugoročne varijacije te specifičnost podataka (npr. autokorelacije ili jako izražen šum), postaje jasno da anomalija za t_{+5} nije neuobičajena pojava u prikazanim kompozitima (slika 9.8b i 9.9).

Na kraju treba napomenuti da klasični statistički testovi (kao npr. t-test) također mogu biti korišteni u procjeni statističke značajnosti nizova s pamćenjem, no prethodno treba načiniti prilagodbu broja stupnjeva slobode (Forbush i sur., 1982, 1983) pomoću izračuna efektivne veličine uzorka (Ripley, 1987; Neal, 1993).

9.7.1. Provjera statističke značajnosti rada Svensmark i suradnika

Svensmark i sur. (2009) su istraživali povezanost kozmičkoga zračenja i niske naoblake tijekom 22 najveća Forbusheva smanjenja u razdoblju od 1987. do 2007. uz pomoć različitih nizova podataka za naoblaku (ISCCP, MODIS, SSM/I) te podataka o aerosolima u atmosferi (AERONET). Prema njihovim rezultatima postoji značajan odziv u svim analiziranim parametrima naoblake u odnosu na promjene u kozmičkome zračenju tijekom Forbushevih smanjenja. To je suprotno opažanjima drugih autora koji nisu uočili odziv ni za jedan analiziran parametar u naoblaci (poglavlje 6, npr. Kristjánsson i sur., 2008; Laken i sur., 2009).

U sljedećem radu Svensmark i sur. (2012) koristili su 6 različitih parametara iz MODIS podataka vezanih za naoblaku i 13 najvećih Forbushevih smanjenja u razdoblju dostupnosti MODIS podataka (2000-2006). Autori su upotrijebili istu metodologiju kao i u prethodnom radu. Uočili su značajne promjene u četiri parametra naoblake (reflektivnost naoblake ϵ , optička gustoća naoblake τ , količina vode u atmosferi LWP¹⁶, udio vodenih oblaka LCF¹⁷) sa značajnošću od 2-4 σ za vrijeme 5 najvećih od ukupno 13 Forbushevih smanjenja. Međutim, njihova analiza svih 13 Forbushevih događaja nije pokazala da su promjene u parametrima naoblake povezane s kozmičkim zračenjem.

U ovome radu načinjena je detaljna analiza rezultata koje su dobili Svensmark i sur. (2012). Udio vodenih oblaka (LCF) je odabran kao parametar, budući da su za LCF Svensmark i sur. (2012) dobili najveću značajnost od 4 σ (vjerojatnost od 0.006 %) za t_{+6} .


Na slici 9.10 je prikazan kompozit s 5 najvećih od ukupno 13 Forbushevih smanjenja, konstruiran na temelju globalno usrednjenih MODIS podataka za LCF. Svensmark i sur. (2012) su u analizi uklonili samo linerani trend u podacima. Kako bi dobili anomalije, koristili su postupak normalizacije u razdoblju od t_{-15} do t_{-5} (sjenčano područje na slici 9.10). Intervale pouzdanosti (crvene linije) procijenili su pomoću 100 kompozita s nasumce odabranim događajima u periodu analize od 36 dana. Pripadna standardna odstupanja su normalizirali na period prije Forbushevog događaja, tj. od t_{-15} do t_{-5} te potom proširili na cijeli period analize. Takvim postupkom su zanemarene autokorelacije u podacima naoblake, što je dovelo do pogrešne procjene značajnosti. Dodatni problem predstavljaju srednjoročne varijacije u podacima, koje nisu bile uklonjene.

Kada se u obzir uzmu autokorelacije, intervali pouzdanosti razlikuju se od onih koje su odredili Svensmark i sur. (2012). Intervali pouzdanosti izračunati u ovome radu su prikazani na slici 9.10 za 95 % i 99 % razinu crtanim i točkastim linijama. Dobiveni su pomoću 10000 Monte Carlo simulacija za svaku točku pojedinačno. Značajna anomalija

¹⁶eng. *Liquid Water Path*

¹⁷eng. *Liquid Cloud Fraction*

u LCF-u ima u ovom slučaju puno manje standardno odstupanje ($<3\sigma$) no i dalje je značajna na 95 % razini.



Slika 9.10.: Kompozit konstruiran na temelju globalno usrednjenih MODIS podataka za LCF tijekom pet najvećih Forbushevih smanjenja primjenom metoda koje su koristili Svensmark i sur. (2012). LCF vrijednostima je uklonjen linearni trend, a normalizirane su na period između t_{-15} i t_{-5} , koji je označen sivim sjenčanim područjem. Intervali pouzdanosti na 95 % razini (2σ) koje su procijenili Svensmark i sur. (2012) su prikazani crvenim linijama. Ispravno određeni intervali pouzdanosti temeljeni na 10000 Monte Carlo simulacija su prikazani za dvostranu 95 % (crtkane linije) i 99 % (točkaste linije) razinu pouzdanosti.

Kompozit na slici 9.11a konstruiran je na temelju istih podataka kao onaj na slici 9.10, ali koristeći anomalije s oduzetim 21-dnevnim srednjakom i intervale pouzdanosti temeljene na 10000 Monte Carlo simulacija izračunatih za svaku točku pojedinačno. Vidljivo je da je anomalija za t_{+6} i dalje značajna na 95 % razini pouzdanosti. No u dužem periodu analize amplituda anomalije za t_{+6} nije više neuobičajena. Ako se period analize produži na npr. 200 dana (slika 9.11b), postoji 9 anomalija sa sličnom ili većom amplitudom u odnosu na anomaliju na t_{+6} , što je u skladu s očekivanjem ($200 \cdot 0.05 = 10$).


U kompozitima s malim brojem događaja često mogu dominirati pojedinačni događaji s velikom varijabilnošću. To je bio slučaj u analizi 5 Forbushevih događaja koju su načinili Svensmark i sur. (2012). Ako se na listi Forbushevih događaja, poredanih tako da se intenzitet promjene toka kozmičkoga zračenja smanjuje s rednim brojem (Svensmark i sur., 2012), drugi događaj zamijeni šestim, kompozit više ne pokazuje značajne vrijednosti u periodu analize (slika 9.12a). To je u prvi mah iznenađujuće jer je zamjenom događaja ukupna promjena u toku kozmičkoga zračenja smanjena za samo mali iznos: s 82 % na

76 %¹⁸. Međutim, ako se kompozit rastavi na pojedinačne događaje, kako je prikazano na slici 9.12b, vidljivo je da su velike oscilacije u drugom Forbushevom događaju zapravo uzrok značajnosti anomalije kompozita za t_{+6}) (slike 9.11 i 9.12).


Iako neki autori smatraju da je promjenu u naoblaci moguće detektirati samo za najveća Forbusheva smanjenja, u ovome slučaju hipotetski odziv naoblake lakše je detektirati pomoću 13 nego pomoću 5 događaja. Naime, za kompozit od 5 događaja izračunati intervali pouzdanosti na 95 % razini iznose ± 0.70 , a za kompozit od 13 događaja iznose ± 0.44 . Razlika u intervalima pouzdanosti između tih dviju kompozita iznosi 37 %. Nadalje, ako se koristi 13 Forbushevih događaja, tada su promjene u kozmičkome zračenju manje za 29 % u odnosu na analizu 5 najvećih događaja. Sukladno navedenome je šum u naoblaci smanjen za veću vrijednost (37 %) nego što je smanjen pad u toku kozmičkoga zračenja kada se koristi više Forbushevih događaja (29 %). Naravno, ovaj izračun vrijedi samo uz pretpostavku da je povezanost između kozmičkoga zračenja i naoblake linearna.

Dunne (2012) je drugačijim statističkim metodama od onih predstavljenih u ovome radu došla do sličnih zaključaka o pogrešno procijenjenoj značajnosti odziva naoblake u radu Svensmark i sur. (2012).

¹⁸Svensmark i sur. (2012) definiraju jačinu Forbushovog smanjenja u odnosu na promjene koje ima tok kozmičkoga zračenja između Sunčeva minimuma i maksimuma, što odgovara promjeni od 100 %



Slika 9.11.: Kompozit konstruiran na temelju globalno usrednjenih MODIS podataka za LCF tijekom pet najvećih Forbushevih smanjenja prikazan u periodu od a) ± 20 i b) ± 100 dana. LCF vrijednosti su izražene kao anomalije s oduzetim 21-dnevnim srednjakom. Intervali pouzdanosti temeljeni na 100000 Monte Carlo simulacija su prikazani za dvostranu 95 % (crtkane linije) i 99 % (točkaste linije) razinu pouzdanosti. Sjenčano područje u b) prikazuje period analize (t_{-15} do t_{20}) iz rada [Svensmark i sur. \(2012\)](#).



Slika 9.12.: a) Kompozit konstruiran na temelju globalno usrednjenih MODIS podataka za LCF tijekom pet najvećih Forbushevih smanjenja. Umjesto drugog događaja analiziran je šesti događaj. Ostala četiri događaja u kompozitu su ista kao i u radu [Svensmark i sur. \(2012\)](#). b) MODIS LCF podaci za pojedinačne Forbusheve događaje. Crvenom debelom linijom je označen drugi Forbushev događaj (19.1.2005), koji u usporedbi s ostalih pet Forbushevih događaja pokazuje puno veću varijabilnost.

10. Zaključak

Vremenska dinamika Sunčeve aktivnosti je složena i sastoji se od dugoročnih i kratkoročnih promjena. Dugoročne varijacije su uglavnom povezane s 11-godišnjim Sunčevim ciklusom, no jačina ciklusa također varira, što se događa na stoljetnim vremenskim skalama. Kratkoročne promjene u Sunčevoj aktivnosti su vezane za pojedinačne pojave na Suncu, kao što su npr. snažni Sunčevi bljeskovi i koronini izbačaji mase (CME). Takve pojave mogu biti uzrok geomagnetskih oluja, koje dovode do cijeloga niza značajnih promjena u Zemljinom svemirskom okolišu i atmosferi te mogu izazvati dalekosežne posljedice za ljudske tehnologije i djelatnosti (npr. telekomunikacije, opskrba električnom energijom, kvarovi na satelitima).

Kako bi se izbjegle štete, koje mogu uzrokovati međuplanetarni koronini izbačaji (ICME) važno je predvidjeti njihov dolazak sa Sunca na Zemlju. S tom svrhom razvijen je analitički model magnetohidrodinamičkoga otpora, koji omogućava brz i jednostavan izračun tranzitnih vremena ICME-a. U ovom radu pokazano je da masa ICME-a ima značajan utjecaj na vrijeme njegova dolaska na Zemlju. Model je provjeren pomoću niza ICME događaja i implementiran u obliku javnoga prognostičkog sučelja na internetu.

Galaktičko kozmičko zračenje je također modulirano Sunčevom aktivnošću i ima obrnuto proporcionalne promjene u toku. One mogu iznositi od nekoliko do više desetaka postotaka. U tim promjenama, koje se mogu detektirati na Zemlji pomoću neutronske monitora, najveću ulogu ima Sunčevo magnetsko polje i geomagnetsko polje Zemlje, a oba su ovisna o Sunčevoj aktivnosti.

Obzirom da su direktna opažanja Sunčeve aktivnosti dostupna samo za period manji od dva stoljeća, indirektni podaci o Sunčevoj aktivnosti mogu se dobiti pomoću kozmogenih izotopa (^{10}Be , ^{14}C) proizvedenih djelovanjem kozmičkoga zračenja u atmosferi i pohranjenih u prirodnom arhivu kao što je led ili godovi u drvetu. Spektralna analiza dugoročnih podataka o Sunčevoj aktivnosti u posljednjih 9300 godina, temeljena na mjerenjima izotopa ^{10}Be , koja je provedena u ovome radu, razotkrila je jednu od dominantnih periodičnosti Sunčeve aktivnosti od oko tisuću godina.

Najveća kratkoročna smanjenja u kozmičkome zračenju su tzv. Forbusheva smanjenja, uzrokovana CME-ima u doba jake Sunčeve aktivnosti. Manje promjene u toku kozmičkoga zračenja mogu nastati kao posljedica korotirajućih interakcijskih područja (CIR).

Nastanak CIR-eva je povezan s brzim Sunčevim vjetrom u područjima koroninih šupljina.

Analiza toka kozmičkoga zračenja u ovome radu pokazala je da za vrijeme silazne faze Sunčevoga ciklusa (npr. 2005. godina), kada su CIR-evi najizraženiji, smanjenje u kozmičkome zračenju iznosi od 0.5 % do 2 % za razdoblja od oko tjedan dana. Pad toka kozmičkoga zračenja najbolje korelira s jakosti međuplanetarnoga magnetskog polja B , što znači da pojačano magnetsko polje, koje se formira na prednjim rubovima brzih struja u Sunčevom vjetru, modulira galaktičko kozmičko zračenje i djeluje kao svojevrsni štit od toga zračenja. Porast vrijednosti magnetskog polja B i smanjenja toka kozmičkoga zračenja su vremenski odmaknuti za 2 do 3 dana, što omogućava da se na temelju vrijednosti Sunčevoga magnetskog polja predvidi pad toka kozmičkoga zračenja.

Postoje čvrsti dokazi da Sunčeva aktivnost djeluje i na Zemljinu klimu. Prema [Rind \(2002\)](#) su za razumijevanje utjecaja Sunčeve aktivnosti na klimu potrebna tri ključna elementa: 1) dugoročne i kratkoročne promjene u Sunčevoj aktivnosti, 2) međudjelovanje Sunca i Zemlje, 3) mehanizmi koji objašnjavaju odziv Zemljinoga klimatskog sustava na te promjene. Prva dva elementa su poznata, no mehanizmi utjecaja Sunčeve aktivnosti na klimatske promjene još nisu u potpunosti razjašnjeni.

Neki od tih mehanizama temelje se na pretpostavci da kozmičko zračenje utječe na naoblaku. Tu hipotezu je moguće provjeriti opažanjima, budući da su u zadnjih tridesetak godina dostupni globalni satelitski podaci naoblake. U ovome radu pokazano je da dugoročne analize nisu prikladne za provjeru hipoteze iz dva razloga. Takve analize su opterećene nizom detekcijskih i kalibracijskih pogrešaka, koje nastaju kada se analiziraju duži vremenski periodi satelitskih podataka o naoblaci. Osim toga, na dužim vremenskim skalama na naoblaku mogu utjecati i drugi čimbenici, kao npr. unutarnje oscilacije klime i na taj način interferirati u analizi.

Alternativna mogućnost provjere hipoteze su kratkoročne analize koje koriste Forbusheva smanjenja. Takvo ispitivanje provedeno je i u ovome radu. Detaljna analiza korelacija između izračunate efektivne atmosferske ionizacije i satelitskih podataka globalne naoblake tijekom 6 Forbushevih smanjenja nije pružila niti jedan dokaz da postoji odziv u naoblaci za vrijeme Forbushevih smanjenja:

- Značajne korelacije između promjena u naoblaci i atmosferskoj ionizaciji nisu nađene ni u analizi svih 6 Forbushevih smanjenja zajedno niti u analizi pojedinačnih događaja. U analizi pojedinačnih oblačnih slojeva također nisu dobivene značajne korelacije.
- Za kontrolne događaje su uočene iste varijacije u naoblaci kao i za Forbusheva smanjenja, a testovi osjetljivosti su pokazali da je metoda dovoljno osjetljiva da

detektira globalne promjene u naoblaci uzrokovane kozmičkim zračenjem.

- Nisu uočene razlike u značajnosti dobivenih korelacija za različita regionalna područja analize (visoke i niske geografske širine, područja iznad kopna i ocenana).

Analogni rezultati dobiveni su i u drugim radovima (npr. [Kristjánsson i sur., 2002, 2008](#); [Laken i sur., 2009](#); [Krissansen-Totton i Davies, 2013](#)). No postoje radovi u kojima su dobivene značajne pozitivne (npr. [Pudovkin i Veretenenko, 1995](#); [Todd i Kniveton, 2004](#); [Svensmark i sur., 2009](#)) ili čak negativne (npr. [Wang i sur., 2006](#); [Troshichev i sur., 2008](#)) korelacije između kozmičkoga zračenja i naoblake.

Budući da bi prema nekim pokazateljima parametri poput ukupnoga Sunčevog zračenja (TSI) mogli utjecati na naoblaku i ometati ispitivanje utjecaja kozmičkoga zračenja, načinjena je detaljna kompozitna analiza uzoraka sa značajnijim povećanjima i smanjenjima u TSI. Također su u obzir uzeti podaci kozmičkoga i ultraljubičastoga Sunčeva zračenja. Analizirane su različite visine naoblake te različita globalna i regionalna područja (visoke i niske geografske širine, područja iznad kopna i oceana), a u obzir je uzet i posmak od 20 dana. Niti za jedan od tri uzorka kompozita nije detektiran utjecaj TSI na promjene u naoblaci. Sukladno rezultatima zaključeno je da TSI ne ometa detekciju utjecaja kozmičkog zračenja na naoblaku.

Ako se umjesto satelitskih podataka koristi dnevni raspon temperatura zraka na površini Zemlje kao indirektan podatak za naoblaku, može se obuhvatiti veće vremensko razdoblje i veći broj Forbushevih smanjenja. Na taj način su kompozitnom analizom ispitana dva uzorka Forbushevih smanjenja: 267 događaja sa smanjenjem intenziteta u toku kozmičkoga zračenja većim od 3% i 29 događaja sa smanjenjem intenziteta u toku kozmičkoga zračenja većim od 7 %. Analiza je pokazala da ne postoje značajne promjene u naoblaci koje bi bile povezane sa promjenama u toku kozmičkoga zračenja.

Nadalje, razmotrene su pogreške koju mogu nastati zbog neprikladne metodologije i statističkih testova u provjeri hipoteze utjecaja kozmičkoga zračenja na naoblaku i koje bi mogle biti uzrokom proturječnosti rezultata objavljenih radova. Pokazano je da je obrada podataka naoblake (npr. filtriranje i normalizacija) te pravilna konstrukcija kompozita presudna u smanjivanju šuma (sinoptičke varijacije u naoblaci) do iznosa koji omogućuje detekciju potencijalnog signala u naoblaci. Predstavljene su metode statističke provjere, temeljene na Monte Carlo simulacijama, koje nisu ovisne o pretpostavkama vezanim za ispitivanu populaciju (npr. autokorelacije). Pokazano je da se pomoću Monte Carlo simulacija može procijeniti šum u naoblaci, koji ovisi o broju događaja u kompozitima i veličini analiziranoga područja. Kada je poznat šum, moguće je jednostavnim izračunom procijeniti granicu detekcije signala u naoblaci uzrokovano kozmičkim zračenjem.

Neki od radova u kojima su nađene značajne korelacije između kozmičkoga zračenja i

naoblake analizirani su obzirom na obradu podataka i statističke provjere. Doneseni su sljedeći zaključci:

- Odnos signala i šuma je povezan s vremenskim i prostornim ograničenjima u podacima. Ako se smanjuju područja usrednjavanja podataka i/ili period analize (a time i broj događaja), povećava se šum u podacima, što utječe na pomak granice detekcije. No, broj Forbushevih događaja sa značajnijim smanjenjem u toku kozmičkoga zračenja je ograničen. U razdoblju od 10 godina ima samo oko 10 Forbushevih događaja s padom kozmičkoga zračenja većim od 10 %, koji je po veličini usporediv s promjenama kozmičkoga zračenja tijekom Sunčeva ciklusa.
- Varijacije naoblake s periodima većim od analiziranih perioda mogu uzrokovati pogrešne procjene statističke značajnosti rezultata. Te varijacije se ne mogu uvijek odstraniti uklanjanjem linearnih trendova, stoga je važno da se koriste prikladni filtri.
- Postupci normalizacije podataka mogu utjecati na amplitude varijacija u kompozitima i procjenu njihove statističke značajnosti te su stoga jedan od ključnih uzroka pogrešne procjene statističke značajnosti.
- Autori dugoročnih i kratkoročnih analiza često ne posjeduju dovoljno informacija o satelitskim podacima naoblake, npr. o detekcijskim i kalibracijskim pogreškama tih podataka.
- Pristranost statističkih provjera (kao npr. t-test), temeljenim na pogrešnim pretpostavkama vezanim za ispitivanu populaciju (npr. autokorelacije, normalizacija) mogu biti uzrokom pogrešnih procjena statističke značajnosti.

Na temelju svega navedenoga može se zaključiti sljedeće:

- Ne postoji uvjerljiv dokaz koji podržava hipotezu utjecaja kozmičkoga zračenja na naoblaku u kratkoročnim (Forbusheva smanjenja) ili u dugoročnim analizama satelitskih podataka o naoblaci.
- Jedan od glavnih uzroka proturječnih rezultata kratkoročnih analiza koje koriste Forbusheva smanjenja su neprimjerene statističke provjere i manje metodološke razlike u analizi kompozita.
- Budući da su raspoloživi podaci o naoblaci dostupni samo za kraća vremenska razdoblja (npr. 30 godina za satelitske podatke) i imaju veliki sinoptički šum u odnosu na traženi signal, njima nije moguće pouzdano detektirati promjene u naoblaci, koje

bi hipotetski mogle biti uvjetovane kozmičkim zračenjem, ukoliko su one vrlo male ili ako imaju regionalan karakter. Stoga se utjecaj kozmičkoga zračenja na naoblaku ne može potpuno isključiti na lokalnoj i regionalnoj razini, ali ako postoji, onda je vrlo malen.

- Kozmičko zračenje ne utječe globalno na naoblaku te nije uzrok većim promjenama klime ili današnjem globalnom zatopljenju.

A. Dodatak

A.1. Kratice

- **ACE** - Advanced Composition Explorer
- **ACR** - anomalno kozmičko zračenje (eng. *Anomalous Cosmic Rays*)
- **ACRIM** - Active Cavity Radiometer Irradiance Monitor
- **CCN** - oblačne kondenzacijske jezgre (eng. *Cloud Condensating Nuclei*)
- **CH** - koronine šupljine (eng. *Coronal Holes*)
- **CIR** - korotirajuća interakcijska područja (eng. *Corotating Interactive Regions*)
- **CR** - kozmičko zračenje (eng. *cosmic rays*)
- **CME** - koronini izbačaj mase (eng. *Coronal Mass Ejection*)
- **DBM** - Drag Based Model
- **DOY** - dani u godini (eng. *Day of the Year*)
- **DTR** - dnevni raspon temperatura (eng. *Diurnal Temperature Range*)
- **ENSO** - El Niño - južna oscilacija (eng. *El Niño–Southern Oscillation*)
- **F10.7** - Sunčevo zračenje u radio spektru, F10.7 (2800Mhz), indirektni podaci za daleko ultraljubičasto Sunčevo zračenje
- **Fd** - Forbusheva smanjenja (eng. *Forbush decrease*)
- **GCR** - galaktičko kozmičko zračenje (eng. *Galactic Cosmic Rays*)
- **GEC** - globalni električni strujni krug (eng. *Global Electric Circuit*)
- **ICME** - međuplanetarni koronin izbačaj (eng. *Interplanetary Coronal Mass Ejection*)

- **ISCCP** - međunarodni satelitski projekt klimatologije naoblake (eng. *International Satellite Cloud Climatology Project*)
- **IR** - infracrveno (zračenje, 750 nm - 3 mm)
- **LASCO** - Large Angle and Spectrometric Coronagraph (SoHO satelit)
- **LCF** - udio vodenih oblaka (eng. *Liquid Cloud Fraction*)
- **MODIS** - MODerate Resolution Imaging Spectroradiometer
- **MHD** - magnetohidrodinamika
- **NM** - neutron monitor
- **NCEP/NCAR** - National Centers for Environmental Prediction / National Center for Atmospheric Research
- **O-C** - razlika između promatranih (O) i izračunatih (C) vrijednosti
- **PMOD/WRC** - Physikalisch-Meteorologisches Observatorium Davos / World Radiation Centre
- **SCR** - Sunčevo kozmičko zračenje (eng. *Solar Cosmic Rays*)
- **SEP** - Sunčeve energetske čestice (eng. *Solar Energetic Particles*)
- **SST** - površinska temperatura mora (eng. *Sea Surface Temperature*)
- **TSI** - ukupno Sunčevo zračenje (eng. *Total Solar Irradiance*)
- **TT** - tranzitno vrijeme (eng. *Transit Time*)
- **UV** - ultraljubičasto (zračenje)
- **UTC** - srednje vrijeme po Greenwichu (eng. *Coordinated Universal Time*)
- **VGGR** - Vertikalni granični geomagnetski rigiditet (P_c)
- **VIS** - vidljivo (zračenje, 390 - 750 nm)
- $r_\odot$ - Sunčev polumjer ($0.696 \cdot 10^6 km$)
- Φ - Sunčeva modulacijska funkcija

A.2. Tablice

Događaj	IncTSI	DecTSI-A	DecTSI-B
1	24.07.1988.	30.01.1984.	30.01.1984.
2	7.02.1989.	1.07.1988.	1.07.1988.
3	12.04.1989.	19.12.1988.	15.06.1989.
4	12.05.1989.	12.03.1989.	5.09.1989.
5	7.06.1989.	15.06.1989.	4.07.1990.
6	26.08.1989.	5.09.1989.	24.08.1990.
7	20.02.1990.	4.07.1990.	21.11.1990.
8	13.05.1990.	24.08.1990.	18.12.1990.
9	21.10.1990.	21.11.1990.	16.01.1991.
10	22.01.1991.	18.12.1990.	31.01.1991.
11	6.03.1991.	16.01.1991.	24.02.1991.
12	9.04.1991.	31.01.1991.	26.07.1991.
13	19.05.1991.	24.02.1991.	21.08.1991.
14	4.07.1991.	25.03.1991.	2.10.1991.
15	9.08.1991.	10.06.1991.	27.12.1991.
16	7.11.1999.	26.07.1991.	31.01.1992.
17	14.12.1999.	21.08.1991.	25.02.1992.
18	9.09.2000.	2.10.1991.	29.03.1992.
19	30.11.2003.	28.10.1991.	19.08.1992.
20	27.12.1991.	8.02.1993.	
21	31.01.1992.	10.05.1993.	
22	25.02.1992.	2.10.1993.	
23	29.03.1992.	25.11.1996.	
24	19.08.1992.	10.09.1997.	
25	8.02.1993.	14.02.1999.	
26	10.05.1993.	26.12.1999.	
27	2.10.1993.	28.02.2000.	
28	25.11.1996.	25.04.2000.	
29	10.09.1997.	19.05.2000.	
30	14.02.1999.	22.09.2000.	
31	26.12.1999.	28.03.2001.	
32	28.02.2000.	2.04.2002.	
33	25.04.2000.	29.07.2002.	
34	19.05.2000.	17.08.2002.	
35	22.09.2000.	9.06.2003.	
36	28.03.2001.	6.01.2004.	
37	25.09.2001.	12.08.2004.	
38	2.04.2002.		
39	29.07.2002.		
40	17.08.2002.		
41	9.06.2003.		
42	29.10.2003.		
43	6.01.2004.		
44	22.07.2004.		
45	12.08.2004.		
46	5.11.2004.		
47	15.01.2005.		
48	13.09.2005.		

Tablica A.1.: Lista ključnih dana (s najvećim promjenama u TSI) koji su odabrani za sastavljanje kompozitnih uzoraka *DecTSI-A*, *DecTSI-B* i *IncTSI*.

Bibliografija

- Abreu, J. A., J. Beer, F. Steinhilber, S. M. Tobias, i N. O. Weiss. For how long will the current grand maximum of solar activity persist? *Geophysical Research Letters*, 35: L20109, 2008. doi: 10.1029/2008GL035442.
- Abreu, J. A., J. Beer, A. Ferriz-Mas, K. G. McCracken, i F. Steinhilber. Is there a planetary influence on solar activity? *Astronomy & Astrophysics*, 548:A88, 2012. doi: 10.1051/0004-6361/201219997.
- Abreu, J. A., J. Beer, F. Steinhilber, M. Christl, i P. W. Kubik. ^{10}Be in Ice Cores and ^{14}C in Tree Rings: Separation of Production and Climate Effects. *Space Science Reviews*, 176:343–349, 2013. doi: 10.1007/s11214-011-9864-y.
- Agee, E. M., K. Kiefer, i E. Cornett. Relationship of Lower-Troposphere Cloud Cover and Cosmic Rays: An Updated Perspective. *Journal of Climate*, 25:1057–1060, 2012. doi: 10.1175/JCLI-D-11-00169.1.
- Agostinelli, S., J. Allison, K. Amako, i sur. GEANT4 - a simulation toolkit. *Nuclear Instruments and Methods in Physics Research A*, 506:250–303, 2003. doi: 10.1016/S0168-9002(03)01368-8.
- Alley, R. B., J. Marotzke, W. D. Nordhaus, i sur. Abrupt Climate Change. *Science*, 299: 2005–2010, 2003. doi: 10.1126/science.1081056.
- Almeida, J., S. Schobesberger, A. Kürten, i sur. Molecular understanding of sulphuric acid-amine particle nucleation in the atmosphere. *Nature*, 502:359–363, 2013. doi: 10.1038/nature12663.
- Arnold, F. Atmospheric Aerosol and Cloud Condensation Nuclei Formation: A Possible Influence of Cosmic Rays? *Space Science Reviews*, 125:169–186, 2006. doi: 10.1007/s11214-006-9055-4.
- Arnold, F. Atmospheric Ions and Aerosol Formation. *Space Science Reviews*, 137:225–239, 2008. doi: 10.1007/s11214-008-9390-8.

- Artamonova, I. i S. Veretenenko. Galactic cosmic ray variation influence on baric system dynamics at middle latitudes. *Journal of Atmospheric and Solar-Terrestrial Physics*, 73:366–370, 2011. doi: 10.1016/j.jastp.2010.05.004.
- Austin, J., K. Tourpali, E. Rozanov, i sur. Coupled chemistry climate model simulations of the solar cycle in ozone and temperature. *Journal of Geophysical Research (Atmospheres)*, 113(D12):D11306, 2008. doi: 10.1029/2007JD009391.
- Bazilevskaya, G. A., I. G. Usoskin, E. O. Flückiger, i sur. Cosmic Ray Induced Ion Production in the Atmosphere. *Space Science Reviews*, 137:149–173, 2008. doi: 10.1007/s11214-008-9339-y.
- Beer, J. Long-term indirect indices of solar variability. *Space Science Reviews*, 94:53–66, 2000. doi: 10.1023/A:1026778013901.
- Beer, J., W. Mende, i R. Stellmacher. The role of the sun in climate forcing. *Quaternary Science Reviews*, 19:403–415, 2000. doi: 10.1016/S0277-3791(99)00072-4.
- Beer, J., K. G. McCracken, J. Abreu, U. Heikkilä, i F. Steinhilber. Cosmogenic Radionuclides as an Extension of the Neutron Monitor Era into the Past: Potential and Limitations. *Space Science Reviews*, 176:89–100, 2013. doi: 10.1007/s11214-011-9843-3.
- Belov, A. Large Scale Modulation: View From the Earth. *Space Science Reviews*, 93: 79–105, 2000. doi: 10.1023/A:1026584109817.
- Belov, A. V., L. I. Dorman, E. A. Eroshenk, i sur. Anisotropy of Cosmic Rays and Forbush Decreases in 1991. *International Cosmic Ray Conference*, 4:912, 1995.
- Belov, A. V., E. A. Eroshenko, V. A. Oleneva, A. B. Struminsky, i V. G. Yanke. What determines the magnitude of forbush decreases? *Advances in Space Research*, 27:625–630, 2001. doi: 10.1016/S0273-1177(01)00095-3.
- Bond, G., B. Kromer, J. Beer, i sur. Persistent Solar Influence on North Atlantic Climate During the Holocene. *Science*, 294:2130–2136, 2001. doi: 10.1126/science.1065680.
- Borgazzi, A., A. Lara, E. Echer, i M. V. Alves. Dynamics of coronal mass ejections in the interplanetary medium. *Astronomy & Astrophysics*, 498:885–889, 2009. doi: 10.1051/0004-6361/200811171.
- Brest, C. L., W. B. Rossow, i M. D. Roiter. Update of Radiance Calibrations for ISCCP. *Journal of Atmospheric and Oceanic Technology*, 14:1091, 1997. doi: 10.1175/1520-0426(1997)014<1091:UORCFI>2.0.CO;2.

- Brueckner, G. E., R. A. Howard, M. J. Koomen, i sur. The Large Angle Spectroscopic Coronagraph (LASCO). *Solar Physics*, 162:357–402, 1995. doi: 10.1007/BF00733434.
- Brueckner, G. E., J.-P. Delaboudiniere, R. A. Howard, i sur. Geomagnetic storms caused by coronal mass ejections (CMEs): March 1996 through June 1997. *Geophysical Research Letters*, 25:3019–3022, 1998. doi: 10.1029/98GL00704.
- Burke, H. K. i A. A. Few. Direct measurements of the atmospheric conduction current. *Journal of Geophysical Research*, 83:3093–3098, 1978. doi: 10.1029/JC083iC06p03093.
- Bütikofer, R., O. E. Flückiger, L. Desorgher, i M. R. Moser. The extreme solar cosmic ray particle event on 20 January 2005 and its influence on the radiation dose rate at aircraft altitude. *Science of The Total Environment*, 391(2–3):177–183, 2008. doi: 10.1016/j.scitotenv.2007.10.021.
- Calder, N. *Die launische Sonne widerlegt Klimatheorien*. Böttiger, 1997.
- Campbell, G. G. View angle dependence of cloudiness and the trend in isccp cloudiness. In *Thirteenth Conference on Satellite Meteorology and Oceanography, American Meteorological Society, Boston Press*, volume 6, 2004.
- Cane, H. V. Coronal Mass Ejections and Forbush Decreases. *Space Science Reviews*, 93: 55–77, 2000. doi: 10.1023/A:1026532125747.
- Cane, H. V., I. G. Richardson, T. T. von Rosenvinge, i G. Wibberenz. Cosmic ray decreases and shock structure: A multispacecraft study. *Journal of Geophysical Research*, 99:21429, 1994. doi: 10.1029/94JA01529.
- Cantó, J., R. F. González, A. C. Raga, i sur. The dynamics of velocity fluctuations in the solar wind - I. Coronal mass ejections. *Monthly Notices of the Royal Astronomical Society*, 357:572–578, 2005. doi: 10.1111/j.1365-2966.2005.08670.x.
- Cargill, P. J. On the Aerodynamic Drag Force Acting on Interplanetary Coronal Mass Ejections. *Solar Physics*, 221:135–149, 2004. doi: 10.1023/B:SOLA.0000033366.10725.a2.
- Cargill, P. J., J. Chen, D. S. Spicer, i S. T. Zalesak. Magnetohydrodynamic simulations of the motion of magnetic flux tubes through a magnetized plasma. *Journal of Geophysical Research*, 101:4855–4870, 1996. doi: 10.1029/95JA03769.
- Carlsson, M., R. F. Stein, Å. Nordlund, i G. B. Scharmer. Observational Manifestations of Solar Magnetoconvection: Center-to-Limb Variation. *The Astrophysical Journal*, 610: L137–L140, 2004. doi: 10.1086/423305.

- Carslaw, K. S., R. G. Harrison, i J. Kirkby. Cosmic Rays, Clouds, and Climate. *Science*, 298:1732–1737, 2002. doi: 10.1126/science.1076964.
- Cho, K.-S., Y.-J. Moon, M. Dryer, i sur. A statistical comparison of interplanetary shock and CME propagation models. *Journal of Geophysical Research (Space Physics)*, 108: 1445, 2003. doi: 10.1029/2003JA010029.
- Chree, C. Some Phenomena of Sunspots and of Terrestrial Magnetism at Kew Observatory. *Royal Society of London Philosophical Transactions Series A*, 212:75–116, 1913. doi: 10.1098/rsta.1913.0003.
- Chree, C. Some Phenomena of Sunspots and of Terrestrial Magnetism. Part II. *Royal Society of London Philosophical Transactions Series A*, 213:245–277, 1914. doi: 10.1098/rsta.1914.0006.
- Close, F., M. Marten, i C. Sutton. *Spurensuche im Teilchenzoo: die elementaren Bausteine der Materie*. Spektrum Akademischer Verlag, 1989.
- Cooke, D. J., J. E. Humble, M. A. Shea, D. F. Smart, i N. Lund. On cosmic-ray cut-off terminology. *Nuovo Cimento C*, 14:213–234, 1991. doi: 10.1007/BF02509357.
- Dai, A., K. E. Trenberth, i T. R. Karl. Effects of Clouds, Soil Moisture, Precipitation, and Water Vapor on Diurnal Temperature Range. *Journal of Climate*, 12:2451–2473, 1999. doi: 10.1175/1520-0442(1999)012<2451:EOCSMP>2.0.CO;2.
- Damon, P. E. i P. Laut. Pattern of Strange Errors Plagues Solar Activity and Terrestrial Climate Data. *EOS Transactions*, 85:370–374, 2004. doi: 10.1029/2004EO390005.
- Dansgaard, W., S. J. Johnsen, H. B. Clausen, i sur. North Atlantic climatic oscillations revealed by deep Greenland ice cores. *Washington DC American Geophysical Union Geophysical Monograph Series*, 29:288–298, 1984. doi: 10.1029/GM029p0288.
- Debrunner, H., O. E. Flückiger, i J. A. Lockwood. Response of Neutron Monitors to Solar Cosmic Ray Events. In *Proceedings of the 8th European Cosmic Ray Symposium*, Rome, 1984.
- Desorgher, L., E. O. Flückiger, M. Gurtner, M. R. Moser, i R. Bütikofer. Atmocomics: a Geant 4 Code for Computing the Interaction of Cosmic Rays with the Earth's Atmosphere. *International Journal of Modern Physics A*, 20:6802–6804, 2005. doi: 10.1142/S0217751X05030132.

- Dickinson, R. E. Solar variability and the lower atmosphere. *Bulletin of the American Meteorological Society*, 56:1240–1248, 1975. doi: 10.1175/1520-0477(1975)056<1240:SVATLA>2.0.CO;2.
- Dragić, A., I. Aničin, R. Banjanac, i sur. Forbush decreases - clouds relation in the neutron monitor era. *Astrophysics and Space Sciences Transactions*, 7:315–318, 2011. doi: 10.5194/astra-7-315-2011.
- Dragić, A., N. Veselinović, D. Maletić, i sur. Further investigations into the connection between cosmic rays and climate. *ArXiv e-prints*, 2013.
- Dryer, M., Z. Smith, C. D. Fry, i sur. Real-time shock arrival predictions during the “Halloween 2003 epoch”. *Space Weather*, 2:S09001, 2004. doi: 10.1029/2004SW000087.
- Dumbović, M., B. Vršnak, J. Čalogović, i M. Karlica. Cosmic ray modulation by solar wind disturbances. *Astronomy & Astrophysics*, 531:A91, 2011. doi: 10.1051/0004-6361/201016006.
- Dumbović, M., B. Vršnak, i J. Čalogović. Solar influences on the short-term cosmic ray modulation. *Central European Astrophysical Bulletin*, 36:65–70, 2012a.
- Dumbović, M., B. Vršnak, J. Čalogović, i R. Župan. Cosmic ray modulation by different types of solar wind disturbances. *Astronomy & Astrophysics*, 538:A28, 2012b. doi: 10.1051/0004-6361/201117710.
- Dunne, E. M. Comment on Effects of cosmic ray decreases on cloud microphysics by Svensmark et al. *Atmospheric Chemistry & Physics Discussions*, 12:C1000, 2012.
- Dunne, E. M., L. A. Lee, C. L. Reddington, i K. S. Carslaw. No statistically significant effect of a short-term decrease in the nucleation rate on atmospheric aerosols. *Atmospheric Chemistry & Physics*, 12:11573–11587, 2012. doi: 10.5194/acp-12-11573-2012.
- Eddy, J. A. The Maunder Minimum. *Science*, 192:1189–1202, 1976. doi: 10.1126/science.192.4245.1189.
- Eichkorn, S., S. Wilhelm, H. Aufmhoff, K. H. Wohlfrom, i F. Arnold. Cosmic ray-induced aerosol-formation: First observational evidence from aircraft-based ion mass spectrometer measurements in the upper troposphere. *Geophysical Research Letters*, 29:1698, 2002. doi: 10.1029/2002GL015044.
- Enghoff, M. B., J. O. P. Pedersen, U. I. Uggerhøj, S. M. Paling, i H. Svensmark. Aerosol nucleation induced by a high energy particle beam. *Geophysical Research Letters*, 38: L09805, 2011. doi: 10.1029/2011GL047036.

- Evan, A. T., A. K. Heidinger, i D. J. Vimont. Arguments against a physical long-term trend in global ISCCP cloud amounts. *Geophysical Research Letters*, 34:L04701, 2007. doi: 10.1029/2006GL028083.
- Farrar, D. P. Are cosmic rays influencing oceanic cloud coverage – or is it only el niño? *Climatic Change*, 47(1-2):7–15, 2000. doi: 10.1023/A:1005672825112.
- Fedulina, I. i J. Laštovička. Effect of Forbush decreases of cosmic ray flux on ozone at higher middle latitudes. *Advances in Space Research*, 27:2003–2006, 2001. doi: 10.1016/S0273-1177(01)00303-9.
- Fleitmann, D., S. J. Burns, M. Mudelsee, i sur. Holocene Forcing of the Indian Monsoon Recorded in a Stalagmite from Southern Oman. *Science*, 300:1737–1740, 2003. doi: 10.1126/science.1083130.
- Flückiger, O. E. Forbush decreases geomagnetic and atmospheric effects cosmogenic nuclides. *International Cosmic Ray Conference*, 9:301, 1985.
- Forbes, T. G. A review on the genesis of coronal mass ejections. *Journal of Geophysical Research*, 105:23153–23166, 2000. doi: 10.1029/2000JA000005.
- Forbush, E. S. Three unusual cosmic-ray increases possibly due to charged particles from the sun. *Physical Review*, 70:771–772, 1946.
- Forbush, S. E. On World-Wide Changes in Cosmic-Ray Intensity. *Physical Review*, 54:975–988, 1938. doi: 10.1103/PhysRev.54.975.
- Forbush, S. E., S. P. Duggal, M. A. Pomerantz, i C. H. Tsao. Random Fluctuations, Persistence, and Quasi-Persistence in Geophysical and Cosmical Periodicities: A Sequel. *Reviews of Geophysics and Space Physics*, 20:971, 1982. doi: 10.1029/RG020i004p00971.
- Forbush, S. E., M. A. Pomerantz, C. H. Tsao, i S. P. Duggal. Statistical considerations in the analysis of solar oscillation data by the superposed epoch method. *Solar Physics*, 82:113–122, 1983. doi: 10.1007/BF00145551.
- Fröhlich, C. Observations of Irradiance Variations. *Space Science Reviews*, 94:15–24, 2000. doi: 10.1023/A:1026765712084.
- Fröhlich, C. Solar Irradiance Variability Since 1978. Revision of the PMOD Composite during Solar Cycle 21. *Space Science Reviews*, 125:53–65, 2006. doi: 10.1007/s11214-006-9046-5.

- Fröhlich, C. i J. Lean. The Sun's total irradiance: Cycles, trends and related climate change uncertainties since 1976. *Geophysical Research Letters*, 25:4377–4380, 1998. doi: 10.1029/1998GL900157.
- Garcia-Munoz, M., G. M. Mason, i J. A. Simpson. A New Test for Solar Modulation Theory: the 1972 May-July Low-Energy Galactic Cosmic-Ray Proton and Helium Spectra. *Astrophysical Journal*, 182:L81, 1973. doi: 10.1086/181224.
- Garcia-Munoz, M., G. M. Mason, i J. A. Simpson. The anomalous He-4 component in the cosmic-ray spectrum at below approximately 50 MeV per nucleon during 1972-1974. *Astrophysical Journal*, 202:265–275, 1975. doi: 10.1086/153973.
- Gierens, K. i M. Ponater. Comment on “Variation of cosmic ray flux and global cloud coverage - a missing link in solar-climate relationships” by H. Svensmark and E. Friis-Christensen (1997). *Journal of Atmospheric and Solar-Terrestrial Physics*, 61:795–797, 1999. doi: 10.1016/S1364-6826(99)00040-1.
- Gleeson, L. J. i W. I. Axford. Cosmic Rays in the Interplanetary Medium. *Astrophysical Journal*, 149:L115, 1967. doi: 10.1086/180070.
- Gleeson, L. J. i W. I. Axford. Solar Modulation of Galactic Cosmic Rays. *Astrophysical Journal*, 154:1011, 1968. doi: 10.1086/149822.
- González-Esparza, J. A., A. Lara, E. Pérez-Tijerina, A. Santillán, i N. Gopalswamy. A numerical study on the acceleration and transit time of coronal mass ejections in the interplanetary medium. *Journal of Geophysical Research (Space Physics)*, 108:1039, 2003. doi: 10.1029/2001JA009186.
- Gopalswamy, N. Coronal Mass Ejections of Solar Cycle 23. *Journal of Astrophysics and Astronomy*, 27:243–254, 2006. doi: 10.1007/BF02702527.
- Gopalswamy, N., A. Lara, R. P. Lepping, i sur. Interplanetary acceleration of coronal mass ejections. *Geophysical Research Letters*, 27:145–148, 2000. doi: 10.1029/1999GL003639.
- Gopalswamy, N., S. Akiyama, S. Yashiro, i P. Mäkelä. Coronal Mass Ejections from Sunspot and Non-Sunspot Regions. In Hasan, S. S. i R. J. Rutten, editors, *Magnetic Coupling between the Interior and Atmosphere of the Sun*, pages 289–307, 2010. doi: 10.1007/978-3-642-02859-5_24.
- Gosling, J. T. The solar flare myth. *Journal of Geophysical Research*, 98:18937–18950, 1993. doi: 10.1029/93JA01896.

- Gosling, J. T., S. J. Bame, D. J. McComas, i J. L. Phillips. Coronal mass ejections and large geomagnetic storms. *Geophysical Research Letters*, 17:901–904, 1990. doi: 10.1029/GL017i007p00901.
- Gray, L. J., J. Beer, M. Geller, i sur. Solar Influences on Climate. *Reviews of Geophysics*, 48:RG4001, 2010. doi: 10.1029/2009RG000282.
- Grieder, P. K. *Cosmic rays at earth: researcher's reference manual and data book*. Elsevier, 2001.
- Hörrak, U., J. Salm, i H. Tammet. Bursts of intermediate ions in atmospheric air. *Journal of Geophysical Research (Atmospheres)*, 103:13909, 1998. doi: 10.1029/97JD01570.
- Haigh, J. D. The Impact of Solar Variability on Climate. *Science*, 272:981–984, 1996. doi: 10.1126/science.272.5264.981.
- Hale, G. E., F. Ellerman, S. B. Nicholson, i A. H. Joy. The Magnetic Polarity of Sun-Spots. *Astrophysical Journal*, 49:153, 1919. doi: 10.1086/142452.
- Hanslmeier, A., R. Brajša, J. Čalogović, i sur. The chaotic solar cycle. II. Analysis of cosmogenic ^{10}Be data. *Astronomy & Astrophysics*, 550:A6, 2013. doi: 10.1051/0004-6361/201015215.
- Harrison, R. G. A balloon-carried electrometer for high-resolution atmospheric electric field measurements in clouds. *Review of Scientific Instruments*, 72:2738–2741, 2001. doi: 10.1063/1.1369639.
- Harrison, R. G. i M. H. P. Ambaum. Enhancement of cloud formation by droplet charging. *Royal Society of London Proceedings Series A*, 464:2561–2573, 2008. doi: 10.1098/rspa.2008.0009.
- Harrison, R. G. i M. H. P. Ambaum. Observing Forbush decreases in cloud at Shetland. *Journal of Atmospheric and Solar-Terrestrial Physics*, 72:1408–1414, 2010. doi: 10.1016/j.jastp.2010.09.025.
- Harrison, R. G. i D. B. Stephenson. Empirical evidence for a nonlinear effect of galactic cosmic rays on clouds. *Royal Society of London Proceedings Series A*, 462:1221–1233, 2006. doi: 10.1098/rspa.2005.1628.
- Harrison, R. G., M. H. P. Ambaum, i M. Lockwood. Cloud base height and cosmic rays. *Royal Society of London Proceedings Series A*, 467:2777–2791, 2011. doi: 10.1098/rspa.2011.0040.

- Heikkilä, U., J. Beer, J. A. Abreu, i F. Steinhilber. On the Atmospheric Transport and Deposition of the Cosmogenic Radionuclides (^{10}Be): A Review. *Space Science Reviews*, 176:321–332, 2013. doi: 10.1007/s11214-011-9838-0.
- Henning, S., E. Weingartner, S. Schmidt, i sur. Size-dependent aerosol activation at the high-alpine site Jungfraujoch (3580 m asl). *Tellus Series B Chemical and Physical Meteorology B*, 54:82, 2002. doi: 10.1034/j.1600-0889.2002.00299.x.
- Herbst, K., A. Kopp, i B. Heber. Influence of the terrestrial magnetic field geometry on the cutoff rigidity of cosmic ray particles. *Annales Geophysicae*, 31:1637–1643, 2013. doi: 10.5194/angeo-31-1637-2013.
- Herman, J. R. i R. A. Goldberg. Sun, weather, and climate. *NASA Special Publication*, 426, 1978.
- Herschel, W. Observations Tending to Investigate the Nature of the Sun, in Order to Find the Causes or Symptoms of Its Variable Emission of Light and Heat; With Remarks on the Use That May Possibly Be Drawn from Solar Observations. *Royal Society of London Philosophical Transactions Series I*, 91:265–318, 1801.
- Hess, V. F. Über beobachtungen der durchdringenden strahlung bei sieben freiballonfahrten. *Phys. Ztschr.*, 13:1084–1091, 1912.
- Hill, S. M., V. J. Pizzo, C. C. Balch, i sur. The NOAA Goes-12 Solar X-Ray Imager (SXI) 1. Instrument, Operations, and Data. *Solar Physics*, 226:255–281, 2005. doi: 10.1007/s11207-005-7416-x.
- Hoppel, A. W, V. R. Anderson, i C. J. Willett. *Atmospheric Electricity in the Planetary Boundary Layer - The Earth's Electrical Environment*. The National Academies Press, 1986.
- Houghton, J. T., L. G. Meiro Filho, B. A. Callander, i sur. *Climate Change 1995: The Science of Climate Change*. Cambridge University Press, 1996.
- Howard, R. A., J. D. Moses, A. Vourlidas, i sur. Sun Earth Connection Coronal and Heliospheric Investigation (SECCHI). *Space Science Reviews*, 136:67–115, 2008. doi: 10.1007/s11214-008-9341-4.
- Hoyt, D. V. i K. H. Schatten. *The role of the sun in climate change*. New York : Oxford University Press, 1997.
- IPCC, . Fifth assessment report of the intergovernmental panel on climate change: Climate change 2013 - the physical science basis. Technical report, WMO/UNEP, 2013.

- Jackman, C. H., M. T. Deland, G. J. Labow, E. L. Fleming, i M. López-Puertas. Satellite Measurements of Middle Atmospheric Impacts by Solar Proton Events in Solar Cycle 23. *Space Science Reviews*, 125:381–391, 2006. doi: 10.1007/s11214-006-9071-4.
- Jokipii, J. R. i K. Marti. Temporal variations of cosmic rays over a variety of time scales. In Smoluchowski, R., J. M. Bahcall, i M. S. Matthews, editors, *The Galaxy and the Solar System*, pages 116–128, 1986.
- Jørgensen, T. S. i A. W. Hansen. Comments on “Variation of cosmic ray flux and global cloud coverage - a missing link in solar-climate relationships” by Henrik Svensmark and Eigil Friis-Christensen, *Journal of Atmospheric and Solar-Terrestrial Physics*, 59 (1997), 1225-1232]. *Journal of Atmospheric and Solar-Terrestrial Physics*, 62:73–77, 2000. doi: 10.1016/S1364-6826(99)00106-6.
- Kalnay, E., M. Kanamitsu, R. Kistler, i sur. The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin of the American Meteorological Society*, 77:437–472, 1996. doi: 10.1175/1520-0477(1996)077<0437:TNYRP>2.0.CO;2.
- Kazil, J. i E. R. Lovejoy. Tropospheric ionization and aerosol production: A model study. *Journal of Geophysical Research (Atmospheres)*, 109(D18):D19206, 2004. doi: 10.1029/2004JD004852.
- Kazil, J., K. Zhang, P. Stier, i sur. The present-day decadal solar cycle modulation of Earth’s radiative forcing via charged H₂SO₄/H₂O aerosol nucleation. *Geophysical Research Letters*, 39:L02805, 2012. doi: 10.1029/2011GL050058.
- Kelly, B. C., J. Bechtold, i A. Siemiginowska. Are the Variations in Quasar Optical Flux Driven by Thermal Fluctuations? *Astrophysical Journal*, 698:895, 2009. doi: 10.1088/0004-637X/698/1/895.
- Kernthaler, S. C., R. Toumi, i J. D. Haigh. Some doubts concerning a link between cosmic ray fluxes and global cloudiness. *Geophysical Research Letters*, 26:863–865, 1999. doi: 10.1029/1999GL900121.
- Khain, A., V. Arkhipov, M. Pinsky, Y. Feldman, i Y. Ryabov. Rain Enhancement and Fog Elimination by Seeding with Charged Droplets. Part I: Theory and Numerical Simulations. *Journal of Applied Meteorology*, 43:1513–1529, 2004. doi: 10.1175/JAM2131.1.
- King, M. D., Y. J. Kaufman, W. P. Menzel, i D. Tanre. Remote sensing of cloud, aerosol, and water vapor properties from the moderate resolution imaging spectrometer (MODIS). *IEEE Transactions on Geoscience and Remote Sensing*, 30:2–27, 1992. doi: 10.1109/36.124212.

- Kirkby, J., J. Curtius, J. Almeida, i sur. Role of sulphuric acid, ammonia and galactic cosmic rays in atmospheric aerosol nucleation. *Nature*, 476:429–433, 2011. doi: 10.1038/nature10343.
- Knapp, K. R. Calibration Assessment of ISCCP Geostationary Infrared Observations Using HIRS. *Journal of Atmospheric and Oceanic Technology*, 25:183, 2008. doi: 10.1175/2007JTECHA910.1.
- Kodera, K. i Y. Kuroda. Dynamical response to the solar cycle. *Journal of Geophysical Research (Atmospheres)*, 107:4749, 2002. doi: 10.1029/2002JD002224.
- Koskinen, H. E. J. i K. E. J. Huttunen. Geoeffectivity of Coronal Mass Ejections. *Space Science Reviews*, 124:169–181, 2006. doi: 10.1007/s11214-006-9103-0.
- Krissansen-Totton, J. i R. Davies. Investigation of cosmic ray-cloud connections using MISR. *Geophysical Research Letters*, 40:5240–5245, 2013. doi: 10.1002/grl.50996.
- Kristjánsson, J. E., A. Staple, J. Kristiansen, i E. Kaas. A new look at possible connections between solar activity, clouds and climate. *Geophysical Research Letters*, 29:2107, 2002. doi: 10.1029/2002GL015646.
- Kristjánsson, J. E., J. Kristiansen, i E. Kaas. Solar activity, cosmic rays, clouds and climate - an update. *Advances in Space Research*, 34:407–415, 2004. doi: 10.1016/j.asr.2003.02.040.
- Kristjánsson, J. E., C. W. Stjern, F. Stordal, i sur. Cosmic rays, cloud condensation nuclei and clouds - a reassessment using MODIS data. *Atmospheric Chemistry & Physics*, 8: 7373–7387, 2008.
- Kuang, Z., Y. Jiang, i Y. L. Yung. Cloud optical thickness variations during 1983–1991: Solar cycle or ENSO? *Geophysical Research Letters*, 25:1415–1417, 1998. doi: 10.1029/98GL00471.
- Kulmala, M., L. Pirjola, i J. M. Mäkelä. Stable sulphate clusters as a source of new atmospheric particles. *Nature*, 404:66–69, 2000. doi: 10.1038/35003550.
- Labitzke, K. i H. van Loon. Some recent studies of probable connections between solar and atmospheric variability. *Annales Geophysicae*, 11:1084–1094, 1993.
- Laj, C., C. Kissel, A. Mazaud, J. E. T. Channell, i J. Beer. North Atlantic palaeointensity stack since 75ka (NAPIS-75) and the duration of the Laschamp event. In *Astronomy, physics and chemistry of H^+_3* , volume 358 of *Royal Society of London Philosophical Transactions Series A*, page 1009, 2000. doi: 10.1098/rsta.2000.0571.

- Laken, B., A. Wolfendale, i D. Kniveton. Cosmic ray decreases and changes in the liquid water cloud fraction over the oceans. *Geophysical Research Letters*, 36:L23803, 2009. doi: 10.1029/2009GL040961.
- Laken, B., D. Kniveton, i A. Wolfendale. Forbush decreases, solar irradiance variations, and anomalous cloud changes. *Journal of Geophysical Research (Atmospheres)*, 116: D09201, 2011. doi: 10.1029/2010JD014900.
- Laken, B., E. Pallé, i H. Miyahara. A Decade of the Moderate Resolution Imaging Spectroradiometer: Is a Solar-Cloud Link Detectable? *Journal of Climate*, 25:4430–4440, 2012a. doi: 10.1175/JCLI-D-11-00306.1.
- Laken, B., J. Čalogović, T. Shahbaz, i E. Pallé. Examining a solar-climate link in diurnal temperature ranges. *Journal of Geophysical Research (Atmospheres)*, 117(D16):D18112, 2012b. doi: 10.1029/2012JD017683.
- Laken, B. A. i D. R. Kniveton. Forbush decreases and Antarctic cloud anomalies in the upper troposphere. *Journal of Atmospheric and Solar-Terrestrial Physics*, 73:371–376, 2011. doi: 10.1016/j.jastp.2010.03.008.
- Laken, B. A. i J. Čalogović. Solar irradiance, cosmic rays and cloudiness over daily timescales. *Geophysical Research Letters*, 38:L24811, 2011. doi: 10.1029/2011GL049764.
- Laken, B. A. i J. Čalogović. Does the diurnal temperature range respond to changes in the cosmic ray flux? *Environmental Research Letters*, 8(4):045018, 2013. doi: 10.1088/1748-9326/8/4/045018.
- Lam, M. M. i A. S. Rodger. The effect of Forbush decreases on tropospheric parameters over South Pole. *Journal of Atmospheric and Solar-Terrestrial Physics*, 64:41–45, 2002. doi: 10.1016/S1364-6826(01)00092-X.
- Laut, P. Solar activity and terrestrial climate: an analysis of some purported correlations. *Journal of Atmospheric and Solar-Terrestrial Physics*, 65:801–812, 2003. doi: 10.1016/S1364-6826(03)00041-5.
- Lean, J. L. i T. N. Woods. *Solar spectral irradiance: measurements and models*. Cambridge University Press, 2010.
- Leblanc, Y., G. A. Dulk, i J.-L. Bougeret. Tracing the Electron Density from the Corona to 1au. *Solar Physics*, 183:165–180, 1998. doi: 10.1023/A:1005049730506.
- Leighton, R. B. Transport of Magnetic Fields on the Sun. *Astrophysical Journal*, 140: 1547, 1964. doi: 10.1086/148058.

- Lenz, P. i M. Breger. Period04 User Guide. *Communications in Asteroseismology*, 146: 53–136, 2005. doi: 10.1553/cia146s53.
- Liu, Y., A. Thernisien, J. G. Luhmann, i sur. Reconstructing Coronal Mass Ejections with Coordinated Imaging and in Situ Observations: Global Structure, Kinematics, and Implications for Space Weather Forecasting. *The Astrophysical Journal*, 722:1762–1777, 2010. doi: 10.1088/0004-637X/722/2/1762.
- Lockwood, J. A. Forbush Decreases in the Cosmic Radiation. *Space Science Reviews*, 12: 658–715, 1971. doi: 10.1007/BF00173346.
- Lockwood, J. A., W. R. Webber, i H. Debrunner. Forbush decreases and interplanetary magnetic field disturbances - Association with magnetic clouds. *Journal of Geophysical Research*, 96:11587, 1991. doi: 10.1029/91JA01012.
- Lovejoy, E. R., J. Curtius, i K. D. Froyd. Atmospheric ion-induced nucleation of sulfuric acid and water. *Journal of Geophysical Research (Atmospheres)*, 109:D08204, 2004. doi: 10.1029/2003JD004460.
- Luo, Z., W. B. Rossow, T. Inoue, i C. J. Stubenrauch. Did the Eruption of the Mt. Pinatubo Volcano Affect Cirrus Properties?. *Journal of Climate*, 15:2806–2820, 2002. doi: 10.1175/1520-0442(2002)015<2806:DTEOTM>2.0.CO;2.
- Ma, L. H. Thousand-Year Cycle Signals in Solar Activity. *Solar Physics*, 245:411–414, 2007. doi: 10.1007/s11207-007-9048-9.
- Makino, M. i T. Ogawa. Responses of atmospheric electric field and air-earth current to variations of conductivity profiles. *Journal of Atmospheric and Terrestrial Physics*, 46: 431–445, 1984. doi: 10.1016/0021-9169(84)90087-4.
- Manchester, W. B., T. I. Gombosi, I. Roussev, i sur. Modeling a space weather event from the Sun to the Earth: CME generation and interplanetary propagation. *Journal of Geophysical Research (Space Physics)*, 109:A02107, 2004. doi: 10.1029/2003JA010150.
- Manoharan, P. K. Evolution of Coronal Mass Ejections in the Inner Heliosphere: A Study Using White-Light and Scintillation Images. *Solar Physics*, 235:345–368, 2006. doi: 10.1007/s11207-006-0100-y.
- Maričić, D., B. Vršnak, A. L. Stanger, i sur. Acceleration Phase of Coronal Mass Ejections: II. Synchronization of the Energy Release in the Associated Flare. *Solar Physics*, 241: 99–112, 2007. doi: 10.1007/s11207-007-0291-x.

- Marsh, N. i H. Svensmark. Galactic cosmic ray and El Niño-Southern Oscillation trends in International Satellite Cloud Climatology Project D2 low-cloud properties. *Journal of Geophysical Research (Atmospheres)*, 108:4195, 2003. doi: 10.1029/2001JD001264.
- Marsh, N. D. i H. Svensmark. Low Cloud Properties Influenced by Cosmic Rays. *Physical Review Letters*, 85:5004–5007, 2000. doi: 10.1103/PhysRevLett.85.5004.
- Masarik, J. i J. Beer. Simulation of particle fluxes and cosmogenic nuclide production in the Earth’s atmosphere. *Journal of Geophysical Research*, 104:12099–12112, 1999. doi: 10.1029/1998JD200091.
- Masarik, J. i J. Beer. An updated simulation of particle fluxes and cosmogenic nuclide production in the Earth’s atmosphere. *Journal of Geophysical Research (Atmospheres)*, 114(D13):D11103, 2009. doi: 10.1029/2008JD010557.
- Mason, B. J. *The physics of clouds*. Oxford monographs on meteorology. Clarendon Press, 1971.
- McCracken, K. G., F. B. McDonald, J. Beer, G. Raisbeck, i F. Yiou. A phenomenological study of the long-term cosmic ray modulation, 850-1958 AD. *Journal of Geophysical Research (Space Physics)*, 109(A18):A12103, 2004. doi: 10.1029/2004JA010685.
- McCracken, K. G., J. Beer, i F. Steinhilber. Evidence for Planetary Forcing of the Cosmic Ray Intensity and Solar Activity Throughout the Past 9400 Years. *Solar Physics*, 2014. doi: 10.1007/s11207-014-0510-1.
- McKenna-Lawlor, S. M. P., M. Dryer, M. D. Kartalev, i sur. Near real-time predictions of the arrival at Earth of flare-related shocks during Solar Cycle 23. *Journal of Geophysical Research (Space Physics)*, 111(A10):A11103, 2006. doi: 10.1029/2005JA011162.
- Meehl, G. A., J. M. Arblaster, G. Branstator, i H. van Loon. A Coupled Air Sea Response Mechanism to Solar Forcing in the Pacific Region. *Journal of Climate*, 21:2883, 2008. doi: 10.1175/2007JCLI1776.1.
- Meehl, G. A., J. M. Arblaster, K. Matthes, F. Sassi, i H. van Loon. Amplifying the Pacific Climate System Response to a Small 11-Year Solar Cycle Forcing. *Science*, 325:1114, 2009. doi: 10.1126/science.1172872.
- Michalek, G., N. Gopalswamy, A. Lara, i P. K. Manoharan. Arrival time of halo coronal mass ejections in the vicinity of the Earth. *Astronomy & Astrophysics*, 423:729–736, 2004. doi: 10.1051/0004-6361:20047184.

- Nandy, D., A. Muñoz-Jaramillo, i P. C. H. Martens. The unusual minimum of sunspot cycle 23 caused by meridional plasma flow variations. *Nature*, 471:80–82, 2011. doi: 10.1038/nature09786.
- Neal, R. M. Probabilistic inference using Markov chain Monte Carlo methods. Technical Report CRG-TR-93-1, Dept. of Computer Science, University of Toronto, 1993. 144pp.
- Ney, E. P. Cosmic Radiation and the Weather. *Nature*, 183:451–452, 1959. doi: 10.1038/183451a0.
- Nicoll, K. A. i R. G. Harrison. Experimental determination of layer cloud edge charging from cosmic ray ionisation. *Geophysical Research Letters*, 37:L13802, 2010. doi: 10.1029/2010GL043605.
- Norris, J. R. What Can Cloud Observations Tell Us About Climate Variability? *Space Science Reviews*, 94:375–380, 2000. doi: 10.1023/A:1026704314326.
- Norris, J. R. Multidecadal changes in near-global cloud cover and estimated cloud cover radiative forcing. *Journal of Geophysical Research (Atmospheres)*, 110:D08206, 2005. doi: 10.1029/2004JD005600.
- Okike, O. i A. B. Collier. A multivariate study of Forbush decrease simultaneity. *Journal of Atmospheric and Solar-Terrestrial Physics*, 73:796–804, 2011. doi: 10.1016/j.jastp.2011.01.015.
- Pallé, B. E. Possible satellite perspective effects on the reported correlations between solar activity and clouds. *Geophysical Research Letters*, 32:L03802, 2005. doi: 10.1029/2004GL021167.
- Pallé, B. E. i C. J. Butler. Cosmic rays and climate: The influence of cosmic rays on terrestrial clouds and global warming. *Astronomy and Geophysics*, 41(4):040000–4, 2000. doi: 10.1046/j.1468-4004.2000.00418.x.
- Pallé, B. E. i C. J. Butler. Sunshine records from Ireland: cloud factors and possible links to solar activity and cosmic rays. *International Journal of Climatology*, 21:709–729, 2001. doi: 10.1002/joc.657.
- Parker, E. N. Theory of streaming of cosmic rays and the diurnal variation. *Planetary and Space Science*, 12:735–749, 1964. doi: 10.1016/0032-0633(64)90054-6.
- Pestiaux, P., I. MerschVan der , A. Berger, i J. C Duplessy. Paleoclimatic variability at frequencies ranging from 1 cycle per 10 000 years to 1 cycle per 1000 years: Evidence

- for nonlinear behaviour of the climate system. *Climatic Change*, 12(1):9–37, 1988. doi: 10.1007/BF00140262.
- Picone, J. M., A. E. Hedin, D. P. Drob, i A. C. Aikin. NRLMSISE-00 empirical model of the atmosphere: Statistical comparisons and scientific issues. *Journal of Geophysical Research (Space Physics)*, 107:1468, 2002. doi: 10.1029/2002JA009430.
- Pierce, J. R. i P. J. Adams. Can cosmic rays affect cloud condensation nuclei by altering new particle formation rates? *Geophysical Research Letters*, 36:L09820, 2009. doi: 10.1029/2009GL037946.
- Pincus, R., S. Platnick, S. A. Ackerman, R. S. Hemler, i R. J. Patrick Hofmann. Reconciling Simulated and Observed Views of Clouds: MODIS, ISCCP, and the Limits of Instrument Simulators. *Journal of Climate*, 25:4699–4720, 2012. doi: 10.1175/JCLI-D-11-00267.1.
- Pittock, A. B. A critical look at long-term sun-weather relationship. *Reviews of Geophysics and Space Physics*, 16:400–420, 1978. doi: 10.1029/RG016i003p00400.
- Pizzo, V. J., S. M. Hill, C. C. Balch, i sur. The NOAA Goes-12 Solar X-Ray Imager (SXI) 2. Performance. *Solar Physics*, 226:283–315, 2005. doi: 10.1007/s11207-005-7417-9.
- Priest, E. R. *Solar magneto-hydrodynamics*. Springer, 1982.
- Pudovkin, M. I. i S. V. Veretenenko. Cloudiness decreases associated with Forbush decreases of galactic cosmic rays. *Journal of Atmospheric and Terrestrial Physics*, 57: 1349–1355, 1995. doi: 10.1016/0021-9169(94)00109-2.
- Pudovkin, M. I., S. V. Veretenenko, R. Pellinen, i E. Kyrö. Cosmic ray variation effects in the temperature of the high-latitudinal atmosphere. *Advances in Space Research*, 17: 165–168, 1996. doi: 10.1016/0273-1177(95)00746-2.
- Raes, F., A. Janssens, i V. R. Dingenen. The role of ion-induced aerosol formation in the lower atmosphere. *Journal of Aerosol Science*, 17(3):466 – 470, 1986. doi: 10.1016/0021-8502(86)90135-7.
- Ram, M. i M. R. Stolz. Possible solar influences on the dust profile of the GISP2 Ice Core from central Greenland. *Geophysical Research Letters*, 26:1043–1046, 1999. doi: 10.1029/1999GL900199.
- Rich, F. J., P. J. Sultan, i W. J. Burke. The 27-day variations of plasma densities and temperatures in the topside ionosphere. *Journal of Geophysical Research (Space Physics)*, 108:1297, 2003. doi: 10.1029/2002JA009731.

- Richardson, I. G. Energetic Particles and Corotating Interaction Regions in the Solar Wind. *Space Science Reviews*, 111:267–376, 2004. doi: 10.1023/B:SPAC.0000032689.52830.3e.
- Rind, D. The Sun's Role in Climate Variations. *Science*, 296:673–678, 2002. doi: 10.1126/science.1069562.
- Ripley, Brian D. *Stochastic Simulation*. John Wiley & Sons, Inc., 1987.
- Robbrecht, E., D. Berghmans, i R. A. M. Van der Linden. Automated LASCO CME Catalog for Solar Cycle 23: Are CMEs Scale Invariant? *The Astrophysical Journal*, 691:1222–1234, 2009. doi: 10.1088/0004-637X/691/2/1222.
- Rollett, T., C. Möstl, M. Temmer, i sur. Constraining the Kinematics of Coronal Mass Ejections in the Inner Heliosphere with In-Situ Signatures. *Solar Physics*, 276:293–314, 2012. doi: 10.1007/s11207-011-9897-0.
- Rossow, W. B. i R. A. Schiffer. ISCCP Cloud Data Products. *Bulletin of the American Meteorological Society*, 72:2–20, 1991. doi: 10.1175/1520-0477(1991)072<0002:ICDP>2.0.CO;2.
- Rossow, W. B. i R. A. Schiffer. Advances in Understanding Clouds from ISCCP. *Bulletin of the American Meteorological Society*, 80:2261–2288, 1999. doi: 10.1175/1520-0477(1999)080<2261:AIUCFI>2.0.CO;2.
- Rotter, T., A. M. Veronig, M. Temmer, i B. Vršnak. Relation Between Coronal Hole Areas on the Sun and the Solar Wind Parameters at 1 AU. *Solar Physics*, 281:793–813, 2012. doi: 10.1007/s11207-012-0101-y.
- Roy, I. i J. D. Haigh. Solar cycle signals in sea level pressure and sea surface temperature. *Atmospheric Chemistry & Physics*, 10:3147–3153, 2010. doi: 10.5194/acp-10-3147-2010.
- Rycroft, M. J., S. Israelsson, i C. Price. The global atmospheric electric circuit, solar activity and climate change. *Journal of Atmospheric and Solar-Terrestrial Physics*, 62:1563–1576, 2000. doi: 10.1016/S1364-6826(00)00112-7.
- Rycroft, M. J., R. G. Harrison, K. A. Nicoll, i E. A. Mareev. An Overview of Earth's Global Electric Circuit and Atmospheric Conductivity. *Space Science Reviews*, 137:83–105, 2008. doi: 10.1007/s11214-008-9368-6.
- Schär, C., P. L. Vidale, D. Lüthi, i sur. The role of increasing temperature variability in European summer heatwaves. *Nature*, 427:332–336, 2004. doi: 10.1038/nature02300.

- Schuermans, C. J. E. i A. H. Oort. A statistical study of pressure changes in the troposphere and lower stratosphere after strong solar flares. *Pure and Applied Geophysics*, 75: 233–246, 1969. doi: 10.1007/BF00875058.
- Schwabe, M. Die Sonne. Von Herrn Hofrath Schwabe. *Astronomische Nachrichten*, 20: 283, 1843. doi: 10.1002/asna.18430201706.
- Schwenn, R., A. dal Lago, E. Huttunen, i W. D. Gonzalez. The association of coronal mass ejections with their effects near the Earth. *Annales Geophysicae*, 23:1033–1059, 2005. doi: 10.5194/angeo-23-1033-2005.
- Shapiro, S. S. i M. B. Wilk. An analysis of variance test for normality (complete samples). *Biometrika*, 52(3/4):591–611, 1965.
- Shea, M. A., D. F. Smart, i L. C. Gentile. The use of the McIlwain L-parameter to estimate cosmic ray vertical cutoff rigidities for different epochs of the geomagnetic field. *International Cosmic Ray Conference*, 5:332–335, 1985.
- Simpson, J. A. Cosmic-Radiation Intensity-Time Variations and Their Origin. III. The Origin of 27-Day Variations. *Physical Review*, 94:426–440, 1954. doi: 10.1103/PhysRev.94.426.
- Singh, Y. P. i Badruddin. Statistical considerations in superposed epoch analysis and its applications in space research. *Journal of Atmospheric and Solar-Terrestrial Physics*, 68:803–813, 2006. doi: 10.1016/j.jastp.2006.01.007.
- Sloan, T. i A. W. Wolfendale. Testing the proposed causal link between cosmic rays and cloud cover. *Environmental Research Letters*, 3(4):024001, 2008. doi: 10.1088/1748-9326/3/2/024001.
- Smart, D. F. i M. A. Shea. A simplified model for timing the arrival of solar flare-initiated shocks. *Journal of Geophysical Research*, 90:183–190, 1985. doi: 10.1029/JA090iA01p00183.
- Smart, D. F., M. A. Shea, i E. O. Flückiger. Magnetospheric Models and Trajectory Computations. *Space Science Reviews*, 93:305–333, 2000. doi: 10.1023/A:1026556831199.
- Smith, Z. K., M. Dryer, S. M. P. McKenna-Lawlor, i sur. Operational validation of HAFv2's predictions of interplanetary shock arrivals at Earth: Declining phase of Solar Cycle 23. *Journal of Geophysical Research (Space Physics)*, 114:A05106, 2009. doi: 10.1029/2008JA013836.

- Snow-Kropla, E. J., J. R. Pierce, D. M. Westervelt, i W. Trivitayanurak. Cosmic rays, aerosol formation and cloud-condensation nuclei: sensitivities to model uncertainties. *Atmospheric Chemistry & Physics*, 11:4001–4013, 2011. doi: 10.5194/acp-11-4001-2011.
- Steinhilber, F. i J. Beer. Prediction of solar activity for the next 500 years. *Journal of Geophysical Research (Space Physics)*, 118:1861–1867, 2013. doi: 10.1002/jgra.50210.
- Steinhilber, F., J. A. Abreu, i J. Beer. Solar modulation during the Holocene. *Astrophysics and Space Sciences Transactions*, 4:1–6, 2008. doi: 10.5194/astra-4-1-2008.
- Steinhilber, F., J. Beer, i C. Fröhlich. Total solar irradiance during the Holocene. *Geophysical Research Letters*, 36:L19704, 2009. doi: 10.1029/2009GL040142.
- Steinhilber, F., J. A. Abreu, J. Beer, i K. G. McCracken. Interplanetary magnetic field during the past 9300 years inferred from cosmogenic radionuclides. *Journal of Geophysical Research (Space Physics)*, 115:A01104, 2010. doi: 10.1029/2009JA014193.
- Stone, E. C., A. M. Frandsen, R. A. Mewaldt, i sur. The Advanced Composition Explorer. *Space Science Reviews*, 86:1–22, 1998. doi: 10.1023/A:1005082526237.
- Stubenrauch, C. J., W. B. Rossow, F. Chéruy, A. Chédin, i N. A. Scott. Clouds as Seen by Satellite Sounders (3I) and Imagers (ISCCP). Part I: Evaluation of Cloud Parameters. *Journal of Climate*, 12:2189–2213, 1999. doi: 10.1175/1520-0442(1999)012<2189:CASBSS>2.0.CO;2.
- Stubenrauch, C. J., W. B. Rossow, S. Kinne, i sur. Assessment of Global Cloud Datasets from Satellites: Project and Database Initiated by the GEWEX Radiation Panel. *Bulletin of the American Meteorological Society*, 94:1031–1049, 2013. doi: 10.1175/BAMS-D-12-00117.1.
- Sun, B. i R. S. Bradley. Solar influences on cosmic rays and cloud formation: A reassessment. *Journal of Geophysical Research (Atmospheres)*, 107:4211, 2002. doi: 10.1029/2001JD000560.
- Svensmark, H. Cosmoclimatology: a new theory emerges. *Astronomy and Geophysics*, 48(1):18–24, 2007. doi: 10.1111/j.1468-4004.2007.48118.x.
- Svensmark, H. i N. Calder. *The chilling stars: a new theory of climate change*. Icon Books, 2007.
- Svensmark, H. i E. Friis-Christensen. Variation of cosmic ray flux and global cloud coverage—a missing link in solar-climate relationships. *Journal of Atmospheric and Solar-Terrestrial Physics*, 59:1225–1232, 1997. doi: 10.1016/S1364-6826(97)00001-1.

- Svensmark, H., T. Bondo, i J. Svensmark. Cosmic ray decreases affect atmospheric aerosols and clouds. *Geophysical Research Letters*, 36:L15101, 2009. doi: 10.1029/2009GL038429.
- Svensmark, J., M. B. Enghoff, i H. Svensmark. Effects of cosmic ray decreases on cloud microphysics. *Atmospheric Chemistry & Physics Discussions*, 12:3595–3617, 2012. doi: 10.5194/acpd-12-3595-2012.
- Taktakishvili, A., M. Kuznetsova, P. MacNeice, i sur. Validation of the coronal mass ejection predictions at the Earth orbit estimated by ENLIL heliosphere cone model. *Space Weather*, 7:S03004, 2009. doi: 10.1029/2008SW000448.
- Temmer, M., B. Vršnak, i A. M. Veronig. Periodic Appearance of Coronal Holes and the Related Variation of Solar Wind Parameters. *Solar Physics*, 241:371–383, 2007. doi: 10.1007/s11207-007-0336-1.
- Temmer, M., T. Rollett, C. Möstl, i sur. Influence of the Ambient Solar Wind Flow on the Propagation Behavior of Interplanetary Coronal Mass Ejections. *The Astrophysical Journal*, 743:101, 2011. doi: 10.1088/0004-637X/743/2/101.
- Temmer, M., B. Vršnak, T. Rollett, i sur. Characteristics of Kinematics of a Coronal Mass Ejection during the 2010 August 1 CME-CME Interaction Event. *The Astrophysical Journal*, 749:57, 2012. doi: 10.1088/0004-637X/749/1/57.
- Tinsley, B. A. Influence of Solar Wind on the Global Electric Circuit, and Inferred Effects on Cloud Microphysics, Temperature, and Dynamics in the Troposphere. *Space Science Reviews*, 94:231–258, 2000. doi: 10.1023/A:1026775408875.
- Tinsley, B. A. i G. W. Deen. Apparent tropospheric response to MeV-GeV particle flux variations: A connection via electrofreezing of supercooled water in high-level clouds? *Journal of Geophysical Research (Atmospheres)*, 96:22283, 1991. doi: 10.1029/91JD02473.
- Tinsley, B. A., G. M. Brown, i P. H. Scherrer. Solar variability influences on weather and climate: Possible connections through cosmic ray fluxes and storm intensification. *Journal of Geophysical Research*, 94:14783–14792, 1989. doi: 10.1029/JD094iD12p14783.
- Tinsley, B. A., R. P. Rohrbaugh, M. Hei, i K. V. Beard. Effects of Image Charges on the Scavenging of Aerosol Particles by Cloud Droplets and on Droplet Charging and Possible Ice Nucleation Processes. *Journal of Atmospheric Sciences*, 57:2118–2134, 2000. doi: 10.1175/1520-0469(2000)057<2118:EOICOT>2.0.CO;2.

- Tinsley, B. A., L. Zhou, i W. Liu. The role of volcanic aerosols and relativistic electrons in modulating winter storm vorticity. *Advances in Space Research*, 50:819–827, 2012. doi: 10.1016/j.asr.2011.12.019.
- Todd, M. C. i D. R. Kniveton. Changes in cloud cover associated with Forbush decreases of galactic cosmic rays. *Journal of Geophysical Research*, 106:32031–32042, 2001. doi: 10.1029/2001JD000405.
- Todd, M. C. i D. R. Kniveton. Short-term variability in satellite-derived cloud cover and galactic cosmic rays: an update. *Journal of Atmospheric and Solar-Terrestrial Physics*, 66:1205–1211, 2004. doi: 10.1016/j.jastp.2004.05.002.
- Toptygin, I. N. *Cosmic Rays in Interplanetary Magnetic Fields*. D. Redel Publishing Company, Dordrecht, 1985.
- Torrence, C. i G. P. Compo. A Practical Guide to Wavelet Analysis. *Bulletin of the American Meteorological Society*, 79:61–78, 1998. doi: 10.1175/1520-0477(1998)079<0061:APGTWA>2.0.CO;2.
- Travis, D. J., A. M. Carleton, i R. G. Lauritsen. Climatology: Contrails reduce daily temperature range. *Nature*, 418:601, 2002. doi: 10.1038/418601a.
- Tripathi, S. N., S. Vishnoi, S. Kumar, i R. G. Harrison. Computationally-efficient Expressions for the Collision Efficiency Between Electrically Charged Aerosol Particles and Cloud Droplets. *Quarterly Journal of the Royal Meteorological Society*, 132(618): 1717–1731, 2006. doi: 10.1256/qj.05.125.
- Troshichev, O., V. Vovk, i L. Egorova. IMF-associated cloudiness above near-pole station Vostok: Impact on wind regime in winter Antarctica. *Journal of Atmospheric and Solar-Terrestrial Physics*, 70:1289–1300, 2008. doi: 10.1016/j.jastp.2008.04.003.
- Tsyganenko, N. A. A magnetospheric magnetic field model with a warped tail current sheet. *Planetary and Space Science*, 37:5–20, 1989. doi: 10.1016/0032-0633(89)90066-4.
- Tung, K. K. i C. D. Camp. Solar cycle warming at the Earth's surface in NCEP and ERA-40 data: A linear discriminant analysis. *Journal of Geophysical Research (Atmospheres)*, 113:D05114, 2008. doi: 10.1029/2007JD009164.
- Udelhofen, P. M. i R. D. Cess. Cloud cover variations over the United States: An influence of cosmic rays or solar variability? *Geophysical Research Letters*, 28:2617–2620, 2001. doi: 10.1029/2000GL012659.

- Usoskin, I. G., L. Desorgher, P. Velinov, i sur. Ionization of the Earth's atmosphere by solar and galactic cosmic rays. *Acta Geophysica*, 57(1):88–101, 2009a. doi: 10.2478/s11600-008-0019-9.
- Usoskin, I. G., K. Horiuchi, S. Solanki, G. A. Kovaltsov, i E. Bard. On the common solar signal in different cosmogenic isotope data sets. *Journal of Geophysical Research (Space Physics)*, 114:A03112, 2009b. doi: 10.1029/2008JA013888.
- Švestka, Z. Varieties of Coronal Mass Ejections and Their Relation to Flares. *Space Science Reviews*, 95:135–146, 2001.
- Vasiliev, S. S. i V. A. Dergachev. The 2400-year cycle in atmospheric radiocarbon concentration: bispectrum of ^{14}C data over the last 8000 years. *Annales Geophysicae*, 20: 115–120, 2002. doi: 10.5194/angeo-20-115-2002.
- Versteegh, G. J. M. Solar Forcing of Climate. 2: Evidence from the Past. *Space Science Reviews*, 120:243–286, 2005. doi: 10.1007/s11214-005-7047-4.
- Vogt, S., G. F. Herzog, i R. C. Reedy. Cosmogenic nuclides in extraterrestrial materials. *Reviews of Geophysics*, 28:253–275, 1990. doi: 10.1029/RG028i003p00253.
- Vonmoos, M., J. Beer, i R. Muscheler. Large variations in Holocene solar activity: Constraints from ^{10}Be in the Greenland Ice Core Project ice core. *Journal of Geophysical Research (Space Physics)*, 111(A10):A10105, 2006. doi: 10.1029/2005JA011500.
- Vourlidas, A., P. Subramanian, K. P. Dere, i R. A. Howard. Large-Angle Spectrometric Coronagraph Measurements of the Energetics of Coronal Mass Ejections. *The Astrophysical Journal*, 534:456–467, 2000. doi: 10.1086/308747.
- Vourlidas, A., D. Buzasi, R. A. Howard, i E. Esfandiari. Mass and energy properties of LASCO CMEs. In Wilson, A., editor, *Solar Variability: From Core to Outer Frontiers*, volume 506 of *ESA Special Publication*, pages 91–94, 2002.
- Vršnak, B. Deceleration of Coronal Mass Ejections. *Solar Physics*, 202:173–189, 2001. doi: 10.1023/A:1011833114104.
- Vršnak, B. Processes and mechanisms governing the initiation and propagation of CMEs. *Annales Geophysicae*, 26:3089–3101, 2008. doi: 10.5194/angeo-26-3089-2008.
- Vršnak, B. i T. Žic. Transit times of interplanetary coronal mass ejections and the solar wind speed. *Astronomy & Astrophysics*, 472:937–943, 2007. doi: 10.1051/0004-6361:20077499.

- Vršnak, B., D. Ruždjak, D. Sudar, i N. Gopalswamy. Kinematics of coronal mass ejections between 2 and 30 solar radii. What can be learned about forces governing the eruption? *Astronomy & Astrophysics*, 423:717–728, 2004. doi: 10.1051/0004-6361:20047169.
- Vršnak, B., D. Sudar, i D. Ruždjak. The CME-flare relationship: Are there really two types of CMEs? *Astronomy & Astrophysics*, 435:1149–1157, 2005. doi: 10.1051/0004-6361:20042166.
- Vršnak, B., D. Sudar, D. Ruždjak, i T. Žic. Projection effects in coronal mass ejections. *Astronomy & Astrophysics*, 469:339–346, 2007a. doi: 10.1051/0004-6361:20077175.
- Vršnak, B., M. Temmer, i A. M. Veronig. Coronal Holes and Solar Wind High-Speed Streams: II. Forecasting the Geomagnetic Effects. *Solar Physics*, 240:331–346, 2007b. doi: 10.1007/s11207-007-0311-x.
- Vršnak, B., M. Temmer, i A. M. Veronig. Coronal Holes and Solar Wind High-Speed Streams: I. Forecasting the Solar Wind Parameters. *Solar Physics*, 240:315–330, 2007c. doi: 10.1007/s11207-007-0285-8.
- Vršnak, B., T. Žic, T. V. Falkenberg, i sur. The role of aerodynamic drag in propagation of interplanetary coronal mass ejections. *Astronomy & Astrophysics*, 512:A43, 2010. doi: 10.1051/0004-6361/200913482.
- Wagner, G., D. M. Livingstone, J. Masarik, R. Muscheler, i J. Beer. Some results relevant to the discussion of a possible link between cosmic rays and the Earth's climate. *Journal of Geophysical Research: Atmospheres*, 106:3381–3387, 2001. doi: 10.1029/2000JD900589.
- Wang, A. H., S. T. Wu, i N. Gopalswamy. Magnetohydrodynamic analysis of January 20, 2001, CME-CME interaction event. *Washington DC American Geophysical Union Geophysical Monograph Series*, 156:185–195, 2005. doi: 10.1029/156GM21.
- Wang, M. J., L. P. He, i H. Y. Jia. Cloudiness Variation Observed at Yangbajing during Forbush Decrease of Galactic Cosmic Rays. *High Energy Physics and Nuclear Physics*, 30:75–78, 2006.
- Webb, D. F. i R. A. Howard. The solar cycle variation of coronal mass ejections and the solar wind mass flux. *Journal of Geophysical Research*, 99:4201–4220, 1994. doi: 10.1029/93JA02742.
- Webb, D. F., T. G. Forbes, H. Aurass, i sur. Material ejection. *Solar Physics*, 153:73–89, 1994. doi: 10.1007/BF00712493.

- White, W. B., J. Lean, D. R. Cayan, i M. D. Dettinger. Response of global upper ocean temperature to changing solar irradiance. *Journal of Geophysical Research*, 102:3255–3266, 1997. doi: 10.1029/96JC03549.
- Wibberenz, G., J. A. Le Roux, M. S. Potgieter, i J. W. Bieber. Transient Effects and Disturbed Conditions. *Space Science Reviews*, 83:309–348, 1998. doi: 10.1023/A:1005083109827.
- Wilks, D. S. Resampling Hypothesis Tests for Autocorrelated Fields. *Journal of Climate*, 10:65–82, 1997. doi: 10.1175/1520-0442(1997)010<0065:RHTFAF>2.0.CO;2.
- Willson, R. C. i A. V. Mordvinov. Secular total solar irradiance trend during solar cycles 21–23. *Geophysical Research Letters*, 30:1199, 2003. doi: 10.1029/2002GL016038.
- Wilson, C. T. R. On the measurement of the earth-air current and on the origin of atmospheric electricity. In *Proceedings of Cambridge Philosophical Society*, volume 13, pages 363–382, 1906.
- Wilson, C. T. R. On a Method of Making Visible the Paths of Ionising Particles through a Gas. *Royal Society of London Proceedings Series A*, 85:285–288, 1911. doi: 10.1098/rspa.1911.0041.
- Wilson, C. T. R. On Some Determinations of the Sign and Magnitude of Electric Discharges in Lightning Flashes. *Royal Society of London Proceedings Series A*, 92:555–574, 1916. doi: 10.1098/rspa.1916.0040.
- Yu, F. Altitude variations of cosmic ray induced production of aerosols: Implications for global cloudiness and climate. *Journal of Geophysical Research (Space Physics)*, 107:1118, 2002. doi: 10.1029/2001JA000248.
- Yu, F. i R. P. Turco. Ultrafine aerosol formation via ion-mediated nucleation. *Geophysical Research Letters*, 27:883–886, 2000. doi: 10.1029/1999GL011151.
- Yu, F. i R. P. Turco. From molecular clusters to nanoparticles: Role of ambient ionization in tropospheric aerosol formation. *Journal of Geophysical Research*, 106:4797–4814, 2001. doi: 10.1029/2000JD900539.
- Zhao, X. P., S. P. Plunkett, i W. Liu. Determination of geometrical and kinematical properties of halo coronal mass ejections using the cone model. *Journal of Geophysical Research (Space Physics)*, 107:1223, 2002. doi: 10.1029/2001JA009143.

Životopis

JAAŠA ČALOGOVIĆ rođen je u Zagrebu 1980. godine. Diplomirao je ekologiju 2005. godine na Saveznoj Visokoj Tehničkoj Školi u Zürichu (ETH Zürich) sa specijalizacijom u području fizike i atmosfere. Nakon studija radi kao znanstveni suradnik (2005-2006) na Institutu za Fiziku Sveučilišta u Bernu. Krajem 2006. godine seli u Zagreb, gdje radi kao suradnik Zagrebačke Zvezdarnice na različitim edukacijskim projektima. Od 2007. godine djelatnik je Opservatorija Hvar (Geodetski Fakultet, Zagreb) gdje radi kao znanstveni novak na projektu „Eruptivni procesi u Sunčevoj atmosferi“. Aktivni je istraživač na SOTERIA, COMESEP i COST EU FP7 projektima. Član je Hrvatskog astronomskog društva, a 2009. godine je izabran za nacionalnoga koordinatora „Međunarodne godine astronomije 2009“. Tijekom znanstvenoga skupa „Research at Jungfrauojoch – Top of Science“ (2006) primio je drugu nagradu za najbolji poster. Članak Čalogović i sur. 2010 „Sudden cosmic ray decreases: No change of global cloud cover“ objavljen u Geophysical Research Letters izabran je kao najpopulariji članak u svim AGU časopisima u veljači 2010. Bio je recenzent za Geophysical Research Letters, Journal of Geophysical Research i International Journal of Climatology, a 2011. godine dobio je priznanje kao izvanredan recenzent za Geophysical Research Letters.

Radovi

1. Laken, B. i J. Čalogović. Does the diurnal temperature range response to changes in the cosmic ray flux?. *Environmental Research Letters*, 8:045018, 2013. doi:10.1088/1748-9326/8/4/045018.
2. Laken, B. i J. Čalogović. Composite analysis with Monte Carlo methods: an example with cosmic rays and clouds. *Journal of Space Weather and Space Climate*, 3:A29, 2013. doi:10.1051/swsc/2013051.
3. Hanslmeier, A., R. Brajša, J. Čalogović, B. Vršnak, D. Ruždjak, F. Steinhilber, C. L. MacLeod, Ž. Ivezić i I. Skokić. The chaotic solar cycle - II. Analysis of cosmogenic ^{10}Be -data. *Astronomy & Astrophysics*, 550:A6, 2013. doi: 10.1051/0004-6361/201015215

4. Laken, B. A., E. Pallé, J. Čalogović i M. E. Dunne. A cosmic ray–climate link and cloud observations. *Journal of Space Weather and Space Climate*, 2:A18, 2012. doi:10.1051/swsc/2012018.
5. Laken, B., J. Čalogović, T. Shahbaz, i E. Pallé. Examining a solar-climate link in diurnal temperature ranges. *Journal of Geophysical Research (Atmospheres)*, 117:D18112, 2012. doi:10.1029/2012JD017683.
6. Čalogović, J., M. Dumbović, N. Novak, B. Vršnak, R. Brajša, V. Ruždjak, W. Pötzi, W. Hirtenfellner-Polanec, A. Veronig, A. Hanslmeier, M. Klvana i P. Ambrož. Solar H-alpha and white light telescope at Hvar Observatory. *Central European Astrophysical Bulletin*, 36:83-88, 2012.
7. Dumbović, M., B. Vršnak i J. Čalogović. Solar influences on the short-term cosmic ray modulation. *Central European Astrophysical Bulletin*, 36, 65-70, 2012.
8. Vršnak B., T. Žic, D. Vrbanec, M. Temmer, T. Rollett, C. Möstl, A. Veronig, J. Čalogović, M. Dumbović i S. Lulić i sur. Propagation of Interplanetary Coronal Mass Ejections: The Drag-Based Model. *Solar Physics*, 285:295-315, 2012. doi: 10.1007/s11207-012-0035-4.
9. Laken, B., J. Čalogović, J. Beer i E. Pallé. Interactive comment on “Effects of cosmic ray decreases on cloud microphysics” by J. Svensmark et al. *Atmospheric Chemistry and Physics*, 12:C962-C973, 2012.
10. Dumbović, M., B. Vršnak, J. Čalogović i R. Župan. Cosmic ray modulation by different types of solar wind disturbances. *Astronomy & Astrophysics*, 538, A28, 2012. doi: 10.1051/0004-6361/201117710.
11. Laken, B. i J. Čalogović. Solar irradiance, cosmic rays and cloudiness over daily timescales. *Geophysical Research Letters*, 38:L24811, 2011. doi:10.1029/2011GL049764.
12. Dumbović, M., B. Vršnak, J. Čalogović i M. Karlica. Cosmic ray modulation by solar wind disturbances. *Astronomy & Astrophysics*, 531, A91, 2011. doi:10.1051/0004-6361/201016006.
13. Čalogović, J., C. Albert, F. Arnold, J. Beer, L. Desorgher i E. Flückiger. Sudden cosmic ray decreases: No change of global cloud cover. *Geophysical Research Letters*, 37:L03802, 2010. doi:10.1029/2009GL041327.

14. Čalogović, J., B. Vršnak, M. Temmer i A. Veronig. Cosmic ray modulation by corotating interaction regions. *Proceedings of the International Astronomical Union*, 257:425-427, 2009.
15. Vršnak, B., D. Vrbanec, J. Čalogović i T. Žic. The role of aerodynamic drag in dynamics of coronal mass ejections, *Proceedings of the International Astronomical Union*, 257:271-277, 2009.
16. Vršnak, B., D. Vrbanec i J. Čalogović. Dynamics of coronal mass ejections - The mass-scaling of the aerodynamic drag. *Astronomy & Astrophysics*, 490(2):811-815, 2008. doi:10.1051/0004-6361:200810215.

Konferencije, radionice, projektni sastanci i škole

- 18-22. studenog 2013, 10th European Space Weather Week, Antwerpen, Belgija: usmeno izlaganje rada: "Satellite retrieved cloud data limitations and the evaluation of a solar-cloud link".
- 8-10. listopada 2013, Kanzelhohe Colloquium 2013, Kanzelhöhe, Austrija: usmeno izlaganje rada: "KSO-Hvar collaboration on H- α and white-light observations".
- 30. rujna - 4. listopada 2013, Projektni sastanak "TOSCA science and management committee meetings", Institute of Atmospheric Physics - ASCR, Prag, Češka: usmeno izlaganje radova: "Testing cloud data for hypothesized solar signals" i "Prediction of the Solar Cycle".
- 17-20. lipanj 2013, SCOSTEP International Study for Earth-Affecting Solar Transients (ISEST) Workshop, Hvar, Hrvatska: prisustvovanje na radionici, voditelj lokalnog organizacijskog odbora.
- 15-19. travnja 2013, Projektni sastanak "COMESSEP 2nd Year Progress Meeting", Zagreb, Hrvatska: prisustvovanje na projektnom sastanku, voditelj lokalnog organizacijskog odbora.
- 5-9. listopada 2012, 9th European Space Weather Week, Bruxelles, Belgija: usmeno izlaganje rada: "Testing a link between cosmic rays and cloudiness over daily timescales".
- 3-7. rujna 2012, XIIth Hvar Astrophysical Colloquium - The Sun and Heliosphere, Hvar, Hrvatska: usmeno izlaganje rada: "Testing a link between cosmic rays, so-

lar irradiance and cloudiness over short timescales", član lokalnog organizacijskog odbora.

- 2-6. srpnja 2012, *XIth Hvar Astrophysical Colloquium - The Most Mysterious Binaries: Significance for Astrophysics*, Hvar, Hrvatska: član lokalnog organizacijskog odbora, usmeno izlaganje: "Istraživanje Sunca i Sunčeve aktivnosti na Opservatoriju Hvar".
- 18-21. lipnja 2012, *Projektni sastanak FP7 COMESEP projekta*, Belgisch Instituut voor Ruimte-Aeronomie (BIRA), Bruxelles, Belgija: dogovor o integraciji DBM-a (Drag Based Model) u COMSEP alert system.
- 14-15. lipnja 2012, *ISSI workshop - "Cosmic ray influence upon atmospheric processes"*, Bern, Švicarska: u sklopu radionice je usmeno izložen rad "Forbush decrease events and clouds".
- 25. veljača - 24. ožujak 2012, *Instituto de Astrofísica de Canarias (IAC), La Laguna, Tenerife, Španjolska*: znanstveno usvršavanje u sklopu EU COST ES1005 (TOSCA) projekta (STSM-9537), posjet dr. sc. Benjaminu Lakenu na IAC-u sa svrhom izrade rada: "Towards a better assessment of data limitations in the evaluation of a solar – cloud link".
- 13-14. prosinca 2011, *Projektni sastanak "HELIO meeting"*, Paris Observatory, Pariz, Francuska: u sklopu projektnog sastanka predstavljen rad "CH/CIR and Drag Based Model" te dogovorena suradnja na HELIO projektu.
- 15-18. studenoga 2011, *Projektni sastanak "COST Action ES1005 (TOSCA) Meeting"*, GFZ, Potsdam, Njemačka: usmeno izlaganje rada: "Forbush decrease events and clouds".
- 9-12. listopada 2011, *5th Central European Solar Physics Meeting*, Bairisch Kölldorf, Austrija: predstavljen poster: "Solar H- α and white light telescope at Hvar Observatory".
- 21-27. kolovoza 2011, *Ljetna škola "2011 ISWI-Europe Summer School in Space Science"*, Astronomical Institute of the SAS, Tatranská Lomnica, Slovačka: sudjelovanje na ljetnoj školi.
- 6-10. lipanj 2011, *Third Workshop - "Solar influences on the magnetosphere, ionosphere and atmosphere"*, Sozopol, Bugarska: usmeno izlaganje rada: "Testing a link between solar irradiance and cloud cover over daily timescales".

- 30. svibnja - 1. lipnja 2011, Projektni sastanak "3rd SOTERIA General Meeting", Leuven, Belgija: sudjelovanje na projektnom sastanku.
- 16-21. siječnja 2011, Space Climate Symposium 4, Goa, Indija: predstavljeni poster: „Testing a link between solar irradiance and atmospheric parameters” i “Cosmic Ray modulation by Solar Wind Disturbances”.
- 18-22. rujna 2010, Xth Hvar Astrophysical Colloquium - The active Sun, Hvar, Hrvatska: sudjelovanje na znanstvenom skupu, član lokalnog organizacijskog odbora.
- 25-29. travnja 2010, Radionica - "Solar, Cosmic Rays and Climate Connections", The Institute for Advanced Studies - The Hebrew University of Jerusalem, Jeruzalem, Izrael: usmeno izlaganje rada: "Forbush Decreases and Clouds: Do changes in cosmic ray intensity influence the cloud cover?".
- 14-19. rujna 2009, Projektni sastanak "SOTERIA event study workshop", Hvar, Hrvatska: sudjelovanje na projektnom sastanku FP7 SOTERIA projekta.
- 7-13. rujna 2009, IHY-ISWI Regional Meeting - "Heliophysical phenomena and Earth's environment", Šibenik, Hrvatska: predstavljen poster “Cosmic Ray modulation by Corotating Interaction Regions”, član lokalnog organizacijskog odbora.
- 22-31. svibnja 2009, Split Workshop in Atmospheric Physics and Oceanography, Split, Hrvatska: sudjelovanje na znanstvenoj radionici.
- 14-22. ožujka 2009, Space Climate Symposium 3, University of Oulu, Saariseleka, Finska: sudjelovanje u "Space climate" školi (15.-18.3.), usmeno izlaganje rada: "Forbush Decreases and Clouds: Do changes in Cosmic Ray intensity influence the Cloud Cover?".
- 22-26. rujna 2008, IXth Hvar Astrophysical Colloquium - Solar minimum meeting, Hvar, Hrvatska: usmeno izlaganje: "Sudden Cosmic Ray Decreases: No Change of Global Cloud Cover", član lokalnog organizacijskog odbora.
- 15-19. rujna 2008, International Astronomical Union (IAU) Symposium 257 on „Universal Heliophysical Processes, Ioannina, Grčka: usmeno izlaganje: "Forbush Decrease: No Change of Global Cloud Cover", predstavljen poster: "Cosmic Ray Modulation by Corotating Interaction Regions".
- 11-14. rujna 2006, Research at Jungfraujoch – “Top of Science”, Interlaken, Švicarska: predstavljen poster: "Forbush Decreases and Cloud Cover".

- 5-9. *prosinac 2005, AGU Fall Meeting, San Francisco, SAD*: predstavljen poster: "Forbush Decreases and Cloud Cover".