

# **Detekcija potresa u sjeverozapadnim Dinaridima uz upotrebu neuronskih mreža**

---

**Wild, Dorian**

**Master's thesis / Diplomski rad**

**2024**

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

*Permanent link / Trajna poveznica:* <https://urn.nsk.hr/um:nbn:hr:217:618108>

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

*Download date / Datum preuzimanja:* **2024-05-13**



*Repository / Repozitorij:*

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



SVEUČILIŠTE U ZAGREBU  
PRIRODOSLOVNO-MATEMATIČKI FAKULTET  
GEOFIZIČKI ODSJEK

Dorian Wild

DETKECIJA POTRESA U  
SJEVEROZAPADNIM DINARIDIMA UZ  
UPOTREBU NEURONSKIH MREŽA

Diplomski rad

Zagreb, 2024.

SVEUČILIŠTE U ZAGREBU  
PRIRODOSLOVNO-MATEMATIČKI FAKULTET  
GEOFIZIČKI ODSJEK

DIPLOMSKI SVEUČILIŠNI STUDIJ FIZIKA-GEOFIZIKA

SMJER: SEIZMOLOGIJA I FIZIKA ČVRSTE ZEMLJE

Dorian Wild

Diplomski rad

**Detekcija potresa u sjeverozapadnim  
Dinaridima uz upotrebu neuronskih mreža**

Voditelj diplomskog rada: izv. prof. dr. sc. Josip Stipčević

Zagreb, 2024.

Zahvaljujem voditelju diplomskog rada izv. prof. dr. sc. Josipu Stipčeviću na prijedlogu teme koja me uvela u fascinantni svijet umjetne inteligencije i pomoći tijekom izrade rada. Zahvaljujem doc. dr. sc. Ivi Dasović na pedantnosti i pomoći tijekom pisanja diplomskog rada.

Najviše se zahvaljujem svojoj obitelji i djevojcima koji su mi bili najveća podrška i oslonac tijekom ovih godina studiranja te konačne izrade diplomskog rada.

## Sažetak

Dolaskom doba nazvanim *Big Data*, dogodilo se eksponencijalno povećanje količine seizmičkih podataka zbog povećanja broja seizmičkih postaja i napretka tehnologije, zbog čega tradicionalne metode analize i ručne detekcije faza postaju neodržive. Ususret tom vremenu, testira se novi pristup koji koristi neuronske mreže za automatizaciju detekcije i karakterizaciju seizmičkih događaja, s ciljem povećanja točnosti i učinkovitosti u odnosu na postojeće automatizirane sustave. U ovom radu analiziran je sveobuhvatni skup podataka kojeg čini testni katalog potresa u razdoblju 2009. - 2018. godine u sjeverozapadnim Dinaridima primjenom modela *PhaseNet* za detekciju seizmičkih faza i *GAMMA Associatora* za izradu sintetičkih kataloga te procedura koje značajno poboljšavaju detekciju potresa. Korišteno je pet varijanti modela *PhaseNet* treniranih na pet različitih baza podataka: INSTANCE, STEAD, ETHZ, SCEDC i GEOFON sa svrhom detekcije P- i S-faza, te algoritam na temelju strojnog učenja zvan *GAMMA Associator* sa svrhom asocijacije i izrade sintektičkog kataloga. Najprije se varijante modela *PhaseNet* primjenjuju na uzorak iz stvarnog kataloga u svrhu određivanja najefikasnije varijante modela *PhaseNet*, te se potom ta varijanta primjenjuje na cijeli skup podataka. Kombinacija modela *PhaseNet* s tehnikom učenja prijenosom i *GAMMA Associatora* omogućava stvaranje kataloga potresa koji sadrži preko 92 % identičnih događaja iz usporednog stvarnog kataloga, te također 10 puta više novih događaja. Rezultati naglašavaju potencijal strojnog učenja za revoluciju u praćenju potresa pružanjem bržih, većih i pravovremenijih sposobnosti detekcije. Ovo istraživanje ne samo da doprinosi napretku metoda detekcije potresa, već otvara i puteve za buduća istraživanja u seismologiji i povezanim područjima.

# **Neural network based earthquake detection in the northwest Dinarides**

## **Abstract**

With the arrival of the era called Big Data, there has been an exponential increase in the volume of seismic data due to the expansion of seismic stations and the advancement of technology, due to which traditional methods of analysis and manual phase detection are becoming unsustainable. Therefore, a new approach that uses neural networks to automate the detection and characterization of seismic events is being tested, with the goal of increasing accuracy and efficiency compared to existing automated systems. In this thesis, the PhaseNet models and GaMMA Associator were applied in the analysis of a comprehensive data set of the test earthquake catalogue for the period of 2009 - 2018 in the northwest Dinarides to significantly improve earthquake detection and create a synthetic earthquake catalogue. Five variants of the PhaseNet model trained on five different databases were used: INSTANCE, STEAD, ETHZ, SCEDC and GEOFON to detect P and S phases, and GaMMA Associator, an algorithm based on machine learning for association and creation of a synthetic catalog. The models were first applied to a sample from the real catalog to determine the most efficient variant of PhaseNet, and then that variant is applied to the entire data set. The combination of PhaseNet and GaMMA Associator generates an earthquake catalog that contains over 92% identical events from the comparative real catalog, and 10 times more new events. The findings underscore the potential of machine learning to revolutionize earthquake monitoring by providing more reliable and timely detection capabilities. This research not only contributes to the advancement of seismic detection methods but also opens avenues for future investigations in seismology and related fields.

# Sadržaj

<b>1. Uvod</b>	<b>1</b>
1.1. <i>Seizmotektonsko okruženje sjeverozapadnih Dinarida</i> . . . . .	1
1.2. <i>Motivacija i ciljevi rada</i> . . . . .	1
<b>2. Teorijska podloga</b>	<b>3</b>
2.1. <i>Osnove o potresima</i> . . . . .	3
2.2. <i>Seizmički valovi</i> . . . . .	4
2.3. <i>Lociranje potresa</i> . . . . .	6
2.4. <i>Katalog potresa</i> . . . . .	7
<b>3. Osnove strojnog učenja</b>	<b>10</b>
3.1. <i>Povijesni pregled</i> . . . . .	10
3.2. <i>Osnovni koncepti</i> . . . . .	12
3.3. <i>Vrste učenja</i> . . . . .	14
3.4. <i>Određivanje točnosti modela</i> . . . . .	15
3.4.1. <i>Minimizacija pogreške na testnom skupu</i> . . . . .	17
3.5. <i>Umjetne neuronske mreže</i> . . . . .	18
3.5.1. <i>Struktura</i> . . . . .	19
3.5.2. <i>Učenje neuronskih mreža</i> . . . . .	20
3.5.3. <i>Vrste neuronskih mreža</i> . . . . .	21
3.5.4. <i>Konvolucijske neuronske mreže</i> . . . . .	22
<b>4. Metode</b>	<b>25</b>
4.1. <i>Određivanje faza: PhaseNet</i> . . . . .	25
4.2. <i>Određivanje potresa: GaMMA Associator</i> . . . . .	28
4.2.1. <i>Kalibracija GaMMA Associatora</i> . . . . .	29
4.3. <i>Primjena: Učenje prijenosom</i> . . . . .	30
<b>5. Podaci</b>	<b>32</b>
5.1. <i>Baze podataka za trening</i> . . . . .	32
5.1.1. INSTANCE . . . . .	32
5.1.2. STEAD . . . . .	33
5.1.3. ETHZ, GEOFON i SCEDC . . . . .	34

5.2. <i>Podaci za testiranje</i> . . . . .	35
5.3. <i>Testni katalog potresa</i> . . . . .	38
<b>6. Rezultati i diskusija</b>	<b>40</b>
6.1. <i>Detekcije faza</i> . . . . .	40
6.2. <i>Dogadaji (uzorak)</i> . . . . .	42
6.3. <i>Dogadaji (cijeli skup)</i> . . . . .	46
<b>7. Zaključak</b>	<b>55</b>
<b>Literatura</b>	<b>57</b>
<b>Dodatak A</b>	<b>62</b>
<b>Dodatak B</b>	<b>64</b>
<b>Dodatak C</b>	<b>67</b>
C1. <i>ObsPy</i> . . . . .	67
C2. <i>SeisBench</i> . . . . .	68
<b>Dodatak D</b>	<b>69</b>

# 1. Uvod

## 1.1. Seizmotektonsko okruženje sjeverozapadnih Dinarida

Dinaridi ili Dinarsko gorje su mlađe ulančano gorje u Južnoj i Jugoistočnoj Europi, a koje se proteže od Italije kroz Sloveniju, Hrvatsku, Bosnu i Hercegovinu, Srbiju, Crnu Goru, Kosovo do Albanije. Karakterizira ih kompleksna geologija i struktura na koju primarno utječu tektonski procesi asocirani s konvergencijom Euroazijske i Afričke ploče.

Seizmička aktivnost na ovom području također je pod utjecajem kompozicije i strukture Dinarida, koje se sastoje od debelih naslaga karbonatnih taloženja (vapnenci i dolomiti), formirajući značajne geološke značajke poput vanjskih i unutarnjih Dinarida. Najbitniji rasjedi na ovom području su Čićarijski rasjed i sustav rasjeda Velebitskih planina.

Područje istraživanja obuhvaća sjeverozapadne Dinaride, te zahvaća područje Slovenije i Hrvatske (slika 5.3). Karakterizirano je umjerenom seizmičkom aktivnošću s manjim brojem jakih potresa. Prostorno, ovo područje se nalazi na sjeveroistočnom rubu Jadranske mikroploče, okruženo s Alpama na sjeveru, Panonskim bazenom na istoku i Jadranskim morem na zapadu. Seizmička aktivnost na ovom području primarno je povezana s kompleksnim geodinamičkim interakcijama, posebno zbog trenutno aktivne subdukcije Jadranske mikroploče pod Euroazijsku ploču. Ova interakcija, koja je započela u kasnoj kredi, dovela je do značajne tektonske aktivnosti i strukturnih složenosti (Rajh et al., 2022).

Na području istraživanja, dominantni uzrok potresa je transpresijski režim uz lokalnu kompresiju. Glavni tip rasjeda je s pomakom po pružanju (engl. *strike-slip*) rasjed koji ima pružanje sjeverozapad-jugoistok. Najsnažniji potres na području istraživanja u ovom radu se dogodio početkom 16. stoljeća uzduž Idrijskog rasjeda s  $M_w = 6.8$  (Vičić et al., 2019).

## 1.2. Motivacija i ciljevi rada

Značajan napredak u instrumentalnoj seismologiji i tehnologiji posljednjih desetljeća doveo je do eksponencijalnog porasta količine podataka koji su dostupni za analizu.

Povećanje broja seizmoloških mreža instrumenata širom svijeta rezultiralo je ne samo većim brojem detektiranih potresa, već i bogatstvom podataka koji su potrebni za njihovu analizu. Ovi podaci su ključni za razumijevanje seizmičkih procesa, procjenu seizmičkog hazarda te unapređenje graditeljskih standarda i protokola za smanjenje štete. Međutim, paralelno s ovim porastom, povećava se i izazov učinkovitog i točnog analiziranja tih podataka. Tradicionalni pristupi analizi, koji se u velikoj mjeri oslanjaju na ručno određivanje seizmičkih faza i lociranje potresa, postaju sve više neodrživi u svjetlu ove sve veće količine podataka.

Ručno lociranje potresa, iako iznimno važno za razumijevanje seismograma potresa, postaje sve zahtjevniji zadatak zbog povećanja broja seizmoloških postaja i sakupljenih podataka. Iskusni seizmolozi mogu precizno odrediti karakteristike potresa, uključujući njegovu lokaciju, dubinu i magnitudu, interpretirajući seizmičke valove zabilježene na više postaja. Međutim, s obzirom na kontinuirani priljev podataka, ova metoda je vremenski zahtjevna i jednim dijelom sklona subjektivnoj interpretaciji, što može dovesti do varijacija u rezultatima.

Osim toga, unatoč značajnim poboljšanjima u automatiziranim tehnikama detekcije potresa, postizanje razine preciznosti i pouzdanosti koju pružaju iskusni analitičari ostaje izazov. Automatizirani sustavi često se suočavaju s poteškoćama u razlikovanju seismograma potresa od pozadinskog šuma ili u identifikaciji slabih potresa u podacima s visokom razinom šuma. Ove poteškoće naglašavaju potrebu za naprednjim pristupima koji mogu efikasno obraditi i analizirati velike količine podataka.

U ovom kontekstu, metode strojnog učenja nude obećavajuće rješenje. Strojno učenje, grana umjetne inteligencije koja se bavi razvojem algoritama koji se poboljšavaju kroz iskustvo, pokazalo se kao moćni alat u mnogim područjima znanosti i inženjerstva. Primjena metoda strojnog učenja u detekciji potresa otvara nove mogućnosti za automatsku identifikaciju i karakterizaciju seismograma potresa s visokom točnošću i u realnom vremenu.

U ovom radu istraživan je potencijal primjene različitih algoritama strojnog učenja u detekciji i analizi potresa. Cilj je bio razviti modeli koji mogu precizno identificirati seizmičke faze u seismogramu, smanjujući pritom potrebu za ručnom analizom i prevladavajući ograničenja postojećih automatiziranih sustava. Kroz kombinaciju teorijske analize i empirijskih testiranja, u radu je detaljno ispitano kako različite tehnike stroj-

nog učenja, *PhaseNet* za detekciju faza i *GaMMA Associator* za izgradnju sintetičkog kataloga, mogu biti primijenjene za poboljšanje detekcije potresa. Posebna pažnja posvećena je izazovima kao što su visoka razina šuma u podacima, mala učestalost potresa u odnosu na ukupan broj zabilježenih potresa, i potreba za brzom obradom podataka kako bi se omogućile pravovremene reakcije na potrese.

Analizirajući velike skupove podataka dobivene od mreža seismoloških instrumenata širom svijeta, u ovom radu je pokazano kako moderni algoritmi strojnog učenja mogu značajno unaprijediti sposobnost detekcije i karakterizacije potresa. Veća točnost i efikasnost u identifikaciji potresa predstavlja ključni korak prema naprednjem i pouzdanim pružanjem praćenju seizmičke aktivnosti na globalnoj razini. ML pristup ne samo da nudi potencijal za poboljšanje trenutnih metoda detekcije potresa, već također otvara put za daljnje istraživanje u području seismologije i povezanih disciplina.

## 2. Teorijska podloga

### 2.1. *Osnove o potresima*

**Potres** se definira kao iznenadno otpuštanje nakupljene potencijalne energije u unutrašnjosti Zemlje u obliku elastičnih (seizmičkih) valova i topline. Najčešći oblici potresa nazivaju se tektonski potresi koji čine više od 90 % potresa. Tektonski potresi nastaju na rasjedima i rezultat su djelovanja tektonskih sila. Izuzev tektonskih, događaju se još i vulkanski (oko 7 %), urušni (oko 3 %) te umjetni (npr. nuklearne eksplozije) i vrlo rijetko impaktni. Uz potres vežemo nekoliko karakterističnih veličina:

- **Žarište (hipocentar)** – definira se kao točka na rasjednoj plohi u kojoj je došlo do naglog oslobođanja nakupljene elastične energije, te je iz ove točke nastavljen daljnji pomak po rasjednoj plohi.
- **Epicentar** – definira se kao točka na površini Zemlje koja se nalazi vertikalno iznad hipocentra.
- **Mehanizam pomaka u žarištu potresa** – opisuje vrstu tektonske napetosti u stijenama oko potresnoga izvora te kinematske značajke dvaju rasjeda.
- **Magnituda** – mjera (broj) koja opisuje količinu oslobođene elastične energije potresa.

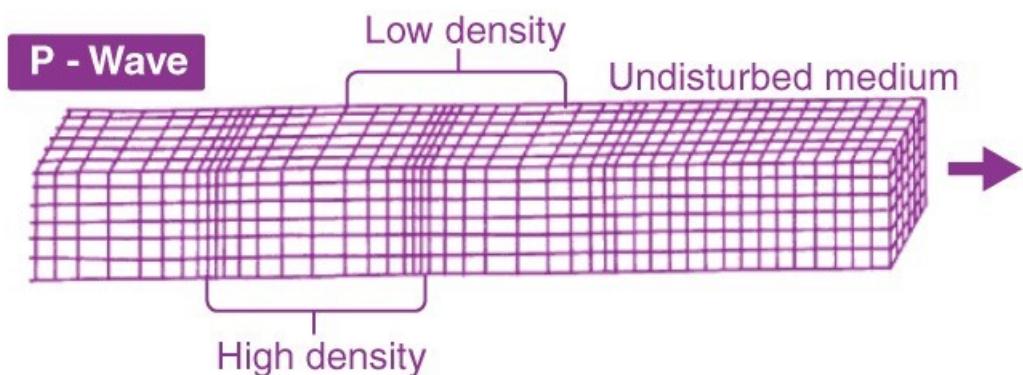
Slom i pomak po rasjedu nije trenutačan uzduž čitave površine rasjedanja, nego započinje u jednoj točki (žarište) i širi se po rasjedu približno brzinom putovanja S-valova, otprilike 3 km/s. Ovaj proces se odvija sve dok su naprezanja veća od elastičnosti i čvrstoće stijena ili trenja između rasjednih krila. Zbog tog procesa dolazi do pomaka samo na jednom dijelu rasjeda, što potencijalno može uzrokovati prijenos napetosti na ostale dijelove rasjeda ili na susjedne rasjede. Zbog ovakvog učinka prijenosa napetosti može doći do pojave novih potresa (serije potresa), te proces potpunog otpuštanja napetosti može potrajati od nekoliko dana do nekoliko godina. Nakon razdoblja otpuštanja slijedi razdoblje ponovnog nakupljanja napetosti tijekom kojeg se rijetko pojavljuju potresi, sve do ponovnog iznenadnog otpuštanja energije. Takav proces nakupljanja, otpuštanja i ponovnog nakupljanja se zove seizmički ciklus. Potrebno je napomenuti da iako su potresi ciklična pojava, nisu periodična (ne pojavljuju se u pravilnim vremenskim intervalima). Stoga su potresi kvaziperiodična pojava. Kada se govori o serijama potresa, potresi koji slijede nakon najjačeg potresa se nazivaju naknadnim potresima (engl. *aftershocks*). Gibanja tla kojima su uzrok različiti učinci (seizmički nemir, potres, eksplozija itd.) se bilježe i mjere pomoću uređaja zvanog **seizmograf**. Na temelju mjerjenja pomaka, brzine ili akceleracije tla, seismograf stvara **seizmogram** koji predstavlja zapis gibanja tla (Dasović, Herak i Prevolnik, 2021).

## 2.2. *Seizmički valovi*

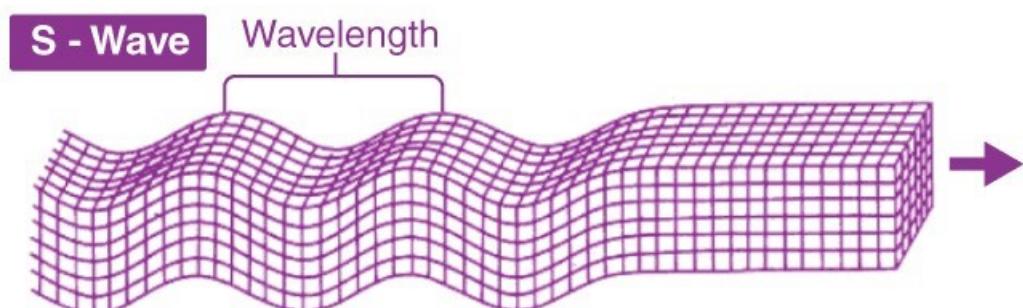
Prilikom oslobađanja energije u procesu potresa, najveći dio energije (oko 90 %) će se utrošiti na trenje i oslobađanje topline, dok će se ostatak osloboditi u obliku seizmičkih valova. Seizmičke valove se može podijeliti na:

- **Prostorne valove** (engl. Body Waves) – nastaju u žarištu potresa i putuju na sve strane kroz unutrašnjost Zemlje. Osnovna podjela je na P-valove i S-valove. P-valovi uzrokuju titranje čestica sredstva u smjeru putovanja vala (longitudinalni valovi). P-valovi su najbrži seizmički valovi te se uvijek prvi uočavaju na seismogramu. S-valovi uzrokuju titranje čestica sredstva okomito na smjer putovanja vala te se na seismogramu uočavaju nakon P-valova. Međutim, S-valovi imaju mnogo veću amplitudu od P-valova te uzrokuju jače podrhtavanje tla. Na slikama 2.1 i 2.2 su prikazani P- i S-val.

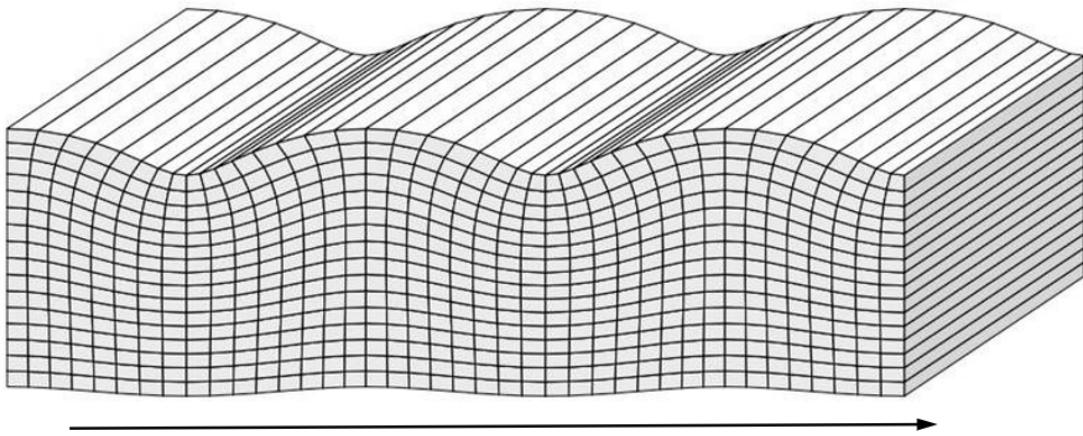
- **Površinske valove** (engl. *Surface Waves*) – putuju uz površinu Zemlje. Zajedničko im je da im amplituda opada s dubinom te da nastaju međudjelovanjem prostornih valova s diskontinuitetima. **Loveovi valovi** nastaju reflekcijom i interferencijom horizontalno polariziranih S-valova (SH-valovi). Tijekom njihovog prolaska kroz sredstvo s brzinom nešto manjom od S-valova, čestice sredstva titraju u horizontalnoj ravnini, okomito na smjer rasprostriranja vala. **Rayleighjevi valovi** nastaju refleksijom i superpozicijom P-valova i vertikalno polariziranih S-valova (SV-valovi). Pri prolasku vala kroz sredstvo, čestice sredstva osciliraju retrogradno po eliptičnoj putanji (u smjeru obrnuto od kazaljke na sat), te direktno nakon određene dubine (u smjeru kazaljke na sat). Na seismogramima dalekih i snažnih potresa koji imaju plitko žarište ( $h < 70$  km) dominiraju površinski valovi. Na slikama 2.3 i 2.4 su prikazani Rayleighev i Loveov val.



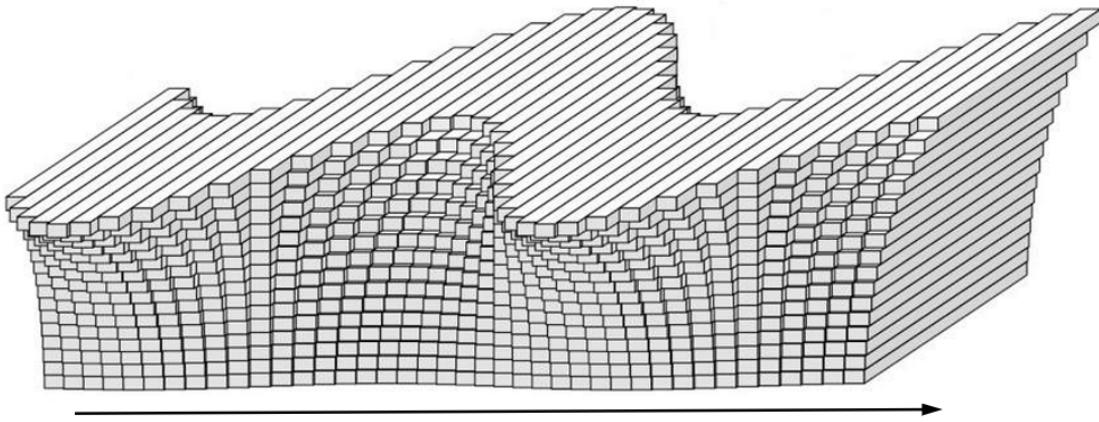
Slika 2.1. Prikaz P-vala (preuzeto sa <https://byjus.com/>)



Slika 2.2. Prikaz S-vala (preuzeto sa <https://byjus.com/>)



Slika 2.3. Prikaz Rayleighovog vala (preuzeto sa URL 3).



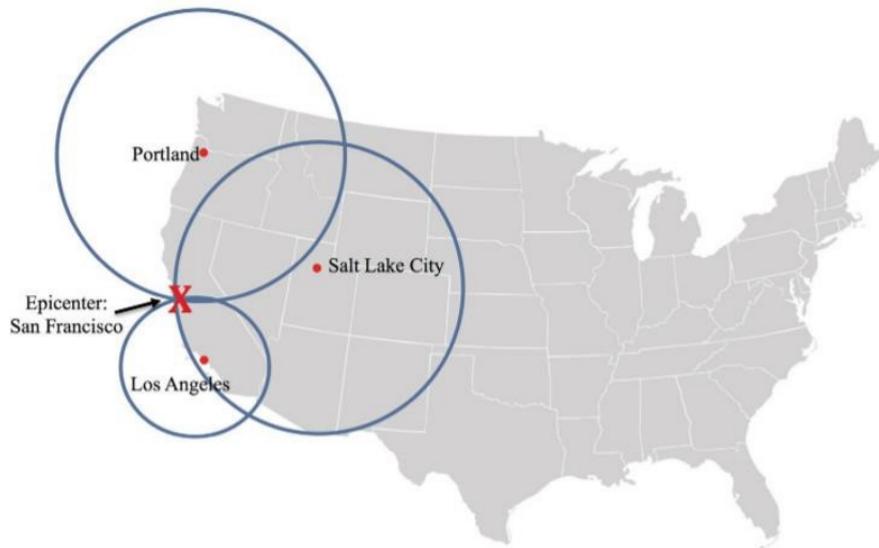
Slika 2.4. Prikaz Loveovog vala (preuzeto sa URL 3).

Promjena brzina prostornih valova unutar Zemlje, te mogućnost konverzije između P- i S-valova uzrokuje mnoge moguće valne staze. Svaka od ovih staza stvara drugačiju i odvojenu seizmičku **fazu**. Faza se definira kao skupina istovrsnih staza valova. Postoje mnoge različite faze seizmičkih valova ovisno o tome kroz koji dio Zemlje (i na koji način) su valovi putovali kroz nju, no specifičnosti oko različitih faza su izvan konteksta ovog rada. Fokus će biti na osnovnim P- i S-fazama (koji imaju jednostavnu stazu od izvora potresa do seizmološke postaje).

### **2.3. Lociranje potresa**

Razni seizmički valovi opisani u prethodnom poglavljtu putuju do mnogih različitih seismoloških postaja te se, ako je uređaj dovoljno osjetljiv i ako valovi imaju dovoljno velike amplitudu (energije), mogu uočiti na seismogramima. P-valovi predstavljaju prvi sig-

nal koji ukazuje na potres, te potom dolaze S-valovi koji se uočavaju kao mnogostruko povećanje amplitude na seizmogramu. Pomoću zapisa na minimalno tri seismološke postaje, moguće je locirati epicentar potresa (četiri postaje za dubinu žarišta potresa). U najjednostavnijem postupku određivanja epicentra potresa primjenju se varijanta triangulacije koja je prikazana na slici 2.5. Za postaje se određuje epicentralna udaljenost pomoću hodokrona (krivulja koja pokazuje ovisnost vremena putovanja pojedinih valova o epicentralnoj udaljenosti), koja definira radijuse opisanih kružnica oko svake postaje, a epicentar predstavlja sjecište tri kružnice. Za što preciznije rezultate, potrebna je gusta, širokorasprostranjena mreža postaja i precizan model brzina. Nedovoljna količina postaja ili loš (poopćen) model unutrašnjosti Zemlje će smanjiti preciznost lociranja potresa (Dasović, Herak i Prevolnik, 2021).



Slika 2.5. Primjer određivanja epicentra potresa pomoću tri seismološke postaje (preuzeto s URL 4).

## 2.4. Katalog potresa

**Katalog potresa** predstavlja ključni proizvod u području seizmologije jer omogućava stvaranje detaljne baze podataka koja je neophodna za analizu seizmičkih aktivnosti određenog područja. Tipičan katalog potresa sadržava detaljne zapise o svakom registriranom potresu, a osnovni podaci koje svaki katalog potresa mora sadržavati su vrijeme nastanka potresa, geografska dužina epicentra, geografska širina epicentra, dubina žarišta i magnituda. Uz osnovne, također postoje i izborni parametri s kojima se

opisuju dodatna svojstva potresa ili su na neki način povezani s potresom (npr. nepozdanosti osnovnih parametara). U idealnom slučaju, svaki katalog potresa trebao bi točno i pouzdano predstaviti cjelokupnu raspodjelu magnituda potresa u određenom vremenskom razdoblju na određenom području, iliti uključivati sve relevantne potrese počevši od određene donje granice magnitude – takav katalog naziva se potpunim katalogom. Nadalje, svaki katalog treba sadržavati podatke koji su prikupljeni, obrađeni i prezentirani na dosljedan način, što omogućuje točne usporedbe između različitih potresa i vremenskih razdoblja – takav katalog naziva se homogenim katalogom (Dasović, Herak i Prevolnik, 2021). Na potpunost kataloga utječe kvaliteta i opseg postaja, dok na homogenost može utjecati promjena u načinu obrade podataka, nagli prestanak praćenja zbog vanjskih faktora itd.

Postoje dvije osnovne podjele na temelju načina stvaranja kataloga potresa:

- **Manualni katalozi** – temelje se na tradicionalnim metodama prikupljanja i analize podataka, gdje seismolozi ručno pregledavaju i analiziraju seismograme potresa. Manualni pristup omogućuje visoku točnost zbog detaljne analize i mogućnosti stručnjaka da primijene svoje znanje i iskustvo u interpretaciji podataka. Međutim, ovaj pristup je vremenski zahtjevan i podložan ljudskim pogreškama, te je manje praktičan za obradu velikih količina podataka ili tijekom razdoblja intenzivne seizmičke aktivnosti.
- **Automatizirani katalozi** – koriste računalne algoritme za automatsko otkrivanje, analizu i unos podataka o potresima. Ovi sustavi su dizajnirani da kontinuirano prate seizmičke podatke, često omogućavajući obradu i izvještavanje u stvarnom vremenu. Automatizacija značajno povećava brzinu i efikasnost obrade podataka, smanjuje utjecaj ljudskih grešaka i omogućuje obradu velikih količina podataka. Međutim, kvaliteta rezultata uvelike ovisi o korištenim algoritmima, što može zahtijevati redovite revizije i prilagodbe od strane stručnjaka kako bi se osigurala njihova točnost.

Sve veći broj seismoloških instrumenata učinio je ručno određivanje nastupa seizmičkih faza sve izazovnijim, dok je ručno određivanje podložno pristranostima jer različiti analitičari mogu interpretirati seismološke podatke na različite načine, dovodeći do nedosljednosti u podacima o lokaciji potresa. Unatoč napretku u automatskom pre-

poznavanju faza (Allen, 1978; Baer i Kradolfer, 1987; Sleeman i Van Eck, 1999; Saragiotis et al., 2002; Kuperkoch et al., 2010), usklađivanje s iskustvom analitičara ostaje teško. To se može pripisati činjenici da su valni oblici potresa vrlo složeni zbog višestrukih učinaka uključujući: mehanizam pomaka u izvoru potresa, raspršenje, smetnje od mnoštva izvora šuma itd. Dodatno, tradicionalne automatizirane metode koriste ručno definirane značajke koje zahtijevaju pažljivu obradu podataka, poput propusnog filtriranja i postavljanja praga aktivacije, što dodatno otežava već vrlo kompleksan problem. Uvođenje strojnog učenja u obliku neuronskih mreža pokazalo se kao vrlo učinkovitom metodom automatske detekcije potresa, te je u današnje vrijeme spoj umjetne inteligencije i seismologije predmet sve intenzivnijeg istraživanja (za detaljniji opis strojnog učenja pogledati poglavlje 3, za detaljniji opis modela *PhaseNet* koji je bio korišten u ovom radu pogledati poglavlje 4).

### 3. Osnove strojnog učenja

#### 3.1. *Povijesni pregled*

**Strojno učenje** (engl., *Machine Learning*, ML) grana je **umjetne inteligencije** (engl. *Artificial Intelligence*, AI) koja se fokusira na razvoj te primjenu algoritama i statističkih modela koji omogućavaju računalnim sustavima da automatski poboljšavaju svoju izvedbu kroz iskustvo, bez izričitog programiranja za svaki novi zadatak (Alpaydin, 2020). Temelj strojnog učenja je sposobnost računalnih sustava da identificiraju složene obrasce i donose intelligentne odluke pomoći analize velikih količina podataka.

Prvi koraci prema modernom strojnom učenju postavljeni su 1950. godine kada je Alan Turing predložio svoj slavni **Turingov test** kao mjerilo za određivanje ima li stroj sposobnost mišljenja (Turing, 1950). Ubrzo nakon toga, 1956. godine, **Dartmouth konferencija** označila je formalni početak umjetne inteligencije kao akademskog polja (McCorduck, 2004). Iako su ovi rani radovi postavili teorijske temelje, praktična primjena strojnog učenja bila je ograničena zbog nedostatka računalne snage i dostupnih podataka.

Tijekom 1970-ih i 1980-ih, istraživači su se suočavali s tzv. „AI zimom”, razdobljem kada je interes i financiranje za AI znatno opalo zbog prethodno nerealiziranih očekivanja. Međutim, unatoč tim izazovima, nastali su važni teorijski radovi. Razvoj algoritma *backpropagation* opisanog u radu Rumelhart et al. (1986) donio je revoluciju u treniranju višeslojnih neuronskih mreža, omogućujući učinkovitije učenje. Ovaj koncept postao je temelj za razvoj dubokog učenja, podskupa strojnog učenja koji koristi složene, višeslojne neuronske mreže.

Krajem 20. stoljeća i početkom 21. stoljeća, inovacije su se ubrzale s razvojem novih algoritama i tehnika. **Potporni vektorski strojevi** (engl. *Support Vector Machines*, SVM) Cortesa i Vapnika (1995) i koncept **slučajnih šuma** Hoa (1995) donijeli su moćne nove metode za klasifikaciju i regresiju.

Ulaskom u eru „velikih podataka”, duboko učenje je doživjelo procvat zahvaljujući sposobnosti dubokih neuronskih mreža da uče iz ogromnih skupova podataka. Radovi kao što su Hinton et al. (2006) i Krizhevsky et al. (2012) koji predstavlja **AlexNet**, duboku konvolucijsku neuronsku mrežu, postavili su temelje za eksploziju interesa i

primjene dubokog učenja u različitim područjima od prepoznavanja slika do procesiranja prirodnog jezika. Nedavni uspjesi poput DeepMindovog *AlphaGo*-a (Silver et al., 2016), koji je pobijedio svjetskog prvaka u igri Go, pokazali su moć podržanog učenja, podskupa strojnog učenja gdje algoritmi uče optimalno djelovati kroz nagrade i kazne.

Danas se strojno učenje nastavlja razvijati brzinom koja je bila nezamisliva prije samo nekoliko desetljeća. S kontinuiranim inovacijama u algoritmima, računalnoj moći i dostupnosti podataka, budućnost strojnog učenja izgleda svjetlija nego ikada. Ovo područje ostaje uzbudljivo polje istraživanja s obećavajućim primjenama u zdravstvu, financijama, proizvodnji, transportu i mnogim drugim industrijama (Jordan i Mitchell, 2015).

### 3.2. Osnovni koncepti

Strojno učenje je karakterizirano kao skup algoritama koji omogućuju računalu da neovisno uči, bez potrebe direktnog programiranja. Specifično, strojno učenje uvjetuje otkrivanje funkcije  $g$  koja nastoji aproksimirati ciljnu funkciju  $f$ . Ciljna funkcija je zaslužna za preslikavanje ulaza (observacija)  $x$  do izlaza  $y$  što se može prikazati kao:  $f : X \rightarrow Y$ . Ovdje  $X$  označava prostor ulaza koji se sastoji od svih mogućih ulaza, dok  $Y$  označava prostor izlaza, koji sadrži sve potencijalne izlaze. Kako bi identificirao funkciju  $g$ , algoritam strojnog učenja koristi primjere za trening, koje su specifični primjeri odabrani iz prostora ulaza  $X$ . Uz svaki ulaz, često (izuzev slučaja nenadziranog učenja) se dodaje i odgovarajući izlaz. To znači da se skup podataka za trening sastoji od  $n$  parova ulaznih i izlaznih vrijednosti  $(x_n, y_n)$ . Tijekom treninga, algoritam istražuje i evaluira razne potencijalne aproksimativne funkcije  $g$ . Ove funkcije su odabранe iz unaprijed zadanih mogućnosti koji se zove **skup hipoteza**, te provjerene pomoću skupa za trening. Proces treninga uključuje konstantnu prezentaciju ulazno-izlaznih parova funkciji  $g$  iz skupa za trening. Sa svakom iteracijom  $g$  se modificira i poboljšava da preciznije generira očekivani izlaz  $y$  za ulaz  $x$ . Konačni cilj je odabrati verziju funkcije  $g$  koja najučinkovitije smanjuje pogrešku kada se uspoređuje s ciljnom (pravom) funkcijom  $f$ , te na taj način poboljšati preciznost budućih predviđanja na temelju novih ulaza.

Kako bi se najbolje optimizirao gore opisan proces strojnog učenja, podaci su obično podijeljeni u tri glavna skupa: skup za trening, validacijski skup i testni skup. Svaki od ovih skupova ima specifičnu ulogu u procesu razvoja i ocjenjivanja modela strojnog učenja:

1. **Skup za trening** (engl. *Training Set*): Skup za trening koristi se za treniranje ili „učenje“ modela strojnog učenja. Ovaj skup podataka omogućava algoritmu da se prilagodi i „nauči“ obrasce ili značajke sadržane u podacima. Obično čini najveći dio dostupnih podataka jer veći broj primjera omogućava modelu da bolje uči i generalizira. Model koristi skup za trening za prilagodbu svojih parametara (npr. ponder u neuronskoj mreži (vidi odjeljak 2.6.1)) kako bi minimizirao grešku u svojim predviđanjima.
2. **Validacijski skup** (engl. *Validation Set*): Validacijski skup koristi se za procjenu

modela tijekom treninga, omogućavajući podešavanje hiperparametara (npr. stopa učenja, broj slojeva u neuronskoj mreži itd.) i za sprječavanje preprilagođavanja (engl. *overfitting*) modela. Ovaj skup podataka nije uključen u trening, ali se koristi za simuliranje kako će model funkcionirati s podacima koje nije nikada vidoio (model se ne trenira izravno na validacijskom skupu; umjesto toga, izvedbe modela na validacijskom skupu koriste se za odlučivanje o prilagodbama modela ili za odabir između različitih modela).

3. **Testni skup** (engl. *Test Set*): Testni skup koristi se za procjenu konačne izvedbe modela, nakon što je model već treniran i validiran. Pruža nepristranu procjenu učinkovitosti modela. Koristi se jednom, na kraju procesa strojnog učenja, kako bi se dobila realna procjena kako će model funkcionirati u stvarnom svijetu.

Razdvajanje podataka na ove tri skupine je ključno za razvoj efikasnih i pouzdanih modela strojnog učenja. To osigurava da model nije samo dobro prilagođen trenutnim podacima, već da dobro generalizira i na novim podacima koje nikada nije vidoio, što je krajnji cilj većine modela strojnog učenja.

Svaki model sadrži određeni broj **hiperparametara**, odnosno parametara čija se vrijednost postavlja prije nego što započne proces učenja modela. Hiperparametri su ključni jer izravno kontroliraju ponašanje algoritma za trening i imaju značajan utjecaj na izvedbu modela koji se trenira. Za razliku od pondera veza i pristranosti mreže, koji se uče iz podataka, hiperparametri se obično postavljaju ručno i podešavaju pomoću validacijskog skupa ili putem tehnika poput unakrsne validacije (Berrar, 2018). Neki od najčešćih hiperparametara koji se mijenjaju u procesu razvoja modela su:

1. **Funkcija gubitka** (engl. *Loss Function*): parametar koji model pokušava minimizirati tijekom treninga. Mjeri koliko precizno se predviđanja modela podudaraju s pravim podacima. Najčešće korišteni parametri su srednja kvadratna pogreška, gubitak unakrsne entropije, *hinge loss* itd.
2. **Stopa učenja** (engl. *Learning Rate*): Određuje koliko prilagoditi pondere mreže s obzirom na gradijent gubitka. Manja stopa učenja zahtijeva više epoha ili ciklusa treninga, dok veća stopa učenja može dovesti do brze konvergencije, ali može premašiti minimalni gubitak.

3. **Broj epoha** (engl. *Epochs*): Broj puta koliko je cijeli skup podataka za trening prošao kroz model.

4. **Arhitektura mreže** (engl. *Network Architecture*): vezano za neuronske mreže. Uključuje broj skrivenih slojeva i neurona u svakom sloju u neuronskoj mreži.

### 3.3. Vrste učenja

Ključna komponenta strojnog učenja je „učenje“ – proces u kojem se algoritmi prilagođavaju novim podacima ili mijenjaju svoje strategije za rješavanje problema na temelju rezultata i povratnih informacija koje dobivaju. Metodologije učenja su razne, a danas se koriste nadzirano (učenje), nенадзирано (učenje), polunadzirano (učenje), podržano (učenje) i učenje prijenosom.

**Nadzirano učenje** (engl. *Supervised Learning*) je najčešći tip strojnog učenja. U ovom pristupu modeli se treniraju na označenim podacima, što znači da svaki primjer u skupu za trening uključuje ulazne podatke zajedno s odgovarajućim izlaznim podacima. Cilj je naučiti pravila koja preslikavaju ulazne podatke na željene izlazne podatke, omogućavajući modelu da donosi točna predviđanja ili odluke za nove podatke koje nikada nije vidio. Nadzirano učenje vrlo je učinkovito kada postoji jasno razumijevanje ulaza i izlaza, jer može proizvesti vrlo precizna predviđanja. Široko je primjenjivo za probleme regresije i klasifikacije, a velika količina dostupnih alata i algoritama čini ga dostupnim za mnoge primjene. Rezultate je također često lakše interpretirati u usporedbi sa složenijim modelima. Glavni nedostatak je potreba za velikom količinom označenih podataka, čije dobivanje može biti skupo i dugotrajno. Također može biti sklon preprilagođavanju, osobito ako je model presložen za količinu dostupnih podataka. Modeli nadziranog učenja možda neće imati dobre rezultate ako najdu na podatke koji se značajno razlikuju od skupa za trening.

**Nenadzirano učenje** (engl. *Unsupervised Learning*) – pri ovakovom učenju modeli rade s neoznačenim podacima. Cilj modela je da sam pokuša otkriti skrivene obrascе, skupine ili strukture unutar podataka te se zbog toga koristi za grupiranje sličnih primjera unutar podataka ili za pronalaženje karakteristika podataka koje pomažu u objašnjenju podataka. Veoma je korisno za istraživačku analizu podataka, identificiranje grupe i redukciju dimenzija. Osobito je korisno kada postoji puno podataka, ali ne postoji jasna predodžba o ishodima ili obrascima koji se traže. Nedostatak jasnih

smjernica može otežati tumačenje rezultata, te može biti teško izmjeriti učinkovitost modela nenadziranog učenja jer ne postoji unaprijed definirane oznake za usporedbu. Ishodi mogu biti manje točni ili smisleni u usporedbi s nadziranim učenjem.

**Podržano učenje** (engl. *Reinforcement Learning*) – algoritmi se treniraju kroz sistem nagrada i kazni. Model se uči kroz donošenje niza odluka, a dobivajući povratne informacije u obliku nagrada ili kazni, može se prilagoditi novim scenarijima i naučiti optimalne strategije kroz pokušaje i pogreške. Podržano učenje moćno je za probleme u kojima je donošenje odluka sekvensijalno, a podaci se prikupljaju kroz interakciju s okruženjem. Idealno je za primjene poput robotike, igara i navigacije. No, modeli podržanog učenja mogu biti složeni i računalno skupi za obuku, te zahtijevaju dobro definiran sustav nagrađivanja, a ako su signali nagrađivanja loše dizajnirani, model možda neće raditi prema očekivanjima. Dodatno, ovaj način učenja često zahtijeva veliki broj pokušaja, što može biti nepraktično u stvarnim problemima.

**Učenje prijenosom** (engl. *Transfer Learning*) je učenje koje uključuje uzimanje prethodno treniranog modela (treniranog na velikom skupu podataka) i njegovo podešavanje s manjim, specifičnim skupom podataka (Bozinovski i Fulgosi, 1976). Ovo je korisno za zadatke u kojima je skup podataka premalen da bi se mogao ispočetka obučavati model u punoj veličini, u čemu je učenje prijenosom vrlo učinkovita metoda. Korištenje unaprijed treniranih modela štedi vrijeme i resurse potrebne za obuku od nule, te omogućuje prijenos znanja iz jedne domene u drugu, što često dovodi do poboljšane izvedbe. Glavni izazov učenja prijenosom je osigurati da je prethodno trenirani model relevantan za novi zadatak jer može doći do problema s kompatibilnošću modela i podešavanjem. Ako se izvorna i ciljna domena previše razlikuju, učenje prijenosom možda neće biti učinkovito i može dovesti do negativnog prijenosa, pri čemu unaprijed trenirani model pogoršava izvedbu.

### **3.4. Određivanje točnosti modela**

Procjena preciznosti modela strojnog učenja ključan je korak u procesu razvoja modela. Procjena ne samo da ocjenjuje koliko dobro model radi, već također pomaže u identificiranju područja za poboljšanje. Kako bi se kvantitativno opisalo kako se algoritam strojnog učenja ponaša pri treningu, validaciji ili testiranju, mora se definirati **mjera izvedbe** (engl. *Performance measure*). Odabir mjere izvedbe ključan je i ovisi

o tome bavi li se model problemom klasifikacije, regresije, dimenzionalnom redukcijom itd. Za klasifikaciju se obično koriste:

1. **Preciznost** (engl. *Precision*) – mjeri udio istinskih pozitivnih predviđanja u ukupnom broju pozitivnih predviđenih. Drugim riječima, odgovara na pitanje: „Od svih instanci koje je model označio kao pozitivne, koliko je zapravo pozitivno?“ Preciznost je ključna u situacijama kada je trošak lažno pozitivnog visok. Na primjer, u detekciji neželjene e-pošte, visoka preciznost znači manji broj željenih e-mailova koji su pogrešno označeni kao neželjeni. Definirana je kao

$$P = \frac{T_p}{T_p + F_p}, \quad (3.1.)$$

gdje je  $T_p$  broj istinskih pozitivnih, a  $F_p$  broj lažno pozitivnih predviđanja.

2. **Osjetljivost** (engl. *Recall*) – mjeri udio istinski pozitivnih predviđanja koje su ispravno identificirane. Odgovara na pitanje: „Od svih istinski pozitivnih predviđanja, koliko ih je model označio kao pozitivne?“ Osjetljivost je ključna u scenarijima gdje je propuštanje pozitivne instance skupo. Na primjer, u medicinskoj dijagnostici za ozbiljnu bolest, preferira se model s visokom osjetljivošću kako bi se osiguralo da što manje slučajeva ostane neotkriveno. Definirana je kao

$$R = \frac{T_p}{T_p + F_n} \quad (3.2.)$$

gdje je  $F_n$  broj lažno negativnih predviđanja.

3. **Rezultat F1** (engl. *F1 Score*) je harmonijska sredina preciznosti i osjetljivosti. Pruža jedinstvenu ocjenu koja balansira preciznost i osjetljivost u jednom broju. F1 je ključan kada se traži ravnoteža između preciznosti i osjetljivosti, i postoji neujednačena distribucija klasa (veliki broj istinski negativnih). Na primjer, u skupu podataka gdje je većina instanci negativna, model može imati visoku točnost jednostavno predviđajući negativno, ali to ne bi bilo korisno. Definiran je kao

$$F1 = 2 \cdot \frac{P \cdot R}{P + R}, \quad (3.3.)$$

gdje je  $F_n$  broj lažno negativnih predviđanja.

Za regresiju se obično koriste:

1. **Srednja kvadratna pogreška** (engl. *Mean Squared Error, MSE*): definira se kao prosječni kvadrat razlike između stvarne vrijednosti  $y_i$  i predviđene vrijednosti iz aproksimativne funkcije  $g$ :

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - g(x_i))^2 \quad (3.4.)$$

Iz jednadžbe se može vidjeti da se veće pogreške više kažnjavaju od manjih (kao rezultat kvadriranja). Stoga korištenje srednje kvadratne pogreške možda neće biti prikladno ako podaci iz skupa za trening i test imaju velika odstupanja.

2. **Srednja absolutna pogreška** (engl. *Mean Absolute error, MAE*) definira se kao absolutna razlika stvarne vrijednosti  $y_i$  i predviđene vrijednosti iz aproksimativne funkcije  $g$ :

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - g(x_i)| \quad (3.5.)$$

*MAE* dopušta odstupanja bez prevelike štete za model (ne kažnjava velika odstupanja).

Bitna stvar za naglasiti je da sve gore navedene mjere izvedbe određuju koliko kvalitetno model predviđa stvarne vrijednosti skupa za trening. No, najbitnija stvar kod strojnog učenja je kako modeli rade predviđanja na podacima koje nikada nisu vidjeli (testni skup). **Pogreška treninga i pogreška validacije** mogu biti vodiči za izbor hipерparametara, aktivacijskih funkcija, stope učenja itd. no te pogreške neće garantirati da **pogreška testa** bude što je manja moguća.

### 3.4.1. Minimizacija pogreške na testnom skupu

Minimiziranje pogrešaka testa i izbjegavanje zamki **preprilagođavanja** (engl. *Overfitting*) i **potprilagođavanja** (engl. *Underfitting*) u strojnom učenju uključuje sveobuhvatan pristup koji obuhvaća rukovanje podacima, upravljanje složenošću modela i strategije provjere valjanosti. Kada se koriste jako kompleksni modeli strojnog učenja, postoji rizik treniranja modela tako da ima malenu pogrešku na skupu za trening, ali veliku pogrešku na testnom skupu. U ovoj situaciji model preprilagođava podatke, točnije počinje učiti značajke iz šuma i netočnih oznaka prisutnih u podacima, te se

„usko specijalizira“ samo za skup za trening koji mu je dan.

Postoji mnogo tehnika kako bi se izbjeglo preprilagođavanje. Prvo, jako je bitno imati dovoljno veliku i kvalitetnu količinu podataka. Više podataka omogućuje modelu da efikasnije nauči obrasce svojstvene podacima, smanjujući rizik preprilagođavanja, a filtriranje sprječava model da uči iz šuma i netočnih podataka. Odabir kompleksnosti modela također tako može utjecati na pogrešku jer jednostavniji modeli manje preprilagođavaju nego kompleksniji. Ovaj proces se zove **regularizacija** (engl. *Regularization*). Tehnike regularizacije kao što su **regularizacija L1** i **L2** pomažu kažnjavanjem većih pondera, obeshrabrujući tako previše složene modele. U neuronskim mrežama smanjenje nepotrebnih pondera ili neurona može smanjiti preprilagođavanje.

**Odbacivanje** (engl. *Dropout*) je jedna od najpopularnijih tehnika regularizacije koja se primjenjuje u sklopu neuronskih mreža. Tijekom treninga, nasumično se deaktivira podskup neurona (ili jedinica) u sloju neuronske mreže. Ova se deaktivacija događa na svakom koraku treninga, pri čemu svaki neuron ima određenu vjerojatnost deaktivacije. Razlog uspjeha ovakve tehnike je u tome što neuroni u neuronskoj mreži mogu razviti međusobnu ko-ovisnost (neki slojevi se prilagode da isprave pogreške prethodnih slojeva). Zbog toga model bolje predviđa na trening skupu, ali lošije generalizira.

Kod potprilagođavanja, modeli strojnog učenja ne uspijevaju naučiti obrasce inherentne podacima (pogreška skupa za trening ili validacijskog skupa se ne mijenja ili povećava tijekom treninga). Korištenjem kompleksnijih modela, smanjivanjem regulacije i boljom selekcijom podataka za trening se može izbjjeći potprilagođavanje.

Za opis opće metodologije razvoja modela strojnog učenja, pogledaj dodatak D.

### 3.5. Umjetne neuronske mreže

**Umjetne neuronske mreže** (engl. *Artificial Neural Networks*, ANN) vrsta su modela strojnog učenja koje su u svojim početcima bile pokušaj imitiranja strukture ljudskog mozga sa svrhom rješavanja zadatka koje tradicionalni algoritmi nisu mogli riješiti (Kleene, 1956). Kroz vrijeme, njihov se fokus premjestio prema poboljšanju praktičnih rezultata, polagano se udaljavajući od pokušaja imitacije ljudskog mozga. Pokazalo se da su ANN-ovi izvrsni u učenju i shvaćanju složenih, nelinearnih odnosa pomoću međusobno povezanih neurona koji tvore različite obrasce u strukturi mreže te su da-

nas najpopularniji modeli strojnog učenja s nevjerojatnim rezultatima u područjima prirodnih i društvenih znanosti, financija, medicine, svemirske industrije, socijalnih medija itd.

### 3.5.1. Struktura

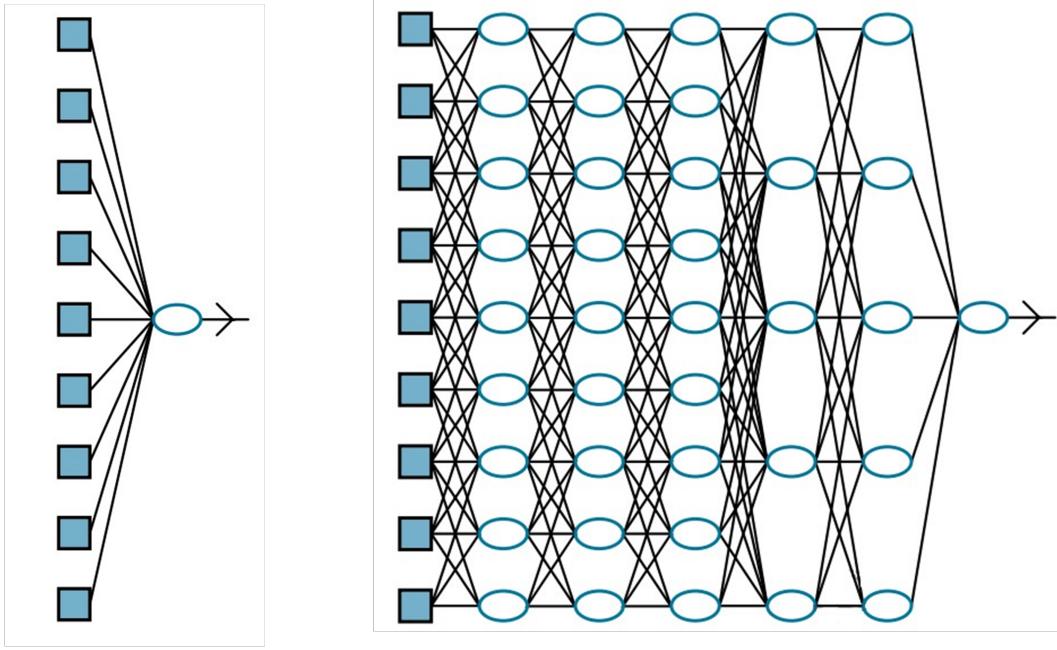
ANN se sastoji od simuliranih povezanih **neurona**, nalik vezama aksona, sinapsi i dendrita u biološkim sustavima, koji predstavljaju osnovnu struktturnu jedinicu svake neuronske mreže. Svaki neuron kroz ove veze vrši interakciju s drugim neuronima, primajući signale (realne brojeve), procesirajući ih (putem nekakve nelinearne funkcije) te šaljući procesirane signale do neurona koji su s njim povezani. Ilustracija neuronske mreže se može vidjeti na slici 3.1.

Svaka veza između neurona ima sa sobom asociran određeni **ponder**. Ponderi moduliraju ulazne signale, određujući koliko svaki ulaz ima utjecaja na izlaz neurona. Svaki ulazni signal u određeni neuron je ponderirana suma svih signala iz povezanih neurona uz dodanu određenu „pristranost“. Ponderi su podesivi parametri koje mreža uči kroz trening. Neka  $a_j$  prikazuje izlaz  $j$ -tog neurona i neka je  $w_{i,j}$  ponder na vezi između neurona  $i$  i  $j$ . Tada je:

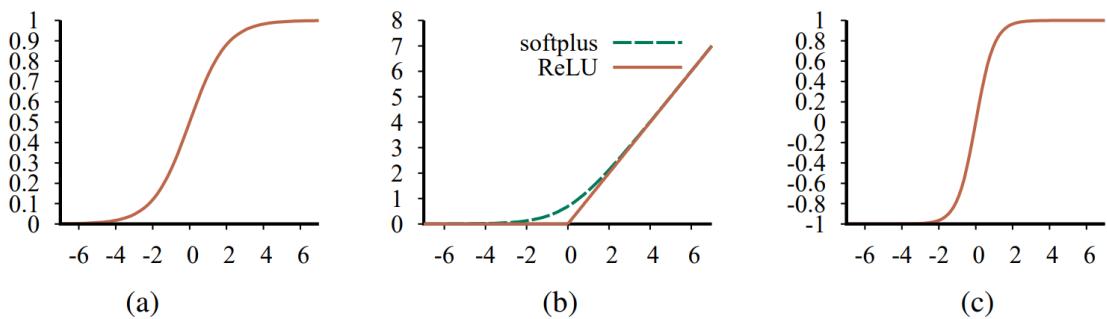
$$a_j = g_j \left( \sum_i w_{i,j} a_i \right) + b \quad (3.6.)$$

gdje je  $b$  **pristranost**, dodatni parametar koji omogućava neuronu da modificira svoj izlaz nezavisno o ulazima, povećavajući fleksibilnost i dajući mu mogućnost da se aktivira čak i kad su ulazi jako mali ili 0, a  $g_j$  nelinearna **aktivacijska funkcija**.

Ponderirana suma iz jednadžbe 3.6. (**aktivacija**) služi kao ulaz za (većinom) nelinearnu funkciju (**aktivacijsku funkciju**) kako bi se izračunao izlaz neurona. Aktivacijske funkcije unose nelinearnosti u model, omogućujući mreži da nauči i reprezentira kompleksne obrasce. Izbor aktivacijske funkcije signifikantno određuje izvedbu i mogućnosti neuronske mreže. Neke od najčešće korištenih su **sigmoidna funkcija**, **ReLU**, **softplus** i **th**. Na slici 3.2 se mogu vidjeti grafovi ovih funkcija. Diskusija prednosti i mana određenih aktivacijskih funkcija izlazi izvan okvira ovog rada.



Slika 3.1. Ilustracija duboke neuronske mreže. Lijeva slika prikazuje jednostavan „plitki“ model kao što je linearna regresija, dok slika desno prikazuje primjer neuronske mreže. Ellipse predstavljaju neurone, a crne ravne crte veze između neurona (preuzeto iz Russel i Norvig (2020)).



Slika 3.2. Najčešće korištene aktivacijske funkcije: (a) logistička ili sigmoidna funkcija; (b) funkcija ReLU i funkcija softplus; (c) th funkcija.

### 3.5.2. Učenje neuronskih mreža

U području umjetnih neuronskih mreža, proces učenja je direktno vezan s algoritmom *Backpropagation*. *Backpropagation*, skraćeno od „backward propagation of errors“, temeljni je algoritam koji se koristi za trening umjetnih neuronskih mreža i usavršavanje. Temeljna ideja algoritma *backpropagation* je prilagoditi pondere neuronske mreže na način koji minimizira razliku između stvarnog izlaza mreže i željenog izlaza (tj. pogreške). Ovaj proces uključuje nekoliko ključnih koraka i načela.

Prvo, ulaz prolazi kroz neuronsku mrežu, sloj po sloj, dok ne dosegne izlazni sloj. Ovaj korak se zove **prosljeđivanje** (engl. *Forward Pass*), gdje se trenutno stanje mreže (s postojećim ponderima) koristi za izračun izlaza. Izlaz mreže se zatim uspoređuje sa stvarnim izlazom (mjerenim podacima) pomoću **funkcije gubitka**. Funkcija gubitka kvantificira razliku ili pogrešku između izračunatog izlaza i stvarnog izlaza.

Funkcionalnost algoritma *backpropagation* događa se tijekom prolaza unatrag. Pogreška izračunata iz funkcije gubitaka propagira se natrag kroz mrežu, počevši od izlaznog sloja i krećući se unatrag do ulaznog sloja. Svrha ovog prolaza unatrag je odrediti doprinos svakog pondera u mreži ukupnoj pogrešci. Tijekom prolaska unatrag, računa se **gradijent funkcije gubitka** s obzirom na svaki ponder. Ovaj gradijent nam govori koliko bi se gubitak promijenio s malom promjenom pondera. Izračunavanje gradijenta vrši se korištenjem **lančanog pravila** iz diferencijalnog računa, matematičkog načela koje omogućuje rastavljanje derivacija funkcija koje su sastavljene od drugih funkcija. Nakon što su gradijenti izračunati, ponderi mreže se ažuriraju. Ovo se ažuriranje radi u smjeru koji minimalno smanjuje pogrešku. Veličina kojom se ponderi ažuriraju određena je **stopom učenja**, hiperparametrom koji kontrolira veličinu koraka ažuriranja pondera.

*Backpropagation* je iterativni proces. Konstantno primjenjuje ove korake kroz više epoha ili iteracija, koristeći cijeli skup podataka za trening. Tijekom svake iteracije, ponderi se lagano prilagođavaju kako bi se smanjila pogreška, postupno vodeći mrežu da uči iz podataka. Jedan od izazova s algoritmom *Backpropagation* u dubokim mrežama je problem **nestajućeg gradijenta**. U vrlo dubokim mrežama, gradijenti mogu postati vrlo mali jer se propagiraju natrag kroz slojeve, što otežava učinkovito ažuriranje pondera. Ovaj problem doveo je do razvoja alternativnih arhitektura i metoda treninga.

### 3.5.3. Vrste neuronskih mreža

Neuroni se organiziraju u više **slojeva**, gdje svaki sloj sadrži određeni broj neurona. Neuroni svakog sloja često se povezuju samo s neuronima koji su u sloju prije ili sloju poslije. Ulazni sloj je onaj koji prima vanjske ulazne podatke (vremenski slijed, tekst, slika, video itd.). Izlazni sloj je onaj koji generira konačni rezultat mreže. Između ta dva sloja se nalazi jedan ili više skrivenih slojeva. Mreža se zove **dubokom neuronskom**

**mrežom** ako sadrži barem dva skrivena sloja. Nadalje, veze između slojeva mogu poprimiti različite oblike (npr. u **potpuno povezanoj mreži** (engl. *Dense Network*), svaki neuron iz jednog sloja povezan je sa svakim neuronom iz drugog sloja). Postoje dva osnovna tipa ANN-ova:

1. **Jednosmjerna neuronska mreža** (engl. *Feedforward Neural Network*, FNN): veze između neurona ne tvore cikluse; podaci se kreću u jednom smjeru. Ne postoje petlje i ciklusi unutar mreže, svaki sloj prima podatke iz prijašnjeg sloja, obrađuje ih i šalje ih u sljedeći sloj, što znači da izlaz iz svakog sloja ne utječe na taj isti sloj. Često se koriste u zadacima kao što je računalni vid gdje je trenutno stanje sve što je potrebno kako bi se donijela odluka.
2. **Ponavljača neuronska mreža** (engl. *Recurrent Neural Network*, RNN): značajno se razlikuju od FNN-ova zbog uključivanja petlji i ciklusa, omogućujući informacijama da ostanu prisutne. U RNN-u, veze između nekih neurona tvore petlje, te na taj način omogućavaju izlazu nekih neurona da utječu na ulaz tih istih neurona (Elman, 1990). Ovakva struktura funkcioniра kao interna memorija neurona, omogućavajući mu da pamti prijašnje ulaze te da ih koristi da modificira trenutni izlaz. Na taj način, RNN-ovi su odlični u prepoznavanju obrazaca u nizovima podataka gdje prijašnji podaci mogu utjecati na sljedeće kao što je tekst, genomi, numerički vremenski nizovi, govor itd.

Ove dvije kategorije predstavljaju najopćenitiju podjelu neuronskih mreža. Kroz vrijeme su nastajale „specijalizirane“ vrste neuronskih mreža koje su se iskazale na određenim vrstama problema. U ovom radu primjenjuju se neuronske mreže poznate kao konvolucijske neuronske mreže.

#### 3.5.4. Konvolucijske neuronske mreže

Standardne neuronske mreže imaju problema kod zadataka analize slika. Naime, slika se ne može smatrati jednostavnim vektorom ulaznih piksela, jer svojstva piksela su određena susjednošću s drugim pikselima. Kada bismo konstruirali neuronsku mrežu s potpuno povezanim slojevima i slikom kao ulazom, dobili bismo jednak rezultat i za trening na originalnim slikama i za slike kojima su pikseli nasumično ispremiješani. Nadalje, pretpostavimo da postoji  $n$  piksela i  $n$  neurona u prvom skrivenom sloju,

kojemu pikseli daju ulaz. Ako su ulazni i prvi skriveni sloj potpuno povezani, to znači da postoji  $n^2$  pondera; za tipičnu megapikselnu RGB sliku, to je  $10^{12}$  pondera. Tako golem prostor parametara zahtjevao bi odgovarajući veliki broj slika za trening i ogroman računalni trošak za pokretanje i dovršavanje algoritma za trening.

Ova analiza sugerira da bi se prvi skriveni sloj trebao konstruirati tako da svaki skriveni neuron prima podatke samo iz malog, lokalnog područja slike. Ovaj način poštuje susjedstvo piksela i smanjuje broj pondera. Nadalje, sve što se može otkriti u jednom malom, lokalnom području slike – možda oko ili vlat trave – izgledalo bi isto da se pojavi u drugom malom, lokalnom području slike. Zbog toga, očekuje se da će slikovni podaci pokazivati približnu **prostornu invarijantnost**, barem u malim do umjerenim mjerilima. Lokalna prostorna invarijantnost može se postići ograničavanjem  $l$  pondera koji povezuju lokalno područje s neuronom u skrivenom sloju tako da budu jednaki za svaki skriveni neuron. (To jest, za skrivene neurone  $i$  i  $j$ , ponderi  $w_{1,i}, \dots, w_{l,i}$  su isti kao  $w_{1,j}, \dots, w_{l,j}$ ). Ovo čini skrivene neurone detektorima značajki koje mogu otkriti istu značajku gdje god se pojavila na slici (Russel i Norvig, 2019).

**Konvolucijske neuronske mreže** (engl. *Convolutional Neural Network*, CNN) su vrsta umjetnih neuronskih mreža koje u ranim slojevima sadrže prostorno lokalne veze, te imaju uzorke pondera koji se ponavljaju kroz neurone u slojevima. Obrazac pondera koji se pojavljuje kroz mnogo lokalnih područja naziva se **jezgra** (engl. *Kernel*), a proces primjene jezgre na podatke se naziva **konvolucija**. Matematički, operacija konvolucije se može prikazati kao:

$$(f \star I)(i, j) = \sum_m \sum_n f(m, n) \cdot I(i - m, j - n) \quad (3.7.)$$

gdje je  $f(m, n)$  matrica jezgre, a  $I(i - m, j - n)$  je dio slike koju jezgra pokriva. Ova operacija izvlači važne značajke poput rubova i tekstura.


U srcu CNN-a su **konvolucijski slojevi** (Fukushima, 1980). Ti se slojevi sastoje od skupa jezgri koje se mogu naučiti i koje su male, ali se protežu kroz punu dubinu ulaznog volumena. Dok ove jezgre „klize“ preko ulazne slike, izvode konvoluciju s dijelom slike na kojem se trenutno nalaze, a rezultati se zbrajaju kako bi proizveli jedan izlaz u mapi značajki. Nakon svake operacije konvolucije, aktivacijska funkcija se primjenjuje na izlaz kako bi se u sustav uvela nelinearna svojstva. Obično se koristi

**ReLU aktivacijska funkcija** (Fukushima, 1969).

Nakon konvolucijskog sloja, CNN-ovi često koriste slojeve **udruživanja**. Glavna funkcija ovih slojeva je postupno smanjivanje prostorne veličine reprezentacije, što uザvrat smanjuje broj parametara i računanja u mreži. Uobičajeni pristup u udruživanju je **maksimalno udruživanje**, gdje se odabire maksimalni element iz područja mape značajki koju pokriva jezgra.

Potpuno povezani slojevi, smješteni na kraju CNN-a, integriraju naučene značajke. Svaki neuron u tim slojevima povezan je sa svakom aktivacijom u prethodnom sloju. Izlazni sloj, koji često koristi funkciju **softmax** za klasifikaciju, pretvara konačne reprezentacije značajki u vjerojatnosti preko unaprijed definiranih klasa. Karakteristike kao što su dijeljenje parametara i lokalna povezanost, gdje se svaka jezgra primjenjuje kroz cijelu sliku i svaki je neuron povezan samo s lokalnim područjem ulaza, određuju učinkovitost CNN-a. Dijeljenje parametara značajno smanjuje broj parametara, čineći mrežu računalno učinkovitom. Na slici 3.3 može se vidjeti ilustracija rada konvolucijske neuronske mreže.

CNN-ovi, sa svojom sposobnošću učenja i tumačenja prostornih hijerarhija značajki, našli su primjenu u različitim primjenama izvan tradicionalne obrade slike, kao što je video analiza, obrada prirodnog jezika, analiza medicinskih slika te analiza vremenskih nizova. Upravo je analiza vremenskih nizova u fokusu ovoga rada, a pokazalo se da CNN-ovi mogu otkriti i naučiti ne samo prostorne hijerarhije značajki, nego i vremenske.



Slika 3.3. Ilustracija rada konvolucijske neuronske mreže. Jezgre konvolucijskog sloja izvlače lokalne značajke slike, a zatim se značajke sažimaju u daljnje konvolucijske slojeve koji otkrivaju sve detaljnije značajke. Nakon što mreža nauči značajke, podaci se pripremaju za izlazni sloj koji vrši konačnu klasifikaciju prvotnog ulaza. Preuzeto s URL 1.

## 4. Metode

Metodologija (*pipeline*) prema kojoj će se vršiti analiza je sljedeća:

1. Prethodna obrada radi pripreme podataka (pogledaj odjeljak 5.2)
2. *PhaseNet* radi detekcije faza
3. *GaMMA Associator* radi asocijacije i stvaranja umjetnog „ML“ kataloga
4. Usporedba s pravim katalogom potresa

### 4.1. Određivanje faza: *PhaseNet*


Neuronska mreža **PhaseNet**, koji su predstavili Zhu i Beroza (2018), predstavlja revolucionarnu metodu zasnovanu na dubokoj konvolucijskoj neuronskoj mreži, dizajniranu za precizno određivanje nastupnih vremena seizmičkih valova, ključnog aspekta za prepoznavanje i lociranje potresa. PhaseNet iskorištava moćne sposobnosti učenja dubokih neuronskih mreža iz označenih podataka (signala i šuma) što se pokazalo kao velika prednost za složene seizmičke valne oblike. Mreža je trenirana na različitim katalozima dostupnih nastupnih vremena P- i S-faza koje su odredili iskusni analitičari. Nefiltrirani trokomponentni seizmički valni oblici su ulaz u PhaseNet, koji je osposobljen za generiranje izlaza triju distribucija vjerojatnosti: P-val, S-val i šum.

Arhitektura PhaseNeta prilagođena je iz modela U-net (Ronneberger et al., 2015), originalno korištenog u obradi biomedicinskih slika, za obradu vremenskih nizova podataka tipičnih za seismograme. Arhitektura PhaseNet-a se može vidjeti na slici 4.1. Ulazni podaci za PhaseNet su nefiltrirane tri komponente seismograma. Svaki sloj PhaseNet-a (osim zadnjeg) sastoji se od **konvolucijskog sloja** i **Relu aktivacijske funkcije**. Ulazni podaci prolaze kroz četiri faze **decimiranja** (engl. *down-sampling*) kako bi se izvukle bitne značajke podataka i svele na nekoliko neurona te četiri faze **ekspanzije** (engl. *up-sampling*) koje proširuju značajke kako bi se na kraju mogle prikazati u obliku distribucije vjerojatnosti. Posljedni (izlazni) sloj sadrži **softmax normiranu eksponencijalnu aktivacijsku funkciju**:

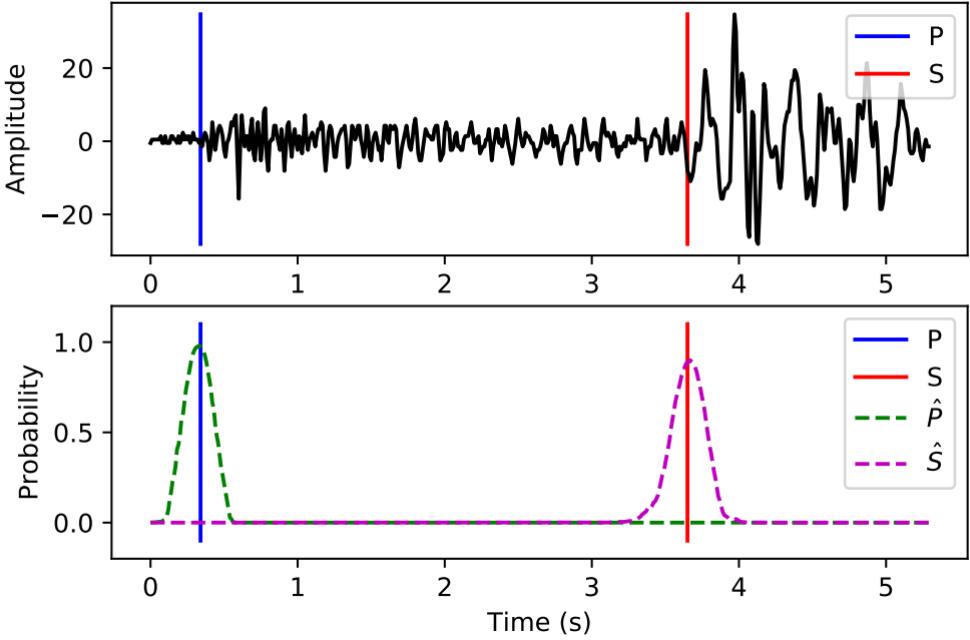
$$q_i(x) = \frac{e^{z_i(x)}}{\sum_{k=1}^3 e^{z_k(x)}} \quad (4.1.)$$

gdje  $i = 1$  predstavlja šum,  $i = 2$  predstavlja P-val, a  $i = 3$  predstavlja S-val. Parametar  $z_i(x)$  predstavlja vrijednosti iz prijašnjeg sloja. Izlazna vrijednost funkcije softmax je Gaussova distribucija vjerojatnosti za P-val, S-val i šum čija je srednja vrijednost 0, a standardna devijacija 0.1 s. Primjer izlaznih distribucija prikazan je na slici 4.2. Predstavljanje izlaznih podataka na ovakav način omogućava algoritmu PhaseNet dvije prednosti:

1. smanjuje utjecaj grešaka koje se nalaze unutar skupova za trening
2. ubrzava konvergenciju jer povećava informacije P- i S-kandidata relativno o šumu.



Slika 4.1. Arhitektura neuronske mreže phaseNet (preuzeto iz Zhu i Beroza, 2018).



Slika 4.2. Primjer primjene PhaseNet-a. Gornja slika predstavlja vertikalnu komponentu seizmograma. Plave i crvene okomite linije predstavljaju nastupna vremena P- i S-faze koja su odredili stručnjaci. Donja slika predstavlja predviđene distribucije vjerojatnosti koje generira PhaseNet (preuzeto iz Zhu i Beroza, 2018).

Funkcija gubitka koju PhaseNet arhitektura pokušava minimizirati je funkcija gubitka **unakrsne entropije**(Cox, 1958) koja mjeri unakrsnu entropiju (iz teorije informacija) između stvarne distribucije vjerojatnosti  $p(x)$  i predviđene distribucije vjerojatnosti  $q(x)$ :

$$H(p, q) = - \sum_{i=1}^3 \sum_x P_i(x) \log q_i(x) \quad (4.2.)$$

Korištenjem opisane arhitekture, te funkcije gubitka unakrsne entropije, prva inačica PhaseNet-a je trenirana na 779 514 primjera iz kataloga potresa NCECD (Northern California Earthquake Data Center Catalog) gdje je skup za trening sadržavao 623 054, validacijski skup 77 866, a testni skup 78 592 primjera. Zhu i Beroza su pokazali da PhaseNet pokazuje značajno bolje rezultate od STA/LTA metode. Nadalje, pokazali su da je preciznost modela PhaseNet u rangu s ljudskim stručnjacima te da u određenim situacijama može odrediti i greške koje su napravili ljudski stručnjaci.

Pomoću programskog okvira *SeisBench* (pogledaj dodatak C), implementirat će se prethodno trenirani modeli PhaseNet-a na zadane podatke. Najprije će se primjeniti na uzorak od 1 godine kako bi se odredilo koji prethodno treniran model je najučinko-

vitiji. U toj situaciji PhaseNet će biti kalibriran na način da filtrira detekcije faza koje imaju vjerojatnost manju od 0.1. Nadalje, kada se odredi najbolji model, primjenit će se na cijeli slijed podataka (za opis podataka pogledaj poglavlje 5).

#### 4.2. Određivanje potresa: **GaMMA Associator**

**GaMMA** (engl. *Gaussian Mixture Model Association*, Zhu et al., 2021) relativno je nova metoda za asocijaciju faza potresa. Tretira asocijaciju faza potresa kao problem nenadziranog grupiranja unutar vjerojatnosnog okvira. Svaki se potres smatra grupom P- i S-faza, a GaMMA koristi multivarijatnu (višedimenzijujsku) Gaussovou distribuciju za modeliranje ovih faza. Integrira lokaciju potresa, vrijeme nastanka i procjenu magnitude, primjenjujući algoritam **maksimizacije očekivanja** za procjenu maksimalne vjerojatnosti. Dizajn GaMMA-e omogućuje korištenje i nastupnog vremena faze i informacije o amplitudi, poboljšavajući njegovu učinkovitost u asocijaciji faza potresa, posebno kad se na seismogramu nalazi mnogo potresa. Ovaj pristup izbjegava potrebu za tipičnim koracima asocijacije kao što su pretraživanje mreže ili nadziranog treninga, što ga čini značajnim napretkom u metodologijama praćenja potresa.

Problem asocijacije unutar GaMMA okvira definiran je na slijedeći način: s obzirom na  $N$  faza gdje svaka faza ima nastupno vrijeme  $t_i$  i amplitudu  $a_i$  detektiranu na i-toj postaji, cilj je grupirati te faze u  $K$  potresa i procijeniti parametre izvora kao što su lokacija  $x_k, y_k, z_k$ , vrijeme nastanka  $t_k$  i magnituda  $m_k$  k-tog potresa. Vjerojatnost svake faze modelira se pomoću modela **Gaussove distribucije miješanja** (engl. *Gaussian mixture distribution*) koja grupira  $N$  podatkovnih točaka u  $K$  grupa maksimiziranjem vjerojatnosti da se te točke mogu objasniti mješavinom  $K$  Gaussovih distribucija:

$$p(\mathbf{x}_i) = w_i \sum_{k=1}^K \phi_k N(\mathbf{x}_i | \mu_k, \Lambda_k^{-1}), \quad \sum_{k=1}^K \phi_k = 1 \quad (4.3.)$$

gdje je  $\mathbf{x}_i$  faza (vektor nastupnih vremena, vrsta faze i amplitude na određenoj postaji),  $\phi_k$  koeficijent miješanja k-tog potresa,  $N$  Gaussova distribucija,  $\Lambda_k$  je matrica preciznosti koja pruža mjeru kako je svaka varijabla u skupu podataka ponderirana u odnosu na svaku drugu varijablu. Točnije, detaljno opisuje kako varijable variraju jedna s drugom, a  $w_i$  je kvaliteta odabira faze (između 0 i 1).

Nadalje će se na log-izglednost vjerojatnosti  $p(\mathbf{x}_i)$  primjeniti algoritam maksimi-

zacije očekivanja. Algoritam maksimizacije očekivanja (EM) je statistička tehnika za pronalaženje procjena maksimalne vjerojatnosti u modelima s latentnim varijablama. Provodi se u dva koraka: korak očekivanja (**E**), koji stvara funkciju za očekivanje log-izglednosti procijenjene pomoću trenutne procjene za parametre, i koraka maksimizacije (**M**), koji izračunava parametre koji maksimiziraju očekivanu log-izglednost pronađenu u koraku E. Ovi se koraci ponavljaju do konvergencije, što rezultira parametrima koji su vjerojatno doveli do promatranih podataka.

#### 4.2.1. *Kalibracija GamMA Associatora*

U prvom koraku procesa kalibracije, koriste se **Svjetski geodetski sustav 1984** (WGS84) i **HTRS96/Croatia TM** (EPSG:3765) koordinatni sustavi za projiciranje geografskih koordinata u lokalni koordinatni sustav. Ova transformacija ključna je za preciznu lokalizaciju i analizu unutar specifičnog geografskog konteksta sjeverozapadnih Dinarida.

Dimenzionalna postavka uključuje analizu podataka u tri dimenzije ( $x, y, z$ ), što je bitno za točnu lokalizaciju seizmičkih događaja. **DBSCAN** (*Density-Based Spatial Clustering of Applications with Noise*) (Ester et al., 1996) grupiranje je omogućeno za identifikaciju grupa seizmičke aktivnosti, što pomaže u razlikovanju seizmičkih događaja. DBSCAN radi na principu identificiranja „središnjih“ točaka i širenja grupa okonjih. Središnja točka definirana je na temelju dva parametra: epsilon ( $\epsilon$ ) i minimalnih uzoraka:

- **Epsilon ( $\epsilon$ )**: Ovaj parametar definira radijus susjedstva oko središnje točke. Ovaj radijus je značajan u određivanju prostornog dosega unutar kojeg se detekcije faza smatraju dijelom iste grupe te jer izravno utječe na osjetljivost algoritma na formiranje grupa. Manji  $\epsilon$  mogao bi rezultirati mnogim malim grupama, potencijalno uzrokovati mašenje širih obrazaca, dok bi veći  $\epsilon$  mogao spojiti različite seizmičke događaje u jednu grupu. Za potrebe ovog rada, *epsilon* je postavljen na 20 km.
- **Minimalni uzorci**: Ovaj parametar određuje minimalni broj točaka potrebnih za formiranje gustog područja. Ovaj prag osigurava da se samo područja s dovoljnom koncentracijom detekcija faza smatraju grupama, čime se smanjuje

vjerojatnost povezivanja slučajnog šuma ili nepovezanih detekcija faza sa seizmičkim događajem. Za potrebe ovog rada, minimalni uzorci su postavljeni na 3.

Za potrebe ovog rada, koristit će se jednostavan uniformni model brzine P-valova 6 km/s i S-valova 3.4 km/s. Zbog toga se ne očekuje velika preciznost u prostornom određivanju lokacija izvora potresa no i dalje će se odviti uspješna asocijacija zbog relativno malih udaljenosti izvora i stanice.

Nadalje, kod primjene na uzorak će se postaviti da svaki događaj mora imati zabilježeno barem 6 faza, dok kod primjene na cijeli katalog potresa će se postaviti da svaki događaj mora imati zabilježeno barem 10 faza. Ovakav strogi uvjet je postavljen kako bi se umanjila vjerojatnost za generiranje lažnih pozitivnih događaja.

#### **4.3. Primjena: Učenje prijenosom**

Modeli PhaseNet-a trenirani na pet različitih baza podataka će se primijeniti na uzorak valnih zapisa s 18 postaja raspoređenih na području sjeverozapadnih Dinarida. Uzimaju se valni zapisi iz 2014. godine jer je jedna od godina koja sadrži najpotpunije podatke. Pod pojmom „sjeverozapadni Dinaridi“ u ovom radu koristit će se područje ograničeno s longitudom  $13.528^{\circ}$ - $15.731^{\circ}$  i latitudom  $45.013^{\circ}$ - $46.499^{\circ}$ . Ovakav specifičan raspon koordinata je definiran s obzirom na testni katalog potresa gdje su uzeti potresi s najmanjim i najvećim longitudama i latitudama kao granični za područje proučavanja. Nakon primjene PhaseNet-a i GaMMA Associator-a, ML katalozi će se filtrirati tako da sadrže događaje koji su u rasponu koordinata kao i testni katalog potresa u svrhu usporedbe.

Nakon konstrukcije ML kataloga, izračunat će se vremenski reziduali (razlika početaka „pravih“ potresa i „ML“ potresa) te prostorni reziduali (razlika longituda/latituda „pravih“ potresa i „ML“ potresa) u svrhu određivanja učinkovitosti svake varijante modela *PhaseNet*. „ML“ potres će se smatrati identičnim kao „pravi“ ako mu je vrijeme početka  $\pm 2.5$  sekundi (vremenski prozor od 5 sekundi) od „pravog“ potresa. Mjere izvedbe **preciznost, osjetljivost, F1, te srednja vrijednost i standardna devijacija** reziduala će se koristiti radi usporedbe između različitih varijanti PhaseNet-a kako bi se utvrdilo koji je najučinkovitiji za ovo područje.

Najučinkovitija varijanta modela *PhaseNet* će se primijeniti na čitav slijed od 10

godina podataka te naposlijetku usporediti sa pravim katalogom potresa za navedeno područje. Nadalje će se pokušati odrediti jesu li događaji koje generira PhaseNet/GaMMA Associator *pipeline* stvarni događaji ili nasumičan šum.

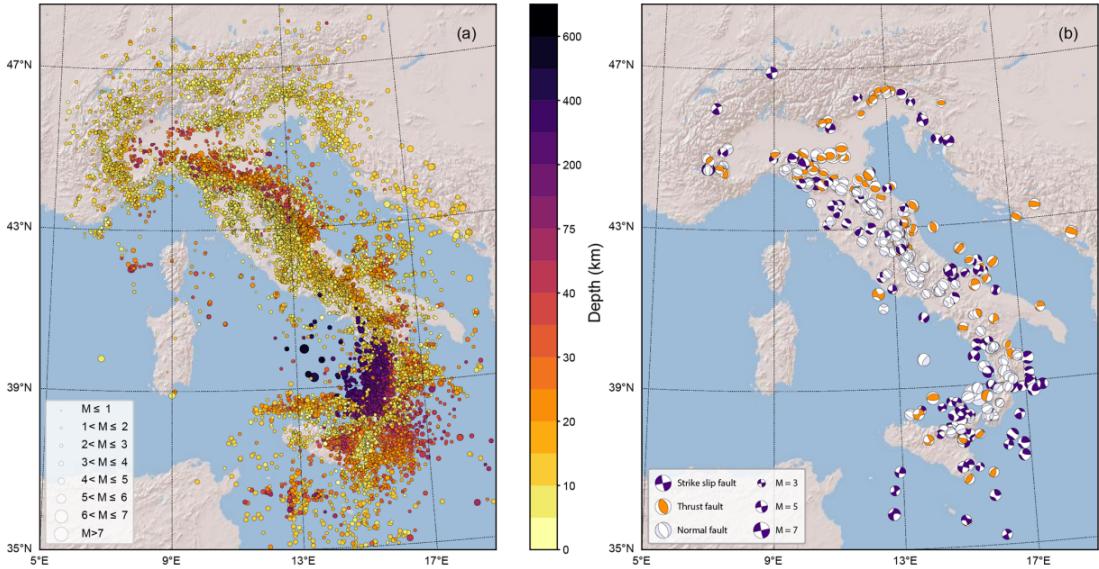
## 5. Podaci

Za potrebe ovog rada korištene su varijante modela PhaseNet trenirane na bazama podataka INSTANCE, STEAD, GEOFON, ETHZ i SCEDC te potom primijenjene na seizmograme seismoloških postaja na području sjeverozapadnih Dinarida. Dvije najinteresantnije baze su INSTANCE i STEAD jer uz sve ostale podatke sadrže mnogo primjera lokalnih potresa s područja sjeverozapadnih Dinarida.

### 5.1. *Baze podataka za trening*

#### 5.1.1. INSTANCE

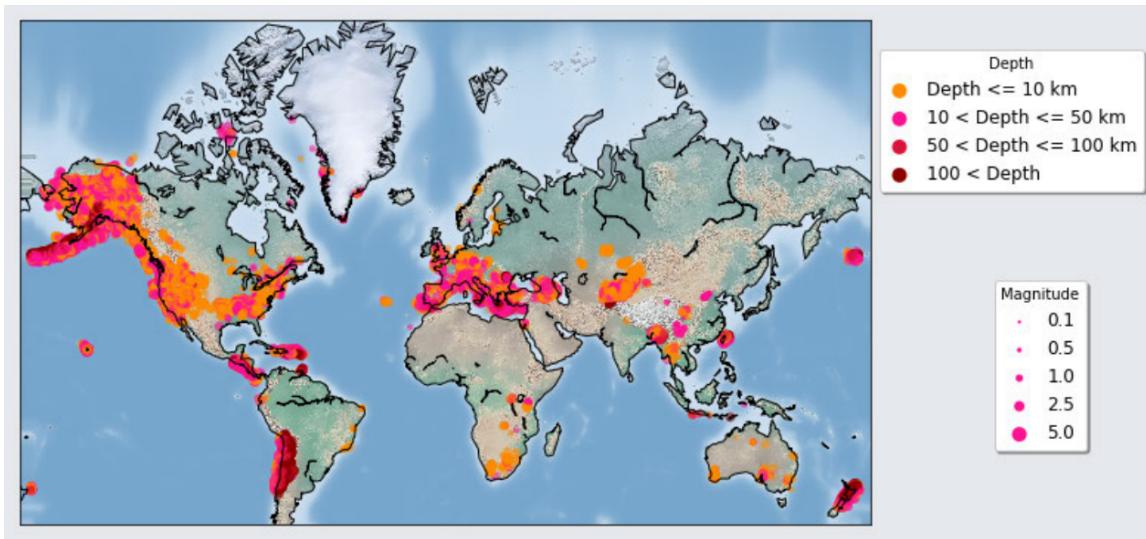
Baza podataka **INSTANCE** sveobuhvatna je zbirka seizmograma potresa prilagođenih za primjenu strojnog učenja. Uključuje gotovo 1.2 milijuna trokomponentnih (3C) seizmograma za oko 50 000 potresa i preko 130 000 seizmograma seizmočkog šuma, ukupno oko 43 000 h podataka. Odabrani potresi predstavljaju podskup cjelokupne seizmičnosti u Italiji u razdoblju od siječnja 2005. do siječnja 2020. i okolnim područjima, pokrivajući značajne potrese s magnitudama u rasponu od 0.0 do 6.5 (Michelini et al., 2021). Na slici 5.1 mogu se vidjeti svi potresi koji su korišteni u bazi podataka, zajedno s dostupnim žarišnim mehanizmima za određene potrese. Pretpostavlja se da će PhaseNet treniran na bazi INSTANCE pokazati jako dobru izvedbu na području sjeverozapadnih Dinarida jer INSTANCE ne sadrži samo potrese i seizmograme s područja Italije, nego sadrži i određen broj potresa s istraživačkog područja te zbog toga može značajno profitirati od **učenja prijenosom**, gdje model treniran na velikoj bazi podataka se primjeni na drugačiju, ali sličnu domenu, suplementiran s malim uzorkom podataka iz te domene. Zbog toga se pretpostavilo da će PhaseNet moći bolje prepoznati značajke koje su bitne za područje sjeverozapadnih Dinarida jer je dio treninga „proveden“ na upravo tom području.



Slika 5.1. a) Karta epicentara potresa koji se nalaze u bazi podataka INSTANCE, pri čemu boja prikazuje dubinu žarišta prema prikazanoj skali. Veličina kruga proporcionalna je magnitudi potresa. b) Karta dostupnih žarišnih mehanizama potresa (preuzeto iz Michelini et al. 2021).

### 5.1.2. STEAD

**STEAD** (*Stanford Earthquake Dataset*) sveobuhvatna je zbirka lokalnih seismograma koji su kategorizirani u dvije glavne klase: potresni i ne-potresni signali. Klasa potresa sastoji se od oko 1 050 000 trokomponentnih seismograma povezanih s približno 450 000 potresa, koje bilježi 2613 prijemnika diljem svijeta. Ovi seismogrami uključuju P- i S-valove i pokrivaju širok raspon magnituda potresa od -0.5 do 7.9. Većina tih potresa ima magnitudu manju od 2.5 i pliči su od 50 km. Ne-potresna klasa sadrži oko 100 000 uzoraka seismograma seizmičkog šuma. Potresi koji su korišteni u svrhu treninga su prikazani na slici 5.2 (Mousavi et al., 2019).



Slika 5.2. Lokalni potresi (lokacija, dubina i magnituda) korišteni u svrhu sastavljanja STEAD baze podataka.

### 5.1.3. ETHZ, GEOFON i SCEDC

**GEOFON** (*GEOFO*rschungs*N*etz), seismološka mreža kojom upravlja njemački istraživački centar za geoznanosti (GeoForschungsZentrum, Potsdam), istaknuta je globalna seismološka mreža koja igra ključnu ulogu u praćenju i analizi seizmičke aktivnosti diljem svijeta. GEOFON-ova mrežna infrastruktura sastojeći se od velikog broja seizmoloških stаница, strateški smještenih na raznim kontinentima. PhaseNet(GEOFON) treniran je na oko 275 000 primjera seismograma u razdoblju od 2009. do 2013. godine. Magnitude potresa koji čine ovaj skup imaju raspon od otprilike 2 do 9, pri čemu je većina ručno odabranih događaja srednjih do velikih magnituda (5–7) (*Helmholtz Centre Potsdam – GFZ German Research Centre for Geosciences*, n.d.).

Baza podataka **SCEDC** (*Southern California Earthquake Data Center*) predstavlja ključni izvor u proučavanju i analizi seizmičkih aktivnosti u Južnoj Kaliforniji. Funkcionirajući kao primarni arhiv za seismološke podatke na ovom području, SCEDC prikuplja, potvrđuje i katalogizira informacije o potresima. PhaseNET(SCEDC) treniran je na skupu podataka iz SCEDC-a koji sadrži sve javno dostupne ručno locirane potrese u seismološkoj mreži Južne Kalifornije u razdoblju od 2000. do 2020. godine. Sadrži oko 8 100 000 primjera valnih oblika (*Southern California Earthquake Data Center*, n.d.).

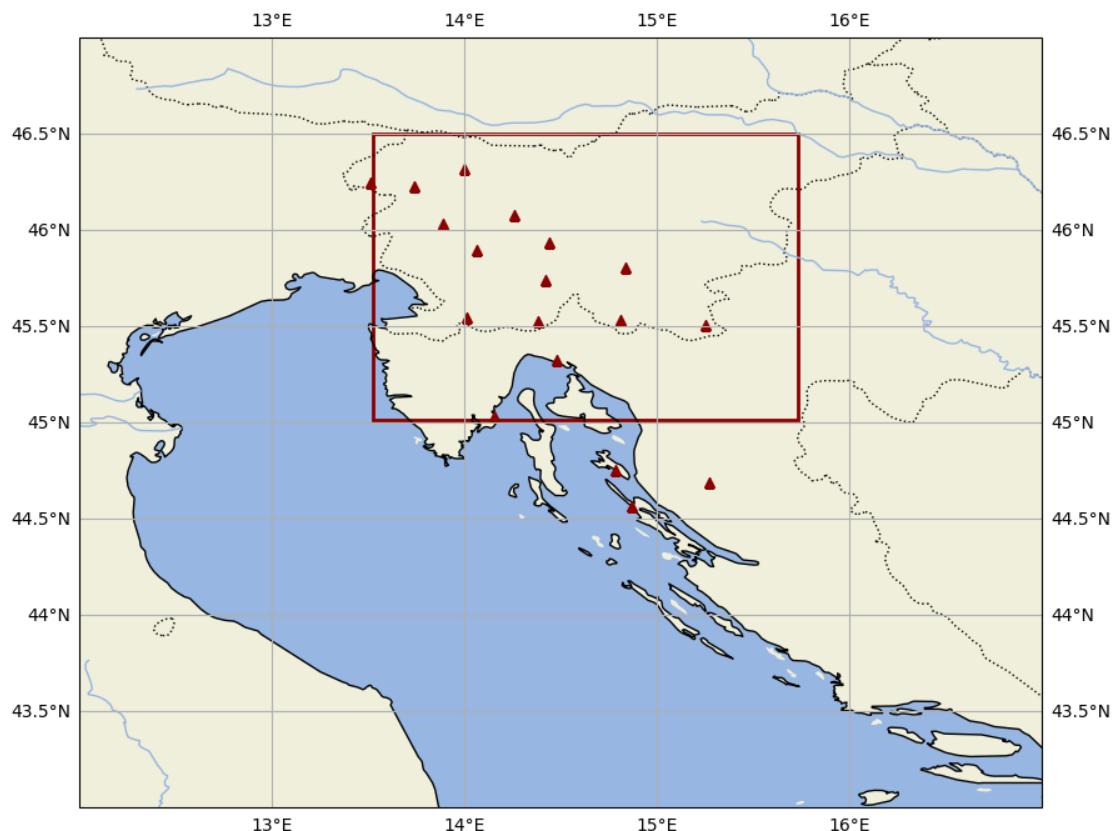
Baza podataka **ETHZ** kojim upravlja Švicarska seizmološka služba (SED) pri ETH Zurich, vitalan je izvor za proučavanje i praćenje seizmičke aktivnosti u Švicarskoj i okolnim područjima. U središtu baze podataka ETHZ nalazi se zbirka seismoloških podataka, koja uključuje detaljne zapise o potresima u i oko Švicarske. Ovi se podaci prikupljaju iz mreže seismoloških postaja postavljenih diljem Švicarske, opremljenih naprednim seismografima. Strateški položaj ovih postaja osigurava visokokvalitetno prikupljanje podataka, pokrivajući potrese različitih magnituda. Skup podataka sadrži 36 743 primjera valnih oblika (ETH Zurich, n.d.).

## **5.2. *Podaci za testiranje***

Varijante modela *PhaseNet* trenirane na pet baza podataka iz prethodnog poglavlja primijeniti će se na podatke koji se sastoje od 10 godina trokomponentnih seismograma potresa (od 1.1.2009. do 31.12.2018.) s 13 slovenskih postaja i 5 hrvatskih postaja. Instrumenti s kojima su prikupljeni podaci su širokopojasni trokomponentni seismografi. Prostorno, hrvatske postaje se nalaze na području sjevernog Jadrana u blizini Slovenije tako da ovih 18 postaja zaokružuju jednu zajedničku prostornu cjelinu. U tablici 5.1 se nalazi popis postaja zajedno s parametrima za svaku postaju, a na slici 5.3 se nalazi prikaz stanica i područja od interesa.

Tablica 5.1. Koordinate hrvatskih i slovenskih seizmičkih postaja pomoću kojih su dobiveni podaci korišteni u radu.

Longituda	Longituda	Latituda	Elevacija(m)
CR.kys.	15.270395	44.68819	554
CR.nvlj.	14.871050	44.56347	8
CR.rabc.	14.782104	44.750429	16
CR.riy.	14.483006	45.325086	183
CR.srmn.	14.15487	45.036052	17
SL.BOJS.	15.251780	45.504350	252
SL.CADS.	13.736850	46.228040	700
SL.CEY.	14.422140	45.738140	579
SL.CRNS.	14.261350	46.080600	689
SL.GBAS.	14.442290	45.934730	538
SL.GORS.	13.999910	46.317410	1048
SL.JAVS.	14.064330	45.893420	1100
SL.ROBS.	13.509440	46.244480	265
SL.VISSL.	14.839290	45.803290	403
SL.VOJS.	13.887740	46.032170	1073
SL.KNDS.	14.380560	45.527910	1024
SL.GBRS.	14.810070	45.531100	610



Slika 5.3. Crvenim pravokutnikom je označeno područje u kojem se nalaze potresi iz testnog kataloga. Postaje s kojih su izmjereni podaci na koje će se primijeniti ML modeli su označeni crvenim trokutima.

Prije primjene modela *PhaseNet* podatke će se pripremiti u obliku koji je konzistentan s podacima koji su korišteni za trening modela *PhaseNet* (radi bolje efikasnosti modela) uz dodatnu pripremu za povećanje efikasnosti primjene *PhaseNeta*. Taj proces zahtjeva nekoliko koraka:

1. **Čišćenje podataka:** Provjerava se je li za svaki vremenski interval postoje tri (Z, N, E) komponente. Svi intervali iz skupa podataka koji ne sadrže sve tri komponente se eliminiraju jer *PhaseNet* kao ulaz zahtjeva tri komponente seismograma.
2. **Podjela u satne segmente:** Podaci će se podijeliti u dijelove (engl. *batch*) jednakih 1-satnih vremenskih intervala. Ovo će omogućiti primjenu paralelnog procesiranja radi brže i efikasnije analize podataka.
3. **Detrending:** Kako bi se osigurala bolja preciznost modela strojnog učenja, podaci će biti podvrgnuti postupku *detrendinga*. Ovaj korak je ključan za uklanjanje mogućih linearnih trendova koji mogu utjecati na rezultate analize, jer trendovi u podacima mogu dovesti do izobličenja u procjeni značajki signala. Detrending osigurava da modeli prepoznaju i uče samo iz relevantnih fluktuacija u seizmičkim zapisima, bez obzira na neželjene ili neinformativne linearne trendove koji mogu biti prisutni.
4. **Uzorkovanje:** Svi zapisi su uzorkovani na 100 Hz kako bi bili u skladu s trening bazama korištenih za trening opisanih u prethodnom odjeljku. Prilikom primjene modela strojnog učenja, posebno u analizi vremenskih nizova, usklađivanje stope uzorkovanja novih podataka sa stopom podataka za trening ključno je za održavanje dosljednosti značajki i pravilne dimenzionalnosti (Conrad et al., 2023). Modeli uče uzorke na temelju specifičnih vremenskih rezolucija, a svaka promjena u uzorkovanju može dovesti do pogrešnog tumačenja signala, gubitka ili pogrešne reprezentacije spektralnih značajki i nedosljednosti u ulaznom obliku i mjerilu, što sve može štetno utjecati na izvedbu. Sposobnost modela da točno primijeni naučene značajke uvelike ovisi o primanju podataka koji odražavaju uvjete koje je taj model imao u okruženju za trening.
5. **Normiranje:** U strojnom učenju, normiranje igra ključnu ulogu u poboljšanju izvedbe i stabilnosti modela. Osigurava da svi ulazi imaju usporedive veličine, što

je osobito važno za modele temeljene na gradijentnom spuštanju (Robbins and Monro, 1951), budući da značajno ubrzava konvergenciju i sprječava da bilo koji valni oblik visoke amplitude iskrivi proces učenja. Dodatno, normalizacija centriра podatke oko nule, smanjujući pristranost i osiguravajući da u scenarijima s više značajki, poput trokomponentnih valnih oblika, svaka jednako doprinosi analizi. Ovo sprječava da bilo koja značajka dominira zbog razlika u mjerilu. Nadalje, normalizacija pomaže u održavanju numeričke stabilnosti, ključnog čimbenika za modele dubokog učenja, ublažavanjem problema poput nestajućeg ili eksplodirajućeg gradijenta (Sunitha et al., 2020). U ovom radu će se zapisi sve tri komponente normirati na svoj odgovarajući absolutni maksimum.

Cijela prethodna obrada će se odradivati pomoću **ObsPy**-a (pogledaj dodatak C), Python biblioteci specijaliziranoj za primjenu u seizmologiji. Također, *PhaseNet* ne zahtjeva filtriranje podataka jer se u trening skupu navode primjeri šuma kako bi naučio razlikovati šum od faza.

### 5.3. *Testni katalog potresa*

Nakon primjene PhaseNeta i GaMMA Associatora, rezultirajući „ML“ katalog će se usporediti sa testnim stvarnim katalogom potresa. Stvarni katalog potresa koji je bio korišten u ovom radu produkt je rada Rajh et al. (2023). Rajh et al. su kao početnu točku analize koristili katalog potresa Slovenske seismološke službe. Taj katalog je sadržavao 7733 lokalnih potresa koji su se dogodili između 2004. i 2018. godine za koje je  $ML \geq 1$ . Njihove su lokacije bile određene pomoću programa HYPOCENTER (Linenert i Havskov, 1995). Većina potresa su imali dubine između 1.1 i 18.3 km. Većina nastupnih vremena P- i S-faza su bila određena na postajama Slovenske seismološke službe, uz pomoć nekoliko postaja iz susjednih država.

Autori su potom koristili nekoliko 1D modela brzina i program VELEST (Kissling et al., 1994) kako bi izračunali vrijednosti parametara hipocentara i parametara modela brzina u svrhu relociranja potresa iz početnog slovenskog kataloga potresa. Proces je uključivao sustavno odabiranje potresa, podešavanja početnih modela i višestruka izvođenja inverznih računa za poboljšanje modela. Detaljniji opis metode se nalazi u Rajh et al. (2023).

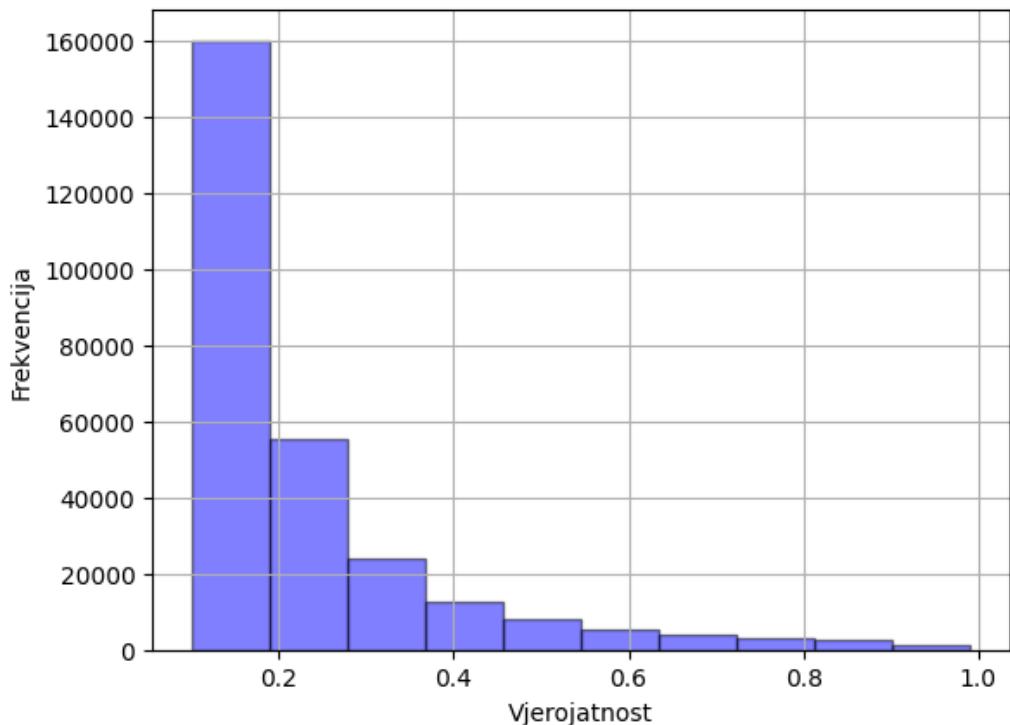
Iz takvog relociranog kataloga (koji će se u ostaku rada također zvati i pra-

vim/stvarnim katalogom) će se odabratи potresi za raspon godina od 01.01.2009. do 30.05.2018. Ukupno u katalogu za navedeni vremenski slijed postoji 2461. potres u rasponu magnituda od 1 do 4.3. Prostorno, dio potresa iz kataloga pripadaju području Slovenije, a dio sjeverozapadnoj Hrvatskoj, kolektivno sjeverozapadnim Dinaridima, specifično, u rasponu latituda od  $45.013 - 46.499^\circ$  i longituda od  $13.528 - 15.731^\circ$ .

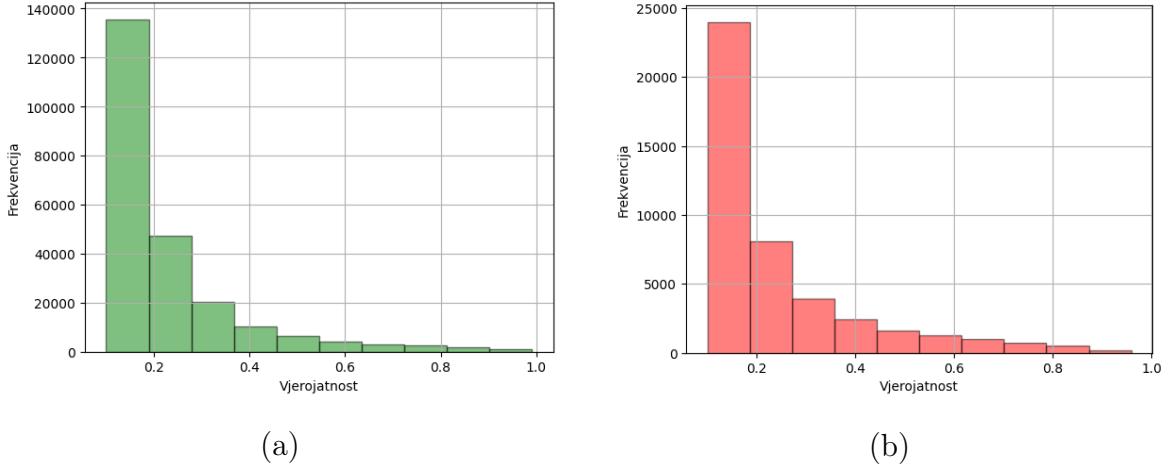
## 6. Rezultati i diskusija

### 6.1. Detekcije faza

Nakon primjene PhaseNet modela treniranih na različitim bazama podataka, generirane su detekcije faza za svaku od navedenih postaja. Za PhaseNet(INSTANCE), histogram detekcija se može vidjeti na slici 6.4, a histogrami pojedinačnih P- i S-detekcija se mogu vidjeti na slici 6.5. Od 276 354 detekcija, P-detekcije tvore 84% svih detekcija, dok s detekcije tvore 16% što je očekivano, jer je u pravilu S-faze teže uočiti zbog p kode, te također jača energija s valova uzrokuje komplikiraniji signal.



Slika 6.4. Histogram vjerojatnosti detekcija P- i S-faza za PhaseNet(INSTANCE) model.



Slika 6.5. (a): Histogram vjerojatnosti detekcija P-faza. (b): Histogram vjerojatnosti detekcija S-faza za PhaseNet(INSTANCE) model.

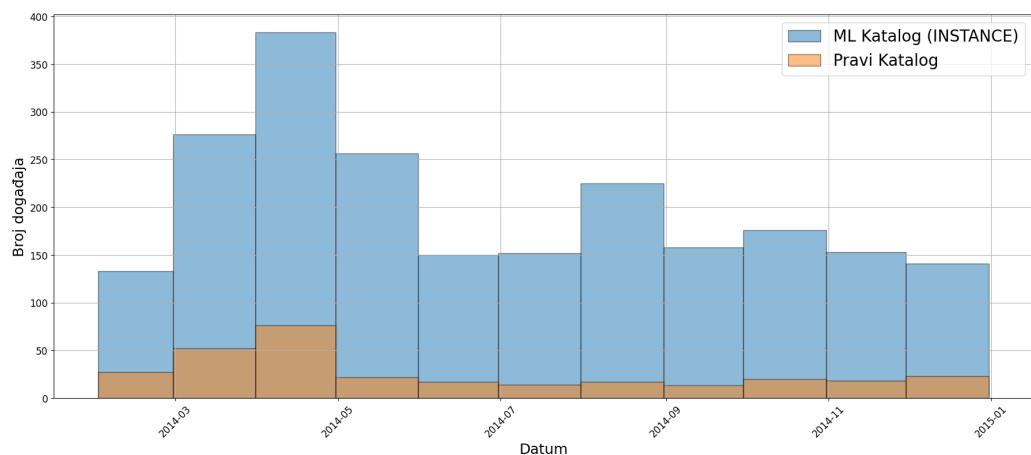
U tablici 6.2 se mogu vidjeti osnovni statistički parametri svih PhaseNet modela. PhaseNet(GEOFON) pokazuje najviše p detekcija, no oni čine 99.94% svih detekcija, što se može objasniti malim udjelom S-faza u bazi podataka GEOFON, zbog čega PhaseNet(GEOFON) nije uspio adekvatno naučiti značajke koje reprezentiraju S-faze. Zanimljivo je da je PhaseNet(STEAD) detektirao više S-faza nego P-faza. Jedan od mogućih objašnjenja je što u bazi podataka STEAD postoji veći broj S-faza nego P-faza, što će omogućiti PhaseNet-u da prezastupa S-faze u procesu detekcije. PhaseNet(INSTANCE), Phasenet(ETHZ) i Phasenet(SCEDC) pokazuju očekivane udjele P-i S-detekcija. Histogrami za ostale modele se mogu vidjeti u Dodatku A.

Tablica 6.2. Osnovni statistički parametri za detekcije svih 5 modela. Srednja vrijednost i standardna devijacija se računaju za vjerojatnosti koje generira PhaseNet.

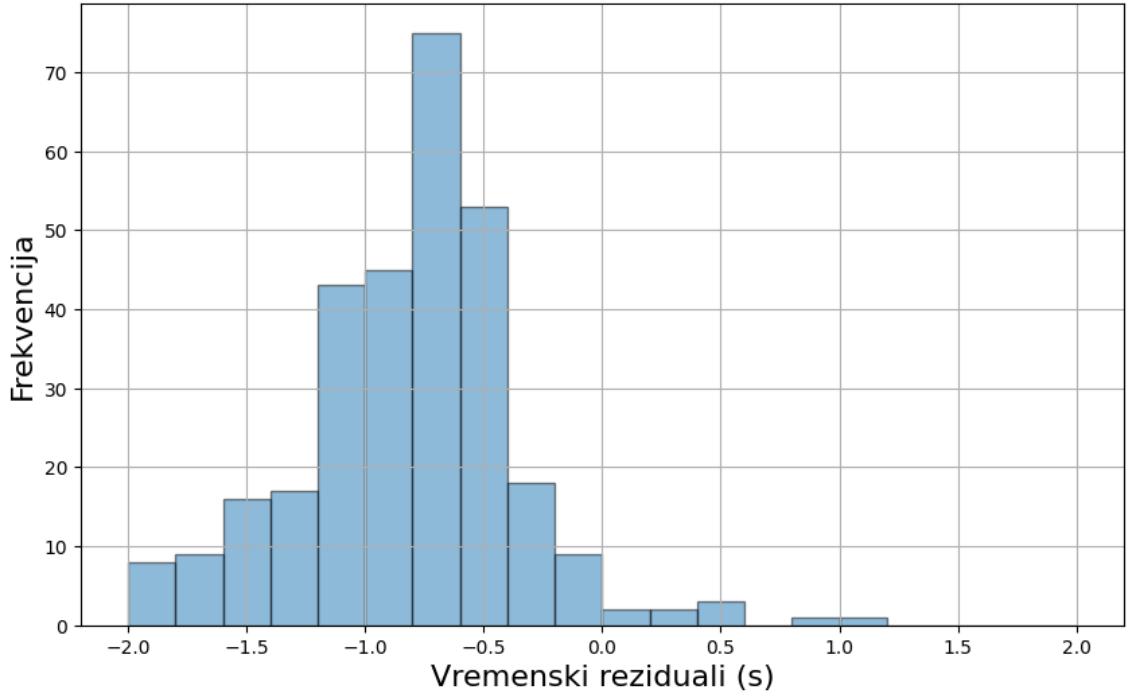
	INSTANCE	STEAD	GEOFON	ETHZ	SCEDC
$N_p$	232479	37188	2328492	116596	309933
$\mu_p$	0.22	0.21	0.21	0.32	0.23
$\sigma_p$	0.15	0.14	0.12	0.23	0.16
$\%p$	0.84	0.41	1.00	0.74	0.82
$N_s$	43875	53955	1299	40259	66170
$\mu_s$	0.24	0.28	0.17	0.26	0.18
$\sigma_s$	0.17	0.19	0.07	0.18	0.10
$\%s$	0.16	0.59	0.00	0.26	0.18

## 6.2. Događaji (uzorak)


Nakon određivanja događaja (vremena početka i koordinata) pomoću GaMMA asocijatora, generirano je 5 „ML“ kataloga potresa s obzirom na 5 različitih baza podataka korištenih za trening PhaseNet-a. Katalog ML\_INSTANCE sadrži 4218 događaja čiji se raspored kroz 2014. godinu može vidjeti na slici 6.6. Distribucija vremenskih reziduala centrirana na -0.80 sekundi sa standardnom devijacijom od 0.45 sekundi se može vidjeti na slici 6.7. Kod usporedbi pravog i ML\_INSTANCE kataloga, vrijednost preciznosti iznosi 0.1311, osjetljivosti 0.9601, a F1 iznosi 0.2307. Osjetljivost od 0.9601 znači da ML\_INSTANCE katalog sadrži 96.01% događaja koji se nalaze u pravom katalogu. Razlog niske vrijednosti preciznosti i F1 je što ML\_INSTANCE katalog sadrži mnogo novih događaja koji se ne nalaze u pravom katalogu. Prostorni reziduali (longitude i latitude) se nalaze na slici 6.8.



Slika 6.6. Distribucija potresa pravog kataloga i ML\_INSTANCE kataloga tijekom 2014. godine.



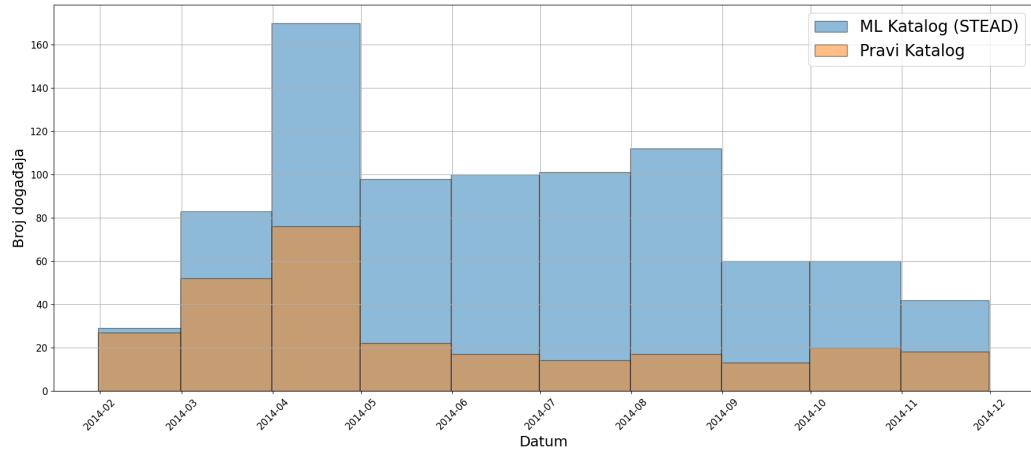
Slika 6.7. Vremenski reziduali (razlika između stvarnih vremena početka i ML vremena početka) između pravog kataloga i ML\_INSTANCE kataloga. Distribucija reziduala je centrirana na -0.80 sekundi sa standardnom devijacijom od 0.45 sekundi.



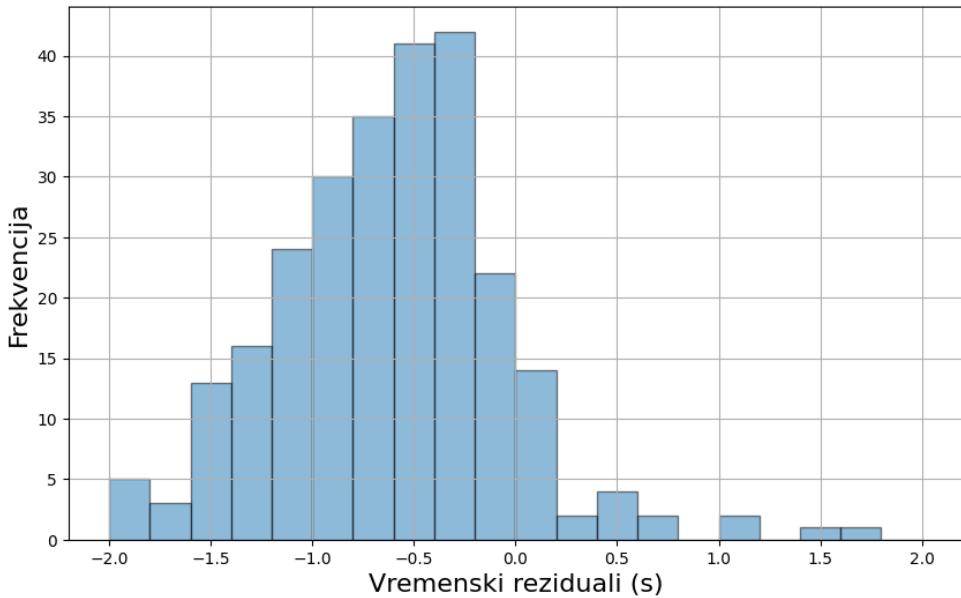
Slika 6.8. (a): Prostorni reziduali (projekcija longitude  $x$  na lokalne koordinate u metrima) između pravog kataloga i ML\_INSTANCE kataloga. (b): Prostorni reziduali (projekcija latitude  $y$  na lokalne koordinate u metrima) između pravog kataloga i ML\_INSTANCE kataloga.

Katalog ML\_STEAD sadrži 1361 događaja čiji se raspored kroz 2014. godinu može vidjeti na slici 6.9. Distribucija vremenskih reziduala centrirana na -0.61 sekundi sa standardnom devijacijom od 0.56 sekundi se može vidjeti na slici 6.10. Kod usporedbi pravog i ML\_STEAD kataloga, vrijednost preciznosti iznosi 0.2826, osjetljivosti 0.8025, a F1 iznosi 0.4180. Osjetljivost od 0.8025 znači da ML\_STEAD katalog sadrži


80.25% događaja koji se nalaze u pravom katalogu. Također, veća preciznost implicira da u sebi sadrži manje novih događaja. Prostorni reziduali (longitude i latitude) se nalaze na slici 6.11.



Slika 6.9. Distribucija potresa pravog kataloga i ML\_STEAD kataloga tijekom 2014. godine.



Slika 6.10. Vremenski reziduali (razlika između stvarnih vremena početka i ML vremena početka) između pravog kataloga i ML\_STEAD kataloga. Distribucija reziduala je centrirana na -0.61 sekundi sa standardnom devijacijom od 0.56 sekundi.



Slika 6.11. (a): Prostorni reziduali (projekcija longitude  $x$  na lokalne koordinate u metrima) između pravog kataloga i ML\_STEAD kataloga. (b): Prostorni reziduali (projekcija latitue  $y$  na lokalne koordinate u metrima) između pravog kataloga i ML\_STEAD kataloga.

Nadalje, rezultati parametara svih kataloga se nalaze u tablici 6.3. Može se vidjeti da ML\_INSTANCE dominira nad drugim katalozima jer sadrži najviše događaja koji se nalaze u pravom katalogu. Objašnjenje ovako dobre izvedbe PhaseNet(INSTANCE) leži u učenju prijenosom: opći model treniran za izvedbu u određenoj (sličnoj) domeni (područje Italije) je u trening skupu sadržavao mali udio primjera iz druge domene (sjeverozapadni Dinaridi) na koji će biti primijenjen. Ova tehnika je omogućila PhaseNet-u da prvotno nauči opće značajke kod prepoznavanja anomalija u seismogramu, te da pomoći učenja prijenosom nauči značajke specifične za određeni teren. Uz već spomenute identične događaje između dva kataloga, ML\_INSTANCE pokazuje velik broj potencijalnih događaja naspram drugih kataloga (izuzev ML\_GEOFON). Druga dva kataloga dobivena pomoći lokalnih baza podataka su ML\_ETHZ i ML\_SCEDC koja, iako ne sadrže primjere s područja sjeverozapadnih Dinarida, i dalje pokazuju visoko razinu izvedbe (pomoći naučenih općih značajki za prepoznavanje anomalija), s manjom razinom preciznošću i brojem detektiranih potencijalnih događaja s obzirom na ML\_INSTANCE. Druga dva ML kataloga su dobivena pomoći globalnih baza podataka. Od njih, ML\_STEAD također pokazuje dobru izvedbu (jer također sadrži primjere sa sjeverozapadnih Dinarida), no s mnogo manje detektiranih potencijalnih događaja naspram prijašnja 3 kataloga. Nasuprot njih, ML\_GEOFON pokazuje lošu izvedbu modela PhaseNet(GEOFON). Razlog je što GEOFON baza podataka sadrži mnogo teleseizmičkih događaja te jako malo S-faza naspram P-faza, što je uzrokovalo da PhaseNet(GEOFON) nedovoljno nauči značajke vezane za lokalne događaje. Gra-

Tablica 6.3. Rezultati parametara izvedbe za sve ML kataloge.

	<b>INSTANCE</b>	<b>STEAD</b>	<b>ETHZ</b>	<b>SCEDC</b>	<b>GEOFON</b>
$N$	4218	1361	2563	3161	5198
$\mu$	-0.8	-0.61	-0.87	-0.96	-1.04
$\sigma$	0.45	0.56	0.42	0.47	0.57
preciznost	0.1311	0.2826	0.1792	0.1288	0.082
osjetljivost	0.9601	0.8025	0.8926	0.7975	0.3884
F1	0.2307	0.418	0.2985	0.2217	0.1349

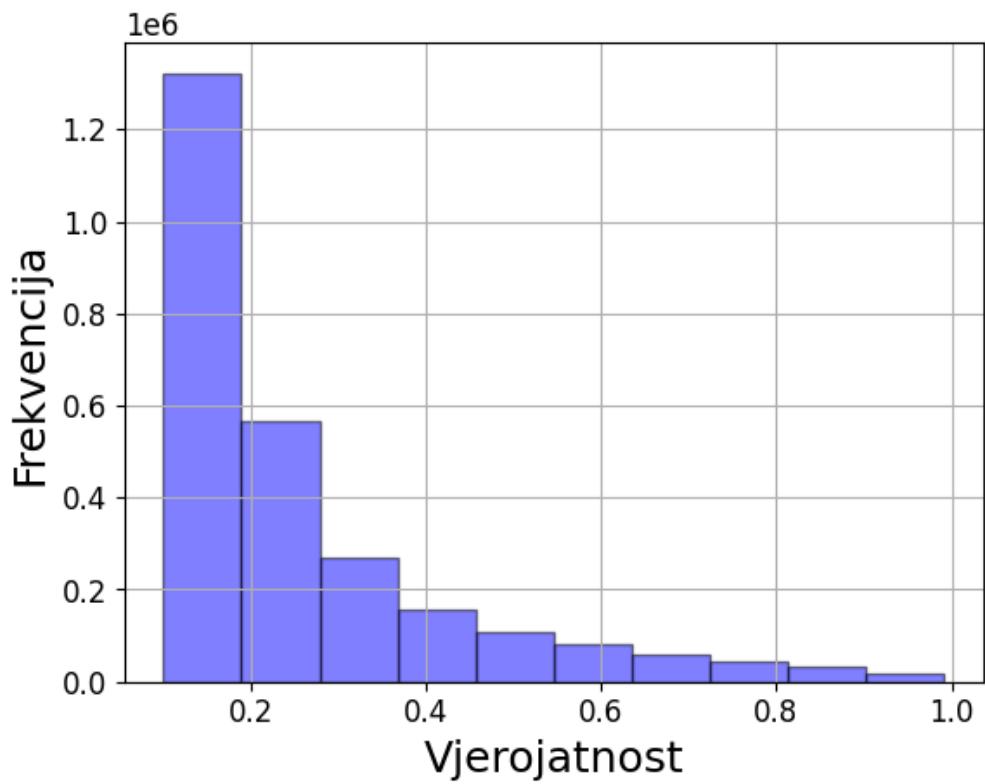
fovi vezani za ostale kataloge se mogu vidjeti u dodatku B.

Iz gornje analize, jasno je da PhaseNet(INSTANCE) pokazuje najbolju izvedbu na uzorku kod potvrđivanja već postojećih stvarnih potresa te visoku izvedbu na temelju svih ostalih parametara. Nadalje će se PhaseNet(INSTANCE) primijeniti na svih 10 godina podataka.


### **6.3. Dogadaji (cijeli skup)**

Nakon primjene PhaseNet(INSTANCE) modela na 10 godina podataka, generirane su detekcije faza za svaku od navedenih postaja. Histogram detekcija se može vidjeti na slici 6.12, a histogrami pojedinačnih P- i S-detekcija se mogu vidjeti na slici 6.13. Od 2 654 473 detekcija, P-detekcije tvore 90% svih detekcija, dok s detekcije tvore 10%.

Statistički parametri za detekcije faza se mogu vidjeti u tablici 6.4.



Slika 6.12. Histogram vjerojatnosti detekcija P- i S-faza za PhaseNet(INSTANCE) model za svih 10 godina podataka.

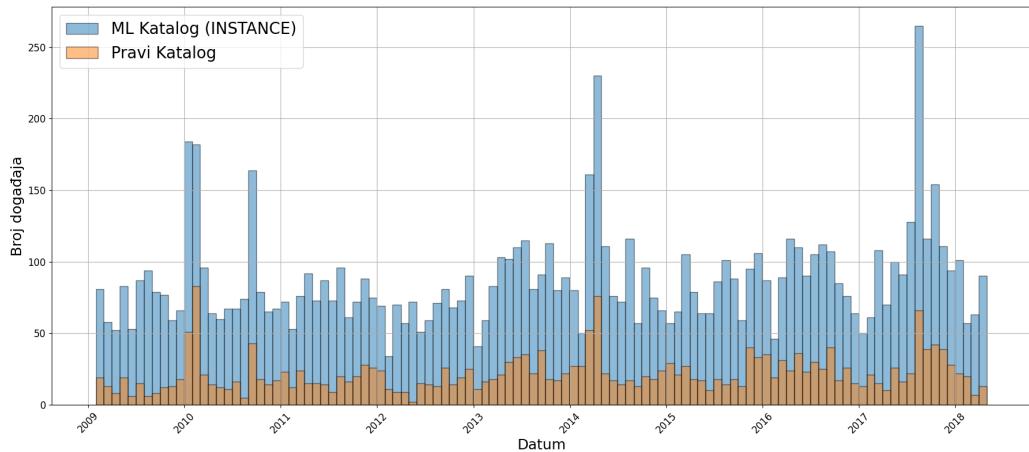


Slika 6.13. (a): Histogram vjerojatnosti detekcija P-faza. (b): Histogram vjerojatnosti detekcija S-faza za PhaseNet(INSTANCE) model za svih 10 godina podataka.

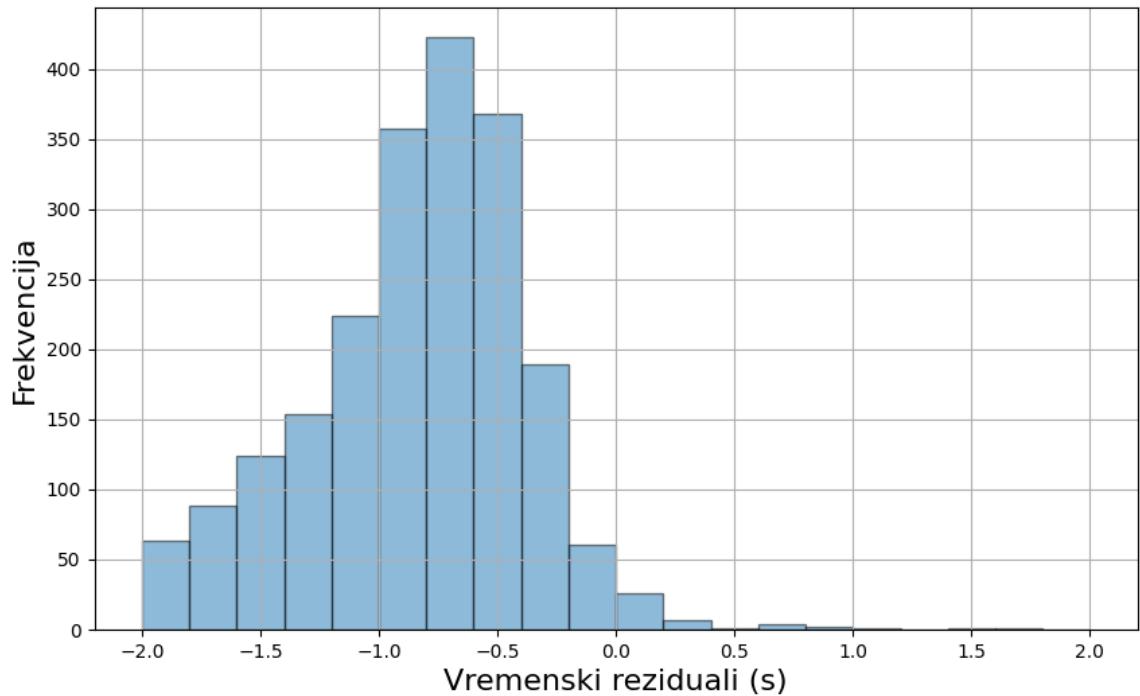
Tablica 6.4. Osnovni statistički parametri za detekcije svih 10 godina. Srednja vrijednost i standardna devijacija se racunaju za vjerojatnosti koje generira PhaseNet.

	<b>Svi</b>	<b>P</b>	<b>S</b>
$N$	2654473	2388420	266053
$\mu$	0.25	0.25	0.28
$\sigma$	0.18	0.17	0.19


Nakon određivanja događaja (vremena početka i koordinata) pomoću GaMMA associatora, generiran je „ML“ katalog potresa s obzirom na svih 10 godina podataka. Katalog ML\_INSTANCE\_FULL sadrži 19762 događaja čiji se raspored može vidjeti na slici 6.14. Distribucija vremenskih reziduala centrirana na -0.90 sekundi sa standardnom devijacijom od 0.54 sekunde se može vidjeti na slici 6.15. Kod usporedbe pravog i ML\_INSTANCE\_FULL kataloga, vrijednost preciznosti iznosi 0.2259, osjetljivosti 0.9225, a F1 iznosi 0.3611. Osjetljivost od 0.9225 znači da ML\_INSTANCE\_FULL katalog sadrži 92.25% događaja koji se nalaze u pravom katalogu. Kako i kod primjena na uzorcima, razlog niske vrijednosti preciznosti i F1 je što ML\_INSTANCE\_FULL katalog sadrži mnogo novih događaja koji se ne nalaze u pravom katalogu. Prostorni reziduali (longitude i latitude) se nalaze na slici 6.16.



Slika 6.14. Distribucija potresa pravog kataloga i ML\_INSTANCE\_FULL kataloga za svih 10 godina.



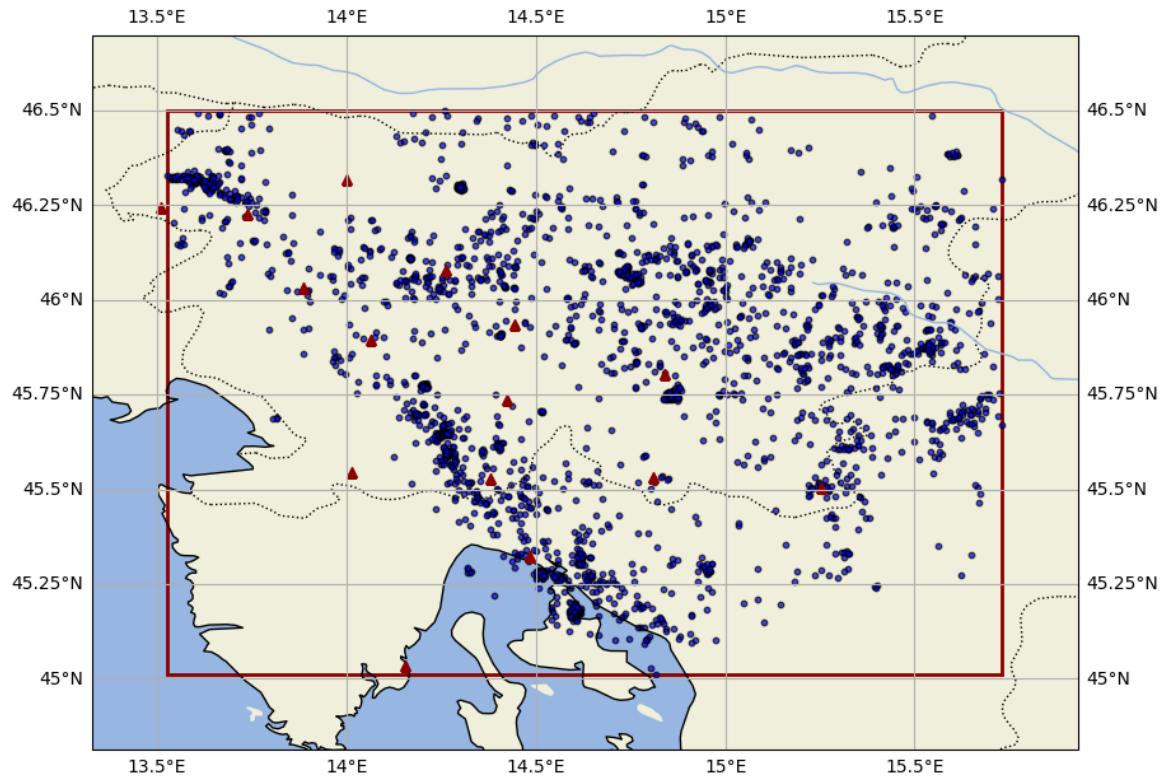
Slika 6.15. Vremenski reziduali (razlika između stvarnih vremena početka i ML vremena početka) između pravog kataloga i ML\_INSTANCE\_FULL kataloga. Distribucija reziduala je centrirana na -0.90 sekundi sa standardnom devijacijom od 0.54 sekunde.



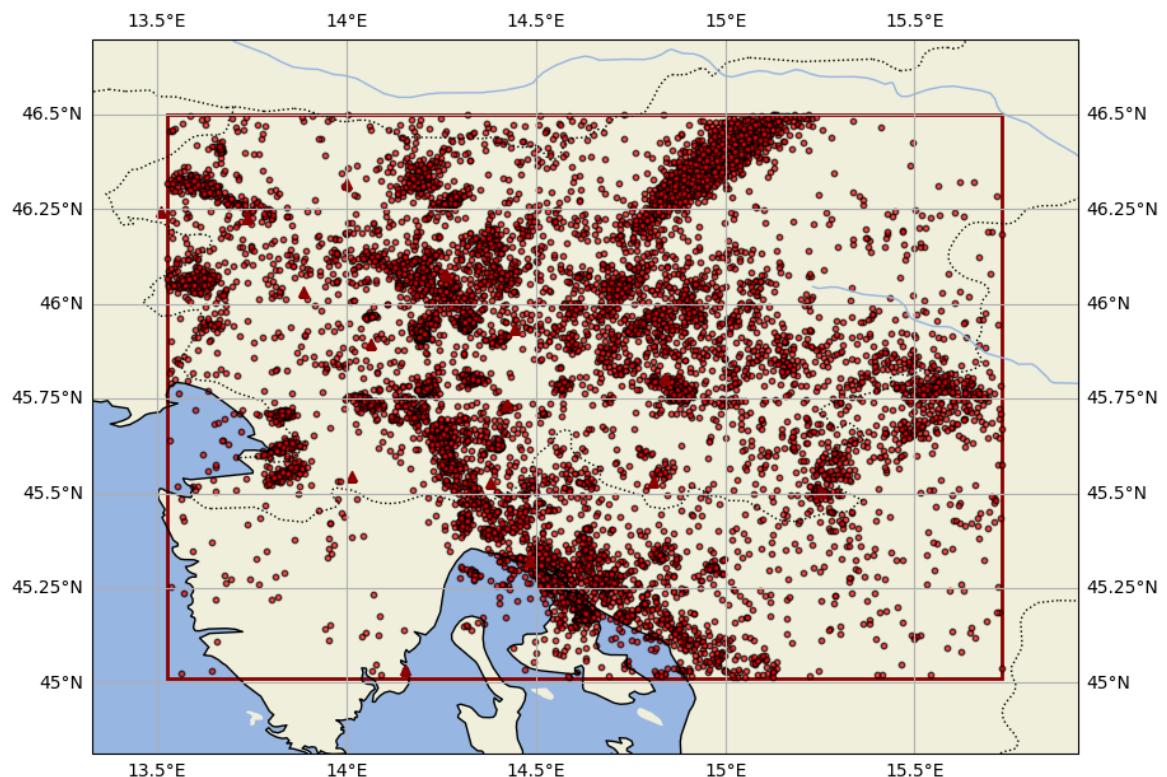
Slika 6.16. (a): Prostorni reziduali (projekcija longitude  $x$  na lokalne koordinate u metrima) između pravog kataloga i ML\_INSTANCE\_FULL kataloga. (b): Prostorni reziduali (projekcija latitue  $y$  na lokalne koordinate u metrima) između pravog kataloga i ML\_INSTANCE\_FULL kataloga.

Najveće pitanje je **jesu li događaji koje PhaseNet/GaMMA Associator profesionalni stvarni** (nasuprot nasumičnom šumu)? Prvi trag daje graf 6.14. Distribucija potresa kroz vrijeme u ML katalogu prati oblik distribucije u pravom katalogu što može ukazati na to da se radi o stvarnim događajima, a ne detektiranom/asociranim šumu. Nadalje, drugi trag daje slika 6.17. Slika 6.17(a) prikazuje prostornu distribuciju po-

tresa iz pravog kataloga, dok 6.17(b) prikazuje prostornu distribuciju događaja iz ML kataloga. Može se primijetiti da nakupine (*clusters*) događaja u oba kataloga prate sličnu prostornu razdiobu (koja je uvjetovana geološko-tektonskim parametrima specifičnim za promatrano područje). Dodatno, ako se distribucija potresa iz ML kataloga usporedi s distribucijom poznatih rasjeda sa slike \*, može se primijetiti da klasteri potresa prate karakteristične oblike poznatih rasjeda kao što je rasjed Rijeka-Velebit koji se proteže uzduž hrvatske obale, Raški rasjed koji se proteže u smjeru NW-SE od Nove Gorice do Ilirske Bistrice, te paralelno s njim Idrijski rasjed koji se također proteže u smjeru NW-SE uzduž kojeg se dogodio najjači potres na promatranom području.

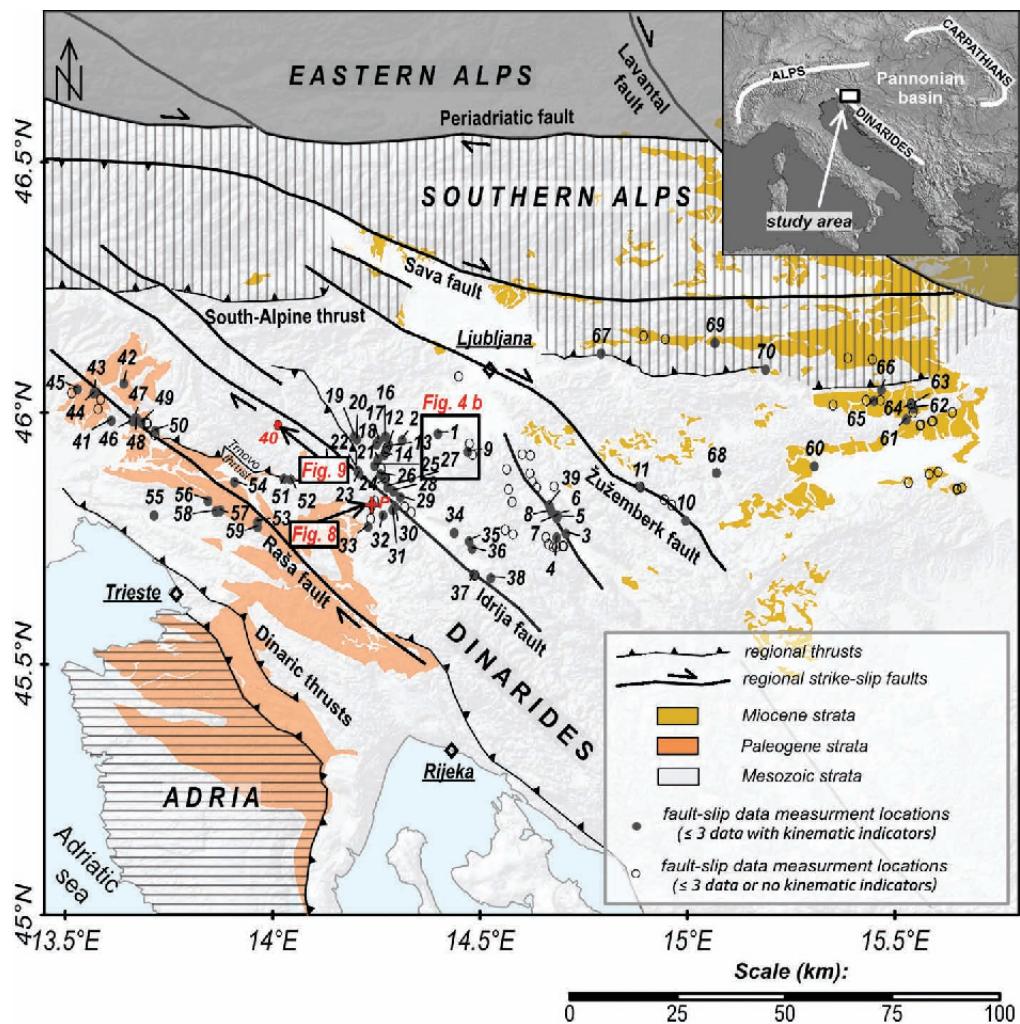


(a)



(b)

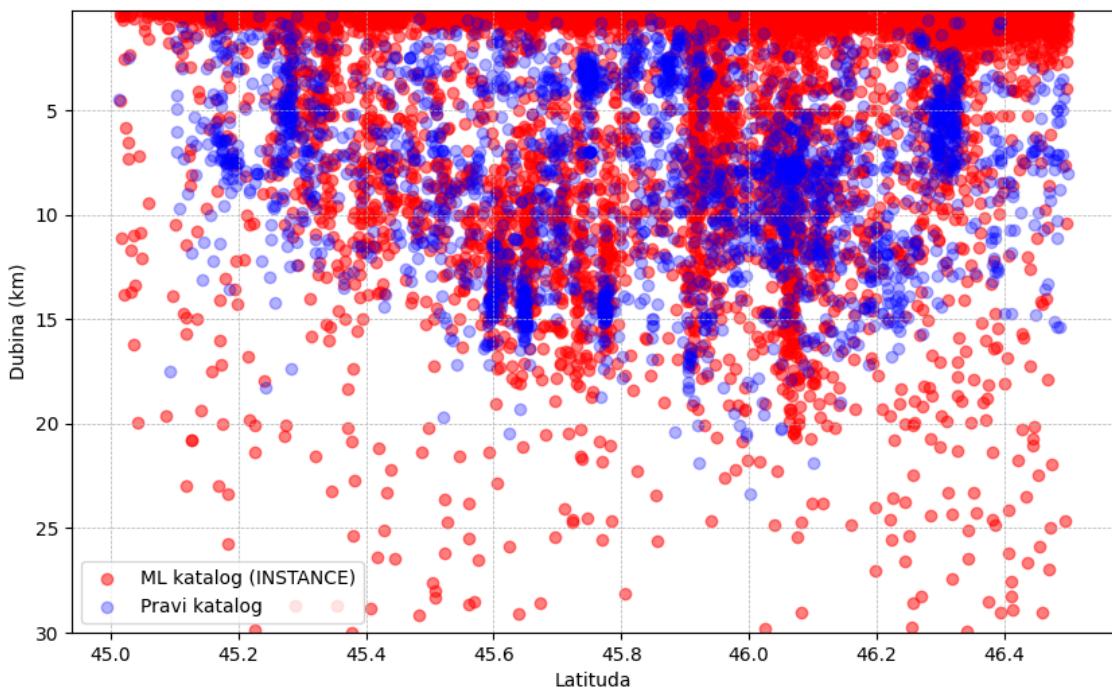
Slika 6.17. (a): Prostorna razdioba potresa iz pravog kataloga. (b): Prostorna razdioba potresa iz ML kataloga.



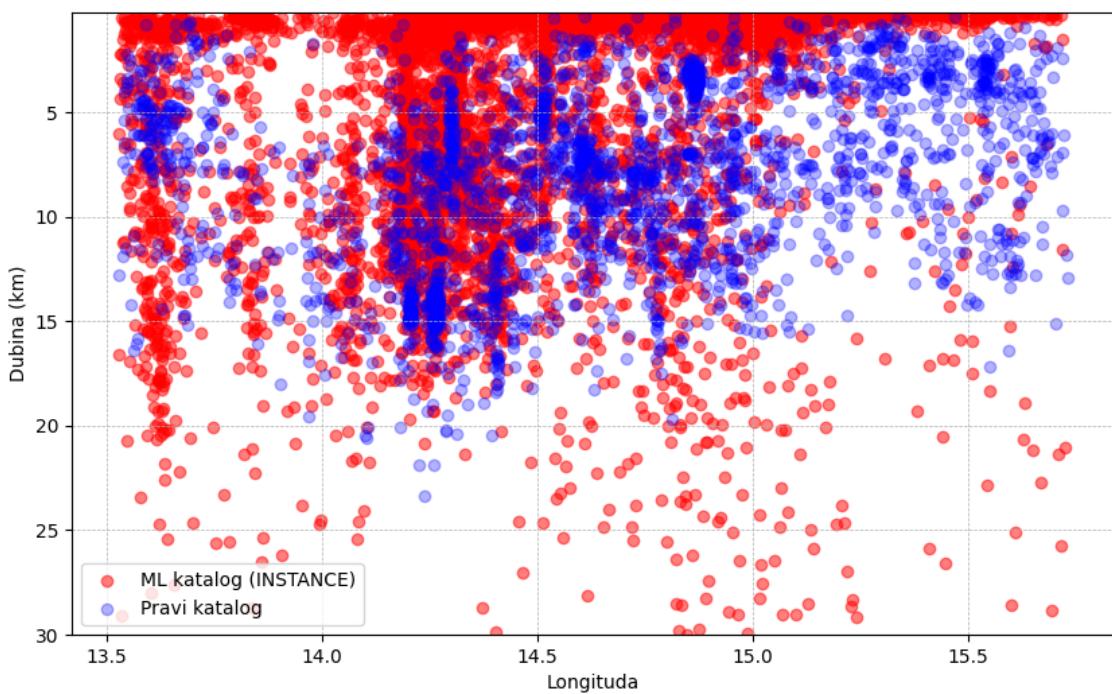
Slika 6.18. Distribucija poznatih rasjeda s područja sjeverozapadnih Dinarida. Preuzeto iz Žibret i Vrabec (2016).

Treći trag daje usporedba distribucija dubina između ova dva kataloga. Na slikama 6.19 i 6.20 se mogu vidjeti distribucije dubina događaja s obzirom na latitudu i longitudu za testni katalog i ML katalog. Jasno se može vidjeti da se specifični klasteri na određenim dubinama podudaraju između dva kataloga. Zanimljivo je također primjetiti klastere koji se ne pojavljuju u pravom katalogu koji mogu biti predmet budućeg istraživanja. Objašnjenje zašto na slici 6.20 na otprilike iznad  $15^{\circ}$  longitude se nalazi vidljivi manjak ML potresa se nalazi na slici 5.3: u bazi podataka koja se koristila za analizu postoji manjak podataka s postaja u istočnom i sjeveroistočnom dijelu Slovenije. To najvjerojatnije uzrokuje detekciju lažnih klastera kao što je kluster na slici 6.21 koji u stvarnosti ne postoje. Daljnji načini na koji bi se moglo provjeriti jesu li asocirani događaji stvarni potresi je analiza i usporedba distribucija magnituda događaja te ručna provjera stručnjaka određenog reprezentativnog uzorka iz populacije

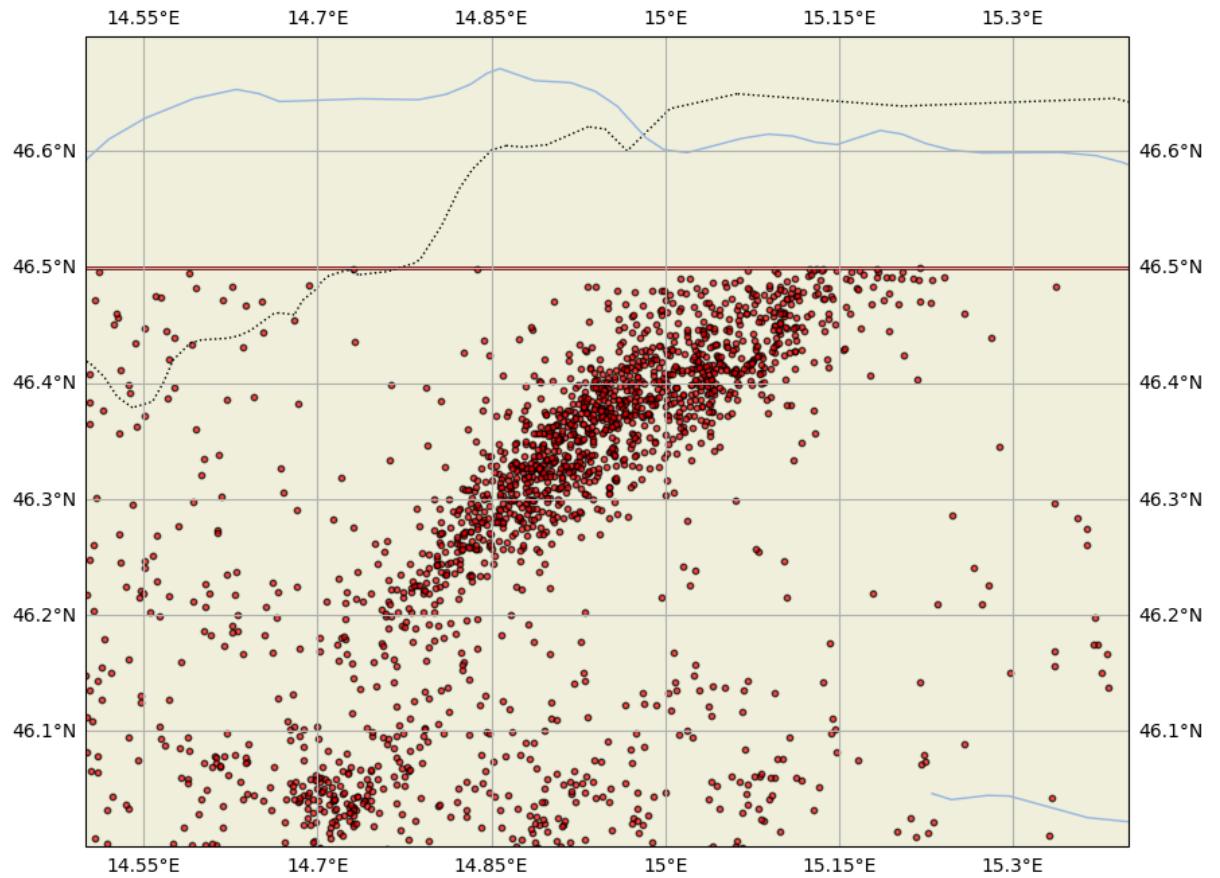
događaja iz ML kataloga.



Slika 6.19. Distribucija dubina potresa s obzirom na latitudu.



Slika 6.20. Distribucija dubina potresa s obzirom na longitudu.



Slika 6.21. Kluster detekcija u ML katalogu u smjeru SI-JZ.

## 7. Zaključak

Ovaj rad istražuje primjenu naprednih tehnika umjetne inteligencije, posebno modela dubokog učenja *PhaseNet* i algoritma asocijacije *GAMMA Associator*, na analizu seizmičkih podataka u području sjeverozapadnih Dinarida. Rezultati istraživanja ne samo da potvrđuju visoku učinkovitost i preciznost ovih modela u detekciji i klasifikaciji potresa, već također otkrivaju nove mogućnosti za poboljšanje primjene modela umjetne inteligencije pomoću učenja prijenosom.

Primjena raznih varijanti *PhaseNet* modela koji su bili trenirani na bazama podataka INSTANCE, STEAD, ETHZ, SCEDC i GEOFON na uzorak jedne godine iz testnog kataloga potresa je omogućila demonstraciju učenja prijenosom kao metode koja značajno smanjuje trošak stvaranja novog *PhaseNet* modela te omogućuje pronašetak najefikasnijeg modela *PhaseNeta*. Navedeni najefikasniji model *PhaseNet*(INSTANCE) se primjenio na cijeli testni katalog potresa te je, uz pomoć *GAMMA Associatora* uspio potvrditi preko 92% postojećih potresa, te je otkrio još 10 puta više potencijalnih novih potresa, pritom mnogostruko smanjujući trošak i vrijeme koji bi bio potreban čitavom timu seismologa. Stroga kalibracija parametara *GAMMA Associatora* smanjuje vjerojatnost da su asocirani događaji lažno pozitivni događaji. Kombinacija *PhaseNeta* (primjenom učenja prijenosom) te *GAMMA Associatora* ima potencijal ne samo da detektira mnogo više potencijalnih potresa u mnogo kraćem vremenu, nego i da rastreti seismologe od potrebe ručnog rada određivanja faza, omogućavajući im da svoje vrijeme fokusiraju na važnije stvari.

Nadalje, kvalitativno su demonstrirane tehnike pomoću kojih bi se moglo potvrditi jesu li događaji u ML katalogu stvarni, poput usporedbe vremenskih i prostornih distribucija potresa između stvarnog i ML kataloga. Daljnja detaljna analiza je potrebna kako bi se odredilo stopa efikasnosti detekcije stvarnih potresa, kao što je analiza distribucije magnituda te ručna provjera asociranih događaja od strane stručnjaka.

Bitno je za naglasati da je primjena AI u seismologiji i drugim znanostima još uvijek jako eksperimentalno i empirijsko područje (a također i općenita umjetna inteligencija) koje se dinamično mijenja iz dana u dan, te u bliskoj budućnosti obećava promjeniti način na koji se uopće pristupa znanosti. Zbog toga su *PhaseNet* i *GAMMA Associator* podložni velikim promjenama u pristupu i arhitekturi (bitno je naglasiti da su tijekom pisanja ovog rada, *PhaseNet* i *GAMMA Associator* prošli kroz preko 20 inačica pro-

mjena arhitekture i pristupa zbog čega je od autora često bila zahtjevana retrogradna adaptacija i ažuriranje).

Dalje, prilagodba i optimizacija AI modela za specifične geološke i seizmičke kontekste, kao što je demonstrirano kroz strategiju učenja prijenosom, otvara put za široku primjenu ovih tehnologija u različitim područjima i za različite scenarije. To ne samo da poboljšava preciznost detekcije i klasifikacije, već također omogućuje detaljniju analizu i bolje razumijevanje lokalnih geoloških struktura i dinamika.

Ovo istraživanje također naglašava potrebu za dalnjim istraživanjima u području integracije AI u seismologiji, uključujući razvoj novih modela, algoritama i pristupa obradi podataka. Očekuje se da će budući radovi uključivati detaljniju analizu podataka, razvoj algoritama za automatsku klasifikaciju tipova seizmičkih događaja, kao i potencijalnu izradu hrvatskog kataloga potresa za različita područja koji će omogućiti još veću preciznost kod detekcije potresa.

## Literatura

- Allen, R. V. (1978): *Automatic earthquake recognition and timing from single traces*. Bulletin of the Seismological Society of America, 68(5), 1521–1532.
- Alpaydin, E. (2020): *Introduction to Machine Learning (4th ed.)*. MIT Press Academic.
- Basodi, S., Ji, C., Zhang, H., & Pan, Y. (2020): *Gradient Amplification: An efficient way to train deep neural networks*. arXiv preprint arXiv:2006.10560.
- Bozinovski, S., & Fulgosi, A. (1976): *The influence of pattern similarity and transfer learning upon the training of a base perceptron B2*. In Proceedings of Symposium Informatica 3-121-5 (pp. 1-5). Bled.
- Chai, C., Maceira, M., Santos-Villalobos, H. J., Venkatakrishnan, S. V., Schoenball, M., Zhu, W., ... & EGS Collab Team. (2020): *Using a deep neural network and transfer learning to bridge scales for seismic phase picking*. Geophysical Research Letters, 47, e2020GL088651.
- Cortes, C., & Vapnik, V. (1995): *Support-Vector Networks*. Machine Learning, 20, 273-297.
- Cox, D.R. (1958): *The Regression Analysis of Binary Sequences*. Journal of the Royal Statistical Society: Series B, 20, 215-242.
- Dasović, I., Herak, M., & Prevolnik, S. (2021). *Potresno inženjerstvo - Obnova zidanih zgrada*. Građevinski fakultet Sveučilišta u Zagrebu.
- Elman, J. L. (1990): *Finding structure in time*. Cognitive Science, 14(2), 179-211.
- Fukushima, K. (1980): *Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position*. Biological Cybernetics, 36, 193-202.
- Fukushima, K. (1969): *Visual feature extraction by a multilayered network of analog threshold elements*. IEEE Transactions on Systems Science and Cybernetics, 5 (4): 322–333.

- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2015): *Deep Learning*. arXiv preprint arXiv:1505.04597.
- Hinton, G. E., Osindero, S., & Teh, Y.-W. (2006): *A fast learning algorithm for deep belief nets*. Neural Computation, 18(7), 1527-1554.
- Jordan, M. I., & Mitchell, T. M. (2015): *Machine learning: Trends, perspectives, and prospects*. Science, 349(6245), 255-260.
- Kissling, E., Ellsworth, W. L., Eberhart-Phillips, D., & Kradolfer, U. (1994). Initial reference models in local earthquake tomography. *Journal of Geophysical Research: Solid Earth*, 99, 19635–19646. <https://doi.org/10.1029/93JB03138>
- Kleene, Stephen C. (1956): "Representation of Events in Nerve Nets and Finite Automata". Automata Studies, Annals of Math. Studies. Princeton Univ. Press. 34. Here: sect.9, p.37-40.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012): *ImageNet classification with deep convolutional neural networks*. In Advances in Neural Information Processing Systems 25 (pp. 1097-1105).
- Küperkoch, L., Meier, T., Lee, J., Friederich, W., & EGELADOS Group. (2010): *Automated determination of P-phase arrival times at regional and local distances using higher order statistics*. Geophysical Journal International, 181, 1159-1170.
- Lienert, B. R., & Havskov, J. (1995). A Computer Program for Locating Earthquakes Both Locally and Globally. *Seismological Research Letters*, 66, 26–36. <https://doi.org/10.1785/gssrl.66.5.26>
- McCorduck, P. (2004): *Machines who think: A personal inquiry into the history and prospects of artificial intelligence (2nd ed.)*. A K Peters/CRC Press.
- Megies, T., Beyreuther, M., Barsch, R., Krischer, L., & Wassermann, J. (2011): *ObsPy: A Python Toolbox for Seismologists, Seismological Observatories, and Data Centers*. Annals of Geophysics, 54(1).
- Michelini, A., Cianetti, S., Gaviano, S., Giunchi, C., Jozinović, D., & Lauciani, V. (2021): *INSTANCE – the Italian seismic dataset for machine learning*. Earth System Science Data, 13(5509-5544).

- Mousavi, S. M., & Beroza, G. C. (2020): *A machine-learning approach for earthquake magnitude estimation*. Geophysical Research Letters, 47, e2019GL085972.
- Mousavi, S. M., Sheng, Y., Zhu, W., & Beroza, G. C. (2019): *STanford EArthquake Dataset (STEAD): A Global Set of Seismic Signals for AI*. IEEE Access, 7, 179464-179472.
- Mousavi, S.M., Ellsworth, W.L., Zhu, W., et al. (2020): *Earthquake transformer—an attentive deep-learning model for simultaneous earthquake detection and phase picking*. Nature Communications, 11, 3952.
- Rajh, G., Stipčević, J., Živčić, M., Herak, M., and Gosar, A. (2021): *Crustal velocity structure beneath the NW Dinarides from 1-D hypocenter-velocity inversion*. EGU General Assembly 2021, online, 19–30 Apr 2021, EGU21-8226.
- Robbins, H., & Monro, S. (1951): *A stochastic approximation method*. The Annals of Mathematical Statistics, 22(3), 400-407.
- Ronneberger, O., Fischer, P., & Brox, T. (2015): *U-Net: Convolutional Networks for Biomedical Image Segmentation*. In LNCS (Vol. 9351, pp. 234-241). Springer International Publishing.
- Ross, Z. E., Yue, Y., Meier, M.-A., Hauksson, E., & Heaton, T. H. (2019): *Phase-Link: A deep learning approach to seismic phase association*. Journal of Geophysical Research: Solid Earth, 124(2), 856–869.
- Ross, Z. E., Meier, M.-A., Hauksson, E., & Heaton, T. H. (2019): *Generalized seismic phase detection with deep learning*. Geophysical Journal International, 216(1), 261-267.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986): *Learning representations by back-propagating errors*. Nature, 323(533), 533-536.
- Russell, S. J., & Norvig, P. (2010): *Artificial intelligence: A modern approach (3rd ed.)*. Prentice Hall.
- Saragiannis, C. D., Hadjileontiadis, L. J., & Panas, S. M. (2002): *PAI-S/K: A Robust Automatic Seismic P Phase Arrival Identification Scheme*. IEEE Transactions on Geoscience and Remote Sensing, 40(6), 1395-1404.

- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., van den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., Dieleman, S., Grewe, D., Nham, J., Kalchbrenner, N., Sutskever, I., Lillicrap, T., Leach, M., Kavukcuoglu, K., Graepel, T., & Hassabis, D. (2016): *Mastering the game of Go with deep neural networks and tree search*. *Nature*, 529(7587), 484–489.
- Sleeman, R., & van Eck, T. (1999): *Robust automatic P-phase picking: an on-line implementation in the analysis of broadband seismogram recordings*. *Physics of the Earth and Planetary Interiors*, 113(5), 265–275.
- Turing, A. M. (1950): *Computing machinery and intelligence*. *Mind*, LIX(236), 433–460.
- Vičič, B., Aoudia, A., Javed, F., Foroutan, M., & Costa, G. (2019). Geometry and mechanics of the active fault system in western Slovenia. *Geophysical Journal International*, 217(3), 1755–1766.
- Woollam, J., Münchmeyer, J., Tilmann, F., Rietbrock, A., Lange, D., Bornstein, T., Diehl, T., Giunchi, C., Haslinger, F., Jozinović, D., Michelini, A., Saul, J., & Soto, H. (2022): *SeisBench—A Toolbox for Machine Learning in Seismology*. *Seismological Research Letters*, 93(3), 1695–1709.
- Woollam, J., Rietbrock, A., Bueno, A., & De Angelis, S. (2019): *Convolutional Neural Network for Seismic Phase Classification, Performance Demonstration over a Local Seismic Network*. *Seismological Research Letters*, 90(2A), 491–502.
- Zhu, W., & Beroza, G. (2018): *PhaseNet: A Deep-Neural-Network-Based Seismic Arrival Time Picking Method*. *Geophysical Journal International*, 216.
- Zhu, W., McBrearty, I., Mousavi, S. M., Ellsworth, W., & Beroza, G. (2021): *Earthquake Phase Association using a Bayesian Gaussian Mixture Model*.
- Žibret, L., & Vrabec, M. (2016). Paleostress and kinematic evolution of the orogen-parallel NW-SE striking faults in the NW External Dinarides of Slovenia unraveled by mesoscale fault-slip data analysis. *Geologia Croatica*, 69(3), 295–305. <https://doi.org/10.4154/gc.2016.30>

URL1. <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>. Zadnji pristup 3. siječnja 2024.

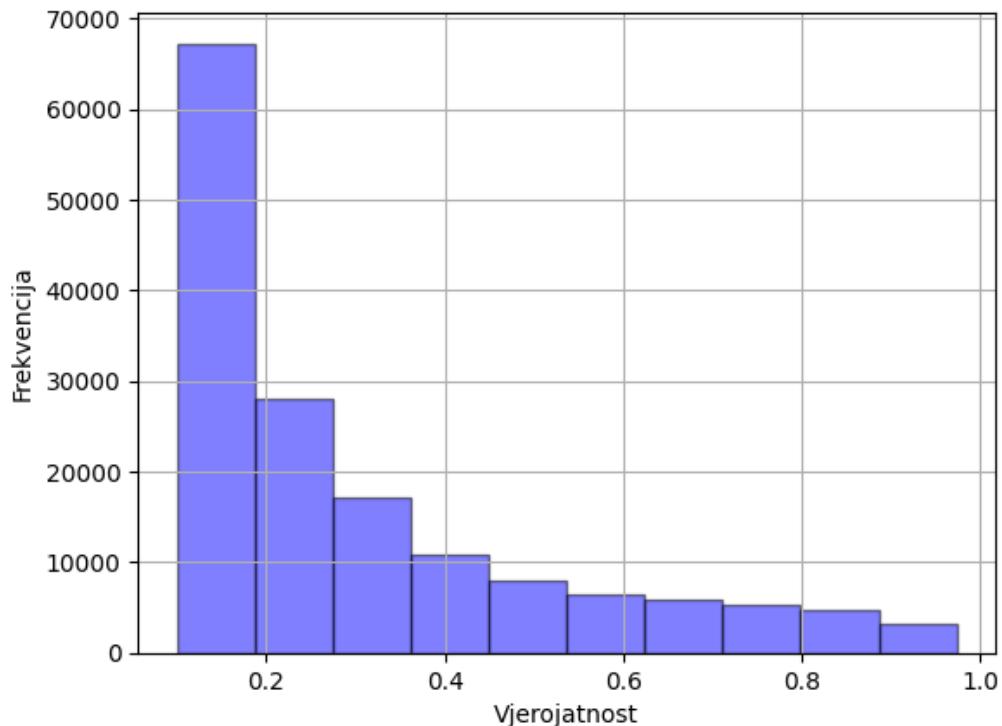
URL2. <https://byjus.com/>). Zadnji pristup 7. siječnja 2024.

URL3. [https://www.researchgate.net/figure/Love-a-and-Rayleigh-b-surface-wave-displacements-for-a-horizontal-propagation-from\\_fig3\\_295863200](https://www.researchgate.net/figure/Love-a-and-Rayleigh-b-surface-wave-displacements-for-a-horizontal-propagation-from_fig3_295863200)). Zadnji pristup 14. siječnja 2024.


URL4. [https://geo.libretexts.org/Learning\\_Objects/Laboratory/Book%3A\\_Laboratory\\_Manual\\_For\\_Introductory\\_Geology\\_\(Deline\\_Harris\\_and\\_Tefend\)](https://geo.libretexts.org/Learning_Objects/Laboratory/Book%3A_Laboratory_Manual_For_Introductory_Geology_(Deline_Harris_and_Tefend))). Zadnji pristup 22. siječnja 2024.

## Dodatak A

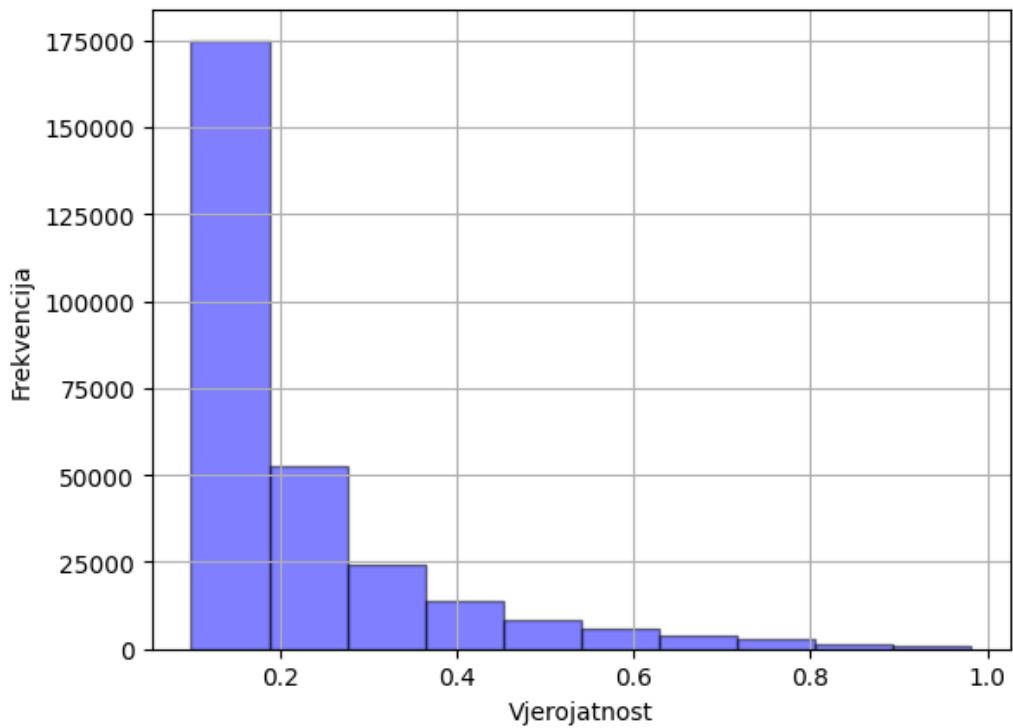
U dodatku A se nalaze detektirane faze za sve ostale PhaseNet modelle uz pojedinačne P- i S-faze.



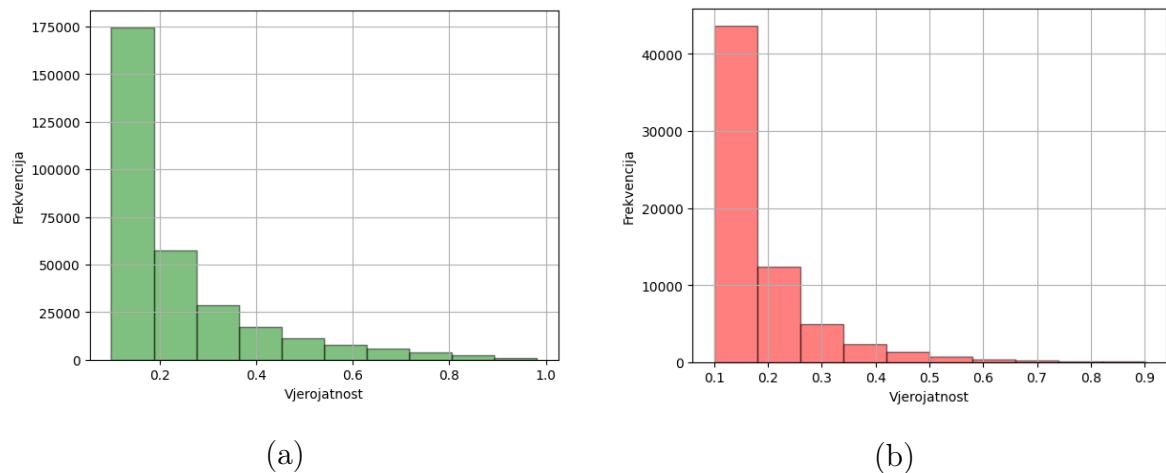
Slika A1. Histogram vjerojatnosti detekcija P- i S-faza za PhaseNet(ETHZ) model.



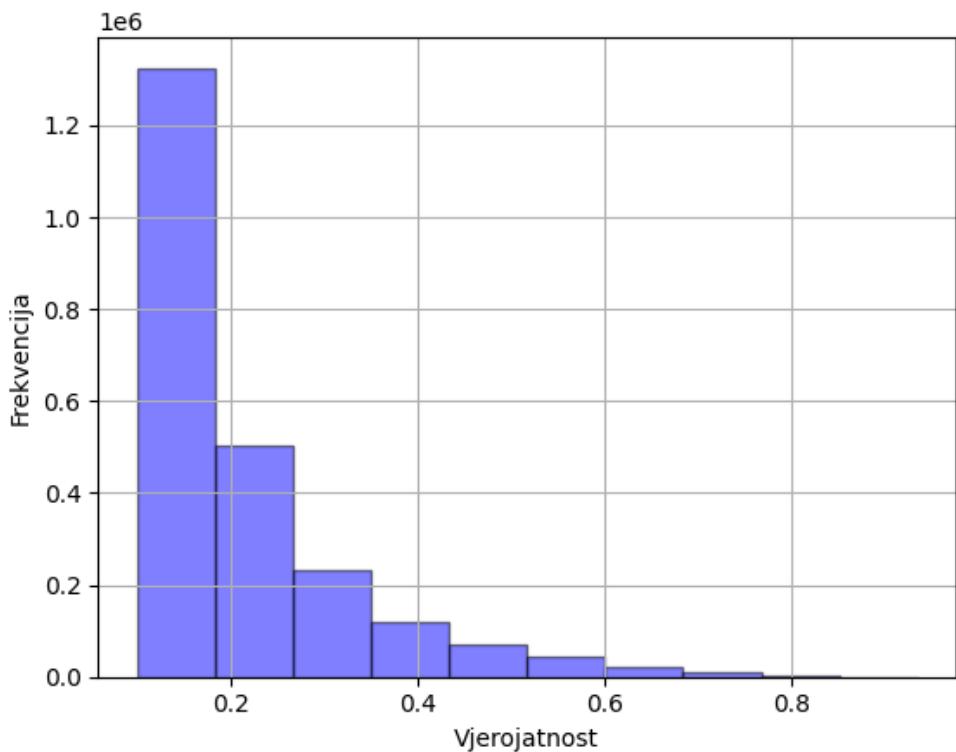
Slika A2. (a): Histogram vjerojatnosti detekcija P-faza. (b): Histogram vjerojatnosti detekcija S-faza za PhaseNet(ETHZ) model.



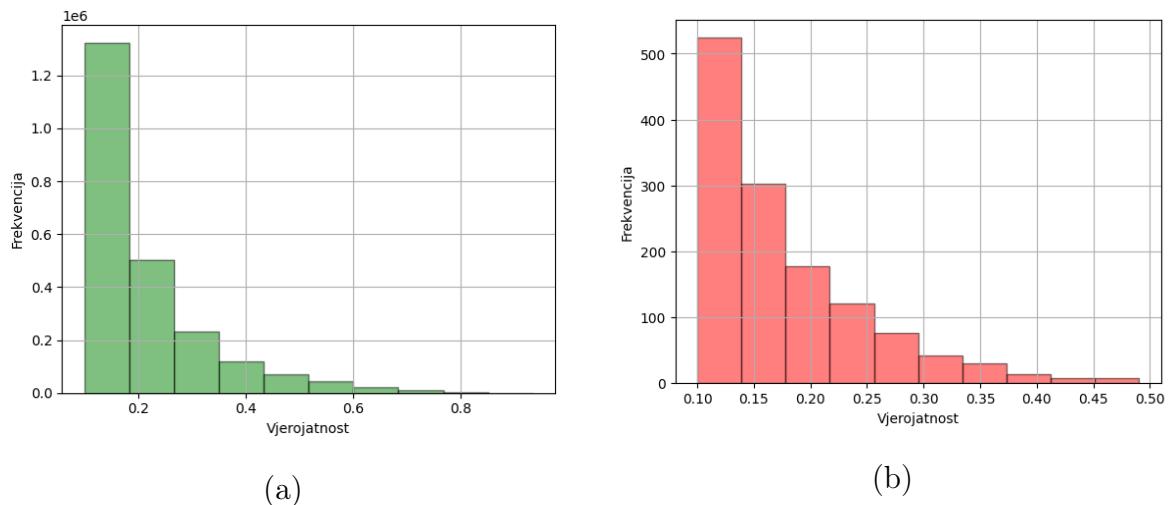
Slika A3. Histogram vjerojatnosti detekcija P- i S-faza za PhaseNet(SCEDC) model.



Slika A4. (a): Histogram vjerojatnosti detekcija P-faza. (b): Histogram vjerojatnosti detekcija S-faza za PhaseNet(SCEDC) model.



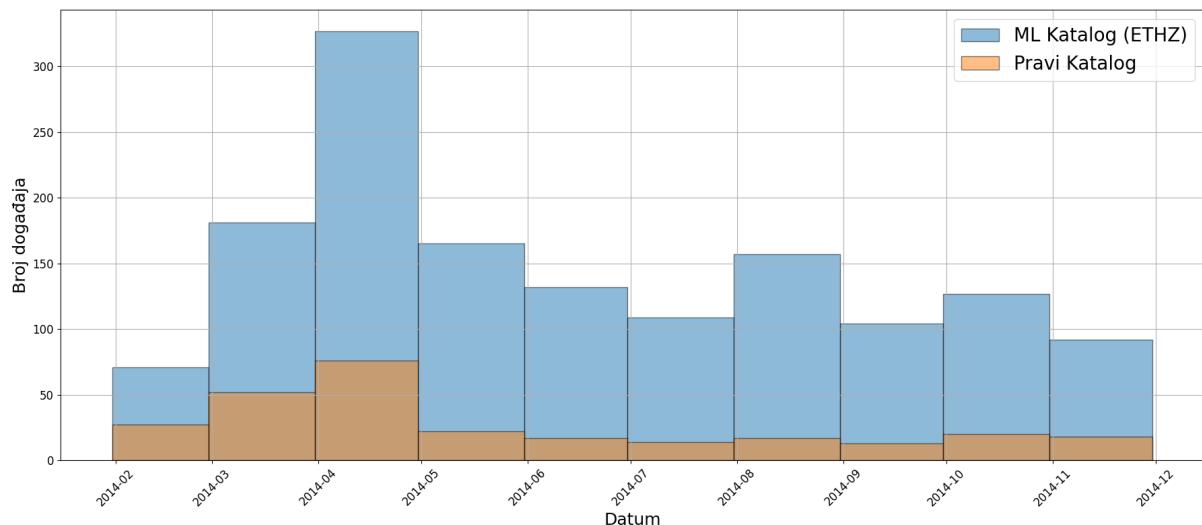
Slika A5. Histogram vjerojatnosti detekcija P- i S-faza za PhaseNet(GEOFON) model.



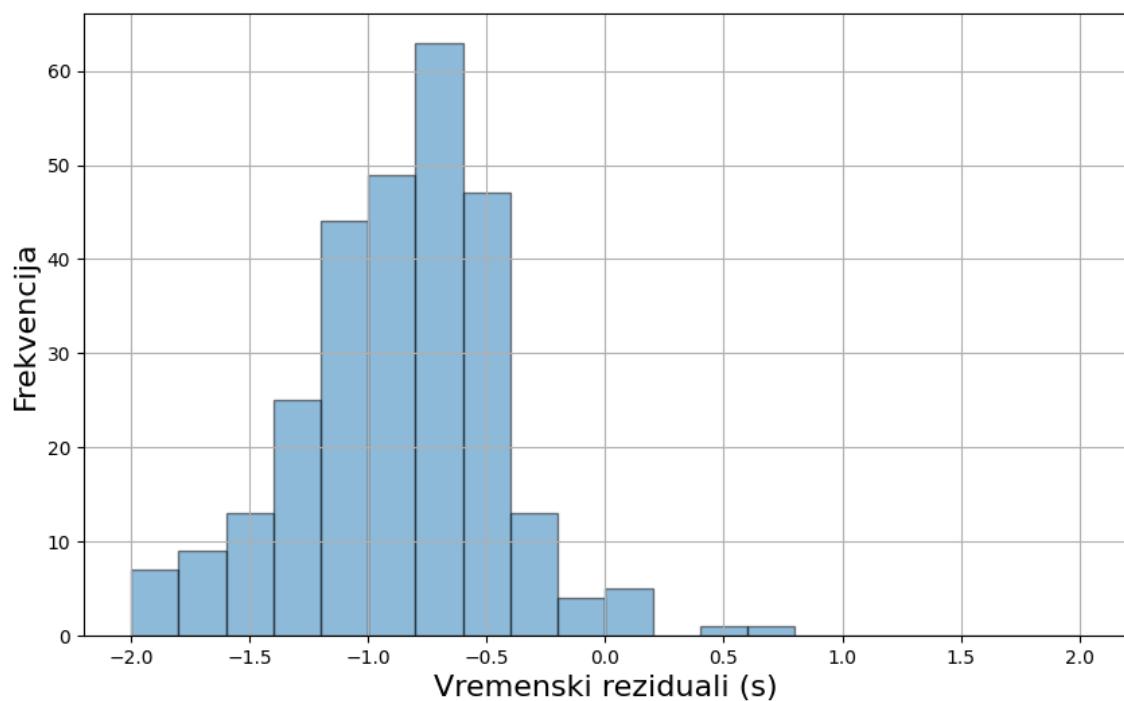
Slika A6. (a): Histogram vjerojatnosti detekcija P-faza. (b): Histogram vjerojatnosti detekcija S-faza za PhaseNet(GEOFON) model.

## Dodatak B

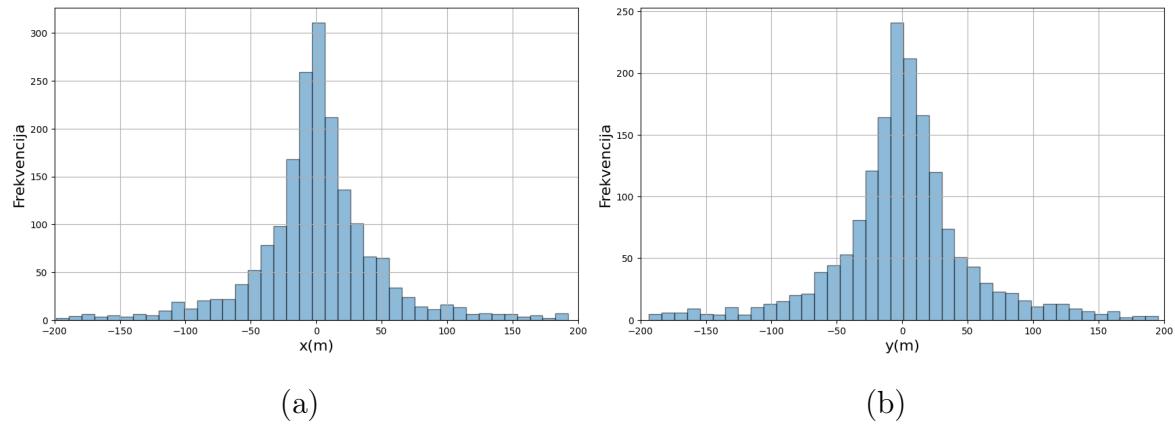
U dodatku B se nalaze vremenski i prostorni reziduali za sve ostale ML kataloge za uzorak podataka iz 2014. godine, te distribucija događaja kroz 2014. godinu.



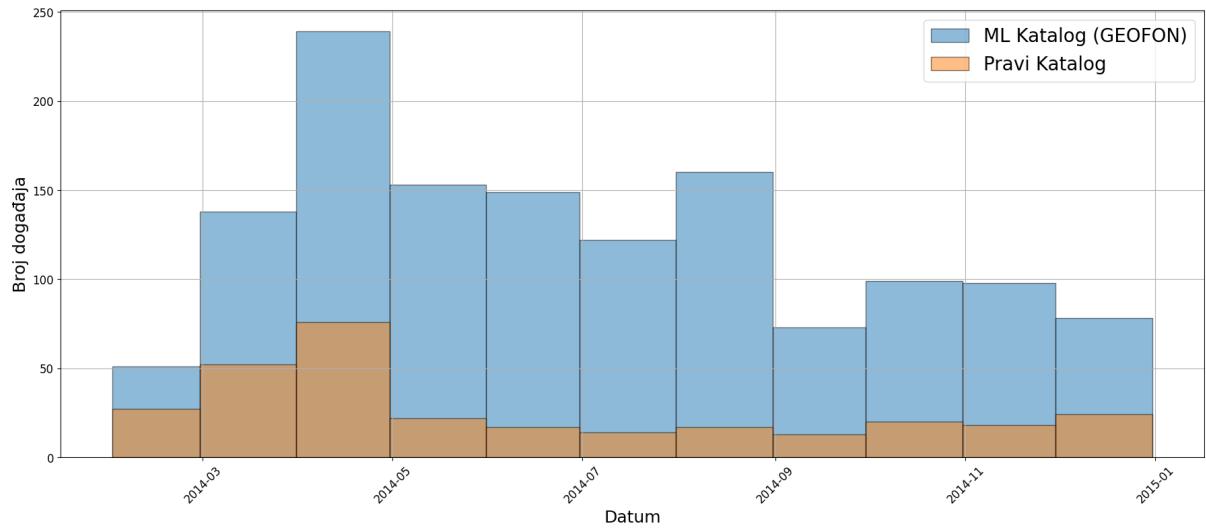
Slika B7. Distribucija potresa pravog kataloga i ML\_ETHZ kataloga tijekom 2014. godine.



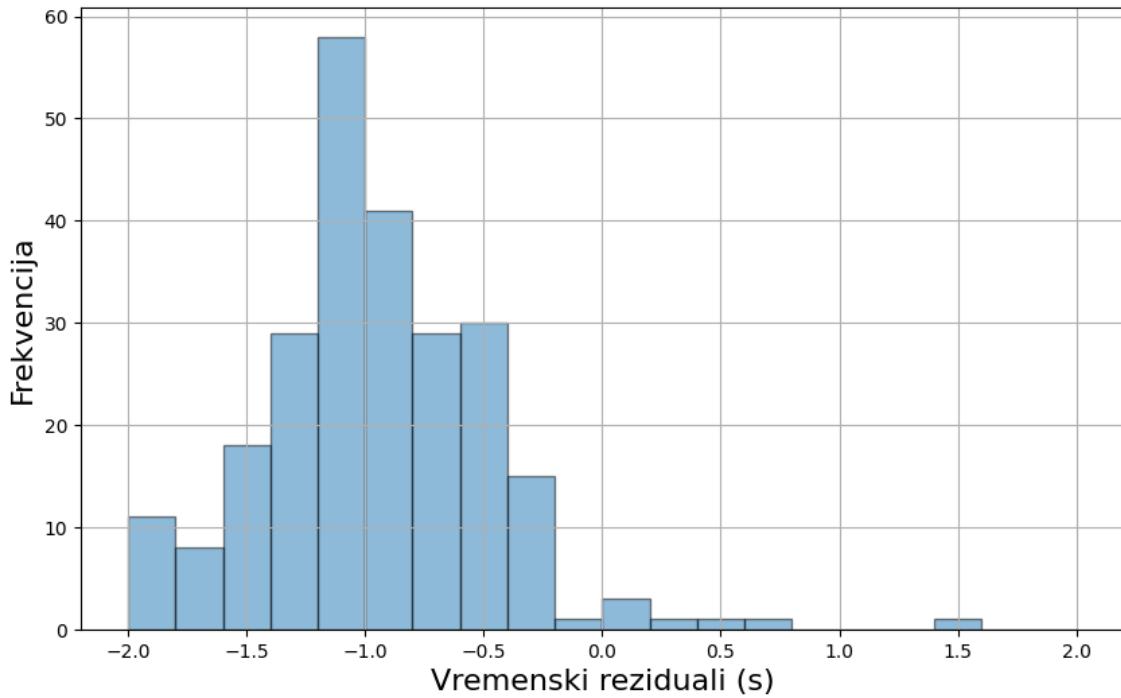
Slika B8. Vremenski reziduali (razlika između stvarnih vremena početka i ML vremena početka) između pravog kataloga i ML\_ETHZ kataloga.



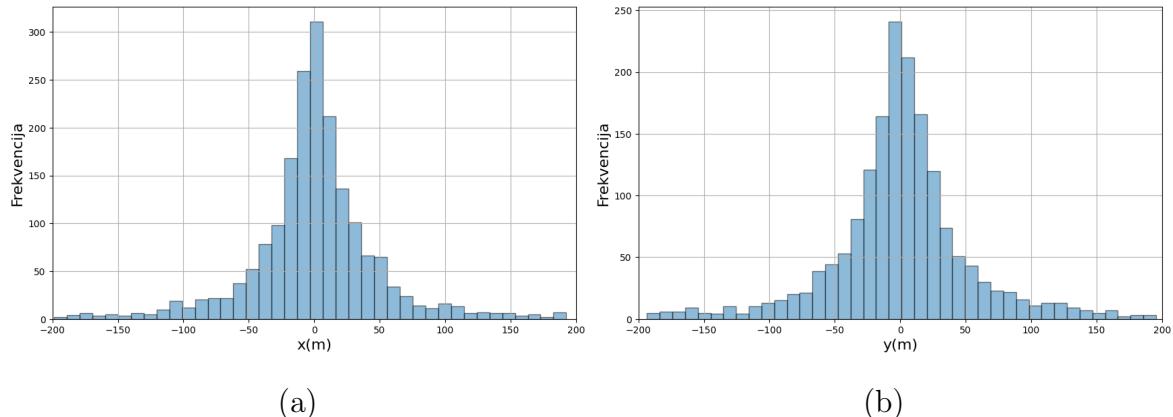
Slika B9. (a): Prostorni reziduali (projekcija longitude  $x$  na lokalne koordinate u metrima) između pravog kataloga i ML\_ETHZ kataloga. (b): Prostorni reziduali (projekcija latitue  $y$  na lokalne koordinate u metrima) između pravog kataloga i ML\_ETHZ kataloga.



Slika B10. Distribucija potresa pravog kataloga i ML\_GEOFON kataloga tijekom 2014. godine.



Slika B11. Vremenski reziduali (razlika između stvarnih vremena početka i ML vremena početka) između pravog kataloga i ML\_GEOFON kataloga.



Slika B12. (a): Prostorni reziduali (projekcija longitude  $x$  na lokalne koordinate u metrima) između pravog kataloga i ML\_GEOFON kataloga. (b): Prostorni reziduali (projekcija latitue  $y$  na lokalne koordinate u metrima) između pravog kataloga i ML\_GEOFON kataloga.

## Dodatak C

### C1. ObsPy

ObsPy, vrhunska Python biblioteka otvorenog koda, zadnjih godina je postala nezamjenjiv alat u području seismologije. Razvijen u suradnji sa seismoložima iz raznih

institucija diljem svijeta, ObsPy je dizajniran za olakšavanje obrade, analize i vizualizacije seizmoloških podataka. Njegova integracija s Pythonom, jednim od najpopularnijih programskih jezika, omogućuje intuitivnu i pristupačnu platformu koja može poslužiti i iskusnim istraživačima i početnicima u tom području (Beyreuther et al., 2010).

Korištenjem Obspy funkcionalnosti *read*, *stream*, *resample*, *normalize*, *merge*, napravit će se prethodna obrada opisana u prethodnom poglavlju. *Trace* objekti (kontinuirani seizmički podaci s jedne postaje) spojeni zajedno u *stream* objekt (kolekcija *trace* objekata) će se integrirati sa *Seisbench* API-om u svrhu primjene modela *PhaseNet*.

## C2. *SeisBench*

**SeisBench** je sveobuhvatan okvir otvorenog koda dizajniran za standardizaciju i pojednostavljenje primjene strojnog učenja u seismologiji. Djeluje kao objedinjena pristupna točka, nudeći standardizirani pristup nizu ML modela i skupova seizmičkih podataka putem jednog sučelja, značajno poboljšavajući korisničko iskustvo i smanjujući duljinu i kompleksnost učenja. Okvir je izgrađen da bude proširiv, potičući doprinose zajednice i osiguravajući da ostane u tijeku s najnovijim razvojem i skupovima podataka u seismologiji (Münchmeyer et al., 2021).

Podatkovni modul uvodi standardizirani format za seizmičke valne oblike i metapodatke, prvenstveno koristeći Hierarchical Data Format 5 (HDF5) za pohranjivanje neobrađenih valnih oblika. Ova standardizacija osigurava usporedivost i ponovljivost u seizmičkom ML istraživanju, dok dodatne optimizacije izvedbi poboljšavaju IO brzinu čitanja/pisanja, što je ključno za učinkovito treniranje i primjenu ML modela. *SeisBench* uključuje različite referentne skupove podataka koji pokrivaju širok raspon seizmičkih okruženja, bitnih za trening robusnih algoritama i procjenu različitih tehnika strojnog učenja (Woollam et al., 2019; Zhu i Beroza, 2019).

Dok se u početku fokusirao na modele dubokog učenja za zadatke kao što su detektiranje faza i otkrivanje dogadaja, *SeisBench*ova fleksibilna arhitektura također omogućuje integraciju i usporedbu tradicionalnih metoda. Omogućuje tipične korake za povećanje podataka i prethodnu obradu putem API-ja za proširenje, čime se štedi vrijeme i osigurava da korisnici ne moraju pisati novi kod za uobičajene operacije. Okvir također standardizira proces izgradnje pipeline-a za generiranje podataka za trening ML modela, minimizirajući pogreške i smanjujući potrebnu količinu kodiranja (Ross et

al., 2018).

SeisBench dolazi s primjerima radnih procesa koji pokazuju njegovu funkcionalnost, pružajući korisnicima predloške koje mogu prilagoditi svojim specifičnim potrebama. Ovi primjeri pokrivaju korištenje unaprijed treniranih modela za odabir novih seizmičkih stream-ova, trening modela i usporednu analizu različitih modela u različitim skupovima podataka (Mousavi et al., 2020.). Rješavanjem nekih od uobičajenih problema na koja se nailazi pri razvoju ML algoritama, SeisBench ima za cilj pomoći korisnicima da ponavljaju i implementiraju svoje modele, unapređujući razvoj sljedeće generacije ML tehnika unutar seismologije. Gledajući u budućnost, *SeisBench* predviđa uključivanje modela za složenije probleme poput određivanja hipocentra i procjene parametara izvora (Mousavi et al., 2019).

## Dodatak D

Kako razviti model od početka do kraja? Pristup od početka do kraja nije striktno sistematičan, te proces sadrži puno „pokušaja i pogrešaka“. Najviše vremena se ulaže u prikupljanje kvalitetnog skupa podataka te pripremi tog skupa podataka. Najčešći pristup u razvoju modela (Russell i Norvig, 2020) se temelji na koracima određivanja problema, prikupljanja podataka i procjeni, odabiru modela i treningu te interpretabilnosti i objašnjivosti.

**Za određivanje problema** potrebno je odrediti koju komponentu određenog problema se može riješiti pomoću tehnika strojnog učenja te na koji način onda pristupiti tom problemu. U jeziku strojnog učenja, potrebno je definirati funkciju gubitka.

**Prikupljanje podataka i procjena.** Svaki projekt strojnog učenja treba podatke kako bi model učio. Postoje razna „pravila“ kolika količina podataka je potrebna za određeni projekt: milijuni za „teške“ probleme, tisuće za „lagane“, 10 puta više podataka nego parametara modela, više podataka za nelinearni model u odnosu na linearne itd. Kada je za određeni projekt ograničena količina podataka koja se može prikupiti, može se povećati količina podataka (engl. *Data Augmentation*) pomoću malih promjena inačica. Jedna od najbitnijih stvari kod odabira podataka je procjena značajki.

Na primjer, ako agent procjenjuje cijene kuća u nekom kvartu, potrebno je razmisliti koje značajke treba uzeti u obzir: broj soba, starost kuće, veličina dvorišta, postoji li u blizini parkiralište, prosječni BDP grada itd. Procjena značajki se smatra jednim od najbitnijih koraka koji određuju koliko će biti uspješan projekt strojnog učenja. Nakon uspješnog odabira i pripreme podataka te procjene značajki, potrebno je izvršiti istraživačku analizu podataka.

**Odabir modela i trenin**g. Nakon određivanja vrste problema, prikupljanjem podataka, filtriranjem i odabirom značajki, potrebno je odrediti kakva je vrsta modela najpoželjnija. Postoji mnogo tipova modela kao što su: slučajna šuma, linearna regresija, logistička regresija, duboka neuronska mreža, ansambl itd. Određeni model je najefikasniji za određenu vrstu problema. Nakon treninga i prilagođavanja modela na skupu podataka za trening, potrebno je provjeriti moć predviđanja modela na validacijskom skupu podataka koji procjenjuje koliko je model precizan te pomoći kojeg se modificiraju hiperparametri modela. Konačno, skup podataka za testiranje služi za konačnu procjenu i evaluaciju treniranog modela.

**Interpretabilnost i objašnjivost.** Za model se kaže da je interpretabilan ako se može odrediti zašto je generirao određenu izlaznu vrijednost za određenu ulaznu vrijednost i kako se ta izlazna vrijednost može promijeniti s promjenom ulazne vrijednosti. Model se smatra objašnjivim ako se može razumjeti konstrukcija kojom dolazi do odgovora. Neki modeli kao duboke neuronske mreže ne mogu se izravno interpretirati da ljudskom biću imaju smisla zbog visoko kompleksnih nelinearnih veza među slojevima. No, može se postaviti objašnjenje kojim neuronska mreža dolazi do odgovora, npr.: ako gleda sliku životinje, prvo detektira koliko ima nogu, potom ima li dlaku, potom proučava okruženje itd. Vrlo često neće postojati jednostavno objašnjenje: prvi razlog zašto se koristi strojno učenje umjesto ručno napisanog programa je taj što je problem kompleksan i nemoguće je napisati tradicionalni program koji bi riješio takav problem. Zbog toga se ni ne može očekivati da će uvjek postojati jednostavno objašnjenje.