Sveučilište J. J. Strossmayera u Osijeku
Fakultet elektrotehnike, računarstva i informacijskih tehnologija

Igor Fosić

Otkrivanje anomalija mrežnog prometa metodom klasifikacije strojnim učenjem u hibridnoj programski definiranoj mreži

Doktorska disertacija

Osijek, 2024.

Doktorski rad je izrađen na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek.

Mentor: prof.dr.sc. Drago Žagar

Doktorski rad ima: 183 stranice.

Doktorski rad br.:

Mojoj obitelji…

SADRŽAJ

1. UVOD

U posljednjih nekoliko godina, eksplozivni rast korištenja interneta nametnuo je brzu evoluciju mrežnih sustava, kao što su računarstvo u oblaku i mrežna virtualizacija, te značajan razvoj komunikacijskih tehnologija, uključujući internet stvari i pametne gradove. Sve ove promjene dovele su do iznimno velikog porasta podatkovnog prometa kroz kompleksne mreže.

Jedan od ključnih elemenata za precizno upravljanje mrežnim sustavima je identifikacija mrežnog prometa. To omogućuje klasifikaciju tokova mrežnog prometa i pruža osnovu za njihovo učinkovito upravljanje. Postoji nekoliko široko korištenih pristupa za prepoznavanje i predviđanje mrežnog prometa, kao što je pristup temeljen na ulaznom sučelju, duboka inspekcija paketa, proučavanje statističkih karakteristika toka mrežnog prometa i primjena strojnog učenja (eng. *machine learning – ML*) [1].

U današnjem suvremenom sigurnosnom okruženju, elementi kibernetičke sigurnosti postali su neizostavni te predstavljaju ključni dio svake poslovne i procesne mrežne strukture. Stalno se susrećemo s izvješćima i vijestima o kibernetičkim napadima, što povećava pritisak za implementacijom sigurnosnih rješenja. Zaštita informacija ima dugu povijest koja datira još od vremena kada su se fizički dokumenti čuvali pod ključem. S razvojem poslovnog svijeta i upotrebom računala, mrežna sigurnost postala je ključna za zaštitu elektroničke infrastrukture. Pojava interneta donijela je revoluciju, otvarajući nezamislive tehnološke mogućnosti, ali istovremeno stvarajući nove ranjivosti i potičući razvoj kibernetičke sigurnosti kao nove industrije. Evoluirajuća priroda sigurnosnih rizika predstavlja jedan od ključnih elemenata kibernetičke sigurnosti. S pojavom novih tehnologija i njihovim raznovrsnim načinima korištenja, neprestano se razvijaju i novi načini kibernetičkih napada. Praćenje ovih čestih promjena i napretka u napadima, te stalno ažuriranje metoda zaštite, predstavlja veliki izazov za sigurnosna rješenja. U rješavanju sve većeg broja i sofisticiranosti kibernetičkih prijetnji, automatizacija je postala ključna. Korištenje umjetne inteligencije i strojnog učenja u mrežama s velikim protokom podataka mogu znatno poboljšati kibernetičku sigurnost. Ovi napredni alati omogućuju brzo i precizno otkrivanje potencijalnih prijetnji, kao i pravovremenu reakciju i obranu od njih.

Razvojem mrežnih sustava istovremeno su porasle i prijetnje mrežnoj sigurnosti. Kibernetički incidenti, kao što su napadi uskraćivanjem mrežnih usluga (eng. *Denial of Service - DoS*), otkrivanje korisničkih podataka ili zlonamjerni upadi u IT sustav (eng. *Information Technology*), predstavljaju samo neke od primjera koji mogu izazvati ozbiljne poremećaje u IT sustavima. Za osiguranje sigurnosti mreže, često se koriste antivirusni softver, vatrozidi i sustavi detekcije (eng. *Intrusion Detection System – IDS, Network Intrusion Detection System - NIDS*) i prevencije upada u mrežnu komunikaciju (eng. *Network Intrusion Prevention System - NIPS*), koji kontinuirano nadziru mrežni promet kako bi otkrili sumnjive i zlonamjerne aktivnosti [2]. Pouzdanost, točnost i brzina detekcije faktori su uspjeha sustava detekcije koji teži poboljšanjima u smanjenju lažnih alarma i povećanju točnosti detekcije. Kako bi se smanjila stopa lažnih alarma i povećala točnost otkrivanja prijetnji, koriste se različiti pristupi strojnog učenja [3].

U današnjem svijetu, nemoguće je učinkovito implementirati tehnologiju kibernetičke sigurnosti bez integracije strojnog učenja. Istovremeno, strojno učenje zahtijeva sveobuhvatan pristup sirovim i obrađenim podatcima kako bi bilo učinkovito. Ukratko, strojno učenje ima potencijal da pojednostavi, unaprijedi, smanji troškove i učini kibernetičku sigurnost efikasnijom, ali to je moguće samo ako podatci korišteni u strojnom učenju pružaju cjelovitu sliku mrežnog okruženja.

Inteligentni sustavi u mrežnom okruženju zahtijevaju adekvatnu podršku na mrežnoj razini. Tradicionalne mreže s distribuiranim upravljanjem otežavaju primjenu tehnika strojnog učenja. No, programski definirano umrežavanje (eng. *Software Defined Network - SDN*) donosi novi pristup pružanju kibernetičke sigurnosti. Mogućnosti SDN-a, kao što su logički centralizirana kontrola, globalni pregled mreže, softverska analiza prometa i dinamičko ažuriranje pravila, olakšavaju primjenu tehnike strojnog učenja u ovom kontekstu.

Pored toga, tradicionalne računalne mreže obično se sastoje od uređaja za prosljeđivanje i filtriranje paketa, kao što su preklopnici, usmjerivači i vatrozidi. Svaki od ovih uređaja ima ulogu u upravljanju širokim spektrom mrežnih protokola i zadržava lokalni pregled cijele mreže. Ova heterogenost u infrastrukturi i kompleksnost upravljanja mrežom čine sigurnosnu mrežnu politiku i optimizaciju performansi još složenijim zadatkom. Ovaj složeni skup uređaja i različitih protokola otežava održavanje i razvoj tradicionalnih IP mreža. Svaki uređaj za prosljeđivanje ima vlastitu konfiguraciju i pravila koja se moraju pratiti kako bi se osigurala ispravna funkcionalnost

i sigurnost mreže. Postizanje dosljedne sigurnosne politike na svakom uređaju zahtijeva pažljivo upravljanje i koordinaciju. Sve to može dovesti do povećane ranjivosti na sigurnosne prijetnje i mogućih problema u performansama.

Paradigma programski definirane mreže (SDN) predstavlja inovativan pristup redizajniranju mrežne arhitekture. U ovom pristupu, upravljačka razina odvaja se od podatkovne razine, što omogućuje bolje upravljanje i kontrolu nad mrežom. Logički centralizirani kontroler igra ključnu ulogu u SDN-u jer održava globalni pogled na cijelu mrežu. SDN omogućuje da se upravljački softver odvoji od tradicionalnih mrežnih uređaja poput preklopnika i usmjerivača. Time se stvara fleksibilniji i dinamičniji način upravljanja mrežom. Upravljačka razina, koju kontrolira logički centralizirani kontroler, može donositi odluke o prosljeđivanju paketa na temelju globalnog pregleda cijele mreže. To omogućuje brže i efikasnije donošenje odluka, što dovodi do poboljšanja performansi i sigurnosti mreže [2]. Ovakav pristup pruža iznimnu priliku za primjenu tehnika strojnog učenja.

U sklopu provedenog istraživanja, maksimalno su iskorištene prednosti SDN arhitekture kako bi se razvio inovativan hibridni model. Ovaj model efikasno kombinira snagu strojnog učenja za prepoznavanje anomalija u mrežnom prometu. U okviru programski definirane mreže (SDN), otvara se prostor za razvoj novih mrežnih aplikacija koje omogućavaju kvalitetan nadzor i učinkovito upravljanje mrežom. Integriranjem pristupa strojnog učenja uz postojeće sigurnosne funkcije kontrolera SDN-a, mogu se postići poboljšanja u sigurnosti mreže i nadzoru prometa. NIDS temeljen na strojnom učenju koristi naučene značajke iz mrežnog prometa kako bi identificirao potencijalne prijetnje i napade. Ovaj pristup još nije dovoljno istražen, posebno u kontekstu razvoja NIDS sustava temeljenih na SDN-u i tehnikama strojnog učenja. Kombiniranje SDN arhitekture s tehnologijama strojnog učenja može otvoriti nove mogućnosti za razvoj naprednih i inteligentnih sigurnosnih rješenja koja se mogu prilagoditi promjenjivim mrežnim uvjetima i prijetnjama, unaprjeđujući sigurnost mrežnih sustava.

Pristup primjene tehnika strojnog učenja na hibridnom SDN sustavu, koji obuhvaća elemente kako tradicionalne tako i programski definirane mrežne arhitekture, predstavlja dodatni izazov. Integracija tradicionalnih i SDN mrežnih uređaja zahtijeva inovativne i sofisticirane tehnike kako bi se osigurala sinergija između oba pristupa. Potencijalne prednosti predloženog modela, kao što

je bolja skalabilnost, efikasnost i sigurnost mreže osigurale su visoku točnost predviđanja različitih vrsta anomalija u stvarnom vremenu.

Zadatak ovog istraživanja je predložiti rješenje za hibridnu SDN mrežu koje omogućuje:

- učinkovitu detekciju anomalija mrežnog prometa uz pomoć strojnog učenja;
- postizanje visoke točnosti predviđanja anomalija u smislu binarne klasifikacije mrežnog prometa unutar stvarnog vremena;
- zaštitu kritičnog segmenta IT sustava unutar hibridne SDN mreže.

U disertaciji se predlaže nov i inovativan pristup kibernetičkoj sigurnosti, usmjeren na stvarne sigurnosne zahtjeve s jednostavnim, sistemskim, strukturiranim i potencijalno automatiziranim procesom kako bi se postiglo sveobuhvatno rješenje sigurnosti IT sustava. Primjenjuju se tehnike strojnog učenja za identifikaciju i odgovor na zlonamjerni promet. Sustav se sastoji od dva ključna dijela: klasifikatora temeljenog na strojnom učenju i hibridne programski definirane mreže. Klasifikator se obučava razlikovati normalni i zlonamjerni promet koristeći referentni i stvarni skup podataka za oba tipa prometa. Nakon toga, uz prednosti hibridne SDN mreže, sustav reagira na rezultate klasifikatora blokiranjem zlonamjernog prometa.

Predloženi model ima nekoliko prednosti u odnosu na postojeće sustave za otkrivanje upada na mreži jer je prilagodljiv za implementaciju i u tradicionalnom i u SDN mrežnom okruženju, no postiže najveće prednosti i optimalne performanse kada se koristi u hibridnom SDN okruženju, što je detaljno opisano u disertaciji. Osim toga, karakterizira ga brz odziv u stvarnom vremenu, čineći ga iznimno prikladnim za kritične sustave. Sposobnost trenutnog odgovora bitna je za pouzdan rad u situacijama gdje je nužno osigurati trenutne reakcije i visoku razinu pouzdanosti.

Uz postizanje visoke točnosti detekcije anomalija, predloženi model ističe se sposobnošću otkrivanja nepravilnosti u mrežnom prometu koristeći smanjen broj ulaznih značajki. Njegova učinkovitost u preciznom identificiranju neželjenog prometa predstavlja značajan napredak, posebno s obzirom na smanjenje potrebnih ulaznih informacija.

Dodatno, predloženi model pokazuje visoku prilagodljivost s obzirom na korištenje različitih algoritama klasifikacije unutar područja strojnog učenja, a sposobnost integracije s raznovrsnim algoritmima omogućuje prilagodbu modela specifičnim zahtjevima i karakteristikama ulaznih

podataka. Ova prilagodljivost pruža široki raspon mogućnosti za optimizaciju performansi i postizanje najboljih rezultata u različitim scenarijima primjene.

Model je postavljen u pasivni položaj unutar mrežnog okruženja, unatoč tome što njegova funkcionalnost ostaje aktivna zahvaljujući iskorištenim mogućnostima SDN-a. Ovakav pristup omogućuje smanjenje potrebe za kopiranjem mrežnog prometa radi analize i detekcije anomalija. Istovremeno, izbjegava se unos dodatnog kašnjenja koje je često prisutno u sustavima i uređajima koji se nalaze u aktivnom mrežnom položaju. Na taj način se poboljšava ukupna učinkovitost sustava, dok se istodobno umanjuju potencijalni negativni učinci na brzinu i latenciju mrežnog prometa, što je posebno važno u dinamičnim i zahtjevnim mrežnim okolinama.

1.1. Struktura rada

Disertacija je organizirana na sljedeći način:

Poglavlje 2. istražuje izazove kibernetičke sigurnosti u kontekstu programski definiranih mreža (SDN) te prikazuje utjecaj prelaska sa statičnih sigurnosnih mehanizama, poput vatrozida i sustava za otkrivanje upada, na napredne strategije u SDN okruženju. Dodatno se naglašava važnost komunikacije između slojeva putem API-ja (eng. *Application Programming Interface*) te ističe prednosti programabilnosti, agilnosti i centralnog upravljanja koje SDN pruža. Proučavaju se i hibridne SDN mreže koje kombiniraju tradicionalne i SDN uređaje kako bi pružile fleksibilnost i olakšale postupni prijelaz prema potpunoj SDN arhitekturi. Opisuje kibernetičke napade u SDN okruženju, s osvrtom na integraciju strojnog učenja s SDN kontrolerima kako bi se optimizirali sustavi za otkrivanje prijetnji. Razmatraju se različite tehnike, uključujući sustave za otkrivanje i suzbijanje prijetnji, detekciju DDoS napada, upotrebu mamaca, IDSaaS (eng. *Intrusion Detection System as a Service*), tehnologije detekcije upada u IoT-u te okviri za unapređenje sigurnosti u podatkovnim centrima temeljenim na SDN-u.

U 3. poglavlju obrađen je pregled sustava za otkrivanje upada (IDS) temeljenih na strojnom učenju, s naglaskom na primjeni u programski definiranim mrežama (SDN). Pregled literature naglašava kontinuirani interes za integraciju SDN-a i strojnog učenja radi očuvanja sigurnosti mreža. Prikazani su i objašnjeni tipični zadatci i podjela strojnog učenja, te se detaljno bavi

nadziranim strojnim učenjem, analizirajući proces klasifikacije. Opisuje klasične klasifikatore poput stabla odluke, slučajne šume, stroja s potpornim vektorima, Naivnog Bayesa i K-najbližeg susjeda. Istražuju se različite metrike uspješnosti klasifikacije, uključujući matricu konfuzije, točnost, preciznost, opoziv, F mjere i područje ispod krivulje AUC (eng. *Area under the Curve*). Opisuje se važnost pravilnog odabira metrike ovisno o karakteristikama problema klasifikacije i distribuciji klasa kako bi se osigurala pravilna evaluacija učinkovitosti klasifikatora.

Poglavlje 4. istražuje sigurnosna rješenja kroz integraciju SDN-a, naglašavajući inovativan pristup podržan strojnim učenjem, s posebnim fokusom na primjenu strojnog učenja za detekciju napada u SDN mrežama. Detaljno su opisani struktura, odabir i prilagodba ulaznih podataka modela za otkrivanje anomalija u mrežnom prometu. Ovo uključuje analizu i usporedbu javno dostupnih referentnih skupova podataka poput UNSW-NB15, CSE-CIC-IDS2018, i LUFlow2021, te NetFlow skupova podataka, kao i predobradu tih podataka kroz eliminaciju suvišnih značajki, čišćenje neispravnih vrijednosti te kodiranje kategorijskih značajki, uključujući upotrebu labeliranja i One-hot metode. Nadalje, poglavlje detaljno opisuje proces odabira i prilagodbe referentnih skupova podataka za detekciju anomalija, uključujući skaliranje značajki i analizu utjecaja algoritama skaliranja na točnost klasifikacije. Poseban naglasak stavljen je na odabir optimalnog skupa podataka i klasifikatora te detaljan proces odabira hiperparametara klasifikatora putem unakrsne validacije. Predstavljen je NFMIDS (eng. *NetFlow Machine-learning Intrusion Detection System*) model za detekciju kibernetičkih napada, koji se sastoji od ključnih elemenata kao što su algoritmi strojnog učenja, referentni skupovi podataka, stvarni mrežni podaci te integracija s hibridnom SDN arhitekturom. Također su analizirani postojeći modeli za detekciju napada u stvarnom vremenu i pružene smjernice za daljnji razvoj i implementaciju predloženog modela za detekciju prijetnji u mrežnom prometu. Analiza rezultata istraživanja pruža uvid u učinkovitost modela u različitim scenarijima i okolnostima, zaključujući o njegovoj primjenjivosti.

Poglavlje 5. usredotočuje se na prijedlog metode verifikacije modela za detekciju anomalija u kontekstu hibridne programski definirane mreže. Pruža pregled postojećih metoda verifikacije koje su primjenjive u sličnim kontekstima. Predstavljena je i opisana nova metoda verifikacije temeljena na analizi višestrukih NetFlow zapisa mrežnog prometa. U ovom procesu, korišteni su NetFlow zapisi s tri preklopnika postavljenih duž putanje od napadača prema žrtvama. Detekcija anomalija rezultata je uspoređena s detekcijama postojećeg NIDS-a u korporativnoj mreži.

Predložena metoda verifikacije analizirala je očekivane i stvarne vrijednosti vremena detekcije i trajanja kibernetičkih napada te status sučelja SDN preklopnika. Verifikacija je provedena u stvarnom vremenu, unutar hibridnog SDN okruženja, uz i bez prisustva pozadinskog prometa. Rezultati verifikacije pokazali su uspješnu detekciju kibernetičkih napada u dvije od tri konfiguracije NetFlow izvoza, uz niski postotak lažno pozitivnih rezultata za svaku konfiguraciju.

Poglavlje 6. zaključuje disertaciju i raspravlja o sljedećim koracima kao nastavak ovog istraživanja.

2. IZAZOVI KIBERNETIČKE SIGURNOSTI U SDN MREŽNOM OKRUŽENJU

Kako se razvijaju nove tehnologije i uređaji, koncept umrežavanja mijenja se zajedno s njima. Stare, tradicionalne mrežne paradigme su se pokazale previše statičnima i teškima za promjenu. Stoga je nastala paradigma programski definirane mreže kako bi se bolje nosila s rastućim prometom podataka, virtualizacijom mreže i mobilnošću korisnika.

2.1. Tradicionalne mreže

U tradicionalnim mrežama, karakteristike uređaja su čvrsto vezane uz proizvođača, što otežava dodavanje novih funkcionalnosti i zahtijeva rad s mnogo različitih protokola ugrađenih u različit hardver. Sigurnosni mehanizmi, pravila usmjeravanja i prosljeđivanja također su čvrsto povezani za tip i proizvođača samog fizičkog uređaja. Promjene u mreži zahtijevaju ažuriranje susjednih uređaja, što postaje još složenije ako su uređaji raspoređeni na velikom području. Složenost mreža otežava primjenu konzistentnog pristupa, sigurnosti, QoS-a i drugih funkcionalnosti [4], [5]. Sigurnost se u tradicionalnim mrežama često temelji na vatrozidima, sustavima za otkrivanje upada (IDS), sustavima za sprječavanje upada (IPS), kontroli i upravljanju pravilima pristupa. Postojećim statičkim sigurnosnim mehanizmima nedostaje prilagodljivost i skalabilnost. Nedostatak učinkovitih sigurnosnih mehanizama u tradicionalnim mrežama može dovesti do nedovoljne sigurnosti mreže [6], [7], [8].

2.2. Programski definirana mreža

Virtualne mreže nisu novost i postojale su u mnogim oblicima tijekom godina kao MPLS, VPN, ATM, Frame Relay i VLAN. SDN se pojavio kao nova paradigma umrežavanja koja razdvaja mrežni upravljački sloj od podatkovnog sloja čija je svrha odvajanje od specifičnih hardverskih tehnologija, te tako značajno povećava agilnost mreže. Programski definirane mreže stvorene su za automatizaciju i radikalno pojednostavljenje upravljanja računalnim mrežama uz značajno smanjenje pogrešaka što je slučaj kod manualnog rada. Omogućuje mrežama da se

izravno povezuju s aplikacijama putem aplikacijskih programskih sučelja API-ja, poboljšavajući performanse te stvarajući fleksibilnu i dinamičnu mrežnu arhitekturu koja se po potrebi može mijenjati. Kontroleri mogu dinamički rekonfigurirati mrežu kako bi izbjegli zagušenja, implementirali nove usluge, dodali virtualnu infrastrukturu itd. [9], [10].

Programski definirana mreža omogućuje programabilnu kontrolu mreže, što olakšava prilagođavanje novim zahtjevima i dodavanje novih funkcionalnosti bez utjecaja na performanse, pouzdanost i korisničko iskustvo [11]. Novijim istraživanjima predlažu se mehanizmi temeljeni na programski definiranim mrežama kako bi se osigurala veća fleksibilnost, dinamična programabilna funkcionalnost i smanjili operativni troškovi. SDN ima za cilj omogućiti dizajn dinamičnih i programabilnih sigurnosnih kontrola koje rade u stvarnom vremenu s malo ili bez ljudske interakcije, kako bi pružile pristup resursima legitimnim korisnicima, zaštitile sustave od napada i umanjile štetu u slučaju napada. Međutim, pojavom novih kontrola i mogućnosti u SDN-u, također se pojavljuju i nove vrste napada koje nisu bile prisutne u tradicionalnim mrežama [12]. SDN kao paradigma mrežne arhitekture omogućuje dinamičko prilagođavanje mrežnog okruženja trenutnim zahtjevima ili potrebama korisnika i aplikacija te u velikoj mjeri pojednostavljuje upravljanje i proširivanje mreže. Dodatna prednost je mogućnost korištenja mrežnih komponenti različitih proizvođača koji podržavaju protokole prilagođene ovakvoj arhitekturi, bez potrebe poznavanja rada samih uređaja, jer se cjelokupnim mrežnim okruženjem upravlja putem kontrolera.

Neke od glavnih karakteristika SDN arhitekture prema [13]:

- Programabilno upravljanje - kontrola i konfiguracija mreže izravno se programira jer je funkcija prosljeđivanja paketa odvojena od funkcije kontrole te omogućuje vrlo brzo konfiguriranje, upravljanje, osiguravanje i optimiziranje mrežnih resursa pomoću automatiziranih programa;
- Agilnost - izdvajanje kontrole pri prosljeđivanju paketa omogućuje dinamičko podešavanje protoka prometa na cijeloj mreži;
- Centralno upravljanje - mrežna inteligencija je centralizirana u kontrolerima koji imaju globalni pogled na mrežu;
- Otvoreni standardi - SDN se temelji na otvorenim standardima što pojednostavljuje dizajn i rad mreže jer kontroleri koriste iste protokole umjesto onih specifičnih za proizvođača.

Arhitektura modela SDN mreže kao što je prikazano na Slici 2.1 sastoji se od tri različita sloja koji se povezuju putem API-ja:

- Aplikacijski sloj se sastoji od aplikacija krajnjeg korisnika koji koriste SDN komunikacijske usluge;
- Upravljački sloj pruža konsolidiranu upravljačku funkcionalnost koja nadzire ponašanje prosljeđivanja paketa;
- Podatkovni sloj se sastoji od mrežnih elemenata i uređaja koji omogućuju prosljeđivanje paketa.

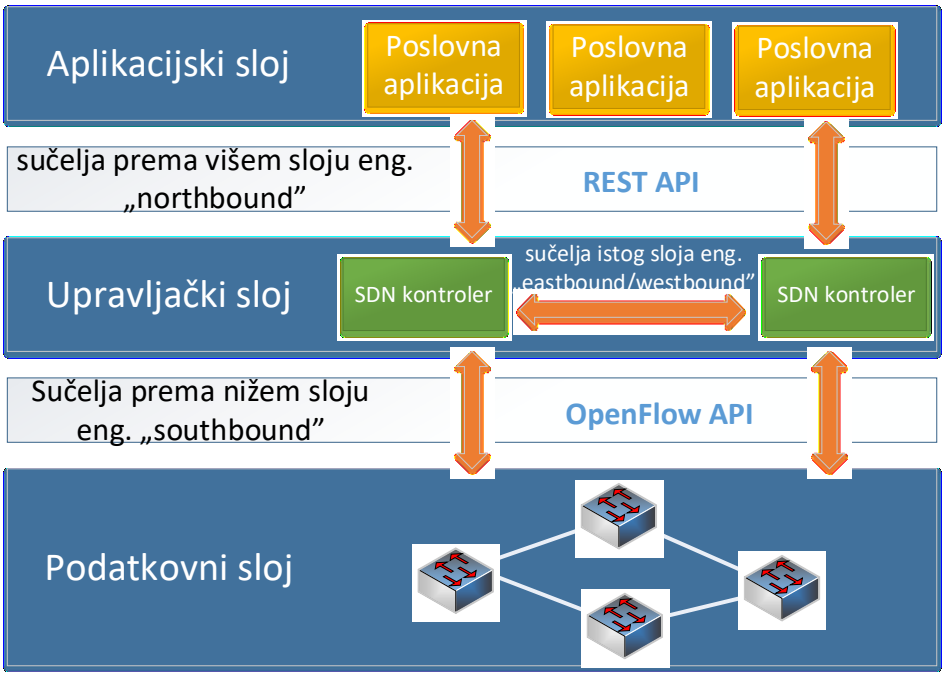

Slika 2.1 Arhitektura programski definirane mreže

U ovakvoj arhitekturi programski definirane mreže slojevi se povezuju pomoću API-ja, te se za sučelje određenog sloja prema nižem sloju koristi engleski naziv "*southbound*", dok se naziv "*northbound*" koristi za sučelje određenog sloja prema višem sloju.

Aplikacijski sloj čine krajnji korisnici i aplikacije koji se koriste SDN mrežnim uslugama. Aplikacija može kontroleru podnijeti zahtjev za određenim promjenama u konfiguraciji i radu mreže. Zahtjevi za upravljanje mrežnom infrastrukturom se odvijaju preko „*northbound*“ API sučelja prema kontroleru i pomoću ovih sučelja se osigurava apstraktni pogled na mrežu. Jedan od često korištenih API-ja je REST API (eng. *REpresentational State Transfer API*).

SDN kontroler u upravljačkom sloju uglavnom je odgovoran za dva zadatka. Jedan je prevesti zahtjeve aplikacijskog sloja u podatkovni sloj, a drugi je dati apstraktni model fizičke mreže aplikacijskom sloju. Kontrolni sloj često se naziva mrežnim operativnim sustavom jer sadrži logiku upravljanja mrežom i pruža aplikacijskom sloju apstraktni prikaz globalne mreže. U SDN okruženju kontroler koristi API-je za komunikaciju s aplikacijskim slojem, podatkovnim slojem i drugim kontrolerima. U distribuiranoj arhitekturi kontrolera oni međusobno komuniciraju koristeći tzv. "*eastbound*"/"*westbound*" API-je koji nisu toliko često korišteni za razliku od "*northbound*" i "*southbound*" API-ja.

Podatkovni sloj se sastoji od uređaja za prosljeđivanje paketa i to je glavna funkcija ovog sloja koji pruža vrlo učinkovite mehanizme za prosljeđivanje. Komunikacija upravljačkog i podatkovnog sloja, odvija se putem tzv. "*southbound*" API sučelja i protokolima poput OpenFlow, CLI/SNMP, Netconf/YANG, ali detalji protokola obično su skriveni od korisnika API-ja jer se korisnik ne mora brinuti o specifičnim protokolima koji implementiraju traženu mrežnu aktivnost [14].

Ključne komponente SDN-a su API-ji koje ga čine moćnim alatom za upravljanje mrežom i rad sa značajkama kao što su programabilnost, neovisnost o protokolu, mogućnost izmjene mrežnih parametara prema potrebi. Upravljački sloj koristi API-je za nadgledanje, upravljanje i olakšavanje komunikacije svih ostalih slojeva. Jedna od vrijednosti SDN-a leži u činjenici da se API koristi na otvoren, neutralan i interoperabilan način [15], [16], [17], [18], [19].

Na Slici 2.2 prikazana je usporedba tradicionalnih mrežnih uređaja i SDN uređaja. Na gornjoj strani slike prikazani su tradicionalni mrežni uređaji, koji se temelje na čvrstim, zatvorenim hardverskim sustavima. To uključuje klasične preklopnike, usmjerivače koji zahtijevaju ručnu konfiguraciju i upravljanje, a samim time su i manje prilagodljivi.

Na donjoj strani slike prikazani su SDN uređaji koji koriste fleksibilan i dinamičan pristup upravljanju mrežom putem softverskih kontrolera. Slikom 2.2 ističu se glavne prednosti SDN-a u usporedbi s tradicionalnim mrežama, uključujući veću agilnost, bolje iskorištavanje resursa i olakšano upravljanje mrežom. Ova usporedba ilustrira evoluciju mrežne tehnologije prema SDN-u kao modernom pristupu upravljanju mrežama.

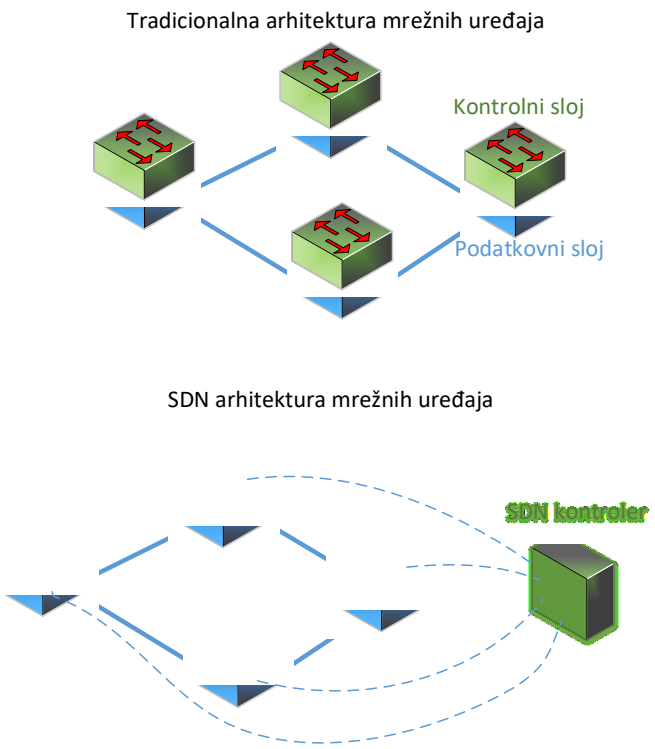

Slika 2.2 Usporedba tradicionalnih i SDN mrežnih uređaja

2.3. Hibridna programski definirana mreža

Mreža koja sadrži kombinaciju SDN i tradicionalnih mrežnih uređaja obično se naziva hibridnom SDN mrežom te nudi niz prednosti i predstavlja prijelazni korak ka potpunom usvajanju SDN-a. Hibridna SDN mreža spaja tradicionalno umrežavanje i SDN protokole koji djeluju u istom okruženju te omogućava uvođenje novih tehnologija i protokola u tradicionalna okruženja bez potpune rekonfiguracije mrežne arhitekture. Potpuna promjena tradicionalne mreže u programski definiranu mrežu bez ikakvog oblika prilagodbe predstavlja rizik koji može utjecati na performanse i sigurnost IT sustava. Nadalje, potrebna su velika financijska sredstva za komponente SDN mreže, a nadogradnja relativno novih tradicionalnih uređaja mreže smatra se neisplativom [20]. Prema [21], [22], [23], [24] hibridne SDN mreže nude niz prednosti:

- Olakšavaju financijske troškove jer je implementacija potpune SDN mreže vrlo skupa i potrebna su dodatna ulaganja za edukaciju, projektiranje, konfiguriranje i rad na SDN mreži;

- Mogu se koristiti za iskorištavanje nekih prednosti SDN paradigme bez implementacije pune SDN mreže. Pristupna mreža može koristiti naslijeđene, tradicionalne uređaje dok distribucijska mreža može koristiti SDN uređaje. Stoga se hibridna SDN mreža može koristiti za obradu i prosljeđivanje većine paketa u pristupnoj mreži putem naslijeđenih, tradicionalnih uređaja dok se SDN uređaji koriste u distribucijskoj mrežnoj razini kako bi iskoristili prednosti SDN-a. Da bi osigurali nesmetan i kontroliran prijelaz dobro je na početku implementirati SDN samo za mali dio nekritičnog prometa;
- SDN omogućuje finu granulaciju kontrole protoka podataka. Ako je potrebna takva kontrola samo za mali dio mreže, tada se može implementirati hibridna SDN mreža dok ostatak mreže koristi tradicionalno umrežavanje;
- Tradicionalni protokoli usmjeravanja vrlo su učinkoviti za neke zadatke poput povezivanja kontrolera SDN-a kako bi kontrolirali različite dijelove mreže. Hibridna SDN mreža se može primijeniti kako bi se oslobodio kontroler od zadataka koje se učinkovito može odraditi s tradicionalnim protokolima usmjeravanja;
- Hibridna SDN mreža olakšava prijelaz s naslijeđenih, tradicionalnih na SDN mrežne uređaje gdje se može raditi postupno raspoređivanje sve više i više SDN uređaja i procijeniti utjecaj zamjene tradicionalnih uređaja;
- Hibridnom mrežom rješava se povezivanje dvije odvojene SDN mreže preko tradicionalnih mrežnih uređaja.

Nekoliko je mogućih hibridnih SDN modela koji se opisuju u literaturi [21], [25]:

- model temeljen na topologiji gdje je mreža podijeljena u zone tako da svaki čvor pripada samo jednoj, tradicionalnoj ili SDN zoni;
- model temeljen na servisu gdje su usluge podijeljene za tradicionalni i SDN dio mreže. Da bi se implementirale neke usluge, poput prosljeđivanja na razini cijele mreže, određeni čvorovi mogu pripadati objema paradigmama;
- model temeljen na klasifikaciji i podjeli prometa u tradicionalni i SDN kontrolirani promet;
- integrirani model gdje je SDN odgovorna za sve mrežne usluge, a koristi tradicionalne protokole kao sučelje za prosljeđivanje paketa te tako može kontrolirati put prosljeđivanja umetanjem pažljivo odabranih ruta u sustav usmjeravanja ili podešavanjem postavki protokola.

Hibridna SDN mreža predstavlja mogući način migracije tradicionalne mreže na potpunu SDN mrežnu arhitekturu.

2.4. Pregled istraživanja i rješenja kibernetičke sigurnosti u SDN mrežnoj arhitekturi

Pregled istraživanja o kibernetičkim napadima s aspekta SDN mrežne arhitekture uključuje različite aspekte poput prijetnji, sigurnosnih izazova, rješenja i trenutnih istraživanja o prijetnjama relevantnim za SDN arhitekturu. Proučena istraživanja pokazuju kako SDN mijenja tradicionalni model sigurnosti mreža i kako se prilagođava novim potrebama.

Autori u [26] opisuju sustav namijenjen otkrivanju i suzbijanju prijetnji na mreži u SDN okruženju. Sustav autonomno nadzire promet i primjenjuje protumjere na kompromitiranim uređajima kako bi održao dostupnost usluga mreže. U tu svrhu, koristi analizu prometa s više značajki za profiliranje normalne upotrebe mreže te normalni profil koristi se za identifikaciju neobičnih uzoraka prometa, a politika obrane odabire se prema prepoznatim anomalijama. Predloženi sustav je evaluiran korištenjem testnog prometa koji simulira DDoS i skeniranje porta. Sustav identificira sučelja koja su napadači kompromitirali i koristi tu informaciju za pokretanje definiranih sigurnosnih rutina na preklopnicima i tako uspostavlja ispravno funkcioniranje mreže. Izvedba predloženog sustava promatrana je u odnosu na vrijeme izvršavanja i korištenje resursa sustava, uključujući upotrebu CPU-a SDN kontrolera i veličinu tablice protoka preklopnika.

Napredak Interneta stvari u medicini i prije svega nesigurna priroda zastarjelih zdravstvenih sustava povećavaju širinu kibernetičkih napada. U radu [27] usmjerena je pažnja na protokole u industrijskim sustavima kao i u sektoru zdravstva. Predstavljen je kvantitativni model prijetnji koji procjenjuje ozbiljnost mogućih kibernetičkih napada u vezi s odgovarajućim naredbama promatranog protokola. Predložen je sustav koji kombinira strojno učenje (ML) i programski definirane mreže (SDN) kako bi se otkrili i ublažili kibernetički napadi modificiranjem i dodavanjem tablica protoka SDN preklopnika koristeći OpenFlow. Detekcija upada temelji se na klasifikatoru koji koristi statistike mrežnog protoka TCP/IP i statistike toka podataka IEC 60 870-5-104 protokola. Rezultati evaluacije pokazali su učinkovitost predloženog IDPS-a mjerenjem uspješnosti klasifikacije.

U radu [28] predloženo je sigurnosno rješenje koje detektira DDoS napade prema SDN-a kontroleru korištenjem odgovarajućih ML algoritama. SDN temeljen na prilagodljivom mehanizmu propusnosti imao je važnu ulogu u unaprjeđenju sigurnosti SDN kontrolera, gdje je XGBoost algoritam korišten za sprječavanje DDoS napada. U analizi su korišteni CICDDoS2019 i NSL-KDD skup podataka za ML algoritme kako bi se poboljšalo sigurnosno rješenje s prilagodljivim mehanizmom propusnosti. Postavljena su tri profila za usporedbu rezultata gdje XGBoost ima potpunu iskoristivost CPU-a i drugih resursa uz minimalne troškove energije i složenost sustava. Korištenje ovog pristupa s algoritmom prilagodljive propusnosti i ML tehnikom poboljšava se točnost predloženog rješenja i smanjuje omjer odbačenih paketa.

Prema istraživanju u radu [29], autori predlažu novi način implementacije sustava za sprječavanje upada temeljenog na SDN/OpenFlow arhitekturi. U predloženom rješenju smanjuju se troškovi implementacije i održavanja SDN mreže gdje se SDN kontroler koristi za racionalno raspoređivanje protoka podataka. U usporedbi s implementacijom IPS-a u tradicionalnim mrežama, predloženo rješenje omogućava unificirano raspoređivanje sigurnosnih pravila u cijeloj mreži. Postiže se jedinstvena učinkovitost u smislu sigurnosti od kibernetičkih napada i koordinacije IPS-ova u cijeloj mreži. SDN kontroler koristi prednosti fleksibilnog raspoređivanja protoka kako bi se poboljšala iskoristivost nekih neiskorištenih IPS-ova i smanjila opterećenja nekih preopterećenih IPS-ova.

Pristup SDN arhitekture s mamcima predstavljeni su u istraživanjima [30] i [31]. Mamci su vrsta aktivne obrambene sigurnosne tehnologije i to je mjesto za koje se očekuje da će biti napadnuto. Ovi sustavi mogu simulirati veliku i stvarnu mrežu kako bi privukli napadače i preusmjerili upade na mamce te tako osigurali vrijeme za daljnju analizu. Ovakav pristup u SDN-u poboljšava nedostatke postojećih tehnologija podmetanja mamaca čiji su mehanizmi uočljivi i napadači ih mogu lako otkriti. SDN kontroler korisnicima omogućuje konfiguriranje vlastitih pravila upravljanja mrežnim podatcima, koja će na temelju upozorenja proslijediti ili preusmjeriti promet na odgovarajuće mamce. SDN kontroler pruža simulaciju topologije mreže u hibridnoj mreži i osigurava preciznu kontrolu podataka tijekom cijele migracije zlonamjernog prometa, čime se poboljšavaju nedostaci u tehnologiji kontrole protoka u tradicionalnoj mreži s mamcima.

Neki IDS-ovi koncipirani su kao usluga (eng. *Intrusion Detection System as a Service - IDSaaS*) u SDN-u koja nastoji otkriti i zaustaviti ulazak zloćudnog prometa i kompromitiranje

mrežnih elemenata u složenijim okruženjima i ispitivanje s realističnijim scenarijima. Prednost IDSaaS strategije proizlazi iz općeg trenda hijerarhijskog upravljanja mrežom, odnosno, ako SDN kontroler nije adekvatno osiguran, klijentski čvorovi (pojedinačni elementi ili mreže koji ovise o uslugama kontrolera) postaju izloženiji napadima i anomalijama u podatkovnom prometu. IDSaaS ima sposobnost postizanja dosljednosti u implementaciji pravila IDS-a na više SDN mreža. Implementacija IDSaaS-a za SDN rezultira i uštedama troškova i vremena pri instalaciji IDS-a za sve pojedine mreže [32], [33].

Predloženi pristup u [34] predstavlja okvir za otkrivanje DDoS napada koristeći statističke parametre u okviru SDN arhitekture. Predloženi okvir rješava problem vezan uz DDoS napad i SDN arhitekturu i ograničenje IDS-a u brzim mrežama. Osim toga predloženo rješenje za otkrivanje upada pruža dobru predikciju napada s visokom učinkovitošću detekcije. Eksperimentalni rezultati pokazuju da je predloženi okvir uspješan u postizanju ravnoteže između učinka detekcije i učinkovitosti okvira u brzoj mreži. Osigurava nisku stopu pogreške uz visoku stopu detekcije i snagu detekcije. Nadalje, pruža ekonomičan pristup bez korištenja vanjske hardverske opreme izvan SDN-a.

Istraživanje [35] razmatra detekciju upada u IoT-u, gdje je predložen mehanizam detekcije upada uz pomoć dubokog učenja uz korištenje SDN-a kako bi onemogućili rastuće kibernetičke prijetnje u IoT-u. Predloženi sustav pruža univerzalnu sposobnost detekcije raznovrsnih potencijalnih sigurnosnih prijetnji, uključujući DOS, DDOS, MITM, botnet napade, infiltracijske napade, napade grubom silom, napade skeniranja itd. Performanse predloženog modela evaluirane su sa ML metrikama uključujući točnost, preciznost, odziv, F1-ocjenu. U validaciji, predloženi okvir uspoređen je s dva referentna klasifikatora u IoT okruženjima.

U radu [36] predstavljen je okvir za poboljšanje sigurnosti u podatkovnim centrima temeljenim na SDN-u. Okvir se oslanja na uvođenje upravljačke jedinice koja se sastoji od sigurnosnog agenta i internog poslužitelja dnevničkih zapisa koji se prikupljaju s različitih sigurnosnih uređaja. Sigurnosni agent analizira takve zapise kako bi blokirao napadače uz pomoć SDN kontrolera. Izrađen je i implementiran koncept koji se izvodi na emulacijskom okruženju.

Jedan od najčešćih napada u mreži su napadi uskraćivanjem usluge (DoS) i distribuirani DoS (DDoS) napadi. U istraživanju [37] pokazano je da određene značajke SDN-a mogu biti korištene kako bi se detektirali i spriječili upadi, te gotovo trenutačno odbacili pakete kad se

detektira napad. Implementiran je i testiran IDPS temeljen na anomalijama mrežnog prometa. Korištena su dva tipa algoritama za praćenje komunikacije temeljenih na brzinama protoka podataka: CB-TRW i RL. Predstavljena je i tehnika detekcije skeniranja portova. Prema rezultatima eksperimenata u SDN okruženju, IDPS se pokazao sposobnim za detekciju Nmap skeniranja portova i različitih vrsta DoS napada. Dio sustava za detekciju upada uključivao je upozorenja od strane SDN kontrolera o prisutnosti napada, prikazujući koji je algoritam otkrio napad, vrijeme napada i obavijest o prirodi napada. Dio sustava za sprječavanje upada automatski je stvarao i slao promjene toka mrežnim preklopnicima kako bi odbacio pakete napadača. Dodatna ispitivanja također su provedena korištenjem stvarnog mrežnog prometa kako bi se mjerio odnos lažno pozitivnih rezultata, postavki praga algoritma i korištenja CPU-a.

Istraživanje u [38] predstavlja rješenje za sprječavanje napada skeniranja portova. Korištenjem statistika mrežnog toka prikupljenih u SDN mreži, detektirani su tokovi skeniranja portova i osigurana je sigurnost mreže ažuriranjem OpenFlow pravila usmjeravanja podataka. Rezultati, prikazani u eksperimentalnoj evaluaciji, pokazuju učinkovitost u detekciji zlonamjernih tokova što rezultira odsustvom lažno pozitivnih i vrlo malim brojem lažno negativnih rezultata.

U radu [39] je provedena analiza sigurnosnih ispitivanja sustava koja se odnosi na trajanje blokiranja otkrivenih napadača. Sustav omogućuje slanje informacija o toku mrežnog prometa putem REST API-ja u Ryu kontroler za blokiranje i uklanjanje pravila s određenog uređaja. Na temelju rezultata ispitivanja svih scenarija, SDN mreža opremljena adaptivnim IPS-om ima sposobnost otkrivanja kibernetičkih napada te može blokirati napadača u trajanju ovisno o učestalosti i vrsti izvršenih napada, uz minimalno dodavanje dodatnog vremena za izvođenje fuzzy algoritma u procesu detekcije.

Tablica 2-1 Pregled literature s aspekta kibernetičkih napada i SDN mrežne arhitekture

#	godina	SDN	Stvarno vrijeme	Stvarna testna okolina	Problem istraživanja
[26]	2018.	✓	×	×	Sigurnost IT sustava od DDos i skeniranja portova
[27]	2022.	✓	×	✓	Sigurnost zdravstvenog IT sustava
[28]	2021.	✓	×	×	Sigurnost SDN kontrolera i sprječavanje DDoS napada
[29]	2013.	✓	×	×	Smanjivanje troškova implementacije i održavanja SDN mreže, poboljšavanje iskoristivosti IPS sustava u SDN okruženju
[30]	2019.	✓	×	×	Preusmjeravanje neželjenog prometa na mamce
[31]	2017.	✓	×	×	Preusmjeravanje neželjenog prometa na mamce
[32]	2017.	✓	✓	✓	IDS kao usluga u SDN-u
[33]	2017.	✓	✓	✓	IDS kao usluga u SDN-u za mobilne mreže
[34]	2021.	✓	×	×	Detekcija DDoS napada
[35]	2022.	✓	×	×	Detekcija kibernetičkih napada u IoT okruženju
[36]	2016.	✓	×	×	Sigurnost u podatkovnim centrima
[37]	2019.	✓	✓	×	Detekcija DoS napada i skeniranja portova u SDN mreži
[38]	2018.	✓	×	×	Detekcija skeniranja portova na uređajima u SDN mreži
[39]	2018.	✓	×	×	Adaptivni IPS u fnkciji obrane od DoS napada

Provedena istraživanja odražavaju neprekidan interes za SDN i sigurnost općenito. Sve analizirane studije uključuju implementaciju SDN-a, što ukazuje na opću prihvaćenost tehnologije

u sektoru kibernetičke sigurnosti. Primjena strojnog učenja nije česta, uglavnom se pojavljuje u kontekstu detekcije prijetnji. Tek nekoliko studija naglašava potrebu za obradom u stvarnom vremenu, što je bitno u okviru sigurnosnih rješenja koja zahtijevaju brze reakcije. Neki radovi koriste stvarne testne okoline, posebno oni koji se bave mobilnim mrežama i SDN uslugama. Raznoliki problemi istraživanja obuhvaćaju širok spektar tema, uključujući sigurnost od DDoS napada, sprječavanje skeniranja portova, poboljšavanje iskoristivosti IPS sustava u SDN okruženju, preusmjeravanje neželjenog prometa te detekciju prijetnji u različitim kontekstima. Unatoč nedostatku primjene strojnog učenja u većini radova, učestalost SDN tehnologije ukazuje na važan princip u pristupu sigurnosti mreže. Uvođenje stvarnih testnih okolina doprinosi valjanosti rezultata, a raznolikost istraživačkih pitanja naglašava složenost izazova kibernetičke sigurnosti u kontekstu SDN-a. Postizanje ravnoteže između učinkovitosti obrambenih tehnika i minimalne potrošnje resursa također predstavlja izazov, s obzirom na pritisak koji kibernetički napadi vrše na ciljane resurse. Potrebno je osigurati obrambeni mehanizam koji minimalno opterećuje resurse sustava dok istovremeno uspješno umanjuje utjecaj kibernetičkih napada.

Napadači koriste sofisticirane metode za izvođenje napada visoke složenosti, stoga je potrebno razviti model koje omogućuje brze reakcije u sigurnosnom kontekstu SDN-a kako bi se ostvarila obrada u stvarnom vremenu. Također, treba istražiti kako integrirati strojno učenje u različite aspekte sigurnosti mreže, ne samo u detekciji već i u onemogućavanju kibernetičkih prijetnji, posebice kritičnih IT sustava. Testiranje u stvarnoj testnoj okolini doprinijet će dobivanju valjanijih rezultata istraživanja, dok će istovremeno pronaći optimalno rješenje koje minimizira utjecaj obrambenih tehnika na resurse sustava, uz istodobno učinkovitu zaštitu od kibernetičkih napada.

3. STROJNO UČENJE I PRIMJENA ZA OTKRIVANJE UPADA U SDN MREŽNOM OKRUŽENJU

Interes za sustave za otkrivanje upada (IDS) bazirane na strojnom učenju ubrzano raste tijekom zadnjih godina, a njihova svrha je otkrivanje upada kroz analizu mrežnih podataka. Ključan aspekt ovih sustava je opsežno prikupljanje mrežnih podataka te primjena rudarenja podataka kako bi se izgradili modeli koji precizno bilježe normalno ponašanje i zlonamjerne upade u mrežnom prometu. Postoji više metoda za detekciju anomalija koje koriste različite pristupe analiziranju podataka, uključujući statističke metode i algoritme nadziranog, polunadziranog, podržanog i nenadziranog strojnog učenja. Primjena programski definirane mreže (SDN) kao tehnologije za mreže predstavlja inovativan pristup koji omogućuje razvoj sigurnosnih rješenja prilagođenih mrežnoj programabilnosti i fleksibilnosti, uz integraciju podrške za strojno učenje. Prilagodba sustava dinamičkim mrežnim uvjetima i stanjima otvara nove mogućnosti za upravljanje i konfiguraciju mreže [40].

Novi pristup detekciji upada uključuje i niz izazova na koje treba obratiti pažnju kako bi se postigli ciljevi kibernetičke sigurnosti i riješili sljedeći problemi:

- **Brzina detekcije u stvarnom vremenu:** potrebno je osigurati brzo otkrivanje zlonamjernog dolaznog prometa u stvarnom vremenu kako bi se što prije reagiralo na potencijalne prijetnje;
- **Prilagodba dinamičnoj mrežnoj promjeni:** IDS sustav mora biti sposoban brzo se prilagoditi čestim promjenama stanja u mreži kako bi zadržao visoku učinkovitost;
- **Reakcija na rijetke i nepoznate napade:** potrebno je osigurati da se sustav može uspješno nositi s rijetkim i nepoznatim napadima uz minimalnu nesigurnost u obradi odluka;
- **Primjenjivost tehnika strojnog učenja u SDN-u:** potrebno je istražiti koje tehnike strojnog učenja su primjenjive i najučinkovitije u kontekstu programski definiranih mreža;
- **Odabir algoritma i relevantnih značajki klasifikatora:** bitno je odabrati najrelevantnije algoritme i značajke klasifikatora strojnog učenja za precizno detektiranje napada;

- **Smanjenje broja značajki:** osigurati smanjenje broja značajki u skupu podataka kako bi se postigla brza obrada uz visoku točnost detekcije;
- **Smanjenje nesigurnosti u odlukama:** minimizirati nesigurnost u obradi odluka kako bi se osigurala pouzdana detekcija.

SDN stvara nove mogućnosti za implementaciju učinkovitijih metoda otkrivanja upada. Zbog otvorenosti platformi koje podržavaju tehnologije SDN-a moguće je koristiti postojeće mehanizme i protokole za prikupljanje podataka koji se mogu koristiti kao izvor podataka za algoritme otkrivanja upada. Programabilnost SDN-a i strojno učenje pružaju vrlo efikasnu tehniku obrane od kibernetičkih napada primjenjivu u raznim područjima. Ubrzanim razvojem na području komunikacijske povezanosti ubrzava se stopa automatizacije, ali u isto vrijeme predstavlja mnoge sigurnosne izazove, stoga sustavi za otkrivanje i sprječavanje upada imaju zadaću unaprijediti iskorištenost resursa, povećati performanse, skalabilnost i sigurnost kritičnih sustava u stvarnom vremenu. Kombinacija strojnog učenja i SDN-a jača obrambene mehanizme, čineći ih prilagodljivima i učinkovitima u suočavanju s dinamičnim kibernetičkim prijetnjama.

3.1. Strojno učenje

Arthur Samuel, pionir proučavanja umjetne inteligencije, je 1959. godine opisao strojno učenje kao "znanstvena disciplina koje računalima daje mogućnost učenja bez izričitog programiranja". Osnovni rad Alana Turinga iz 1950. godine uveo je referentni standard za pokazivanje inteligencije stroja takav da stroj mora biti inteligentan i reagirati na način koji se ne razlikuje od ljudskog bića. Tehničku definiciju dao je Tom M. Mitchell 1997. godine koja glasi: „Za računalni program se kaže da uči iz iskustva *E* s obzirom na neku klasu zadataka *T* i mjeru izvedbe *P*, ako se izvedba na zadacima u *T*, mjerena sa *P*, poboljšava iskustvom *E*. " [52].

Prema [53], tipični zadaci strojnog učenja mogu se opisati kao:

- **Klasifikacija ili kategorizacija**: uključuje popis zadataka ili problema za koje bi stroj trebao koristiti uzorke te svakom uzorku dodijeliti određenu kategoriju ili klasu;

- **Regresija**: vrsta zadataka koji obično izvode predviđanja na način da će rezultat biti stvarna numerička vrijednost za zadanu ulaznu vrijednost podatka;
- **Otkrivanje anomalija**: uključuje analizu zapisnika događaja, izvješća o transakcijama i drugih podatkovnih zapisa na način da se otkriju anomalije i obrasci/događaji koji se razlikuju od uobičajenog ponašanja;
- **Strukturirana bilješka**: uključuje provođenje analize na ulaznim podatcima i dodavanje strukturiranih metapodataka kao bilješke izvornim podatcima kako bi dodatno opisali odnose među elementima podataka;
- **Prijevod**: funkcije automatiziranog strojnog prevođenja ulaznih podataka koji pripadaju određenom jeziku na drugi jezik;
- **Klasteriranje ili grupiranje**: klasteri ili grupe se formiraju od uzoraka ulaznih podataka provjerom karakterističnih obrazaca, sličnosti i odnosa između ulaznih podataka.

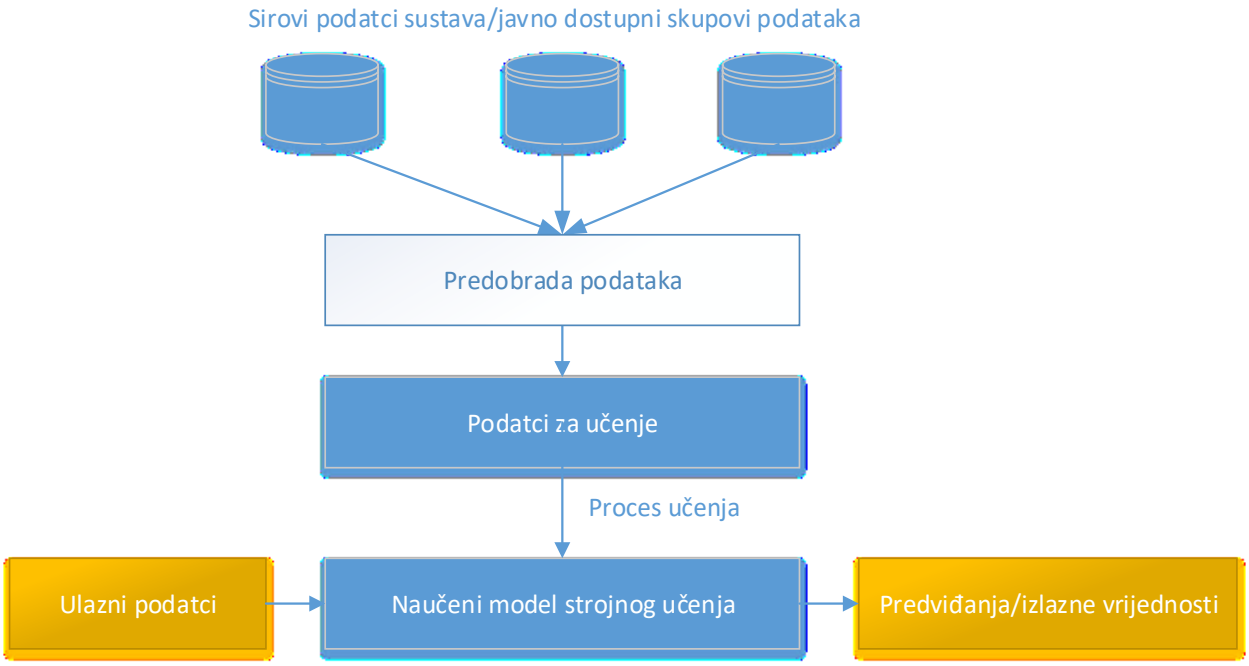

Slika 3.1 Osnovni princip rada strojnog učenja [54]

Slika 3.1 prikazuje pojednostavljeni postupak strojnog učenja. Postupak počinje prikupljanjem ulaznih podataka iz različitih izvora, uključujući javno dostupne skupove podataka, senzore ili druge izvore sirovih podataka. Nakon prikupljanja, ovi se podaci pripremaju za strojno učenje. Ovaj korak uključuje čišćenje podataka, uklanjanje nevažnih ili nepotpunih informacija, skaliranje

i kodiranje kategorijskih podataka kako bi se osigurala kvaliteta ulaznih podataka za model. Nakon pripreme podataka, odabire se odgovarajući model strojnog učenja koji će se koristiti za treniranje. Model se trenira prikupljenim podacima kako bi naučio njihove uzorke i relacije. Kada je model uspješno naučen, može se koristiti za predviđanje rezultata na novim ulaznim podatcima. Ovisno o prirodi problema, to može biti jednostavan model poput linearne regresije, klasifikacije ili složeniji model poput neuronske mreže. Osnovni princip strojnog učenja leži u sposobnosti algoritama da automatski identificiraju obrasce iz ulaznih podataka i njihovih prošlih vrijednosti kako bi donosili predviđanja ili odluke kao izlazne vrijednosti. Nakon implementacije modela, važno je sustavno pratiti performanse kako bi se osigurala preciznost i pouzdanost u predikcijama. Algoritmi prilagođavaju svoje parametre za izgradnju optimalnih logičkih modela kako bi minimizirali razliku između stvarnih i predviđenih izlaznih vrijednosti. Osim toga, moguće je povremeno ponovno treniranje modela s novim podacima kako bi se osigurala njegova prilagodljivost promjenama u okolini ili problema [54], [55].

3.1.1. Kategorije strojnog učenja

Općenito se metode strojnog učenja prema količini ljudskog nadzora u procesu učenja mogu podijeliti na: nadzirano učenje (eng. *supervised learning*), nenadzirano učenje (eng. *unsupervised learning*), polunadzirano učenje (eng. *semi-supervised learning*) i podržano učenje (eng. *reinforcement learning*).

Nadzirano učenje: cilj nadziranog učenja je naučiti model iz označenih podataka koji omogućuju predviđanje budućih podataka. Izraz „nadzirani“ odnosi se na skup uzoraka gdje su izlazne oznake već poznate. Ovako naučeno znanje može se koristiti za predviđanje izlaza za bilo koji novi uzorak ulaznih podataka koji je prethodno bio nepoznat ili neviđen tijekom procesa učenja modela. Dva najčešća zadatka nadziranog strojnog učenja su klasifikacija i regresija. U problemima klasifikacije predviđaju se diskretne vrijednosti, odnosno predviđa se najvjerojatnija kategorija, klasa ili oznaka za nove uzorke. U problemima regresije predviđa se vrijednost varijable kontinuiranog odziva odnosno pokušava se zavisnost varijabli opisati neprekidnom funkcijom.

Nenadzirano učenje: pokušava se otkriti uzorke podataka s nerazvrstanim i neoznačenim podatcima. Jedan od uobičajenih zadataka nenadziranog učenja je grupirati slične podatke odnosno

grupirati slične elemente u „klastere” ili svesti podatke na mali broj „važnih dimenzija”. Nenadzirano učenje više se bavi pokušajem izvlačenja korisnih informacija iz podataka, a ne predviđanjem ishoda.

Polunadzirano učenje: konceptualno je smješteno između nadziranog i nenadziranog učenja, omogućuje iskorištavanje velike količine neobilježenih podataka u kombinaciji s tipično manjim skupovima označenih podataka. Obično polunadzirani algoritmi strojnog učenja pokušavaju poboljšati izvedbu jedne od prethodno spomenutih metoda korištenjem uzajamno povezanih informacija.

Podržano učenje: odnosi se na ciljno orijentirane algoritme koji uče kako postići složeni cilj ili maksimizirati vrijednost određene dimenzije u više iteracija. Ova metoda omogućuje strojevima i softverskim agentima automatsko određivanje idealnog ponašanja u određenom kontekstu kako bi se maksimizirale performanse. Potrebne su povratne informacije kako bi se naučilo koja je akcija najbolja u postizanju maksimalne vrijednosti [52], [53], [56].

3.1.2. Nadzirano strojno učenje

Nadzirano učenje nudi široku primjenjivost na različite probleme poput klasifikacije, regresije i detekcije anomalija, što ga čini izuzetno fleksibilnim za raznolike zadatke strojnog učenja. Razlozi za odabir nadziranog strojnog učenja uključuju jasno definirane ciljne izlazne vrijednosti (predviđanja) koje su ključne za klasifikaciju i detekciju anomalija. Ovaj pristup omogućuje precizno modeliranje uzoraka u podacima te stvara temelj za pouzdane predikcije. Također, nadzirano učenje olakšava kontrolu nad procesom učenja, omogućujući preciznu procjenu performansi modela, što je od vitalnog značaja za detekciju anomalija i klasifikaciju u stvarnim scenarijima primjene.

Nadzirano strojno učenje je grana strojnog učenja koja se temelji na razvoju modela za predviđanje budućih ishoda, a to postiže učenjem na temelju ulaznih i izlaznih parova podataka ili označenih podataka. Cilj ovakvog modela je stvaranje funkcije koja je dovoljno dobra u aproksimaciji i koja može predviđati izlazne vrijednosti novih ulaznih podataka [55]. Princip rada nadziranog učenja može se vizualizirati i razumjeti kroz sljedeći dijagram na Slici 3.2.

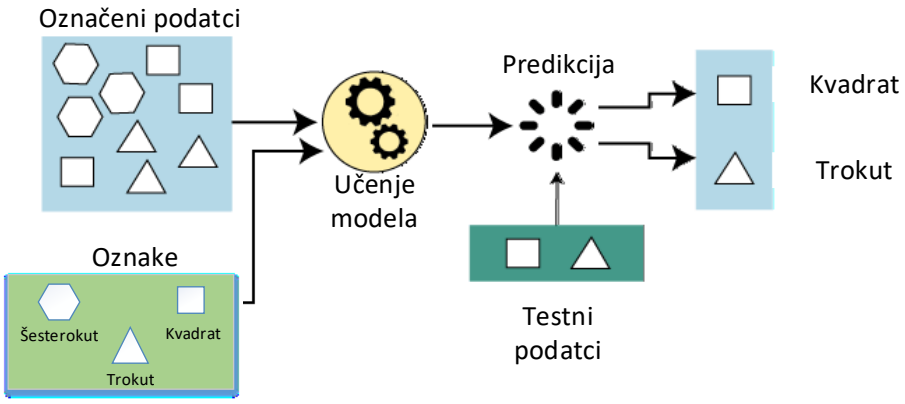

Slika 3.2 Princip rada nadziranog strojnog učenja [55]

Problemi u nadziranom strojnom učenju mogu se grupirati u probleme regresije i probleme klasifikacije. U ovom istraživanju uspoređene su različite vrste klasifikacijskih algoritama korištenih u svrhu otkrivanja anomalija mrežnog prometa, a prema [57], algoritmi klasifikacije nadziranog strojnog učenja mogu se podijeliti na:

- algoritme temeljene na logici (Stablo odlučivanja, Slučajna šuma);
- algoritme strojeva s potpornim vektorima (Strojevi potpornih vektora klasifikacije ili regresije);
- algoritmi temeljeni na statistici (Naivni Bayesovi algoritmi);
- algoritam lijenog učenja (K-najbliži susjed).

Na primjeru otkrivanja anomalija mrežnog prometa teži se postizanju cilja pronalaženja sustavnog načina predviđanja anomalija s obzirom na ulazni skup podataka. U smislu strojnog učenja, ovaj cilj se formulira kao zadatak izvođenja modela nadziranog strojnog učenja nad prikupljenim podatcima, gdje model predviđa vrijednost izlazne varijable na temelju promatranih vrijednosti ulaznih varijabli. Pronalaženje odgovarajućeg modela temelji se na pretpostavci da se za izlaznu varijablu ne uzima nasumična vrijednost i da postoji povezani odnos između ulaznih i izlaznih vrijednosti [58].

U nadziranom učenju promatramo ulaznu varijablu (vektor značajki) $X \in R^d$ koja predstavlja poznate informacije i izlaznu varijablu (oznaku) Y koja predstavlja nepoznate informacije koje želimo predvidjeti. Cilj je predvidjeti Y na temelju X. U praksi, skup pravila za predviđanje izveden je pomoću parametriziranih funkcija $f(w,*): R^d \rightarrow R^k$ gdje $w \in \Omega$ predstavlja parametar modela koji se može naučiti na temelju podataka za učenje. Na primjer, za problem klasifikacije, gdje je

$Y \in \{1, \ldots, k\}$, predviđamo Y pomoću sljedećeg pravila predviđanja prema funkciji $f(w, x) = [f_1(w, x), \ldots, f_k(w, x)] \in R^k$.

Kvaliteta predviđanja mjeri se funkcijom gubitka $L(f(X), Y)$: što je gubitak manji, to je točnost predviđanja bolja.

Nadzirani pristup strojnom učenju uključuje upotrebu označenih podataka kako bi se algoritmu pružile jasne smjernice ili primjeri tijekom učenja. Označeni podatci sadrže ulazne podatke $S_n = [(X_1, Y_1), \ldots, (X_n, Y_n)]$ povezane s odgovarajućim izlaznim vrijednostima, čime se omogućuje modelu da uči od postojećih informacija i prilagodi se na temelju dobivenih podataka. Nastoji se procijeniti vrijednost $\widehat{w} \in \Omega$ na temelju promatranog ulaznog skupa S_n. Algoritam nadziranog učenja A koristi skup podataka za učenje S_n kao ulaz te generira funkciju $f(\widehat{w}, *)$ gdje je $\widehat{w} = A(S_n) \in \Omega$. Nadzirano učenje često se koristi u zadacima poput klasifikacije i regresije, gdje je cilj predvidjeti odgovarajuću klasu ili numeričku vrijednost na temelju ulaznih podataka [59].

3.1.3. Klasifikacija u strojnom učenju

Klasifikacija u strojnom učenju koristi podatke i algoritme kako bi podatkovni uzorci bili svrstani u različite kategorije ili klase. Izbor najboljeg algoritma za klasifikaciju strojnog učenja prema [60] ovisi o raznim faktorima, uključujući:

- Strukture podataka: ukupna veličina skupa podataka, broj značajki i raspodjela klasa;
- Složenost problema: jednostavniji algoritmi poput logističke regresije mogu imati dobre rezultate za jednostavnije probleme, dok se složeniji problemi bolje rješavaju algoritmima poput stabla odlučivanja ili umjetne neuronske mreže;
- Kvaliteta podataka: neadekvatne vrijednosti i korelacija između značajki;
- Vrijeme izvođenja: vrijeme potrebno za izvođenje u sustavu kritičnih i nekritičnih procesa;

Za postizanje što boljih rezultata klasifikacije potrebno je testirati različite algoritme i izabrati onaj koji najbolje funkcionira za određeni problem i skup podataka. Poželjna je i primjena metoda kao što su unakrsna validacija i izolirana provjera kako bi se izbjegli problemi prekomjernog prilagođavanja (eng. *overfitting*) skupu za učenje ili nedovoljne kompleksnosti (eng. *underfitting*).

Klasifikacija podataka se može izvoditi kako s nestrukturiranim tako i sa strukturiranim skupovima podataka. Elementi izlaznog skupa podataka se klasificiraju prema nekoj danoj oznaci ili kategoriji. Neki pojmovi koji se često koriste u klasifikaciji prema [57] su:

- Klasifikator - algoritam koji uči iz skupa za učenje i zatim dodjeljuje oznake (klase) novim ulaznim podatcima;
- Klasifikacijski model - zaključuje valjano mapiranje iz skupa podataka za učenje i predviđa klasu uz pomoć funkcije mapiranja za novi unos podataka;
- Značajka ili svojstvo - parametar pronađen u zadanom skupu podataka koji može u dovoljnoj mjeri pomoći u izgradnji točnog prediktivnog modela.

Najpoznatiji i najučestaliji klasifikatori za detekciju anomalija, koji će biti detaljnije opisani u narednim poglavljima, a dio su Scikit-learn biblioteke otvorenog koda za strojno učenje u programskom jeziku Python, uključuju: klasifikator stabla odluke, slučajnu šumu, stroj s potpornim vektorima, Naivni Bayesov klasifikator i klasifikator K-najbližih susjeda.

3.1.4. Klasifikator stabla odluke

Stablo odluke (eng. *Decision Tree*) je klasifikator temeljen na logici u nadziranoj metodi strojnog učenja koji se koristi i za klasifikaciju i za regresiju. Cilj je stvoriti model koji predviđa vrijednost ili klasu izlazne varijable učenjem jednostavnih pravila odlučivanja zaključenih iz značajki skupa podataka [61]. Klasifikator stabla odluke razdvaja skup podataka na sve manje i manje podskupove na temelju različitih kriterija. Strukturiran je prema stablu, gdje unutarnji čvorovi predstavljaju značajke skupa podataka, grane predstavljaju pravila odluke, a svaki list predstavlja rezultat. Za podjelu skupa podataka koriste se različiti kriteriji sortiranja, a broj podataka će se smanjivati sa svakim dijeljenjem. U stablu odluke postoje dva čvora, a to su tzv. čvor odluke i čvor lista, kao što je prikazano Slikom 3.3. Čvorovi odluka koriste se za donošenje bilo koje odluke i imaju više grana, dok su čvorovi lista izlazne vrijednosti tih odluka i ne sadrže daljnje grane. Stablo odluke klasificira elemente skupa podataka sortirajući ih "niz stablo" od korijenskog čvora do čvora lista [62], [63].

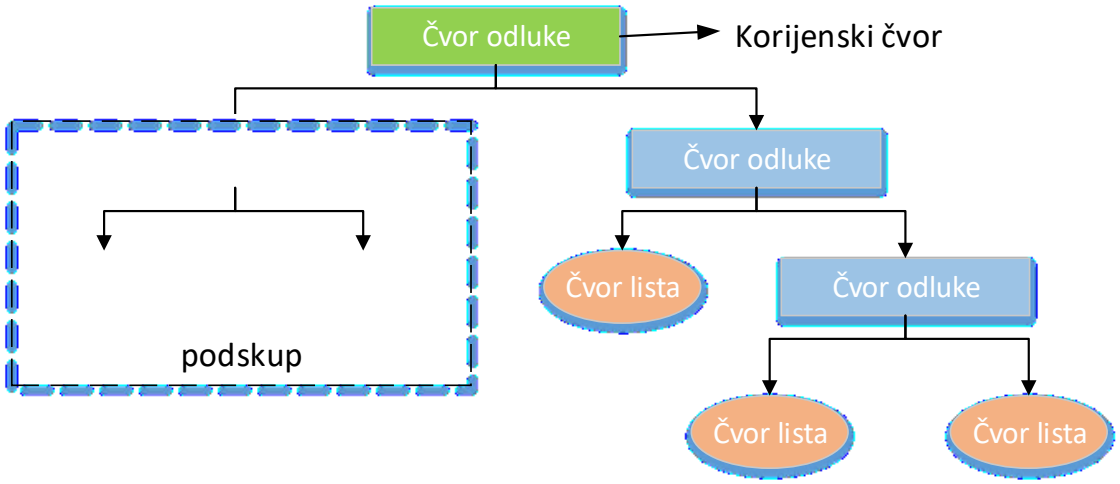

Slika 3.3 Princip klasifikacije pomoću stabla odluke [62]

3.1.5. Klasifikator slučajne šume

Klasifikator Slučajne šume sastoji se od više stabala odluke, svako izgrađeno na različitom podskupu skupa podataka, s ciljem poboljšanja točnosti predviđanja originalnog skupa podataka. Umjesto oslanjanja samo na jedno stablo odluke, ovaj klasifikator koristi predviđanja svakog stabla i zatim na temelju većine glasova donosi konačni rezultat predviđanja [55], [64].

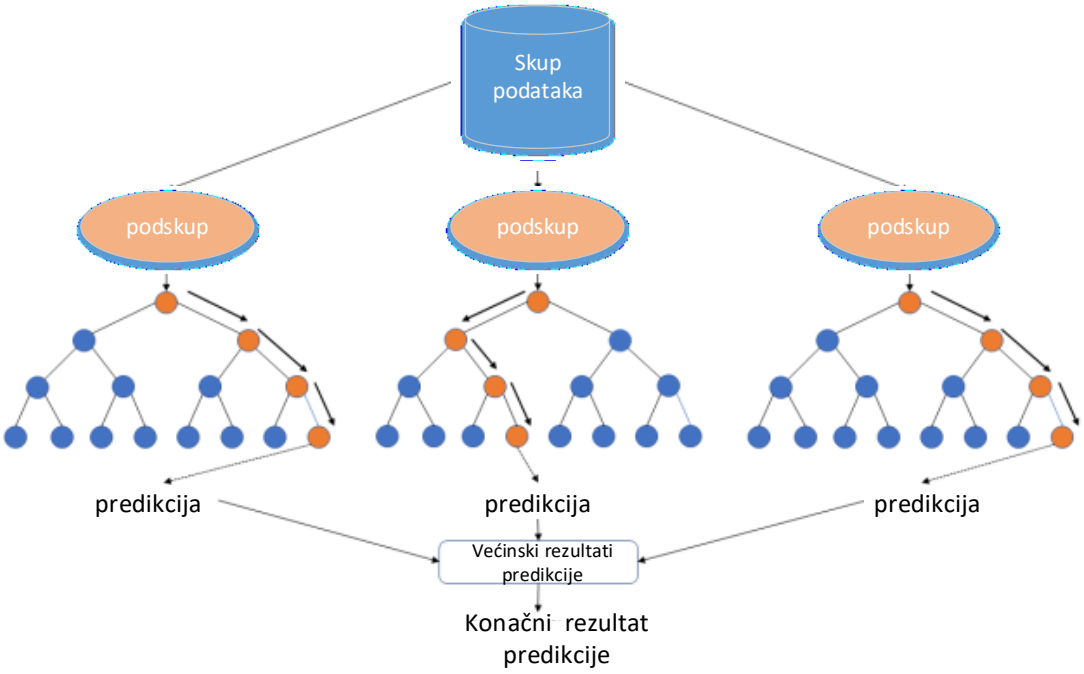

Slika 3.4 Prikaz rada klasifikatora slučajne šume [65]

Klasifikator Slučajne šume umjesto traženja najvažnije značajke tijekom cijepanja čvora traži najbolju značajku među slučajnim podskupom značajki. To rezultira velikom raznolikošću koja općenito rezultira boljim modelom. Stoga se u ovom klasifikatoru za razdvajanje čvora uzima u obzir samo slučajni podskup značajki. Još jedna izvrsna kvaliteta klasifikatora Slučajne šume je ta što je vrlo lako izmjeriti relativnu važnost svake značajke u predviđanju. Na važnost značajke utječe koliko i koji čvorovi koriste tu značajku kako bi smanjili šum na svim ostalim dijelovima klasifikacije. Algoritam Slučajne šume koristi metodu spajanja (eng. *bagging*) kako bi kombinirao jednostavnost stabla odlučivanja s fleksibilnošću, čime povećava točnost i prevladava loše svojstvo stabla odlučivanja koje može biti sklono prekomjernom prilagođavanju podatcima za učenje [66].

U nizu radova i tehničkih izvješća [67], [68], [69], [70] pokazalo se da se znatna poboljšanja u klasifikaciji i točnosti regresije mogu postići korištenjem skupova stabala odluke, pri čemu se svako stablo u skupu konstruira u skladu sa slučajnim parametrom. Konačna predviđanja dobivena su agregacijom preko skupa stabala. Kako su stabla bazne sastavnice modela strukturiranih prediktora, a budući da je svako od tih stabala konstruirano korištenjem funkcije slučajnosti, te se procedure nazivaju "slučajne šume". Za ovu ideju presudni utjecaj imao je rani rad Amita i Gemana [71] o izboru geometrijskih značajki, zatim metoda slučajnog potprostora u radu Ho [72] i Dietterichov pristup slučajnog odabira [73]. Kao što je istaknuto raznim empirijskim studijama, algoritam slučajne šume se pojavio kao ozbiljni konkurent najsuvremenijim metodama. Brz je i jednostavan za implementaciju, daje vrlo točna predviđanja i može podnijeti vrlo velik broj ulaznih varijabli stoga se smatra jednim od najpreciznijih dostupnih tehnika učenja opće namjene. U Breimanovom pristupu [74], svako stablo u zbirci formira se s malom grupom ulaznih podataka, nasumično odabranih u svakom čvoru. Za svaki drugi čvor se odabiru značajke na temelju značajki iz skupa za učenje. Stablo se konstruira pomoću CART (eng. *Classification And Regression Trees*) metode do maksimalne veličine [75]. Pretpostavljamo uzorak podataka za učenje $D_n = \{(X_1, Y_1), \ldots, (X_n, Y_n)\}$ od identičnih i neovisnih slučajnih varijabli u prostoru $[0, 1]^d \times R$ slučajnih varijabli ($d \geq 2$) s istom distribucijom kao nezavisni generički par (X, Y) koji zadovoljava $EY^2 < \infty$. Za fiksni $x \in [0, 1]^d$, cilj je procijeniti regresijsku funkciju $r(x) = E[Y \mid X = x]$ korištenjem podataka D_n. U tom smislu je procjena regresijske funkcije r_n konzistentna ako $E[r_n(X) - r(X)]^2 \rightarrow 0$ kada $n \rightarrow \infty$. Formalno, slučajna šuma je prediktor koji se sastoji od kolekcije nasumičnih baznih regresijskih stabala $\{r_n(x, \Theta_m, D_n), m \geq 1\}$, gdje su $\Theta_1, \Theta_2, \ldots \Theta_m$ izlazne vrijednosti slučajne

varijable Θ. Ta se slučajna stabla kombiniraju kako bi se formirala agregirana regresijska procjena $r_n(X, D_n) = E_\Theta [r_n(X, \Theta, D_n)]$, gdje E_Θ označava očekivanje s obzirom na slučajni parametar. Slučajna varijabla Θ koristi se za određivanje načina na koji se izvode uzastopni rezovi prilikom konstrukcije pojedinačnih stabala [76].

3.1.6. Klasifikator stroja s potpornim vektorima

Strojevi s potpornim vektorima (eng. *Support Vector Machines*) je nadzirani algoritam strojnog učenja koji se može koristiti u regresijskim i klasifikacijskim zadacima. Temelji se na procesu razdvajanja granica između različitih skupina podataka radi njihovog grupiranja u određene kategorije ili klase. Uzorci s jedne strane linije bit će jedna klasa, a uzorci s druge strane pripadaju drugoj klasi. Klasifikator teži maksimiziranju udaljenosti između linije i uzoraka s obje strane radi povećanja pouzdanosti u klasifikaciji uzoraka u određenu klasu. Koordinate ovih podataka zapravo se nazivaju „potporni vektori". U dvoklasnom problemu strojnog učenja cilj je pronaći najbolju klasifikacijsku funkciju kako bi se razlikovali članovi dvije klase u podatcima koji se koriste za učenje. Koncept ovakve funkcije "najbolje" klasifikacije može se realizirati geometrijski kao što je prikazano na Slici 3.5, ali većina klasifikacijskih zadataka nisu jednostavani poput ovog primjera i često su potrebne složene računske operacije kako bi se napravila optimalna podjela.

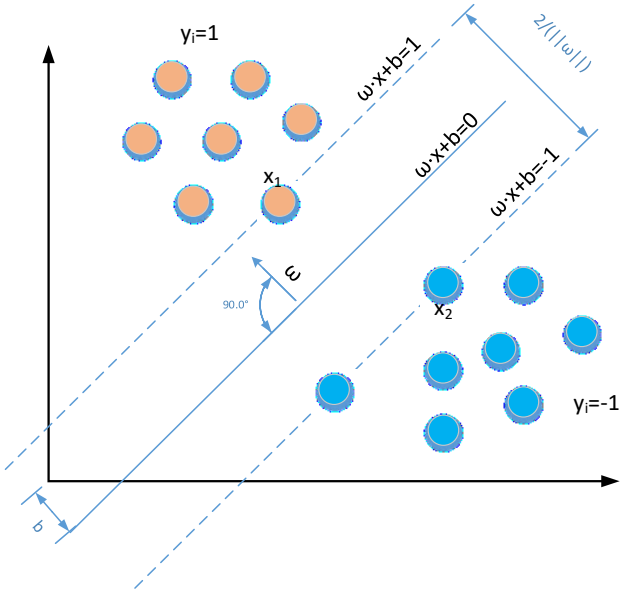

Slika 3.5 Prikaz klasifikacije pomoću stroja s potpornim vektorima za slučaj dvije klase [77]

U slučaju linearno odvojivog skupa podataka, uloga linearne funkcije klasifikacije je maksimizirati razmak hiperravnine koje razdvajaju središta dviju klasa. U skupu podataka za učenje $D = \{(X_1, y_1), (X_2, y_2), \dots, (X_n, y_n)\}$ gdje je X_i karakterističan vektor uzoraka podataka za učenje, a y_i je pridružena oznaka (klasa) tom vektoru može se reći da postoji linearna funkcija koja u potpunosti može odijeliti uzorke u dvije klase. Na Slici 3.5. prikazan je linearno odvojiv skup podataka kojeg prezentira ravna linija, no postoji bezbroj dodatnih linija kojima se može prikazati odjeljivanje. Optimalna linija klasifikacije može se predočiti jednadžbom [78]:

$$\omega \cdot x + b = 0 \ (\omega \in R^n, \ b \in R) \tag{3-1}$$

gdje je ω vektor težina (normala) hiperravnine, a b je pomak hiperravnine. Uzorci iznad linije zadovoljavaju jednadžbu [78]:

$$\omega \cdot x + b > 0, \tag{3-2}$$

a ispod linije zadovoljavaju jednadžbu [78]:

$$\omega \cdot x + b < 0. \tag{3-3}$$

Prema [78] granicu za klasu 1 možemo zapisati kao

$$H1\text{: } \omega \cdot x + b \geq 1 \text{ za } y_i = 1 \tag{3-4}$$

odnosno

$$H2\text{: } \omega \cdot x + b \leq 1 \text{ za } y_i = -1. \tag{3-5}$$

Prema ovim jednadžbama najveća udaljenost se postiže najvećom vrijednosti $\frac{2}{||\omega||}$ odnosno izračunom najmanje vrijednosti za $||\omega||$ [57], [79], [80], [81].

3.1.7. Naivni Bayesov klasifikator

Bayesov klasifikator se u strojnom učenju može upotrijebiti za klasifikaciju dviju ili više klasa. Klasifikator uči analizirajući unaprijed pripremljen skup točno klasificiranih podataka za učenje i može se upotrijebiti za utvrđivanje vjerojatnosti klasa. U tom modelu pretpostavka je da su

značajke uvjetno nezavisne s obzirom na klasu. Temelj cijelog Bayesovog klasifikatora je Bayesov teorem koji uz pomoć jednadžbe [55]:

$$P(A|B) = P(B|A)P(A)/P(B) \tag{3-6}$$

izračunava uvjetnu vjerojatnost temeljenu na prethodnom znanju kojeg imamo o problemu. Ovaj klasifikator određuje vjerojatnost kojom određeni podatak pripada nekoj klasi, izračunavajući vjerojatnost da će se dogoditi neki događaj s obzirom na to da se dogodio neki ulazni događaj. Oznaka P(A|B) predstavlja uvjetnu vjerojatnost pojavljivanja događaja dok P(A) predstavlja vjerojatnost pojavljivanja događaja A, a P(B) predstavlja vjerojatnost pojavljivanja događaja B. Vjerojatnosti klasa su učestalost slučajeva koji pripadaju svakoj klasi podijeljena s ukupnim brojem primjeraka. U binarnoj klasifikaciji vjerojatnost uzorka koji pripada klasi 1 računa se prema jednadžbi [82]:

$$P(klasa = 1) = \frac{broj(klasa=1)}{broj(klasa=0)+broj(klasa=1)} \tag{3-7}$$

Naivni Bayesov algoritam klasifikacije može se generalizirati na rad s kontinuiranim vrijednostima tako da se najčešće pretpostavi Gaussova raspodjela. Ova pretpostavka omogućuje jednostavno procjenjivanje raspodjele podataka za učenje, jer je potrebno samo izračunati srednju vrijednost i standardnu devijaciju podataka za učenje. Iako se za procjenu raspodjele mogu koristiti i druge funkcije, Gaussova (normalna) raspodjela je najčešće odabrana zbog svoje praktičnosti i jednostavnosti u ovom algoritmu. Prema [55] postoje tri vrste Naivnog Bayesova modela:

- Gaussov klasifikator - pretpostavlja da obilježja skupa podataka slijede normalnu raspodjelu. To znači da ako klasifikatori uzimaju kontinuirane vrijednosti umjesto diskretnih tada model pretpostavlja da su te vrijednosti uzorkovane iz Gaussove raspodjele;
- Multinominalni naivni Bayesov klasifikator koristi se kada su podatci multinominalno distribuirani. Primarno se koristi za probleme s klasifikacijom dokumenata gdje klasifikator koristi frekvenciju pojavljivanja riječi;
- Bernoullijev klasifikator djeluje slično multinominalnom klasifikatoru, ali prediktorske varijable su neovisne boolean varijable.

Naivni Bayesov model privlači pažnju zbog svoje jednostavnosti i pouzdanosti. Ovaj algoritam je jedna od najstarijih metoda formalne klasifikacije, ali čak i u svom osnovnom obliku pokazuje iznenađujuću učinkovitost [63][83].

3.1.8. Klasifikator K-najbližeg susjeda

K-najbliži susjed je nadzirani algoritam učenja gdje se rezultat klasificira na temelju većinske klase K-najbližeg susjeda. Ovaj klasifikator je jednostavan i zasniva se na temelju minimalne udaljenosti od promatranog uzorka do uzoraka podatka za učenje kako bi se utvrdili najbliži susjedi. Nakon što se pronađu najbliži susjedi uzima se klasa većine najbližih susjeda *K* kako bi se predvidjela klasa promatranog uzorka kao što je prikazano na Slici 3.6. Klasa promatranog uzorka označenog zelenom bojom predviđa se na temelju udaljenosti do najbližih susjeda.

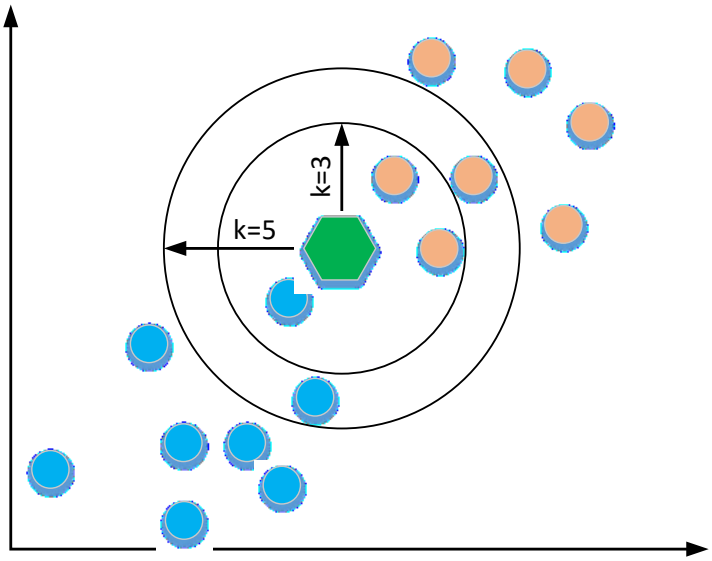

Slika 3.6 Klasifikacija uzorka algoritmom K-najbližeg susjeda [84]

Obično se uzima euklidska udaljenost kao metrika za mjerenje udaljenosti od susjeda. Euklidska udaljenost između dva vektora A i B gdje je $A = (x_1, x_2, x_3, \dots, x_n)$ i $B = (y_1, y_2, y_3, \dots, y_n)$ dana je jednadžbom [85] :

$$d(A,B) = \sqrt{\sum_{i=1}^{m}(x_i - y_i)^2} \quad (3\text{-}8)$$

Ne postoji način za određivanje najbolje vrijednosti koeficijenta *K*, stoga treba isprobati različite vrijednosti kako bi se pronašao najbolji rezultat [85], [86]. Uobičajena vrijednost za K je 5, ali važno je obratiti pažnju na nekoliko stvari [57]:

- Smanjenjem vrijednosti K, predviđanja postaju manje sigurna jer se temelje na manjem broju susjeda;
- Povećanjem vrijednosti K, predviđanja postaju sigurnija jer se temelje na usrednjavanju većine susjeda, što često rezultira preciznijim predviđanjima, ali se zahtijeva više računalnih resursa jer model mora uzeti u obzir više susjeda prilikom donošenja odluka;
- Ako se počne pojavljivati veći broj pogrešaka u predviđanjima, to može ukazivati da je vrijednost K prešla optimalnu granicu;
- U slučajevima klasifikacije, obično se uzima neparan broj za K kako bi se izbjegao nerješen rezultat i nemogućnost određivanja klasifikacije u slučaju podjednakog broja susjeda iz različitih klasa.

3.2. Mjere uspješnosti klasifikacije

Uspješnost algoritma strojnog učenja procjenjuje se pomoću metričkih vrijednosti. Problem ocjenjivanja klasifikatora (tj. mjerenja njegove kvalitete) rješava se pomoću jedinstvene ocjene koja pokušava sažeti specifične uvjete i interese prilikom ocjenjivanja [87]. Postoji mnogo načina ocjenjivanja klasifikatora, a u problemu klasifikacije najčešće se koriste sljedeće vrste mjernih podataka:

- Matrica konfuzije (eng. *Confusion Matrix*);
- Mjera točnosti klasifikacije (eng. *Accuracy*);
- Mjera uravnotežene točnosti (eng. *Balanced Accuracy*);
- Mjera preciznosti (eng. *Precision*);
- Mjera opoziva (eng. *Recall*);
- F mjera (eng. *F Score*);

- Područje ispod krivulje (eng. *Area under Curve*);
- Matthewsov koeficijent korelacije (eng. *Matthews correlation coefficient*);
- Cohen kappa koeficijent (eng. *Cohen's kappa coefficient*);

3.2.1. Matrica konfuzije

Matrica konfuzije prikazuje slučajeve istinitih i lažnih predviđanja dobivenih na osnovu poznatih ulaznih podataka. Binarni klasifikacijski model uključuje četiri moguća scenarija rezultata koje dobivamo kroz usporedbu predviđenih i stvarnih vrijednosti u dvije klase: pozitivnu i negativnu. Rezultat je izlazna vrijednost u obliku matrice i opisuje performanse modela s četiri moguća ishoda koja se različito definiraju. Kada se predvidi pozitivan i dobije pozitivan rezultat, to nazivamo istinito pozitivni rezultat (IP). Kada se predvidi pozitivan, a dobije negativan rezultat, to nazivamo lažno pozitivnim rezultatom (LP) poznat i kao pogreška tipa 1. Kada se predvidi negativan, a dobije pozitivan rezultat, to nazivamo lažno negativnim rezultatom (LN) poznat i kao pogreška tipa 2. Četvrti mogući ishod je kada se predvidi negativan i dobije negativan rezultat, ovo nazivamo istinito negativan rezultat (IN).

Na Slici 3.7 plavi i zeleni krugovi označavaju uzorke za koje se zna da su pozitivni (IP + LN), odnosno negativni (LP + IN), a plava i zelena pozadina/kvadrati prikazuju predviđene pozitivne (IP + LP) i negativne (LN + IN) rezultate. Matrica konfuzije čini osnovu za druge vrste mjernih podataka koje su opisane u nastavku.

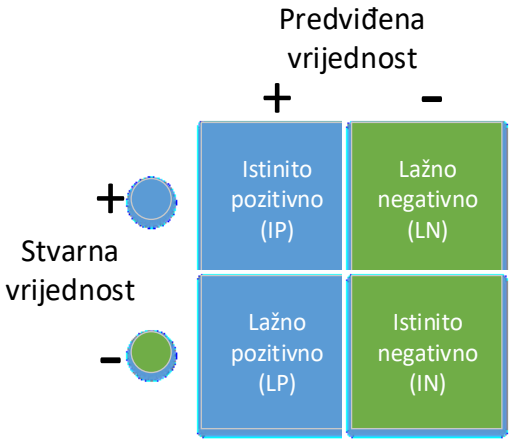

Slika 3.7 Matrica konfuzije za slučaj binarne klasifikacije

3.2.2. Mjera točnosti i pogreške klasifikacije

Tipične ocjene za mjerenje performansi klasifikatora su točnost i klasifikacijska pogreška, koja se za binarni problem može lako izvesti iz matrice konfuzije dimenzije 2x2 kao one prikazane na Slici 3.7. Mjera točnosti je omjer broja točnih predviđanja i ukupnog broja ulaznih uzoraka i izračunava se prema jednadžbama [87]:

$$točnost = \frac{broj\ točnih\ predviđanja}{broj\ ukupnih\ predviđanja} = \frac{IP+IN}{IP+LN+IN+LP} \tag{3-9}$$

$$pogreška = \frac{broj\ lažnih\ predviđanja}{broj\ ukupnih\ predviđanja} = \frac{LP+LN}{IP+LN+IN+LP} \tag{3-10}$$

Ove vrijednosti točnosti i pogreške djeluju dobro samo ako postoji jednak broj uzoraka koji pripadaju svakoj klasi. Na žalost, u stvarnim problemima jednake proporcije uzoraka po klasi prilično su rijetke, te ovakve mjerne vrijednosti mogu dati lažni osjećaj postizanja visoke točnosti. Ovakva situacija je poznata kao problem nebalansiranosti uzoraka. Empirijski je dokazano da su točnost i stopa pogrešake pristrani s obzirom na nebalansiranost uzoraka odnosno ne uzimaju se u obzir slučajevi pogrešnih klasifikacija. Rezultati su snažno pristrani na način da favoriziraju klasu koja je u većini i osjetljivi su na tzv. iskrivljenost klasa. Ovi mjerni parametri za problem klasifikacije nisu najprikladniji ako se uzimaju bez dodatnog razmatranja [87]. Učestalost većinske klase ima veliki utjecaj na izračun točnosti, dok manje zastupljene klase imaju manji utjecaj. Stoga je bitno odabrati adekvatnu metriku evaluacije koja će pridavati veći značaj manjinskoj klasi. Precizno predviđanje što većeg broja slučajeva manjinske klase ključno je za postizanje boljeg rješenja, posebno u situacijama s vrlo nebalansiranim uzorcima [88].

3.2.3. Uravnotežena točnost

Uravnotežena točnost sprječava pretjerane procjene točnosti na nebalansiranim skupovima podataka. Izračunava se kao prosječna vrijednost mjere osjetljivosti (opoziva) za svaku klasu. Stoga je za balansirane skupove podataka rezultat uravnotežene točnosti jednak klasičnoj točnosti. U binarnom problemu, uravnotežena točnost jednaka je aritmetičkoj sredini osjetljivosti (stopi

istinito pozitivnih predviđanja) i specifičnosti (stopi istinito negativnih predviđanja) ili površini ispod ROC (eng. *Receiver Operating Characteristic*) krivulje s binarnim predviđanjima [89].

$$uravnotežena\ točnost = \frac{1}{2}\left(\frac{IP}{IP+LN} + \frac{IN}{IN+LP}\right) \tag{3-11}$$

U [90] autori objašnjavaju nedostatke klasične točnosti (nebalansiran skup podataka i nemogućnost izračunavanja smislenog intervala pouzdanosti na temelju broja uzoraka) i prednosti zamjene s mjerom uravnotežene točnosti.

3.2.4. Mjera preciznosti

Broj istinito pozitivnih rezultata podijeljen s brojem pozitivnih rezultata koje je predvidio klasifikator naziva se mjerom preciznosti i izračunava se prema [91]:

$$preciznost = \frac{IP}{IP+LP} \tag{3-12}$$

Mjera preciznosti je prikladna kada je fokus strojnog učenja na smanjivanju lažno pozitivnih predviđanja [91].

3.2.5. Mjera opoziva

Broj istinito pozitivnih rezultata podijeljen s brojem svih relevantnih uzoraka (svi uzorci koji bi trebali biti identificirani kao pozitivni) naziva se mjerom opoziva i izračunava se prema [91]:

$$opoziv = \frac{IP}{IP+LN} \tag{3-13}$$

Mjera opoziva je prikladna kada je fokus strojnog učenja na smanjivanju lažno negativnih predviđanja [91].

3.2.6. F i G mjera

Nedostaci mjere točnosti i pogreške rezultirali su novim mjernim vrijednostima kojima se želi postići kompromis u klasifikaciji i na pozitivnim i na negativnim uzorcima podataka. Jedna od takvih alternativnih ocjena su: harmonijska i geometrijska sredina izmjerena odvojeno za svaku klasu. Mjere harmonijske i geometrijske sredine daju jednaku važnost svim klasama i korisne su jer uzimaju u obzir oba aspekta performansi modela, preciznost i osjetljivost, što ih čini prikladnim za evaluaciju modela s nebalansiranim klasama [87].

F mjera predstavlja harmonijsku sredinu između vrijednosti opoziva i preciznosti u rasponu između vrijednosti 0 i 1 te pokazuje koliko je precizan klasifikator (koliko se uzoraka ispravno klasificira), kao i koliko je robustan (ne griješi u klasifikaciji u značajanom broju uzoraka). Što je veći F rezultat, to su bolje performanse modela. Matematički se to može izraziti kao [91]:

$$F = 2 * \frac{preciznost * opoziv}{preciznost + opoziv} \tag{3-14}$$

Geometrijska sredina se koristi za maksimiziranje stope IP i IN, a istovremeno zadržavajući obje stope relativno uravnotežene. Matematički se može izraziti kao [88]:

$$G = \sqrt{IP * IN} \tag{3-15}$$

F i G mjere pokazali su se kao bolji parametri nego mjera točnosti u optimizaciji klasifikatora za binarne probleme klasifikacije [88]. F i G mjere daju optimalne rezultate kada dosegnu vrijednost 1, dok postižu najslabije rezultate kada su vrijednosti 0, što je slično kao kod mjera preciznosti i osjetljivosti. F-mjera kombinira preciznost i osjetljivost na uravnotežen način. U nekim slučajevima, želimo F mjeru koja će više naglasiti preciznost, npr. kada je cilj minimizirati lažno pozitivne predikcije, dok su lažno negativne predikcije i dalje bitne. U drugim slučajevima, želimo F mjeru usredotočenu na opoziv, npr. kada je važnije minimizirati lažno negativne predikcije, ali lažno pozitivne predikcije su i dalje važne. Fß (Fbeta) mjera je rješenje za takve probleme, a izvodi se iz F mjere, pri čemu se koeficijent ß koristi za kontroliranje ravnoteže između preciznosti i opoziva [91]:

$$F\beta = \frac{(1+\beta^2) * preciznost * opoziv}{(\beta^2 * preciznost) + opoziv} \tag{3-16}$$

Tri uobičajene vrijednosti za β parametar su prema [91]:

- F0.5 mjera (β=0.5): veći naglasak na preciznosti, manji na opozivu;
- F1 mjera (β=1): jednak naglasak na preciznost i opoziv;
- F2 mjera (β=2): veći naglasak na opozivu, manji na preciznost.

3.2.7. Područje ispod krivulje (AUC)

Jedna od najčešće korištene tehnike za ocjenu klasifikatora je ROC (eng. *Receiver Operating Characteristic*) krivulja, koja je grafički prikaz mjere opoziva u odnosu na stopu lažno pozitivnih rezultata [91]:

$$stopa\ lažno\ pozitivnih\ rezultata = \frac{LP}{LP+IN} \tag{3-17}$$

Informacija o izvedbi klasifikacije u ROC krivulji može se sažeti u rezultat poznat kao AUC odnosno područje ispod ROC krivulje. Ova mjera je neosjetljivija na neravnomjernost u raspodjeli klasa i predstavlja kompromis između opoziva i stope lažno pozitivnih rezultata [87]. Ova mjera pokazuje koliko je model sposoban razlikovati klase. Što je veći AUC, to je model bolji u predviđanju stvarno pozitivnih uzoraka kao pozitivnih rezultata i obrnuto, predviđanju stvarno negativnih uzoraka kao negativnih rezultata.

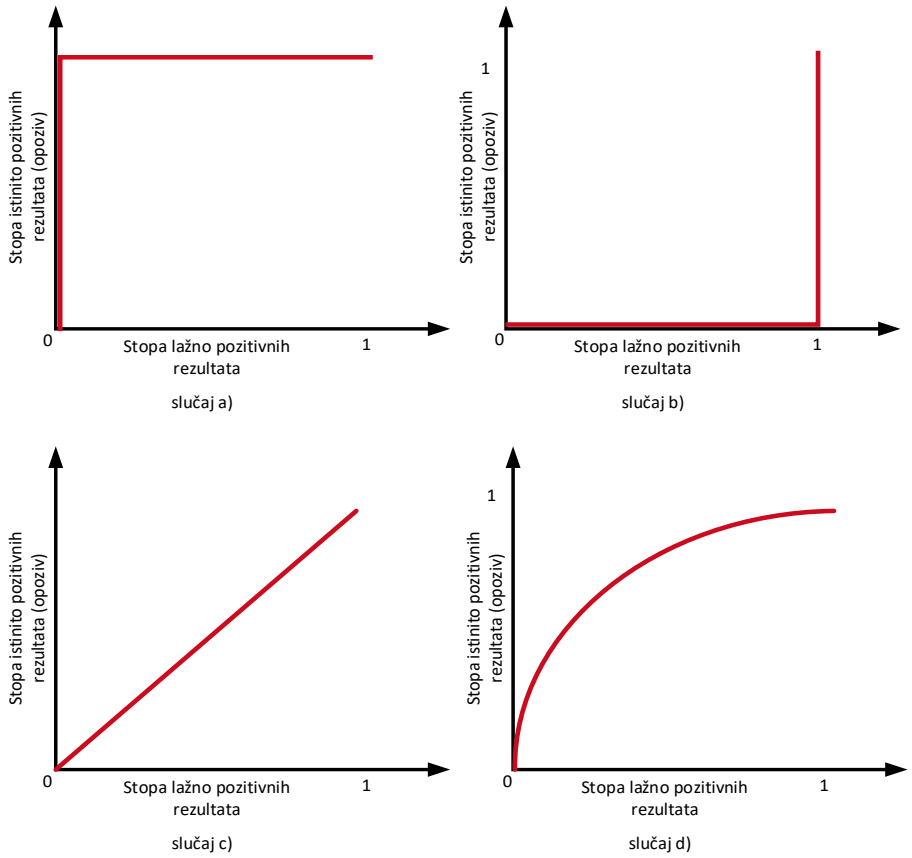

Slika 3.8 Tipične ROC krivulje [92]

AUC vrijednosti se kreću između 0 i 1, a tipični slučajevi su prikazani na Slici 3.8. Izvrsni model ima AUC blizu vrijednosti 1 (slučaj a.), što znači da može dobro odvojiti klase. Loš model ima AUC blizu vrijednosti 0 (slučaj b.), što znači da jako loše razdvaja klase odnosno predviđa suprotno od stvarnih vrijednosti. Za model koji uopće nema sposobnost odvajanja klasa AUC mjera je jednaka vrijednosti 0.5 (slučaj c.), tipična ROC krivulja ima oblik prikazan na Slici 3.8 za slučaj d.

U ROC krivulji, veća vrijednost na osi X označava veći broj lažno pozitivnih nego istinitih negativnih predviđanja. Dok veća vrijednost na osi Y ukazuje na veći broj istinito pozitivnih nego lažno negativnih predviđanja. Dakle, izbor praga ovisi o željenom odnosu i ravnoteži između lažno pozitivnih i lažno negativnih predviđanja [93]. Blizina ROC krivulje gornjem lijevom kutu na Slici 3.8 sugerira da klasifikator ima visoke performanse u razlikovanju između pozitivnih i negativnih uzoraka. AUC predstavlja vjerojatnost da će klasifikator ispravno razlikovati pozitivne i negativne uzorke, a računa se kao površina ispod ROC krivulje. Drugim riječima, AUC je mjera koja

određuje koliko je vjerojatno da će klasifikator dati bolji rezultat za pozitivne uzorke u odnosu na negativne uzorke [94]. Dobra ROC krivulja zatvara veću površinu, dok loša zatvara manju površinu što znači da je visoka AUC vrijednost poželjna, a niska vrijednost AUC nije.

Prema [93], prednosti za korištenje AUC mjere kod odabira klasifikatora su:

- djeluje neovisno s obzirom na raspodjelu klasa;
- pruža dobru skalarnu mjeru rangiranja klasifikatora.

Kada se radi s nebalansiranim skupovima podataka, upotreba AUC mjere je često preferirana u istraživanjima. Neravnoteža klasa može otežati prepoznavanje manjinske klase i stvoriti pristranost u korist većinske klase, što može utjecati na točnost klasifikacije. Klasična mjera točnosti nije uvijek pouzdana jer može dati varljivo visok rezultat kada je manjinska klasa u velikoj mjeri smanjena. Stoga se preporučuje korištenje AUC mjere zajedno s drugim metrikama poput preciznosti i opoziva. Neka istraživanja [95], [96] su pokazala da je korištenje AUC mjere kao samostalne i robustne metrike kod neravnoteže u klasama podataka vrlo učinkovito.

3.2.8. Matthewsov koeficijent korelacije

Matthewsov koeficijent korelacije (MCC eng. *Matthews correlation coefficient*) je koristan u strojnom učenju za procjenu kvalitete binarnih klasifikacija. On uzima u obzir stvarne pozitivne, lažne pozitivne, stvarne negativne i lažne negativne rezultate predviđanja i obično se koristi kao mjerilo koje se može primijeniti čak i kad je veličina klasa vrlo nejednaka. Vrijednost MMC-a kreće se između -1 i 1, pri čemu koeficijent 1 označava savršeno predviđanje, koeficijent 0 prosječno slučajno predviđanje, a koeficijent -1 inverzno predviđanje. U statistici, MMC je također poznat kao phi koeficijent. U binarnom (dvoklasnom) slučaju MCC koeficijent se prema [89] računa jednadžbom :

$$MCC = \frac{IP*IN - LP*LN}{\sqrt{(IP+LP)*(IP+LN)*(IN+LP)*(IN+LN)}} \tag{3-18}$$

3.2.9. Cohen kappa koeficijent

Cohen kappa koeficijent se, poput drugih metrika za evaluaciju strojnog učenja, temelji na matrici konfuzije, ali uzima u obzir neravnotežu u raspodjeli klasa. Rezultat Cohen kappa koeficijenta je između -1 i 1, a vrijednost iznad 0.8 se obično smatra dobrim slaganjem između predviđenih i stvarnih vrijednosti. Ova metrika se može koristiti za usporedbu predviđanja modela strojnog učenja s ručno utvrđenim klasama skupa podataka. Cohenov kappa koeficijent izračunava se prema [97]:

$$\kappa = \frac{P_0 - P_e}{1 - P_e} \tag{3-19}$$

Gdje je P_0 ukupna točnost modela, P_e je mjera slaganja između predviđanja modela i stvarnih vrijednosti klase kao da su slučajno određeni. U binarnom problemu klasifikacije P_e je suma P_{e1} (vjerojatnost da se slučajna predviđanja slažu sa stvarnim vrijednostima klase 1) i P_{e2} (vjerojatnost da se slučajna predviđanja slažu sa stvarnim vrijednostima klase 2). Cohen kappa koeficijent se koristi u svrhu eliminiranja utjecaja nasumičnog pogađanja na točnost klasifikacije i mjeri broj predviđanja koje se ne mogu pripisati slučajnosti. Osim toga, Cohen kappa koeficijent se koristi kako bi ispravio pristranost u predviđanju, uzimajući u obzir točne klasifikacije koje se mogu objasniti samo slučajnim pogađanjem [97].

3.3. Pregled primjene strojnog učenja u SDN mrežama

Istraživanjem literature ustanovljeno je da korištenje strojnog učenja i programski definirane mreže pružaju obećavajuće rješenje za detekciju upada. Napredak u razini točnosti, smanjenje potrebnog vremena za učenje i izvođenje može se još dodatno poboljšati, posebno kako bi se ugradilo u okruženje programski definirane mreže. U nastavku je pregled recentnih provedenih istraživanja koja su povezana s primjenom strojnog učenja u SDN mrežama.

U radu [41] predstavljeni su dizajn i evaluacija dinamičkog klasifikatora strojnog učenja za mrežu baziranu na SDN-u. Korištenjem tri ML tehnike klasificiraju se TCP i UDP tokovi s 3, 5 i 7 parametara uz postizanje visokih točnosti klasifikacije. Također, predstavljen je algoritam

sposoban za kombiniranje različitih ML modela i povećanje točnosti. U svrhu evaluacije performansi predloženi sustav je implementiran u Ryu kontroleru, eliminirajući potrebu ručnog usklađivanja dolaznog prometa i osiguravajući bolji QoS. Rezultati eksperimenata pokazuju značajno smanjenje latencije u analizi prometa.

U radu [42] je predstavljen koncept odabira i obrade tokova radi identifikacije i klasifikacije neovlaštenih aktivnosti u SDN mrežama. Također je pokazano da odgovarajući odabir i obrada značajki toka omogućuju učinkovitu klasifikaciju mrežnog prometa. Rezultati eksperimenata potvrdili su opravdanost korištenja algoritama za smanjenje broja značajki u predloženom sustavu. Za klasifikaciju SDN tokova korištena je metoda stroja s potpornim vektorima (SVM). Postupak testiranja bio je usmjeren na postizanje najviše vrijednosti istinito pozitivnih rezultata te s najmanjim brojem značajki i najnižom vrijednosti vremena izvršavanja procesa.

U radu [43] je predložen R-IDPS sustav koji koristi SDN kako bi postigao potpuno autonomno otkrivanje i sprečavanje upada u IoT sustavima. Dio istraživanja prikazuje evaluaciju performansi centraliziranog IDPS sustava u usporedbi s distribuiranim IDPS sustavima u kontekstu IoT mreža. Integracijom agenata, SDN-a i tehnike strojnog učenja pokazana je snaga distribuiranog dizajna u smislu učinkovitosti i performansi. Istraživanje pokazuje da SVM algoritam koristi manje resursa i vrlo je pogodan za uređaje s niskom potrošnjom energije kao što su IoT uređaji. Za učenje se koristi interni skup podataka sustava. Predloženi dizajn štiti IoT uređaje od nadolazećih prijetnji bez dužih perioda ispadanja. Performanse detekcije sustava protiv DDoS napada pokazuju izvrsnu preciznost te niske stope lažno pozitivnih i lažno negativnih rezultata.

U radu [44] je predložen sustav za detekciju i sprječavanje DDoS napada u SDN sustavu. U procesu detekcije kibernetičkog napada korišten je stroj s potpornim vektorima (SVM) kao klasifikator. Radi bolje preciznosti i smanjenja vremena testiranja, u ovom modelu primijenjene su KPCA (Analiza jezgrenih glavnih komponenata) i GA (Generički algoritam) tehnike za izdvajanje glavnih značajki iz skupa podataka s DDoS napadima i za odabir odgovarajućih parametara za SVM klasifikator. Eksperimentalni rezultati pokazuju da na promatranom skupu podataka, KPCA ima najbolje performanse, a točnost predloženog modela je bolja od nekih postojećih modela.

U radu [45] predloženi su nadzirani algoritmi strojnog učenja za detekciju DDoS napada u tri tipa arhitekture mreže: pojedinačna topologija, linearna topologija i više-kontrolorska topologija. Modeli su trenirani na skupovima podataka u generiranom SDN okruženju pomoću emulatora Mininet i kontrolera RYU. Rezultati simulacije pokazuju da se pojedini algoritmi poput RF (eng. *Random forest*) i KNN (eng. *K-Nearest Neighbours*) mogu učinkovito koristiti u modelima predviđanja kibernetičkih napada.

U radu [46] se proučavaju i primjenjuju tehnike nadziranog učenja kako bi pomogle u detekciji DDoS napada u SDN mreži. Skup podataka za učenje prikupljen je iz eksperimentalnih skupova podataka i generiranog prometa u SDN-u. Različite vrste skupova za učenje testirane su kako bi se vidio utjecaj na rezultate detekcije kibernetičkih napada. Uspoređene su performanse svakog korištenog algoritma nadziranog učenja i validirane su metrike u detekciji, kao i potrošnja CPU-a i vrijeme odziva. Rezultati simulacije pokazuju da se performanse pojedine tehnike nadziranog učenja znatno razlikuju jedna od druge pod istim scenarijem testiranja. Implementacija predloženog rješenja pokazuje da detekcija DDoS napada u stvarnom vremenu korištenjem tehnika nadziranog učenja u SDN-u ima zadovoljavajuću točnost. Ograničenje predloženog sustava je da je pogodan samo za DDoS napade temeljene na preplavljivanju, ne može detektirati ne-volumetrijske napade, poput niskorazinskih DDoS napada i razmatra samo napade usmjerene na kontrolni sloj SDN mrežne arhitekture.

U radu [47] je predstavljena implementacija modularne i fleksibilne SDN bazirane arhitekture za detekciju transportnih i aplikacijskih DDoS napada korištenjem više ML modela i dubokog učenja (eng. *Deep Learning*). Istraživanje različitih ML/DL modela omogućilo je utvrđivanje koje se metode bolje izvode pod različitim vrstama napada i uvjetima. Testirani su ML/DL modeli koristeći dva skupa podataka: CICDoS2017 i CICDDoS2019 koji su pokazali visoku točnost pri klasifikaciji testnog prometa. Također je implementirano simulirano okruženje koristeći mrežni emulator Mininet i SDN kontroler Open Network Operating System (ONOS).

Rad [48] istražuje poboljšanje mrežne sigurnosti u OpenStack oblacima integracijom SDN-a, NFV-a (eng. *Network Function Virtualzation*) i ML/AI-a (eng. *Machine Learning/Artificial Intelligence*). Predložen je okvir OpenStackDP koji se sastoji od senzora za praćenje i otkrivanje anomalija ugrađenih u podatkovni sloj mrežne arhitekture, modula za kibernetičke prijetnje koji koristi ML/AI algoritme za otkrivanje prijetnji u stvarnom vremenu, te virtualnih mrežnih funkcija

(VNFs) za brzo ublažavanje otkrivenih prijetnji. Testiranja su pokazala visoku točnost u otkrivanju anomalija (99,81%), nisku latenciju i brzo vrijeme odgovora. Rad također nudi detaljnu analizu ranjivosti OpenStack mreže te minimalističku izvedbu IDS i sigurnosni orkestracijski okvir za implementaciju sigurnosnih i kontrolnih funkcija u podatkovnom sloju. Zaključeno je da OpenStackDP značajno poboljšava sigurnost i performanse infrastrukture u oblaku, omogućujući brži oporavak od kibernetičkih napada i veću pouzdanost mreže.

U istraživanju [49] je osmišljen novi model za učinkovito prepoznavanje upada u SDN okruženju Interneta stvari (IoT). Prezentirani model slijedi trostupanjski proces u kojem se tehnika Harmony Search algoritma koristi za odabir značajki. Zatim se metoda konvolucijskog autoenkodera koristi za prepoznavanje i klasifikaciju upada u SDN okruženju IoT-a te se provodi postupak podešavanja hiperparametara kako bi se poboljšala učinkovitost detekcije upada. Uspješnost predloženog modela u detekciji upada potvrđena je usporedbom s relevantnim prethodnim istraživanjima.

U radu [50] je predložena hijerarhijska višeklasna klasifikacija za simulirane scenarije DDoS napada kako bi se provjerila sposobnost detekcije kibernetičkih napada. Istraživanje je provedeno kako bi se poboljšala sigurnost SDN mrežne okoline korištenjem strojnog učenja i mehanizama predviđanja te ublažavanja posljedica kibernetičkih napada. Istraživanje uključuje konstrukciju SDN topologije mreže, učenje ML i DL modela kako bi se analizirala njihova sposobnost identifikacije anomalija, te poboljšanje izvedbe klasifikacije nebalansiranih skupova podataka, posebno za manjinske klase.

U istraživanju [51] su prikupljeni podatci mrežnih tokova prometa te je izgrađen učinkovit model strojnog učenja pomoću RF algoritma. Model u stvarnom vremenu detektira DDoS napad analizom toka mrežnog prometa. Uspješno je provedena detekcija i prevencija kibernetičkog napada blokiranjem aplikacije koju koristi tzv. zombi klijent za izvođenje napada dok se drugim ispravnim aplikacijama omogućuje funkcioniranje bez prekida.

Tablica 3-1 Pregled istraživanja upotrebe strojnog učenja u SDN mrežnim okruženjima

#	God.	Skupovi	Okolina	ML algoritmi	SV	Problem istraživanja
[41]	2021.	×	S	SVM, RF, LR	✓	Klasifikacija mrežnog prometa u SDN okruženju
[42]	2018.	×	RT	LR	×	Praćenje i otkrivanje zlonamjernih aktivnosti u SDN mrežama
[43]	2021.	×	S	SVM	✓	Obrana od kibernetičkih napada u IoT mreži
[44]	2020.	1	S	SVM	×	Detekcija i sprječavanje DDoS napada u SDN mreži
[45]	2022.	×	S	RF, KNN, NB, LR	✓	Detekcija i sprječavanje DDoS napada u SDN mreži
[46]	2022.	×	S & RT	KNN, BT, SVM, DT	✓	Detekcija i sprječavanje DDoS napada u SDN mreži
[47]	2021.	2,3	S	KNN, SVM, RF, MLP, CNN, GRU, LSTM	×	Detekcija i sprječavanje DDoS napada u SDN mreži
[48]	2023.	2,4,5	S	Nenadzirani algoritmi strojnog učenja	×	Sigurnost SDN bazirane infrastrukture u oblaku
[49]	2023.	×	S	Neuronske mreže	×	Detekcija upada dubokim učenjem u SDN IoT okruženju
[50]	2022.	6,7	S	DT, RF, KNN, NB, SVM, AdaBoost, MLP, CNN, RNN, LSTM, GRU	×	Detekcija i sprječavanje DDoS napada u SDN mreži
[51]	2022.	×	S	RF	✓	Detekcija i sprječavanje DDoS napada u SDN mreži

Legenda kratica u Tablici 3-1:

1 - NSL-KDD , 2 - CICDoS2017, 3 - CICDDoS2019, 4 - CICIDS2018, 5 - CICIDS2019, 6 - DDoS-SDN, 7 – InSDN, S – simulacijska testna okolina, RT – stvarna testna okolina, SV – korištenje modela u stvarnom vremenu

U Tablici 3-1 prikazan je pregled literature i istraživanja u području sigurnosti mreža, posebno fokusirano na integraciju programski definirane mreže (SDN) i strojnog učenja (ML), a pokazuje kontinuirani interes i razvoj unazad nekoliko godina. Svi pregledani radovi naglašavaju važnost SDN-a kao napredne mrežne paradigme, često koristeći javno dostupne skupove podataka za učenje kako bi proučavali različite scenarije kibernetičkih napada. ML algoritmi, poput Support Vector Machine (SVM), Random Forest (RF), Logistic Regression (LR), K-Nearest Neighbors (KNN) i neuronske mreže, primijenjeni su za detekciju i sprječavanje napada, pružajući raznolik pristup sigurnosnim izazovima. Većina radova koristi simulacijske testne okoline omogućujući kombinaciju kontroliranih laboratorijskih uvjeta s realnim scenarijima. Simulacije uključuju različite vrste napada, a najčešće DDoS kibernetičke napade i testiraju različite ML algoritme u virtualnom okruženju. Unatoč tome, samo nekoliko istraživanja provodi testiranje u stvarnom vremenu, što sugerira potrebu za daljnjim ispitivanjem predloženih pristupa kako bi se potvrdila njihova praktična primjenjivost u stvarnom vremenu. Glavni fokus istraživanja usmjeren je na detekciju i sprječavanje različitih vrsta kibernetičkih napada, uključujući i DoS, DDoS napade u IoT mrežama. Neki radovi također istražuju sigurnost SDN bazirane infrastrukture u oblaku te primjenu ML-a za detekciju upada u SDN IoT okruženju. Ovi rezultati ukazuju na potrebu za daljnjim istraživanjem kako bi se razvile efikasne i pouzdane metode za očuvanje sigurnosti u modernim mrežama koje koriste SDN tehnologije.

Mininet emulator često se koristi za simulaciju virtualnih preklopnika, posebice Open Virtual Switch (OVS), unutar SDN okoline uz korištenje OpenFlow protokola. Važno je napomenuti određena ograničenja povezana s prilagodbom preklopnika i dodavanjem aplikacija na računalne čvorove unutar ovakve simulacijske okoline. Ova simulacijska okolina, iako pruža značajne prednosti za ispitivanje mrežnih koncepta, može predstavljati izazove u fleksibilnosti kada je riječ o implementaciji specifičnih funkcionalnosti i prilagodbi.

4. PRIJEDLOG RJEŠENJA ZA DETEKCIJU ANOMALIJA MREŽNOG PROMETA

Ručne metode detektiranja i praćenja mrežnog prometa mogu biti učinkovite u slučaju nekoliko mjernih podataka, ali u suvremenom okruženju s mnogo mjernih podataka i mjernih točaka, potrebno je razmotriti brže i sveobuhvatnije načine detekcije različitih vrsta anomalija. Tradicionalni sustavi koji nemaju funkcije u stvarnom vremenu mogu se koristiti za analizu povijesnih zapisa i događaja kao i za informiranje o budućim odlukama u dugoročnom planiranju.

U kontekstu istraženih problema, izazova, prednosti i ograničenja primjene programski definirane mreže, te potencijala implementacije strojnog učenja za detekciju kibernetičkih napada kroz analizu anomalija mrežnog prometa, razvijen je jedinstven i napredan model koji obuhvaća sve navedene aspekte. Osnovna ideja predloženog NFMIDS (NetFlow Machine-learning Intrusion Detection System) modela može se jasno ilustrirati Slikom 4.1. Model se sastoji od nekoliko ključnih dijelova, među kojima su: hibridna programski definirana mreža, strojno učenje, referentni skup podataka za učenje, skup podataka iz stvarne mrežne okoline, te primijenjeni najučinkovitiji algoritam strojnog učenja.

Strojno učenje igra važnu ulogu u modelu, koristeći referentni skup podataka za učenje kako bi se steklo znanje o karakteristikama normalnog mrežnog prometa. Dodatno, skup podataka iz stvarne mrežne okoline pruža stvarne scenarije iz kojih model može učiti i prilagođavati se dinamičnim novonastalim uvjetima. Odabir najučinkovitijeg algoritma strojnog učenja presudan je za postizanje visoke preciznosti i brze detekcije anomalija.

Hibridna programski definirana mreža predstavlja temeljni element arhitekture modela. Uključuje SDN kontroler koji omogućuje API komunikaciju prema višim slojevima, poput aplikacija, i nižim slojevima, koji obuhvaćaju SDN mrežnu opremu. Predloženi model uključuje i postojeće mrežne uređaje poput preklopnika u tradicionalnim mrežnim okolinama.

Sve ove komponente zajedno tvore integrirani pristup koji kombinira snagu strojnog učenja s fleksibilnošću SDN arhitekture, čime se ostvaruje unaprijeđena sposobnost detekcije i obrane od kibernetičkih prijetnji.

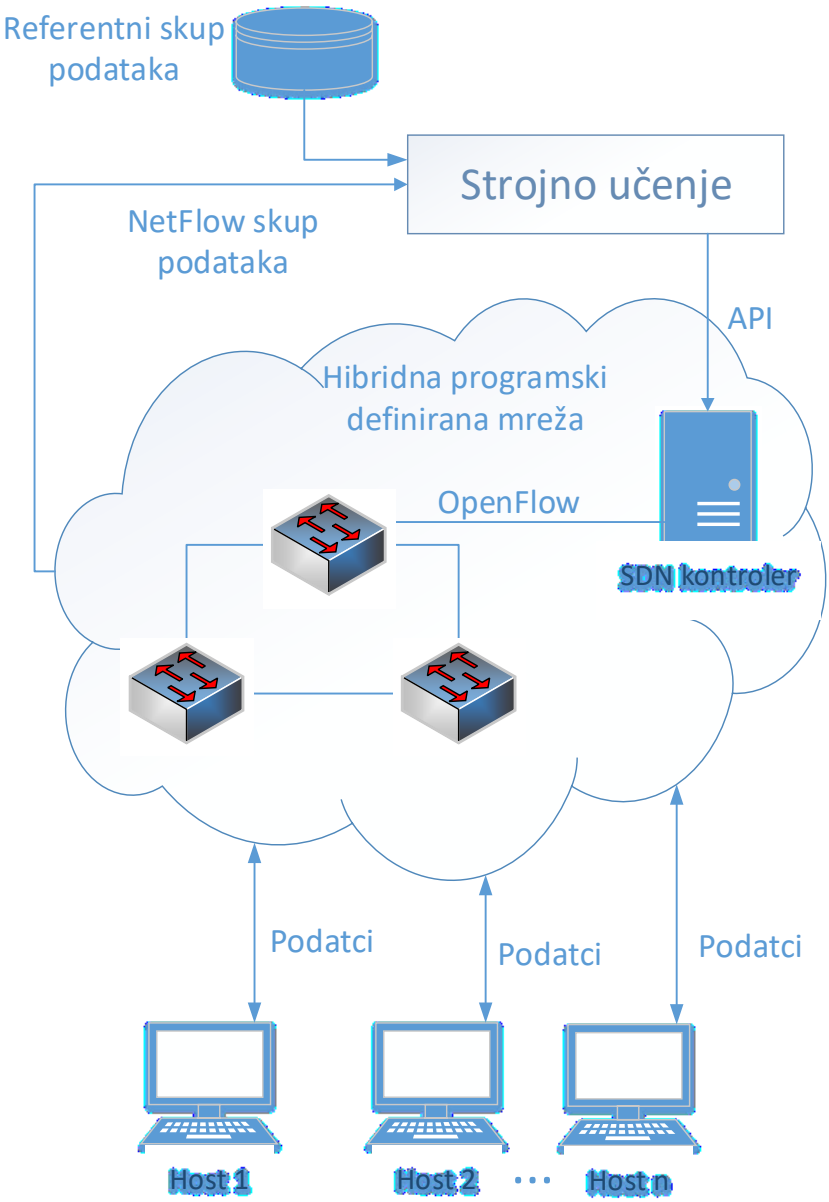

Slika 4.1 Osnovna ideja predloženog rješenja za detekciju anomalija mrežnog prometa u hibridnoj SDN mreži

Narednim koracima u razvoju i implementaciji predloženog modela za detekciju anomalija u mrežnom prometu obuhvatilo se niz faza. Prvo, proveden je pažljiv odabir i usporedba javno dostupnih skupova podataka namijenjenih detekciji anomalija u mrežnom prometu, istovremeno birajući referentni skup podataka za učenje unutar domene strojnog učenja. Zatim je slijedio odabir i usporedba uspješnosti različitih algoritama nadziranog strojnog učenja, s posebnim fokusom na

identifikaciju najprimjenjivijeg algoritma za preciznu detekciju anomalija u mrežnom prometu. Nakon toga je napravljena detaljna predobrada odabranog skupa podataka, prilagođena karakteristikama NetFlow zapisa tokova mrežnih podataka u stvarnoj hibridno programski definiranoj mreži. Ovaj korak imao je bitnu ulogu u optimizaciji podataka za učinkovitu primjenu strojnog učenja. Sljedeći korak je uključivao fino podešavanje hiperparametara odabranih klasifikatora kako bi se postigle najbolje moguće performanse u klasifikaciji i detekciji anomalija. Konačno, implementacija modela obuhvatila je primjenu strojnog učenja na predloženom modelu, što će omogućiti detekciju stvarnih kibernetičkih prijetnji. Ovaj sveobuhvatni pristup osigurao je razvoj visoko učinkovitog sustava za detekciju prijetnji u mrežnom prometu, prilagođenog specifičnostima hibridne programski definirane mreže.

4.1. Odabir i prilagodba ulaznih podataka modela za otkrivanje anomalija mrežnog prometa

Mnoga istraživanja fokusiraju se na otkrivanje anomalija zbog njihove važnosti u otkrivanju novih kibernetičkih napada. Međutim, implementacija sustava detekcije anomalija u stvarnom okruženju izuzetno je složena jer zahtijeva opsežno testiranje, evaluaciju i prilagodbu prije nego što se može implementirati. Implementacija takvih sustava pomoću stvarnih i označenih mrežnih tokova prometa s velikim skupom normalnog i neželjenog mrežnog prometa idealna je metodologija za testiranje i evaluaciju njihove učinkovitosti. Proces odabira i prilagodbe ulaznih podataka može se razložiti u nekoliko faza, koje su prikazane na Slici 4.2 i detaljno objašnjene u sljedećim potpoglavljima.

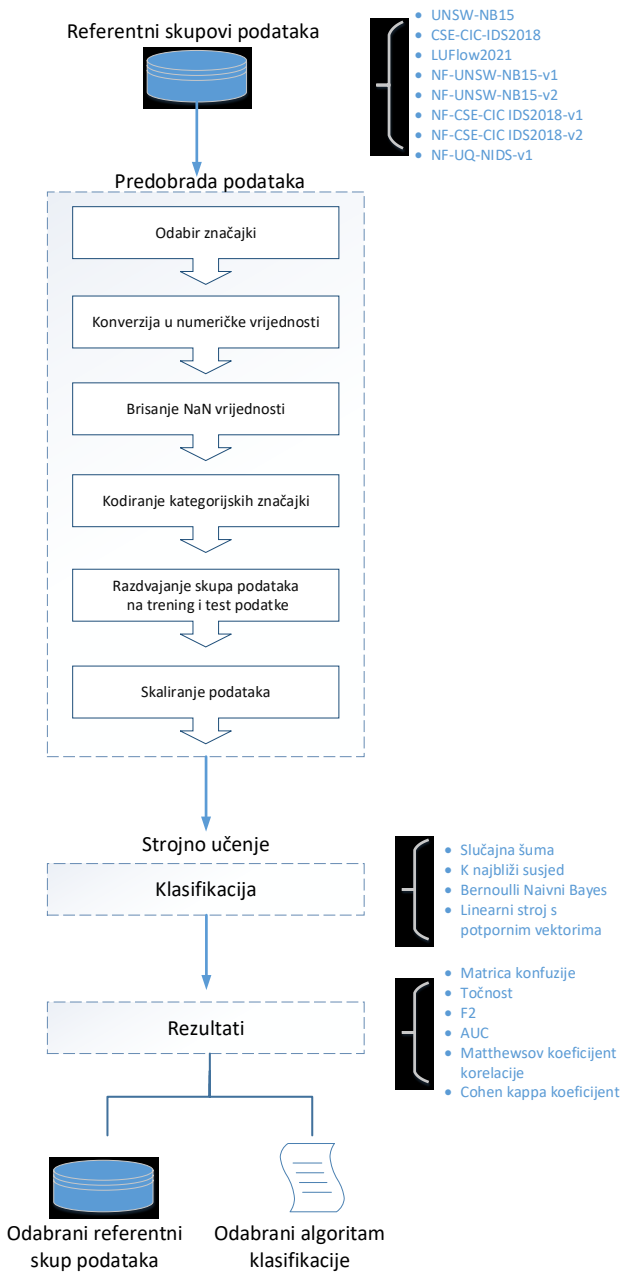

Slika 4.2 Proces odabira i prilagodbe ulaznih podataka

Kako bi se izbjegle nedosljednosti eksperimentalne platforme, sva se ispitivanja implementiraju i izvode u istom okruženju koristeći Python programski jezik i hardverske komponente kao što je prikazano u Tablici 4-1.

Tablica 4-1 Opis komponenti eksperimentalne platforme za odabir i prilagodbu ulaznih podataka

Naziv komponente	Karakteristike
Računalo	Virtualno računalo na VMWare ESX platformi
Operativni sustav	Linux Ubuntu 20.04 LTS
CPU	32
RAM	64 GB
Prostor za pohranu	100 GB
Programski jezik	Python 3.8
Programski alati	Sci-kit Learn 1.1.1

Za ulazne podatke korišteno je osam referentnih javno dostupnih skupova podataka, koji su zahtijevali različitu predobradu kako bi bili prikladni za analizu. Proces predobrade podataka obuhvatio je sljedeće korake: odabir relevantnih značajki u skladu s NetFlow strukturom; konverziju i kodiranje kategorijskih značajki u numeričke vrijednosti radi daljnje analize; čišćenje nepotpunih podataka kako bi se osigurala pouzdanost i točnost u rezultatima; razdvajanje skupa podataka na podskupove za učenje i testiranje kako bi se omogućila validacija modela i skaliranje podataka radi bolje usporedivosti među značajkama. Zatim je provedena evaluacija performansi pet različitih klasifikatora u strojnom učenju na predobrađenim podatcima. Rezultati su bili podvrgnuti analizi kroz različite metrike uspješnosti kako bi se odabrao optimalan referentni skup podataka i najučinkovitiji klasifikator za implementaciju u predloženi model. Ovaj pristup omogućio je identifikaciju najboljih kombinacija podataka i algoritama koji su najprikladniji za ciljani problem u detekciji kibernetičkih prijetnji.

4.1.1. Odabir i usporedba javno dostupnih referentnih skupova podataka za detekciju anomalija

Izrada modela za klasifikaciju podataka i metodologije počela je prikupljanjem podataka o toku prometa. Podatci se mogu prikupiti snimanjem stvarnog prometa podataka u poznatoj mrežnoj infrastrukturi ili korištenjem javno dostupnih skupova podataka za rješavanje određenog problema. U svrhu odabira optimalnog algoritma i podešavanja parametara klasifikatora strojnog

učenja, provedeno je testiranje na više javno dostupnih skupova podataka. Skupovi podataka opisani u daljnjim dijelovima istraživanja koristili su se za učenje i testiranje modela. Prednost ovih skupova podataka je u tome što se lako koriste (dostupni su sirovi podatci) i korišteni su u mnogim znanstvenim istraživanjima, način na koji su generirani dobro je dokumentiran te su označeni kojoj klasi pripadaju pojedini segmenti podataka. Sustavi za otkrivanje napada u mreži temeljeni na strojnom učenju postali su efikasni alati za zaštitu mreža od kibernetičkih napada, a za razvoj i evaluaciju ovih sustava koristi se velik broj javno dostupnih skupova podataka u istraživačkoj zajednici. Međutim, zbog različitih tipova značajki u ovim skupovima podataka, vrlo je teško pouzdano usporediti ML modele koji koriste različite skupove podataka.

4.1.1.1. Cjeloviti skupovi podataka

Tijekom pretraživanja dostupnih javnih podataka za korištenje u modelu strojnog učenja izdvojena su tri skupa podataka stvorenih zadnjih nekoliko godina. Ovi odabrani skupovi podataka korišteni su sa svim značajkama izuzev značajki koje određuju redni broj, IP adrese ili vremenske informacije nastajanja toka mrežnog prometa.

Tablica 4-2 Osnovne karakteristike odabranih skupova podataka

Naziv	**Broj značajki**	**Broj zapisa (tokova prometa)**			**Veličina (MB)**
		Normalan	Anomalije	Ukupno	
UNSW-NB15	49	2218764	321283 (12,65%)	2540047	559
CSE-CIC-IDS2018	80	3522290	1121068 (24,14%)	4643358	1320
LUFlow2021	16	2976850	1273495 (29,96%)	4250345	476

Tablica 4-2 prikazuje osnovne karakteristike odabranih skupova podataka. Svaki skup podataka opisan je brojem značajki, brojem zapisa (tokova prometa) te veličinom u megabajtima. Također, za svaki skup podataka navedeni su podatci o normalnom i neželjenom prometu (anomalije) te ukupan broj zapisa. Uočava se raznolikost ovih skupova podataka u pogledu broja značajki, ukupnog broja zapisa, omjera normalnog i neželjenog mrežnog prometa te njihove veličine. Tablica pruža važne informacije o ovim skupovima podataka koje su od bitne važnosti za njihovu daljnju upotrebu.

UNSW-NB15 skup podataka

Skup podataka UNSW-NB 15 sastoji se od sirovih mrežnih paketa (PCAP datoteka, eng. *Packet Capture*) koji su stvoreni pomoću alata IXIA PerfectStorm u laboratoriju Cyber Range australskog Centra za kibernetičku sigurnost. Ovaj alat je korišten za generiranje primjera stvarnih, suvremenih normalnih aktivnosti i sintetičkih kibernetičkih napada. Skup podataka sadrži devet scenarija napada: *Fuzzers, Analysis, Backdoor, DoS, Exploits, Generic, Reconnaissance, Shellcode* i *Worms*. Alatima Argus, Bro-IDS generirano je ukupno 47 značajki s 2 oznake klase mrežnog prometa [98]. U skupu podataka postoje dvije oznake: jedna označava klasu u binarnom obliku koja razlikuje normalni promet od anomalija, dok druga označava vrstu anomalije (kibernetički napad) ako je promet klasificiran kao anomalija. Značajke su kategorizirane u nekoliko tipova, uključujući kategorijske, numeričke (cjelobrojne, decimalne i binarne) i vremenske. Skup podataka sadrži 2218764 (87,35%) tokova normalnog mrežnog prometa i 321283 (12,65%) anomalija, odnosno ukupno 2540047 tokova mrežnog prometa. U ovom dijelu istraživanja koristio se cijeli skup podataka.

CSE-CIC-IDS2018 skup podataka

Ovaj skup podataka uključuje sedam različitih scenarija napada: *Brute-force, Heartbleed, Botnet, DoS, DDoS, Web napadi i napad infiltracije u mrežu* koji broje trinaest različitih vrsta kibernetičkih napada. U skupu podataka, zapisi su pohranjeni u obliku od 80 značajki koje su izvučene i obrađene iz zabilježenog prometa. Zapisi su organizirani prema datumu, pri čemu se za svaki od 10 dana prikupljanja pohranjuju sirovi podatci koji uključuju promet mreže (PCAP datoteke) i zapisnike događaja (Windows i Linux Ubuntu) za svaki pojedini uređaj. U procesu ekstrakcije značajki iz neobrađenih podataka korišten je alat CICFlowMeter-V3, a izdvojene značajke su pohranjene kao CSV (eng. *Comma-Separated Values*) datoteke [99]. U ovom dijelu istraživanja koristio se skup podatka iz prve četiri CSV datoteke uz dodane tokove mrežnog prometa koji su označeni kao anomalije iz ostalih datoteka. Ovako sastavljen skup podataka se sastoji od ukupno 4.643.358 zapisa, 1.121.068 (24,14%) zapisa su anomalije i ostatak (75,95%)

normalnog mrežnog prometa. Razlog korištenja ovako modificiranog skupa podataka je kako bi se udio normalnog i neželjenog mrežnog prometa približio udjelu u drugim skupovima podataka.

LUFlow2021 skup podataka

LUFlow je skup podataka za detekciju napada u mreži temeljen na toku podataka koji sadrži telemetrijske podatke o kibernetičkim napadima na mamce unutar komunikacijske mreže Sveučilišta Lancaster. Anomalije se u toku podataka automatski označavaju uz pomoć korelacije s izvorima Cyber Threat Intelligence, što omogućuje kontinuirano hvatanje, označavanje i objavljivanje telemetrijskih podataka u ovom skupu podataka. Tokovi koji se nisu mogli odrediti kao zlonamjerni, ali nisu dio normalnog telemetrijskog profila označeni su kao izvanredni tokovi i uključeni su u skup podataka kako bi se potaknula daljnja analiza. Ovaj skup podataka sadrži i uobičajeni promet te se kontinuirano ažurira zahvaljujući mehanizmu automatskog označavanja, što omogućuje otkrivanje novih obrazaca napada u stvarnom vremenu [100]. Ograničenje ovog skupa podataka je što samo označava promet kao benigni ili zlonamjerni te ne sadrži oznaku vrste napada. Ovo ograničenje proizlazi iz činjenice da se podatci prikupljaju iz stvarnog prometa stoga je nemoguće odrediti pravu namjeru koja stoji iza svakog prometa. Osim toga, neki tokovi prometa se klasificiraju kao „*outliers*“ ako sadrže sumnjivu aktivnost. Postojanje ovakve oznake omogućava označavanje nepoznatog prometa te kasnije dodatnom analizom odrediti pravu narav takvog prometa te time poboljšati proces detekcije i prevencije zlonamjernih tokova prometa [101]. Spremište ovih podataka javno je dostupno i strukturirano je prema godini i mjesecu u kojem su podatci prikupljeni. U ovom dijelu istraživanja disertacije koristile su se zadnje uvrštene datoteke iz veljače 2021. godine koje sadrže ukupno 5033685 tokova mrežnog prometa od kojih je 1273495 odnosno 29,96% označeno kao anomalije. Tokovi prometa koji se nisu mogli odrediti kao normalan promet ili anomalije (783340 zapisa) izbačeni su iz promatranja u ovom istraživanju disertacije stoga je ukupan broj zapisa umanjen i iznosi 4250345 zapisa.

4.1.1.2. NetFlow skupovi podataka

Ovi skupovi podataka generirani su iz postojećih referentnih skupova podataka: UNSW-NB15 i CSE-CIC-IDS2018 s osnovnim (zajedničkim) i proširenim skupom značajki, temeljenim na NetFlow protokolu koji pruža statistiku o paketima koji prolaze kroz usmjerivač i postao je standard za prikupljanje operativnih podataka o IP mrežama [102]. Prednost korištenja strukture NetFlow formata uključuje njegovu praktičnu primjenu u stvarnim mrežama. NetFlow skupovi podataka koji se koriste u ovom istraživanju označeni su kao mrežni promet s binarnim klasama i dodatno su razdijeljeni po broju značajki gdje se oznakom v1 označavaju skupovi podataka s 12 osnovnih značajki i 2 oznake kategorije prometa (binarna i kategorijska oznaka), dok se oznakom v2 označava skup podataka s proširenim brojem značajki od ukupno 43 značajke i 2 oznake kategorije prometa (binarna i kategorijska oznaka). U Tablici 4-3 je prikazana usporedba NetFlow skupova podataka s obzirom na broj značajki, broj zapisa i veličine datoteke. Prednost ovih skupova podataka je što su sve vrijednosti značajki numeričke te tako već prilagođene za proces strojnog učenja. NF-UQ-NIDS je skup podataka koji spaja spomenute i druge (BoT-IoT, ToN-IoT) NetFlow skupove podataka te predstavlja univerzalni NIDS skup podataka koji sadrži tokove iz višestrukih mrežnih okruženja i različitih kibernetičkih napada [103]. NF-UQ-NIDS skup podataka ima jednu značajku više od ostalih NetFlow skupova podataka, a označava iz kojeg NF skupa podataka je preuzet zapis no ova značajka se nije koristila jer nema praktičnu važnost u procesu strojnog učenja. NF-UQ-NIDS-v2 skup podatka nije uzet u obzir tijekom istraživanja budući da dostupni hardverski resursi (64 GB RAM memorije) nisu dovoljni za rad s ovako velikim skupom podataka s obzirom na memorijske resurse korištenog računalnog sustava.

Tablica 4-3 Osnovne karakteristike NetFlow skupova podataka

Naziv	**Broj značajki**	**Broj zapisa (tokova prometa)**			**Veličina (MB)**
		Normalan	Anomalije	Ukupno	
NF-UNSW-NB15-v1	14	1550712	72406 (4%)	1623118	114
NF-UNSW-NB15-v2	45	2295222	95053 (4%)	2390275	431
NF-CSE-CIC IDS2018-v1	14	7373198	1019203 (12%)	8392401	605
NF-CSE-CIC IDS2018-v2	45	16635567	2258141 (12%)	18893708	3145
NF-UQ-NIDS-v1	15	9208048	2786845 (23%)	11994893	1048

Svi skupovi podataka spadaju u vrlo nebalansirane skupove podataka gdje je udio anomalija višestruko manji od udjela normalnih zapisa.

Općenito se proces strojnog učenja sastoji od dva osnovna dijela: učenja i evaluacije uspješnosti za nove podatke. Učenje se provodi na referentnim skupovima podataka koji su prethodno označeni. Važnost odabira optimalnog referentnog skupa je bitna jer može značajno poboljšati pripremu modela za detekciju anomalija mrežnog prometa, omogućujući mu da što preciznije identificira anomalije. Definiranje odgovarajućih metrika je nužno za procjenu i odabir najpogodnijeg referentnog skupa, omogućavajući usporedbu različitih skupova podataka u kontekstu problema detekcije anomalija. Prikaz procesa odlučivanja za nebalansirane skupove podataka na Slici 4.3 može pružiti korisnu pomoć pri odabiru odgovarajuće metrike. Kako bi se ocijenile performanse modela koji koristi različite ulazne podatke, potrebno je pravilno odrediti metrike za usporedbu uspješnosti. S obzirom na izrazitu nebalansiranost svih promatranih skupova podataka, ROC AUC (eng. *Receiver Operating Characteristic Area Under the Curve*) metrika se ističe kao najprikladniji kandidat za daljnje korake odabira i prilagodbe ulaznih podataka u procesu strojnog učenja. ROC AUC često se koristi kao metrika u strojnom učenju, posebno u zadacima binarne i višeklasne klasifikacije, iz više razloga. Prvo, ROC AUC pruža pouzdaniju procjenu performansi u nebalansiranim skupovima podataka, gdje klasična točnost može biti nepouzdana metrika zbog osjetljivosti na neravnotežu klasa. Ova metrika uzima u obzir ravnotežu između osjetljivosti i specifičnosti pri različitim pragovima klasifikacije, što je čini otpornijom na nebalansirane ulazne podatke. Dodatno, ROC AUC je neovisan o pragu, ocjenjujući performanse modela pri svim mogućim pragovima klasifikacije, što je korisno kod utjecaja povezanih s lažno pozitivnim i lažno negativnim rezultatima. Ova metrika nije osjetljiva na distribuciju klasa u skupu podataka, što čini ROC AUC izuzetno korisnim za različite scenarije gdje se udjeli klasa razlikuju. Važno je napomenuti da se ROC AUC može koristiti i za binarne i višeklasne klasifikacije, često izračunavajući prosječnu vrijednost za sve klase u višeklasnom kontekstu [92], [96], [104].

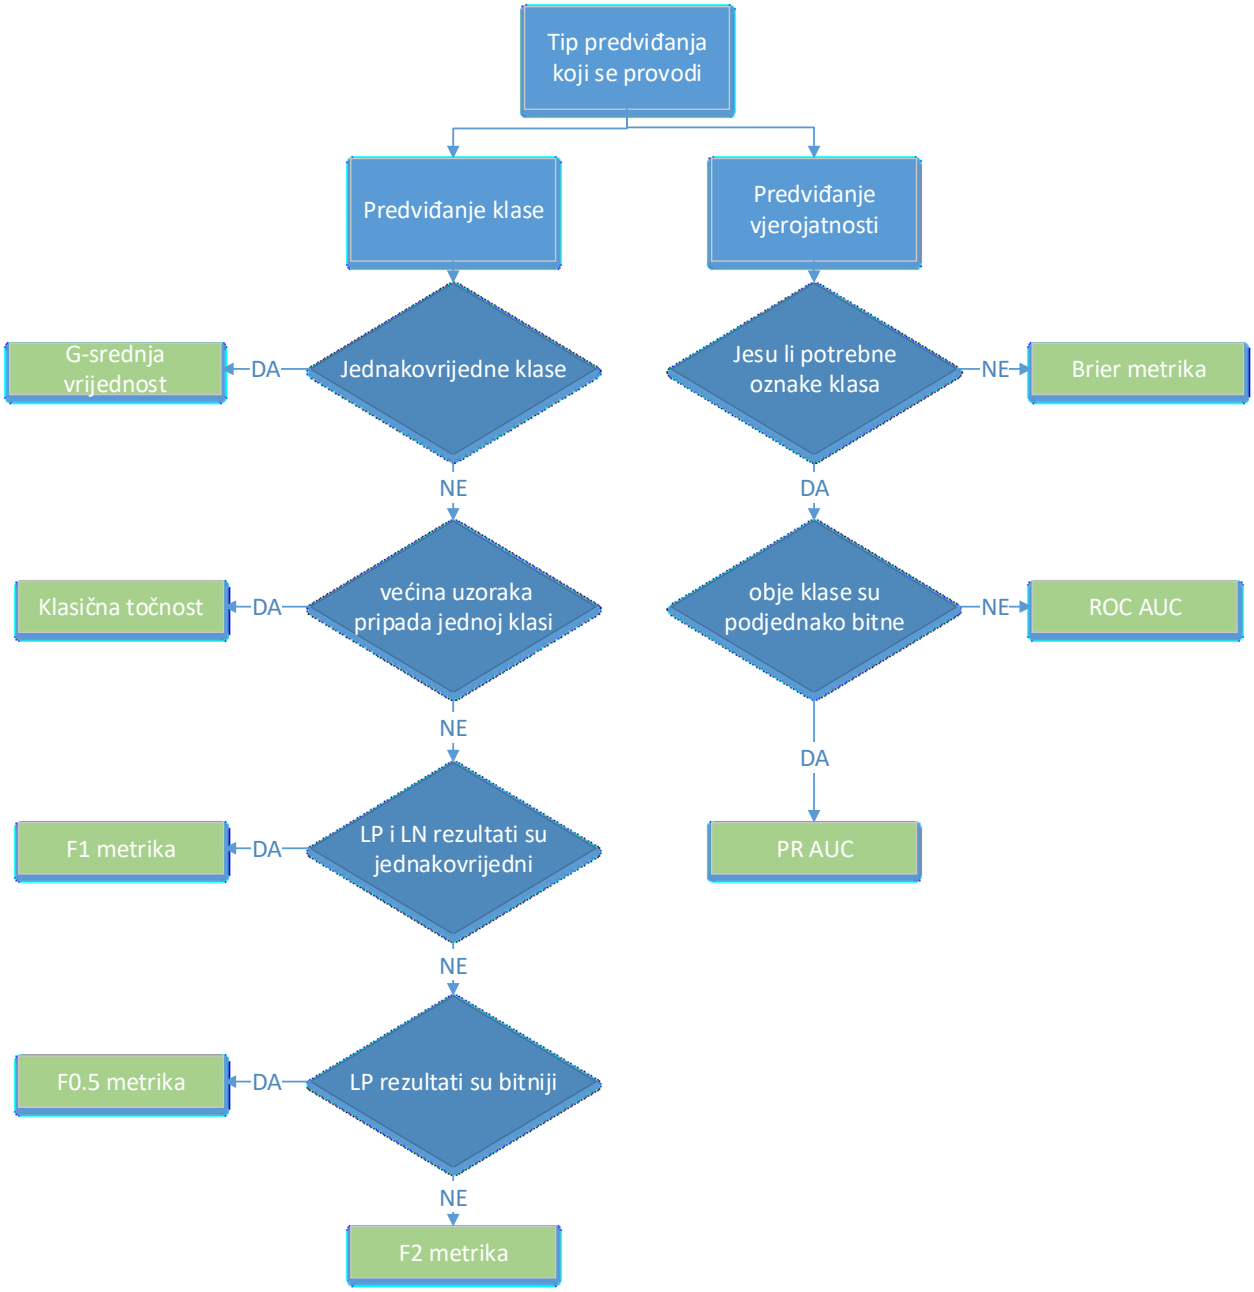

Slika 4.3 Odabir metrike za nebalansirani skup podataka [91]

4.1.2. Predobrada referentnih skupova podataka

Prilikom prikupljanja podataka za razne namjene, bez obzira na to je li to za strojno učenje, rudarenje podataka ili nešto drugo, važno je imati mehanizme za identificiranje i izdvajanje relevantnih podataka koji su potrebni za određenu analitičku svrhu. Svaki sustav strojnog učenja

ima jedinstvene potrebe u pogledu načina na koji se podatci prezentiraju, što znači da je često potrebno izdvojiti i pripremiti relevantne podatke za zadane analitičke svrhe. Izbor specifičnih podataka za analizu može značajno utjecati na modele koji se uče. Stoga, priprema podataka ključna je faza u mnogim projektima strojnog učenja ili rudarenja podataka, koja često predstavlja najzahtjevniji dio projekta. U većini slučajeva, priprema podataka sastoji se od niza transformacija koje se moraju ponoviti nekoliko puta. Bez obzira na dostupnost tehnologija za rad s podatcima, svaka transformacija može zahtijevati veliku količinu ručnog rada i trošiti značajno vrijeme i trud. Stoga se često smatra da je priprema podataka najteži i najduži dio procesa analize podataka [105]. Neuredni i neorganizirani podatci najveća su prepreka dobroj i učinkovitoj analizi te se smatra da se 70% vremena u istraživanju troši na čišćenje podataka [106]. Čišćenje podataka je proces otkrivanja i ispravljanja (ili uklanjanja) oštećenih ili netočnih zapisa iz skupa podataka, tablica ili baze podataka. Prema [105] postupak čišćenja podataka sastoji se od nekoliko faza. Prvo, potrebno je identificirati i definirati pogreške u podatcima, kao što su nepotpunost, netočnost ili irelevantnost. Nakon toga, pogreške se čiste i ispravljaju zamjenom, izmjenom ili brisanjem. U ovoj fazi važno je dokumentirati vrstu i primjer pogreške. Konačno, potrebno je provjeriti jesu li provedene promjene u skladu s zahtjevima korisnika ili procesa. Ovaj proces može se ponavljati više puta kako bi se osiguralo da su podatci čisti i valjani za daljnju upotrebu.

4.1.2.1. Brisanje suvišnih značajki

Ovisno o skupu podataka koji se koristi u procesu strojnog učenja razlikuje se proces brisanja suvišnih odnosno irelevantnih značajki. U klasifikaciji mrežnog prometa, neke značajke kao što su vrijeme stvaranja zapisa, IP adrese ili druge specifične značajke koje se izračunavaju na temelju drugih parametara, mogu postati nevažne [107]. U strojnom učenju i predloženom modelu za detekciju anomalija, IP adresa izvora anomalije ili redni broj toka nisu ključni faktori u odlučivanju o klasifikaciji mrežnog prometa. Slično tome niti informacija o vremenu nastanka ili odredišna IP adresa se ne koristi u fazi učenja modela jer se vrijeme i način izvođenja kibernetičkog napada ne može predvidjeti iz spomenutih informacija. Odabrane i suvišne značajke su obrisane kako bi se smanjila dimenzionalnost skupa podataka te poboljšale performanse procesa strojnog učenja. Osim toga, neke značajke mogu sadržavati nepotpune podatke i tako smanjiti točnost klasifikacije modela. Kako ističu autori u [108], točnost klasifikacije modela može se povećati s određenim

smanjenjem broja značajki. U radu [109] autori su došli do zaključka da je u SDN sustavima za otkrivanje kibernetičkih napada, manji broj značajki poželjniji te da povećanje broja značajki nužno ne dovodi do povećanja točnosti klasifikacije. U skupovima podataka često se koriste kategorijske značajke te postoji potencijalna mogućnost povećanja kompleksnosti skupa podataka tijekom kodiranja značajki u numeričke vrijednosti što dovodi do povećanja vremena potrebnog za klasifikaciju. Udio i tip obrisanih značajki prema određenom skupu podataka prikazan je Tablicom 4-4.

Tablica 4-4 Udio i tip obrisanih značajki tijekom predobrade skupova podataka

Skup podataka	**Broj značajki**	**Broj obrisanih značajki**	**Udio obrisanih značajki**
UNSW-NB15	49	10	20,41%
CSE-CIC-IDS2018	80	1	1,25%
LUFlow2021	16	4	25%
NF-UNSW-NB15-v1	14	3	21,42%
NF-UNSW-NB15-v2	45	3	6,67%
NF-CSE-CIC IDS2018-v1	14	3	21,43%
NF-CSE-CIC IDS2018-v2	45	3	6,67%
NF-UQ-NIDS-v1	15	4	26,67%

U ovoj fazi predobrade podataka uklonjene su značajke koje zbog svoje strukture ili načina prikupljanja nisu značajne ili u daljnjoj obradi (kodiranje) mogu dodatno povećati kompleksnost skupa podataka.

U skupu podataka UNSW-NB15 obrisano je 10 značajki: *redni broj zapisa, srcip, dstip, service, Stime, Ltime, ct_flw_http_mthd, is_ftp_login, ct_ftp_cmd, attack_cat.* Neke od značajki koje se prikupljaju tijekom nadzora mreže, poput vremenske oznake i IP adrese, nisu nužno bitne za otkrivanje kibernetičkih napada. S druge strane, neke značajke, poput specifičnih vrijednosti koje se računaju pomoću drugih alata, ne mogu se prikupiti izravno s mrežnih uređaja.

Skup podataka CSE-CIC-IDS2018 je dobro strukturiran jer su značajke u izvornom obliku već kodirane i ne sadrži značajku IP adrese stoga je obrisana samo jedna značajka, ona koja se odnosi na vrijeme nastanka zapisa, *Timestamp.*

U skupu podataka LUFlow2021 obrisane su 4 značajke: *dest_ip, src_ip, time_end, time_start.* Iako su *dest_ip, src_ip* već u izvornom skupu podataka kodirane, nisu relevantne za klasifikaciju strojnog učenja dok su *time_end, time_start* značajke s vremenima nastanka zapisa također irelevantne.

Referentni NetFlow skupovi podatka imaju značajke koje su već pripremljene za proces strojnog učenja (kodirane značajke), a razlikuju se po broju značajki, verzija v1 sadrži 14 dok verzija v2 sadrži 45 značajki. U obje verzije obrisane su tri značajke: *IPV4_SRC_ADDR*, *IPV4_DST_ADDR i Attack* koje označavaju IP adrese u zapisima odnosno vrstu napada (anomalije) dok je u NF-UQ-NIDS-v1 skupu podataka obrisana i značajka *Dataset* koja označava iz kojih su NetFlow skupova podataka preuzete vrste napada (anomalija). Ovu značajku sadrži samo NF-UQ-NIDS skup podataka. Odabir obrisanih značajki (*Timestamp, IP address*) podudara se s odabirom obrisanih značajki u sličnim istraživanjima [110], [111]. Neke od metoda odabira značajki putem strojnog učenja korištenih kao u [112] koristile su se pri korištenju odabranog referentnog skupa podataka, a opisane su u poglavlju 4.1.5.1. Ove tehnike odabira značajki pomažu u fokusiranju na relevantne podatke, čime se poboljšavaju performanse modela u otkrivanju anomalija i prijetnji unutar mrežne infrastrukture.

4.1.2.2. Čišćenje neispravnih vrijednosti značajki

Gotovo svi skupovi podataka s kojima se susrećemo imaju neke vrijednosti koje nedostaju. Izazovno je učinkovito rukovati takvim podatcima i stvoriti robustne modele. Postoji niz metoda kojima se u podatcima mogu zamijeniti vrijednosti koje nedostaju. Važno je pristupiti svakom skupu podataka na fleksibilan način, koristeći različite metode zamjene takvih vrijednosti ovisno o problemu i značajkama koje se koriste. Najčešće se koriste neke od metoda zamjene neispravnih vrijednosti značajki kako je opisano prema [113]:

- **Brisanje redaka** - ova metoda se obično koristi za manipulaciju skupa podataka s tzv. nul vrijednostima. Uobičajeno se briše određeni redak koji sadrži nul vrijednost za određenu značajku ili cijela značajka ako ima više od 70-75% vrijednosti koje nedostaju. Ova metoda se savjetuje samo ako u skupu podataka ima dovoljno uzoraka. Uklanjanje podataka dovodi do gubitka informacija što može dati neočekivane rezultate tijekom procesa predviđanja.

Prednost ovog načina čišćenja skupa podataka je stvaranje robustnog i vrlo točnog modela, a brisanje određenog retka ili stupca bez posebnih informacija nema veliki negativan utjecaj na proces strojnog učenja. Nedostatci ove metode su gubitak informacija i loš utjecaj na strojno učenje ako je postotak vrijednosti koje nedostaju visok (>30%) u usporedbi s cijelim skupom podataka.

- **Zamjena sa srednjom vrijednosti** - ova metoda može se primijeniti samo na značajke koje imaju numeričke podatke. Srednja vrijednost ili medijan svih vrijednosti značajke može se izračunati i umetnuti kao zamjena za nedostajuće vrijednosti. Primjenom ove metode na skup podataka može doći do povećanja varijabilnosti, ali se istovremeno smanjuje gubitak podataka, što često daje bolje rezultate u usporedbi s metodama poput uklanjanja redaka i stupaca. Prednost ove metode je sprječavanje gubitka podataka, osobito ako je skup podataka mali. Međutim, nedostatci uključuju povećanje varijabilnosti podataka i moguće povećanje pristranosti.
- **Dodjela jedinstvene oznake** - kategorijskim značajkama može se dodijeliti posebna oznaka za vrijednosti koje nedostaju. Ova metoda dodaje nove informacije u skup podataka, što može utjecati na varijabilnost. S obzirom na to da se radi o kategorijskim značajkama, potrebna je njihova konverzija u numerički zapis kako bi algoritam strojnog učenja mogao funkcionirati. Ovisno o tipu kodiranja, može doći do povećanja dimenzionalnosti skupa podataka, što je jedan od nedostataka ove metode. Prednost ove metode je izbjegavanje gubitka informacija.

Tablica 4-5 Udio obrisanih podataka u referentnim skupovima podataka

Skup podataka	**Broj obrisanih redaka**	**Udio obrisanih redaka**
UNSW-NB15	308	0.012%
CSE-CIC-IDS2018	442505	9.529%
LUFlow2021	8621	0.202%
NF-UNSW-NB15-v1	0	0%
NF-UNSW-NB15-v2	0	0%
NF-CSE-CIC IDS2018-v1	0	0%
NF-CSE-CIC IDS2018-v2	0	0%
NF-UQ-NIDS-v1	0	0%

Tijekom procesa predobrade referentnih skupova podataka i čišćenja podataka korištena je metoda brisanja redaka koji sadrže neispravne vrijednosti (eng. *Not-A-Number, NaN*). Ova metoda je odabrana jer je postotak obrisanih redaka bio relativno mali. U Tablici 4-5 udio obrisanih redaka pokazuje relativni udio izgubljenih podataka u odnosu na ukupan broj redaka u svakom skupu podataka. NetFlow skupovi podataka su dobro strukturirani i pročišćeni stoga nije bilo porebno brisanje kao u cjelovitim skupovima podataka. Brisanje podataka s neispravnim podatcima koristi se i u sličnim istraživanjima poput [110], [111], [114] gdje se brišu uzorci s nedostajućim vrijednostima ili tzv „*NaN*“ vrijednostima.

4.1.2.3. Kodiranje kategorijskih značajki

Kodiranje vrijednosti kategorijskih značajki jedan je od važnijih zadataka u pripremi podataka. Većina stvarnih podataka sadrži kategorijske vrijednosti, dok većina modela strojnog učenja radi isključivo s numeričkim vrijednostima. Budući da modeli strojnog učenja izvode matematičke operacije, potrebni su im numerički podaci poput decimalnih ili cijelih brojeva. Stoga se nizovi i druge vrste podataka moraju pretvoriti u odgovarajuće numeričke oblike. Kodiranje kategorijskih podataka je proces pretvaranja tih podataka u numerički format, što omogućava da se podaci s pretvorenim kategorijskim vrijednostima koriste u modelima strojnog učenja za dobivanje rezultata predviđanja. U nastavku je pregled osnovnih metoda pretvaranja kategorijskih u brojčane vrijednosti. Provedeno sustavno empirijsko istraživanje u [115] koje uključuje pet sustava, sedam modela i tri korištena načina kodiranja pokazuje da odabir načina kodiranja nije trivijalan.

Kodiranje labelama

Kodiranje labelama je popularna tehnika kodiranja za prilogodbu kategorijskih značajki gdje se svakoj jedinstvenoj kategorijskoj vrijednosti dodjeljuje jedinstveni cijeli broj na temelju abecednog redoslijeda kategorijskih značajki. Kod ovog načina kodiranja nema povećavanja dimenzionalnosti skupa podataka koji može povećati zahtjeve za izračune kod algoritma strojnog učenja, ali postoji vjerojatnost da model neispravno bilježi odnos između neovisnih značajki kako je prikazano na primjeru tipa protokola u mrežnom prometu u Tablici 4-6. Ovim načinom

kodiranja značajka TCP se smješta između UDP i ICMP vrijednosti, što algoritam može pogrešno protumačiti i imati neželjeni učinak na model [66].

Tablica 4-6 Kodiranje labelama značajke tipa protokola

tip protokola		**tip protokola nakon kodiranja**
tcp		2
tcp		2
udp		3
icmp		1
udp		3

Kodiranje One-hot metodom

Ova tehnika proširuje određenu kategorijsku značajku u više novih značajki koje se nazivaju binarne značajke. Svaka nova binarna značajka ima vrijednost 0 ili 1, ovisno o tome je li pripadajuća kategorijska vrijednost prisutna ili ne. Ovaj postupak omogućuje grupiranje kategorijskih podataka bez gubitka informacija. Tablica 4-7 prikazuje primjer One-hot kodiranja za značajku tipa protokola. U ovom primjeru, originalna značajka "tip protokola" ima tri različite vrijednosti: "tcp", "udp" i "icmp". One-hot kodiranje proširuje ovu kategorijsku značajku u tri nove binarne značajke: "tip protokola_tcp", "tip protokola_udp" i "tip protokola_icmp". Svaki redak u tablici predstavlja jedan primjer iz skupa podataka, a vrijednosti 0 ili 1 u pojedinim stupcima označavaju prisutnost ili odsutnost određenog tipa protokola. Na primjer, u prvom retku tip protokola je "tcp", pa je vrijednost u stupcu "tip protokola_tcp" 1, dok su vrijednosti u stupcima "tip protokola_udp" i "tip protokola_icmp" jednake 0 jer ti protokoli nisu prisutni u ovom primjeru. Svaka vrijednost odabrane značajke tipa protokola u tablici je predstavljena kao 3-dimenzionalni zapis nakon One-hot kodiranja. Općenito, za varijable kardinalnosti *d*, vektori značajke imat će *d*-dimenzija. Zanimljivo svojstvo One-hot kodiranja je da su značajke neovisne – svaka značajka je jednako udaljena jedna od druge u euklidskom prostoru [116].

Tablica 4-7 One-hot kodiranje značajke tipa protokola

tip protokola		**tip protokola_tcp**	**tip protokola_udp**	**tip protokola_icmp**
tcp		1	0	0
tcp		1	0	0
udp		0	1	0
icmp		0	0	1
udp		0	1	0

Nakon primjene One-hot kodiranja, broj značajki može se značajno povećati, što može postati ograničavajući faktor zbog povećane potrebe za računalnim resursima tijekom procesa strojnog učenja. To može rezultirati duljim vremenom izračuna za neke algoritme strojnog učenja.

4.1.2.4. Usporedba kodiranja kategorijskih značajki

Prema dostupnoj dokumentaciji i opisu svih korištenih referentnih skupova podataka kategorijske značajke kodirane su metodom kodiranja labelama. Ovakvi skupovi podataka su pripremljeni za strojno učenje odnosno sve značajke imaju numeričke vrijednosti te nije bilo potrebno kodirati niti jednu značajku. Skup podataka UNSW-NB15 jedini je u svom izvornom obliku sadržavao kategorijske značajke te su na ovome skupu podataka testirane obje metode kodiranja kategorijskih značajki. Rezultati su pokazali jednaku ili vrlo malu razliku u uspješnosti klasifikacije za četiri različita algoritma klasifikacije. Za svaki algoritam klasifikacije primijenjeni su isti procesi predobrade podataka. Primjena One-hot metode kodiranja pokazala je značajnu razliku u utrošku vremena za klasifikaciju kod algoritama K-NN i LSVC. Na temelju usporedbe točnosti AUC i vremenskog utroška na oba načina kodiranja kategorijskih značajki, prema Tablici 4-8, odabrano je kodiranje labelama za daljnja istraživanja na skupovima podataka stvarnih mrežnih okruženja.

Tablica 4-8 Usporedba trajanja i uspješnosti klasifikacije na skupu podataka UNSWB-NB 15

Algoritam	**AUC**		**Trajanje klasifikacije (sat:minuta:sekunda)**	
	Kodiranje labelama	One-hot kodiranje	Kodiranje labelama	One-hot kodiranje
RandomForest	0.9867	0.9866	00:00:21	00:00:21
K-NN	0.978	0.978	00:49:44	01:54:58
BernoulliNB	0.8534	0.8538	00:00:02	00:00:10
LinearSVC	0.9853	0.9892	00:00:29	00:00:25

4.1.2.5. Razdvajanje podataka za učenje i testiranje

Razdvajanje skupa podataka je uobičajena tehnika za ocjenjivanje uspješnosti predviđanja algoritama strojnog učenja. Može se koristiti za probleme klasifikacije ili regresije i može se koristiti za bilo koji nadzirani algoritam strojnog učenja. Postupak uključuje podjelu skupa podataka u dva podskupa. Prvi podskup se koristi za učenje dok se drugi podskup koristi kao ulazni skup podataka nad kojim se izrađuju predviđanja i uspoređuju s očekivanim vrijednostima. Drugi podskup podataka naziva se skupom testnih podataka i koristi se za procjenu uspješnosti modela strojnog učenja. Cilj je procijeniti izvedbu modela strojnog učenja na novim podatcima odnosno podatcima koji se ne koriste za učenje modela. Kada je dostupan dovoljno velik skup podataka, preporučljivo je podijeliti ga na dva dijela: skup za učenje i skup za testiranje [117], [118].

U postupku izgradnje modela klasifikacije, koristi se skup podataka za učenje kako bi se model prilagodio različitim postavkama parametara algoritma klasifikacije. Nakon izgradnje modela, provodi se validacija na skupu podataka za testiranje koji sadrži uzorke s poznatim oznakama. Na taj način, predviđanja modela na testnom skupu mogu se koristiti za procjenu točnosti i performansi modela. Uobičajeni omjeri podjele skupa podataka za učenje i testiranje su 80/20 prema [111], [114], [119], [120], [121], zatim 70/30 prema [122], [123], te 50/50 prema [124], [125].

Scikit-learn platforma koja se koristila za proces klasifikacije u strojnom učenju omogućuje provedbu postupka podjele izvornog skupa podataka putem ugrađene funkcije *train_test_split ()*. Parametar koji se koristi za definiranje omjera podataka za učenje i testiranje je vrijednost „*test_size*“. Ova vrijednost je broj u rasponu 0 do 1, a označava koji omjer iz ukupnog skupa podataka se uzima za test podatake. Još jedno važno razmatranje je nasumično dodjeljivanje

uzoraka podskupovima podataka za učenje i testiranje kako bi se osiguralo da oni reprezentiraju raznolikost izvornog skupa podataka, što bi trebalo rezultirati reprezentativnim rezultatima. Kada se uspoređuju algoritmi strojnog učenja, poželjno je da se rad i procjena uspješnosti temelje na istim podskupovima izvornog skupa podataka. To se postiže fiksiranjem sjemena za generator pseudo-slučajnih brojeva koji se koristi prilikom dijeljenja skupa podataka odnosno postavljanjem "*random_state*" parametra na cjelobrojnu vrijednost. Mnogi problemi klasifikacije koji se rješavaju pomoću strojnog učenja uključuju nebalansirane skupove podataka, što znači da su neke klase zastupljene rjeđe u odnosu na druge. Kada se dijeli skup podataka na podskupove za učenje i testiranje, idealno bi bilo zadržati istu distribuciju uzoraka u svakoj klasi kao što je u izvornom skupu podataka. Odnosno, kako bi se postigla ista distribucija uzoraka u svim klasama u podskupovima kao i u izvornom skupu podataka, može se koristiti parametar "*stratify*" prilikom podjele na podskupove za učenje i testiranje. Korištenjem funkcije *train_test_split ()* u obliku:

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=<decimal number>, random_state=1, stratify=y)

uzima se izvorni skup podataka *X* i *y* kao ulaz i dobiva se skup podataka podijeljen u dva podskupa posebno za učenje i testiranje, *X_train, y_train* i *X_test i y_test*. Podskupovi *X_train, y_train* se koriste u fazi učenja dok se podskup podataka *X_test* i *y_test* koristi za određivanje uspješnosti klasifikacije.

Eksperimentalno testiranje najboljeg omjera podskupova podataka za učenje i testiranje provedeno je s četiri klasifikatora (Slučajna šuma, K-najbliži susjed, linearni stroj s potpornim vektorima i Bernoulli Naivni Bayesov klasifikator). Iako su uobičajeni omjeri 80/20, 70/30 ili 50/50 u ovom dijelu istraživanja ispitani su omjeri 10/90 do 90/10 s korakom 10. Tijekom izračunavanja uspješnosti klasifikatora za skup podataka NF-CSE-CIC-IDS2018-v2 s omjerima 20/80 i 10/90, došlo je do greške odnosno automatskog prekida izračunavanja AUC metrike klasifikacije zbog prezahtjevnih računalnih resursa. Stoga ti rezultati u grafu na Slici 4.9 nisu prikazani.

U nastavku su prikazani grafovi (Slika 4.4 – 4.11) koji prikazuju rezultate za svaki pojedini skup podataka te kako korišteni omjeri podataka za učenje i testiranje utječu na točnost klasifikacije. Na lijevoj ordinati grafa prikazan je medijan AUC točnosti svih klasifikatora, što bolje opisuje rezultate od srednje vrijednosti u slučaju velikih odstupanja u rezultatima, kao što je

primjerice slučaj kod Bernoulli naivnog klasifikatora. Na desnoj ordinati grafa prikazano je ukupno trajanje izračuna AUC točnosti, također prikazano kao medijan svih rezultata koje su postigla navedena četiri klasifikatora.

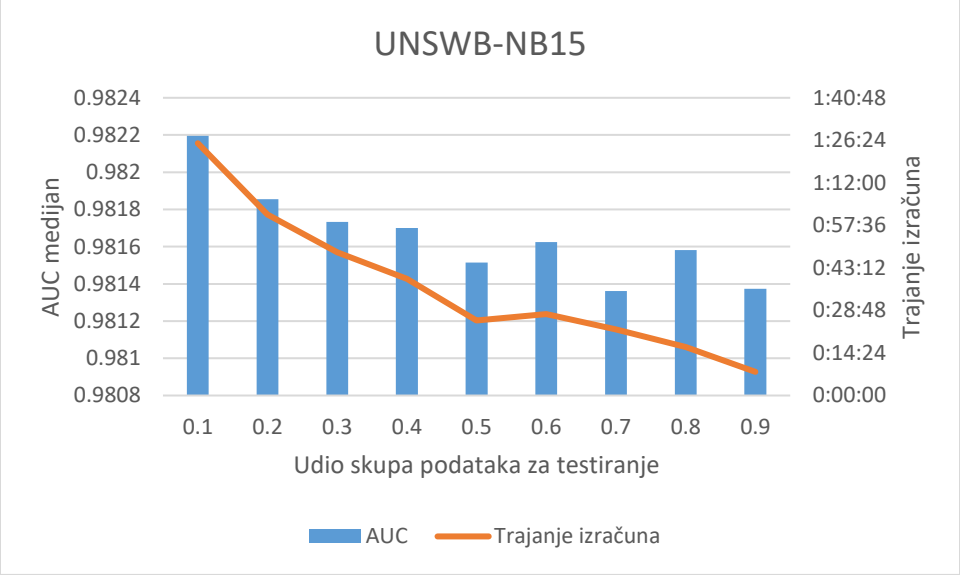

Slika 4.4 Rezultati AUC točnosti i vremena izračuna u odnosu na omjer podskupova za učenje i testiranje na UNSWBNB15 skupu podataka

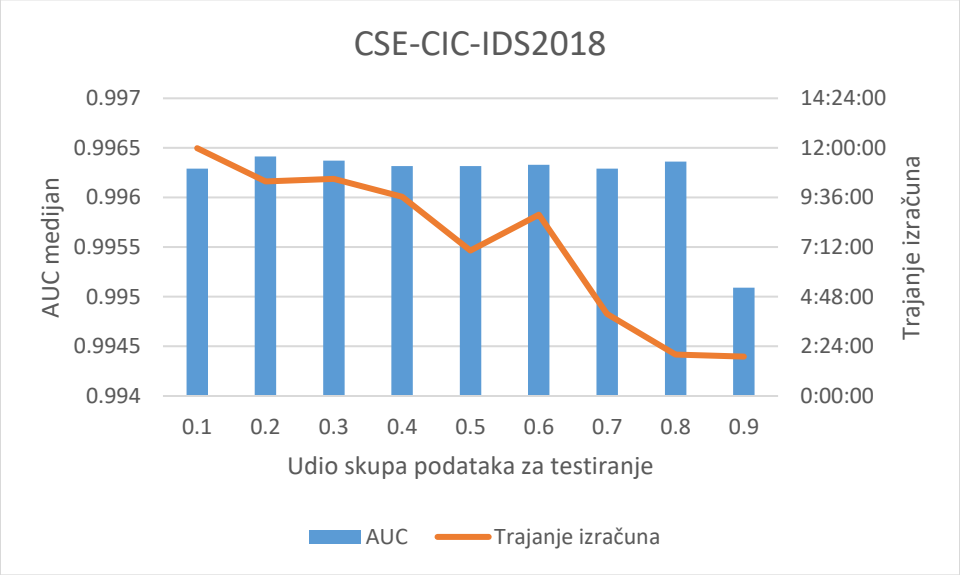

Slika 4.5 Rezultati AUC točnosti i vremena izračuna u odnosu na omjer podskupova za učenje i testiranje na CSE-CIC-IDS2018 skupu podataka

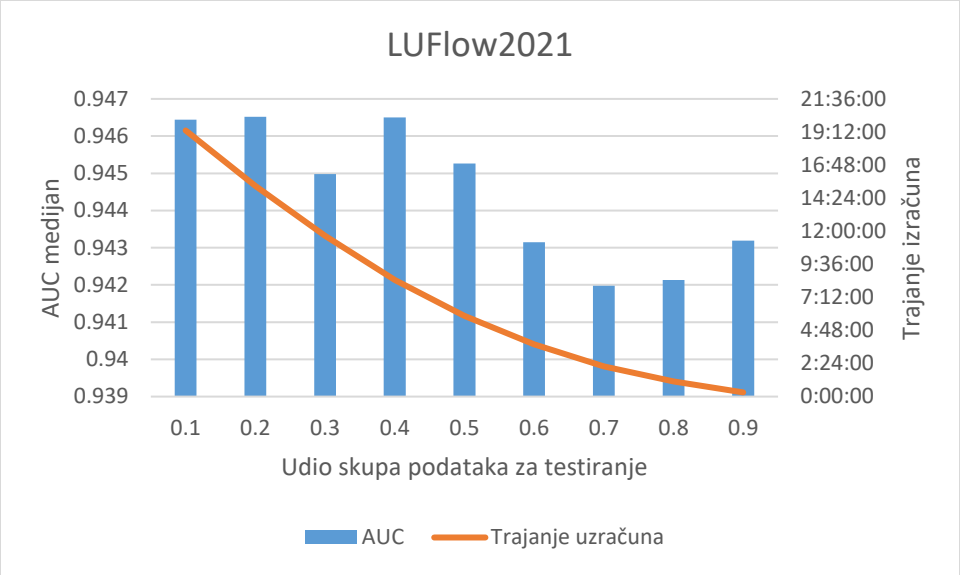

Slika 4.6 Rezultati AUC točnosti i vremena izračuna u odnosu na omjer podskupova za učenje i testiranje na LUFlow2021 skupu podataka

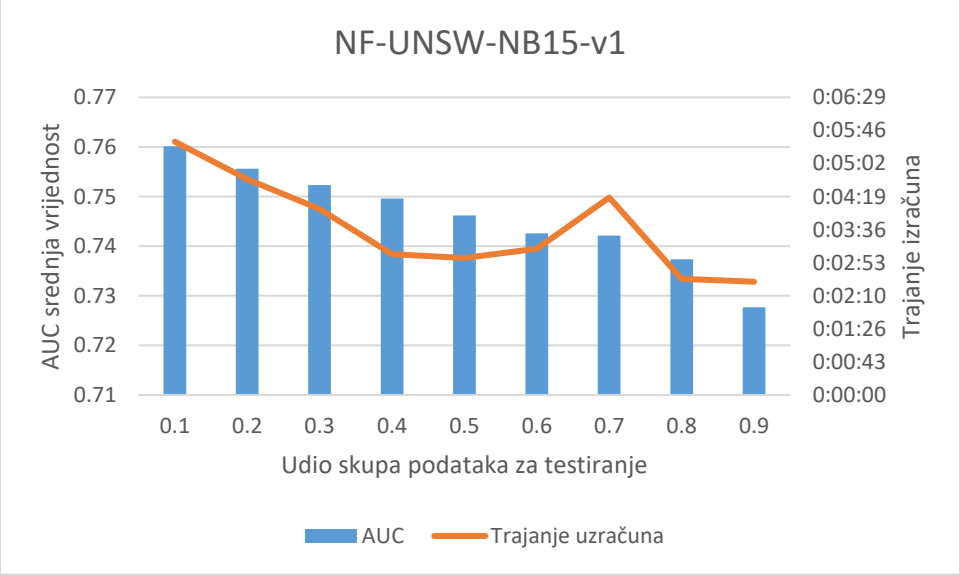

Slika 4.7 Rezultati AUC točnosti i vremena izračuna u odnosu na omjer podskupova za učenje i testiranje na NF-UNSW-NB15-v1 skupu podataka

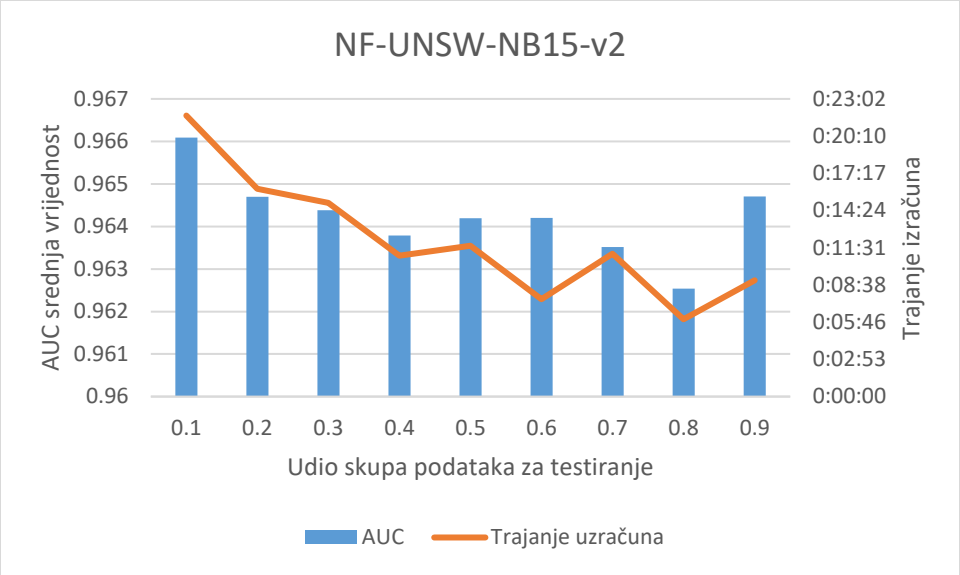

Slika 4.8 Rezultati AUC točnosti i vremena izračuna u odnosu na omjer podskupova za učenje i testiranje na NF-UNSW-NB15-v2 skupu podataka

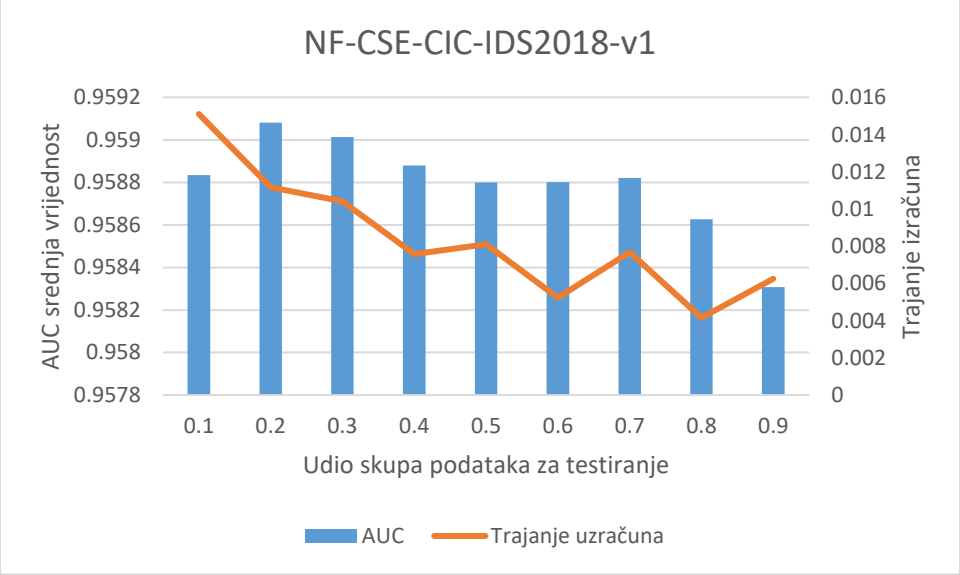

Slika 4.9 Rezultati AUC točnosti i vremena izračuna u odnosu na omjer podskupova za učenje i testiranje na NF-CSE-CIC-IDS2018-v1 skupu podataka

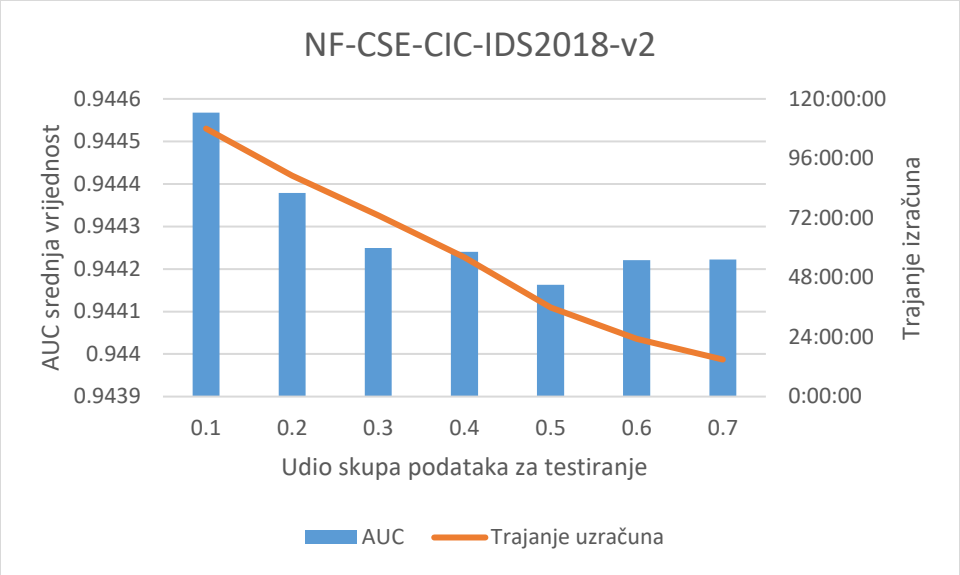

Slika 4.10 Rezultati AUC točnosti i vremena izračuna u odnosu na omjer podskupova za učenje i testiranje na NF-CSE-CIC-IDS2018-v2 skupu podataka

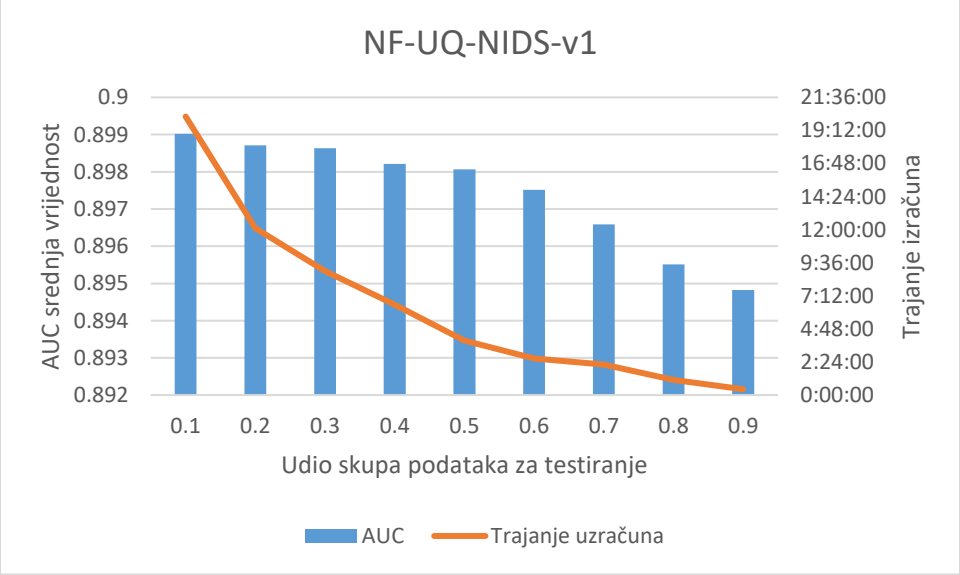

Slika 4.11 Rezultati AUC točnosti i vremena izračuna u odnosu na omjer podskupova za učenje i testiranje na NF-UQ-NIDS-v1 skupu podataka

Eksperimentalno određivanje najboljeg omjera razdvajanja skupa podataka za učenje i testiranje pokazuje da su odstupanja u AUC točnosti vrlo mala (razlika u točnosti je u rasponu od 0.1% - 4.4.%) u ovisnosti o definiranom omjeru. Dodatni parametar, ali ne i ključni, je vrijeme izračunavanja koji se koristi kako bi se usporedili benefiti smanjivanja ili povećanja omjera podjele

skupa podataka. Na osnovi dobivenih rezultata najbolja AUC točnost postignuta je s omjerom 90/10 odnosno 90% podataka koristi se za učenje dok se 10% koristi na testiranje klasifikacije. Omjer od 80/20 također ima visoku AUC točnost ali i značajno ukupno smanjenje trajanje izračuna. Pri ovom omjeru točnost se prosječno smanjuje za 0.1%, a vrijeme potrebno za izračune se smanjuje u prosjeku za 24%. Tablica 4-9 prikazuje postotak promjene AUC točnosti i promjene trajanja izračuna između omjera 90/10 i 80/20. Prilikom izračunavanja srednje vrijednosti uzela se apsolutna vrijednost promjene. Srednja vrijednost promjene AUC točnosti i vermena izračuna je prikazana u zadnjem redu Tablice 4-9. Negativan predznak Δ AUC (%) kod određenih skupova podataka označava bolju točnost pri omjeru 80/20 nego 90/10 što je vidljivo iz prethodnih grafova ovog potpoglavlja.

Tablica 4-9 Usporedba smanjenja AUC točnosti i vremena izračuna između omjera 90/10 i 80/20 trening/test podataka

skup podataka	**Δ AUC (%)**	**Δ vrijeme izračuna (%)**
UNSWB-NB15	0.03	28.31
NF-CSE-CIC-IDS2018-v2	0.0199	17.53
NF-UNSW-NB15-v2	0.1446	26.05
NF-CSE-CIC-IDS2018	-0.0257	34.54
NF-UQ-NIDS	0.0347	40.11
NF-UNSW-NB15	0.5922	14.8
LUFlow2021	-0.0078	20.80
CSE-CIC-IDS2018	-0.0123	13.4
	0.1084	24.4425

Uzevši u obzir ove činjenice i usporedbu omjera korištenih u sličnim istraživanjima u daljnjem razvoju modela koristio se omjer **80/20** (trening/test). Smanjenje u AUC točnosti odabirom ovog omjera nadoknadio se u dijelu finog podešavanja hiperparametara odabranog klasifikatora.

4.1.2.6. Skaliranje značajki

Skaliranje značajki ulaznog skupa podataka se preporučuje u predobradi podataka tijekom izgradnje modela strojnog učenja, jer može značajno poboljšati performanse modela i učiniti ga učinkovitijim. Prilikom korištenja algoritama strojnog učenja, ulazne vrijednosti moraju biti numeričke vrijednosti. Ako postoji znatna razlika u rasponima vrijednosti među pojedinim

značajkama, pretpostavka je da značajke s većim rasponom imaju veći utjecaj, što znači da će brojevi s većim rasponom imati važniju ulogu tijekom učenja modela. Ako raspon vrijednosti neobrađenih podataka uvelike varira, u nekim algoritmima strojnog učenja ciljne funkcije ne rade ispravno bez normalizacije odnosno skaliranja. Python *sklearn.preprocessing* je dio biblioteke otvorenog koda za strojno učenje u Pythonu koji pruža različite tehnike za predobradu podataka, uključujući skaliranje, kodiranje kategorijskih varijabli, normalizaciju i mnoge druge operacije koje su ključne u pripremi podataka za strojno učenje. Neke od uobičajenih funkcija skaliranja vrijednosti značajki su: *Min Max Scaler, Standard Scaler i Robust Scaler* i koriste se u sličnim istraživanjima [66], [105], [110], [115]. Kako bi se odredila najbolja funkcija skaliranja uspoređene su funkcije skaliranja na svim referentnim skupovima podataka kako bi se utvrdio njihov utjecaj na povećanje točnosti klasifikatora.

Standardni skaler

Standardno skaliranje (eng. *Standard scaling*) jedna je od najčešćih tehnika skaliranja značajki u strojnom učenju. Postupak standardnog skaliranja uključuje oduzimanje srednje vrijednosti svake značajke iz svakog uzorka i zatim podjelu sa standardnom devijacijom. To osigurava da se sve vrijednosti značajki transformiraju na istu skalu, čime se olakšava uspoređivanje među značajkama. Standardni rezultat uzorka *x* izračunava se prema [126] na sljedeći način:

$$z = (x - u)/s \tag{4-1}$$

gdje je *u* srednja vrijednost uzoraka za učenje, a *s* je standardna devijacija uzoraka za učenje. Primjena standardnog skaliranja je osobito korisna za modele koji zahtijevaju normalnu raspodjelu podataka, poput mnogih linearnih modela, kao i nekih metoda klasteriranja i neuronskih mreža [126].

Robustni skaler

Robustno skaliranje (eng. *Robust scaling*) je tehnika skaliranja značajki u strojnom učenju koja se koristi kada je potrebno skalirati podatke s anomalijama, tj. odstupanjima od uobičajenog obrasca distribucije podataka. Ovaj skaler uklanja medijan i mjeri podatke prema interkvartilnom rasponu IQR (raspon između 1. kvartila i 3. kvartila). Centriranje i skaliranje se odvijaju neovisno o svakoj značajki izračunavanjem relevantne statistike o uzorcima u skupu za učenje. Robustno

skaliranje je osobito korisno za modele koji nisu otporni na anomalije, poput mnogih linearnih modela koji se temelje na srednjoj vrijednosti i standardnoj devijaciji [127].

MinMax skaler

MinMax skaliranje *(*eng. *MinMax scaling)* je tehnika u strojnom učenju koja se koristi za transformiranje podataka. Njena svrha je prilagoditi sve značajke u skupu za učenje unutar određenog opsega. Uobičajeno se primjenjuju dva opsega: od 0 do 1 kada su vrijednosti značajki pozitivne, i od -1 do 1 kada su neke vrijednosti značajki negativne. Mogu se postaviti i neki proizvoljni rasponi poput [0,5]. Ovaj se skaler dobro ponaša ako je standardna devijacija mala i kada distribucija uzoraka nije Gaussova, a često se koristi za normalizaciju podataka kako bi se osigurala jednaka važnost svake značajke u skupu podataka. Vrlo je osjetljiv na anomalije, a postupak MinMax skaliranja uključuje oduzimanje minimalne vrijednosti svake značajke iz svakog uzorka i zatim podjelu s rasponom vrijednosti značajke (razlikom između maksimalne i minimalne vrijednosti). Transformacija je prema [128] definirana kao:

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \tag{4-2}$$

4.1.2.7. Utjecaj algoritma skaliranja na točnost klasifikacije

Kada se usporede AUC vrijednosti klasifikacije četiri klasifikatora na svim skupovima podataka, uz primjenu svih triju spomenutih tehnika skaliranja, moguće je utvrditi koja je tehnika skaliranja najbolja za primjenu na tim skupovima podataka. Na grafovima (Slika 4.12 i Slika 4.13) su prikazane AUC vrijednosti pojedinih klasifikatora prema različitim skupovima podataka. Važno je napomenuti da određeni algoritmi skaliranja nisu primjenjivi na svim skupovima podataka, kao što je slučaj s NF-CSE-CIC-IDS2018-v2 gdje su izračuni AUC vrijednosti automatski prekinuti tijekom izračunavanja zbog manjka računalnih resursa. Stoga, ti rezultati algoritama skaliranja nisu uvršteni na prikazanim grafovima. Na temelju rezultata i usporedbe AUC vrijednosti na svim cjelovitim skupovima podataka, zaključuje se da je MinMax skaler najbolji izbor za skaliranje značajki (zbog zaokruživanja vrijednosti na četiri decimale RobustScaler i StandardScaler za RF algoritam u Tablici 4-10 imaju jednake vrijednosti). Ova

tehnika može se primijeniti na sve skupove podataka, a također pokazuje najveću točnost na većini skupova podataka. U Tablici 4-10 prikazane su vrijednosti na cjelovitim skupovima podataka gdje se prema točnosti ističe klasifikator Slučajne šume koristeći MinMax algoritam skaliranja podataka na skupu podataka LUFlow2021.

Tablica 4-10 Usporedba AUC vrijednosti i tehnika skaliranja s cjelovitim skupovima podataka

metoda skaliranja	**skup podataka**	**algoritam**			
		BNB	***K-NN***	***LSVC***	***RF***
MinMaxScaler	CSE-CIC-IDS2018	0.8239	0.9990	0.9939	0.9990
	LUFlow2021	0.7306	0.9997	0.8933	**0.9999**
	UNSWB-NB15	0.8533	0.9781	0.9856	0.9874
RobustScaler	CSE-CIC-IDS2018	0.8086	0.9986	0.9737	0.9991
	LUFlow2021	0.8394	0.9983	0.8389	0.9999
	UNSWB-NB15	0.8568	0.9747	0.9892	0.9872
StandardScaler	CSE-CIC-IDS2018	0.8121	0.9990	0.9936	0.9988
	LUFlow2021	0.8021	0.9996	0.8924	0.9999
	UNSWB-NB15	0.9085	0.9770	0.9855	0.9871

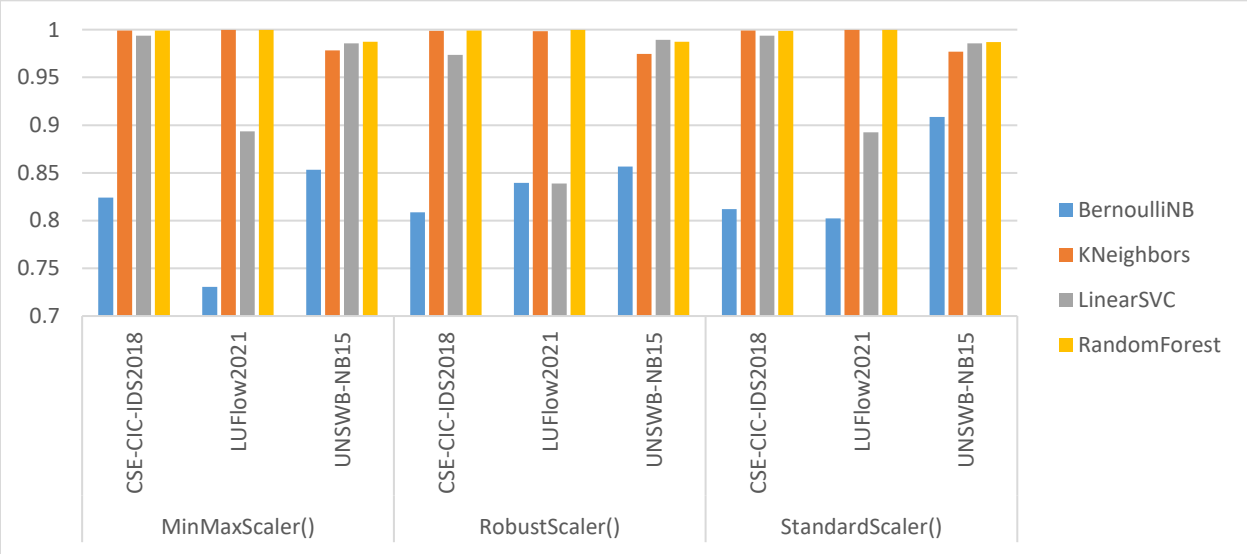

Slika 4.12 Usporedba AUC vrijednosti i tehnika skaliranja s cjelovitim skupovima podataka

U Tablici 4-11 prikazane su vrijednosti na NetFlow skupovima podataka gdje se prema točnosti također ističe klasifikator Slučajne šume koristeći MinMax algoritam skaliranja podataka na skupu podataka NF-UNSW-NB15-v2.

Tablica 4-11 Usporedba AUC vrijednosti i tehnika skaliranja s NetFlow skupovima podataka

metoda skaliranja	skup podataka	algoritam			
		BNB	***K-NN***	***LSVC***	***RF***
MinMaxScaler	NF-CSE-CIC-IDS2018	0.8418	0.9728	0.9454	0.9738
	NF-CSE-CIC-IDS2018-v2	0.8859	0.9821	0.9067	0.9838
	NF-UNSW-NB15	0.6550	0.8563	0.5544	0.9361
	NF-UNSW-NB15-v2	0.6548	0.9839	0.9455	**0.9890**
	NF-UQ-NIDS	0.5881	0.9720	0.8255	0.9855
RobustScaler	NF-CSE-CIC-IDS2018	0.9536	0.9730	0.9491	0.9732
	NF-UNSW-NB15	0.6567	0.9080	0.5654	0.9366
	NF-UNSW-NB15-v2	0.9438	0.9836	0.9465	0.9889
	NF-UQ-NIDS	0.7263	0.9845	0.8363	0.9864
StandardScaler	NF-CSE-CIC-IDS2018	0.8690	0.9733	0.9465	0.9731
	NF-UNSW-NB15	0.5000	0.9119	0.5599	0.9368
	NF-UNSW-NB15-v2	0.9738	0.9829	0.9601	0.9888
	NF-UQ-NIDS	0.7833	0.9813	0.8383	0.9864

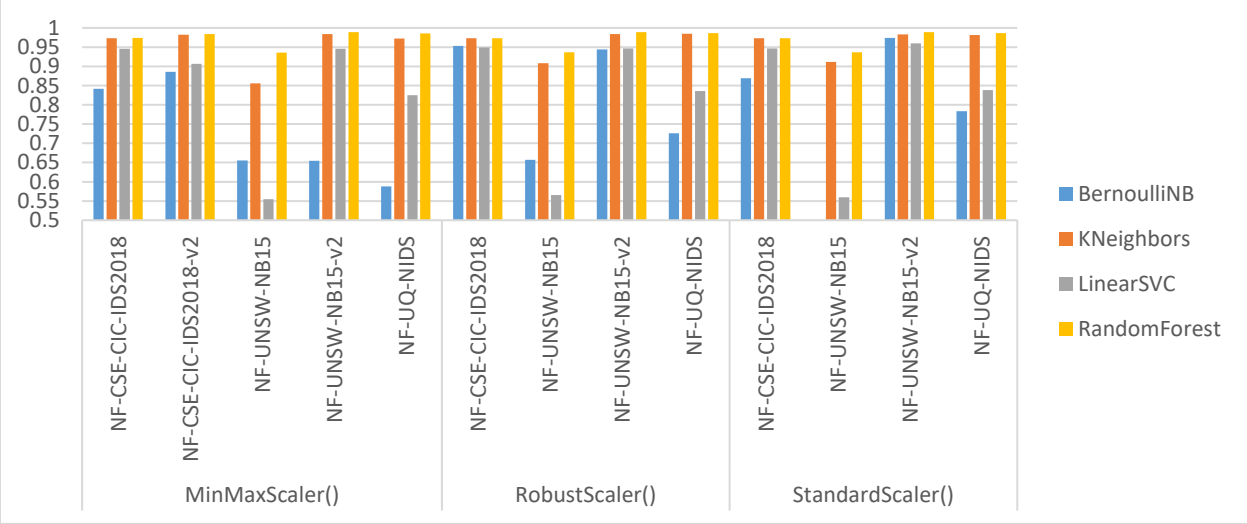

Slika 4.13 Usporedba AUC vrijednosti i tehnika skaliranja s NetFlow skupovima podataka

Nakon provedenog testiranja primjećuju se vrlo ujednačene i najbolje AUC vrijednosti za klasifikatore Slučajne šume i K-najbližeg susjeda za sve tri primijenjene metode skaliranja. Ukupno gledajući, MinMax skaliranje najprihvatljivija je metoda skaliranja te su se ovom metodom skalirali podatci stvarnog NetFlow prometa u daljnjem istraživanju i eksperimentalnim postupcima strojnog učenja.

4.1.3. Odabir referentnog skupa podataka i klasifikatora

Kako bi se odabrao najbolji klasifikator i poslije uspješno koristio u modelu za detekciju anomalija mrežnog prometa bitno je uspješnost klasifikatora provjeriti na više dostupnih javnih skupova podataka. U izračunima su se koristila tri cjelovita skupa podataka: UNSW-NB15, CSE-CIC-IDS2018, LUFlow2021 te NetFlow prilagođeni skupovi podataka: NF-UNSW-NB15-v1, NF-UNSW-NB15-v2, NF-CSE-CIC IDS2018-v1, NF-CSE-CIC IDS2018-v2, NF-UQ-NIDS-v1. Skupovi podataka detaljno su opisani u poglavljima 4.1.1.1. – 4..1.1.2. Svi skupovi podataka podvrgnuti su predobradi, no razlike su bile u primjeni ovisno o njihovoj strukturi i potrebama. Skupovi podataka koji su već bili pripremljeni (NetFlow) i kodirani u numeričke vrijednosti zahtijevali su manje prilagodbe u odnosu na cjelovite skupove podataka koji su bili u svom izvornom obliku. Ovakvim pristupom i korištenjem cjelovitih i NetFlow skupova podataka bilo je moguće usporediti ispravnost postupka predobrade osobito u dijelu kodiranja kategorijskih značajki. Svaka faza predobrade podataka radila se na svim skupovima podataka te se na temelju najboljih AUC vrijednosti određivao najbolji odabir promatrane predobrade.

Tijekom svih ispitivanja utjecaja na točnost klasifikacije u procesu predobrade podataka koristila su se četiri najčešća predstavnika klasifikatora prema podjeli algoritama klasifikacije nadziranog strojnog učenja opisanim u poglavlju 3.4. Ispitivanjem utjecaja više faktora u predobradi podataka opisanih u poglavlju 4.1.2. utvrđeni su najbolji faktori kako slijedi:

- brisanje suvišnih značajki;
- čišćenje neispravnih vrijednosti;
- kodiranje kategorijskih značajki metodom kodiranja labelama;
- 80/20 omjer podataka za učenje i testiranje;
- skaliranje podataka MinMax metodom skaliranja.

Na temelju odabranih faktora predobrade skupova podataka provedena je klasifikacija s četiri različita klasifikatora te je na temelju rezultata klasifikacije odabran referentni skup podataka, kao i najuspješniji klasifikator. Proces ispitivanja rađen je prema psudokodu Algoritam 1., a implemetiran u programskom jeziku Python.

Algoritam 1: Odabir referentnog skupa i najboljeg klasifikatora

Input1: javno dostupni skupovi podataka CSE-CIC-IDS2018, LUFlow2021, UNSWB-NB15, NF-CSE-CIC-IDS2018, NF-CSE-CIC-IDS2018-v2, NF-UNSW-NB15, NF-UNSW-NB15-v2, NF-UQ-NIDS
Input2: klasifikatori BNB, K-NN, LSVC, RF
Output: AUC

```
Za svaki Input1 ponovi:
    Function: učitavanje podataka (csv)
    Return: data
    Function: Predobrada podataka (data)
    Return: data_
    Function: razdvajanje podataka (data, omjer razdvajanja)
        X ← skup podataka svih značajki bez oznake klase
        y ← značajka oznake klase
    Return X_train, X_test, y_train, y_test
    Function: Skaliranje podataka
    Return X_train_scale, X_test_scale, y_train, y_test
    Za svaki Input2 ponovi:
        AUC ← klasifikacija (X_train_scale, X_test_scale, y_train, y_test)
    Ponovi
Ponovi
Kraj
```

Na Slici 4.14 prikazani su rezultati izračuna točnosti klasifikacije uz AUC vrijednosti za sva četiri klasifikatora na promatranim javno dostupnim skupovima podataka. Rezultati pokazuju da je klasifikator Slučajne šume najuspješniji. Na skupu podataka LUFlow2021, ovaj klasifikator postiže izuzetno visoku AUC točnost od 99.98%. Najlošije rezultate ostvaruje Bernoulli Naive Bayes klasifikator koji prema ovim rezultatima nije pogodan za rješavanje problema klasifikacije s ovim tipom podataka. Nešto slabiji rezultat ima klasifikator K-najbližeg susjeda, no vrijeme utrošeno pri klasifikaciji ovim klasifikatorom daleko premašuje vrijeme potrebno za klasifikaciju s klasifikatorom Slučajne šume kao što prikazuje Slika 4.15.

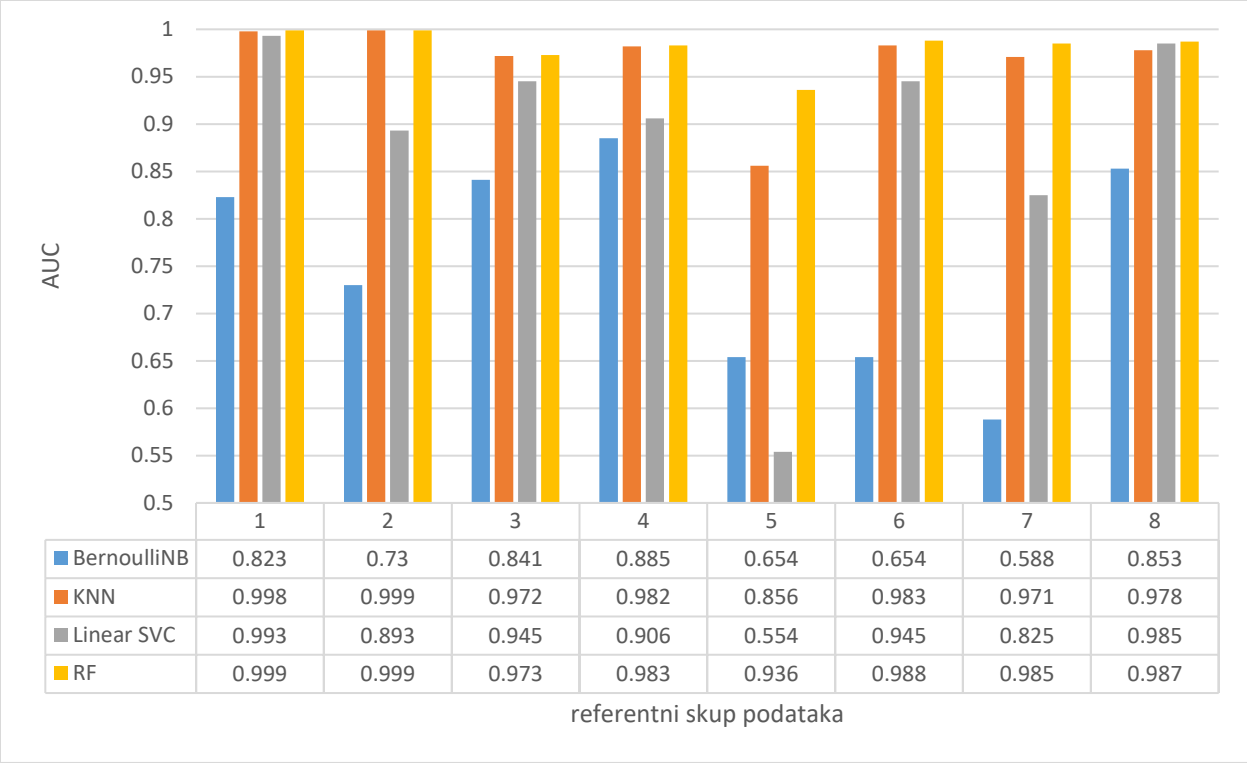

	1	2	3	4	5	6	7	8
BernoulliNB	0.823	0.73	0.841	0.885	0.654	0.654	0.588	0.853
KNN	0.998	0.999	0.972	0.982	0.856	0.983	0.971	0.978
Linear SVC	0.993	0.893	0.945	0.906	0.554	0.945	0.825	0.985
RF	0.999	0.999	0.973	0.983	0.936	0.988	0.985	0.987

Slika 4.14 Usporedba uspješnosti klasifikatora na svim skupovima podataka

Referentni skupovi podataka u Tablici 5.13 su: 1 - CSE-CIC-IDS2018, 2 - LUFlow2021, 3 - UNSWB-NB15, 4 - NF-CSE-CIC-IDS2018, 5 - NF-CSE-CIC-IDS2018-v2, 6 - NF-UNSW-NB15, 7 - NF-UNSW-NB15-v2, 8 - NF-UQ-NIDS

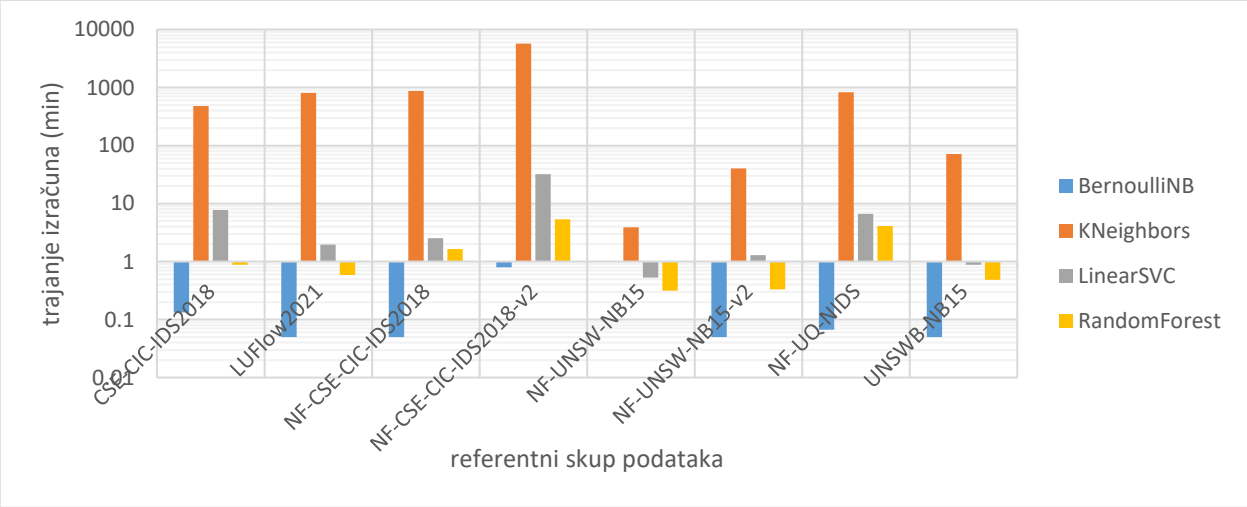

Slika 4.15 Usporedba vremena izračuna AUC točnosti klasifikacije na svim skupovima podataka

Na Slici 4.15 prikazana je logaritamska raspodjela trajanja izračuna jer su vrijednosti izračuna za klasifikator K-najbližeg susjeda izrazito velike u odnosu na trajanje izračuna ostalih klasifikatora. Neki klasifikatori u scikit-learn platformi imaju mogućnost korištenja i raspodjelu izračuna na sve dostupne procesore te je ova mogućnost znatno poboljšala performanse tijekom izračunavanja. Iako je ova mogućnost raspoloživa i za klasifikator K-najbližeg susjeda vrijeme izračuna je i dalje mnogostruko veće od ostalih klasifikatora neovisno o kojem referentnom skupu podataka se radi. Bernoulli Naive Bayes klasifikator izdvaja se po najkraćem vremenu za izračunavanje, ali točnost koju postiže pri klasifikaciji čini ga neprihvatljivim za implementaciju dok se klasifikator Stroja s potpornim vektorom ne izdvaja niti prema točnosti klasifikacije niti prema vremenu potrebnom za izračunavanje.

Tijekom istraživanja za odabir i prilagodbu ulaznih podataka u svim fazama opisanim u prethodnim poglavljima, najbolji rezultati su redovito postignuti korištenjem klasifikatora Slučajne šume. Osim najveće AUC točnosti koja se uzimala kao referentna mjera zbog već ranije opisanih svojstava skupa podataka koji je izrazito nebalansiran, izračunavane su i ostale mjere točnosti opisane u poglavljima 3.5.1. – 3.5.9. Uzevši u obzir i ove mjere točnosti, klasifikator Slučajne šume postizao je u najvećem dijelu najbolje rezultate. Uz postizanje najbolje točnosti svaki puta je bio pri vrhu najboljih rezultata vezano za trajanje izračuna. Najbolji primjer pokazuje Slika 4.15 gdje su na logaritamskoj skali prikazana vremena potrebna za izračunavanja sva četiri algoritma na svim skupovima podataka. Kraća vremena izračunavanja imao je jedino Bernoulli Naive Bayes klasifikator čija je točnost vrlo mala i u nekim slučajevima graniči sa slučajnim pogađanjem klasa. Stoga se može reći da klasifikator Slučajne šume i u ovom segmentu postiže najbolje rezultate. U početnim razmatranjima, vrijeme izračuna nije bilo važno prilikom odabira klasfikatora, ali kako se naučeni model ne može ažurirati i prilagoditi novim podatcima u stvarnom vremenu, potrebno je ponovno provesti postupak učenja s novim skupovima podataka. Stoga, vrijeme izračuna postaje važan čimbenik kako bi se model što prije ažurirao i prilagodio novim podatcima. Bitan čimbenik kod brzine izračunavanja je mogućnost korištenja svih raspoloživih računalnih resursa (na infrastrukturi korištenog virtualnog poslužitelja ukupno je bilo raspoloživo 32 procesora). Prema dokumentaciji scikit-learn-a, jedino klasifikatori Bernoulli NB i Stroj s potpornim vektorima (LinearSVC) nisu mogli koristiti ovu mogućnost, ali i bez toga Bernoulli NB je postizao najbolja vremena prilikom izračunavanja. Zapažen je vrlo velik utjecaj skaliranja

podataka gdje su se uvelike smanjila vremena izračunavanja posebno kod klasifikatora Stroja s potpornim vektorima (LinearSVC).

Uspoređujući s relevantnim istraživanjima detekcije anomalija putem strojnog učenja posljednjih godina, prikazanim u Tablici 4-12, predloženi klasifikator Slučajne šume (RF), korišten na referentnom skupu podataka LUFlow2021, pokazuje bolje rezultate. Ovaj pristup ne samo da postiže visoku točnost prepoznavanja anomalija korištenjem prikladne AUC metrike, već također pruža skalabilnost i učinkovitost u obradi velikih i kompleksnih prije svega nebalansiranih skupova podataka, čime se potvrđuje kao pouzdana metoda za detekciju anomalija u realnim mrežnim okruženjima.

Legende kratica u Tablici 4-12.

ML algoritmi:

RF-Random Forest, LSVC-Linear Support Vector Machines, KNN-K-Nearest Neighbour, BNB-Bernoulli Naive Bayes, ANN-Artificial Neural Network, SVM-Support Vector Machines, NB-Naive Bayes, DT-Decision Tree, GBT-Gradient Boosting Tree, SGD-Stochastic Gradient Descent, LR-Logistic Regression

Skupovi podataka:

1-UNSW-NB15, 2-CIC-IDS2018, 3-LUFlow2021, 4-NF-UNSW-NB15, 5-NF-CIC-IDS2018, 6-NF-LUFlow2021, 7-NF-UQ-NIDS, 8-NSL-KDD, 9-CIDDS-001, 10-ISCX2012, 11-CIC-IDS2017, 12-LUFlow2020, 13-ICS, 14-CTU-13, 15-PantHoney

Evaluacijske metrike:

AUC-Area Under ROC Curve, F2-F2 Score, F1-F1 Score, A-accuracy, BA-Balanced accuracy, R-Recall, P-Precision, CK-Cohen kappa, M-Methews coef., FPR-False Positive Rate, TPR-True Positive Rate, T-time, MSE-Mean Squared Error

Tablica 4-12 Usporedba relevantnih istraživanja detekcije anomalija strojnim učenjem

#	godina	ML algoritmi	Skup podataka	Cijeli skupovi podataka	Evaluacijske metrike	Najbolji rezultat
Predloženi model		**RF**, LSVC, KNN, BNB	1,2,**3**,4,5,6,7	DA	**AUC**, F2, A, BA, R, P, CK, M, T	99.98%
[66]	2020.	**ANN**, SVM, NB, RF, KNN	1,**8**	NE	**A**, FPR, T	99.69%
[101]	2022.	**RF**, DT, SVM, NB	2,**3**,11,12	NE	**A**, P, R, F1	99,91%
[129]	2018.	**RF**, SVM, ANN	**1**	NE	A, CK, FPR, P, R, **AUC**, T	99.10%
[130]	2022.	**GBT**, RF, NB, DT, LSVM	**12**	NE	A, F1, **P**, R	99,98%
[123]	2020.	NB, K-NN, DT, **RF**	1,**11**,13	DA	**A**, P, R, FPR, F1, AUC	99,90%
[131]	2018.	NB, SVM, **RF**	**1**	NE	**AUC**, TPR, FPR	98,10%
[121]	2020.	KNN, LR, NB, DT, SGD, **RF**	**1**	NE	P, MSE, R, F1, A, TPR, FPR	95.43%
[132]	2019.	RF, DT-J48	**14, 15**	NE	**A**, P, FPR, TPR, F1	97,47%

Ovakvi rezultati predloženog modela klasifikacije potvrđuju odabir klasifikatora **Slučajne šume (RF)** kao referentnog klasifikatora za model detekcije anomalija mrežnog prometa uz predloženi odabir i prilagodbu ulaznih podataka. Klasifikator Slučajne šume u većini istraživanja ovakvog tipa pokazuje najbolje rezultate koristeći različite skupove podataka.

U dostupnoj literaturi primijećeno je da su referentni skupovi podataka starijeg datuma, poput NSL-KDD, dominantni, ali s vremenom se bilježi povećanje uvođenja novijih skupova podataka. Ovo se potvrđuje i analizom nedavno provedenih istraživanja prikazanih u Tablici 4-12. Među novijim skupovima podataka ističe se LUFlow, koji je ažuriran novim zapisima od 2020. do 2022. godine, što je obuhvaćeno vremenom nastanka ove disertacije. Kada je riječ o postignutim rezultatima, klasifikator Slučajne šume ostvario je najbolje rezultate kada je primijenjen na cjeloviti skup podataka **LUFlow2021**, što ga čini ključnim odabirom prilikom izrade modela za detekciju anomalija u fazi učenja.

4.1.4. Odabir hiperparametara klasifikatora

Određivanje parametara funkcije predviđanja i testiranja na istim podatcima metodološka je pogreška. Osnovno načelo procjene uspješnosti klasifikatora je da se uzorci koji se koriste za učenje ne smiju koristiti za ocjenu uspješnosti. Slično pravilo vrijedi i za metode odabira hiperparametara koje zahtijeva većina metoda strojnog učenja, na primjer, *broj stabala* za algoritam Slučajne šume, *sigma* i *C* vrijednosti za algoritme Strojeva s potpornim vektorima, te *k* koeficijent za algoritam K-najbližeg susjeda. Vrijednost ovih hiperparametara može utjecati na točnost klasifikacije, a samim time je potrebno optimiziranje odabranih vrijednosti. Ugađanje (eng. *tuning*) hiperparametara je obično empirijski proces s različitim vrijednostima i kombinacijama hiperparametara. Pretpostavlja se da su vrijednosti hiperparametara koje generiraju najveću ukupnu točnost ili neku drugu vrstu metrike optimalne za promatrani model odnosno klasifikator [133].

4.1.4.1. Unakrsna validacija

Model koji bi savršeno reproducirao oznake uzoraka na kojima je treniran imao bi idealan rezultat na tim podatcima, ali bi se lošije nosio s novim, neviđenim podatcima. Ovaj problem naziva se prekomjerno prilagođavanje (eng. *overfitting*). Da bi se to izbjeglo, uobičajena praksa u nadziranom strojnom učenju je zadržati dio dostupnih podataka kao testni skup (X_test, y_test), na kojem se provjeravaju performanse modela na novim podatcima i sprječava prekomjerno prilagođavanje. Na Slici 4.16 prikazan je dijagram toka tipičnog tijeka unakrsne validacije pri procesu učenja modela. Najbolji parametri mogu se odrediti tehnikama pretraživanja poput *GridSearchCV*.

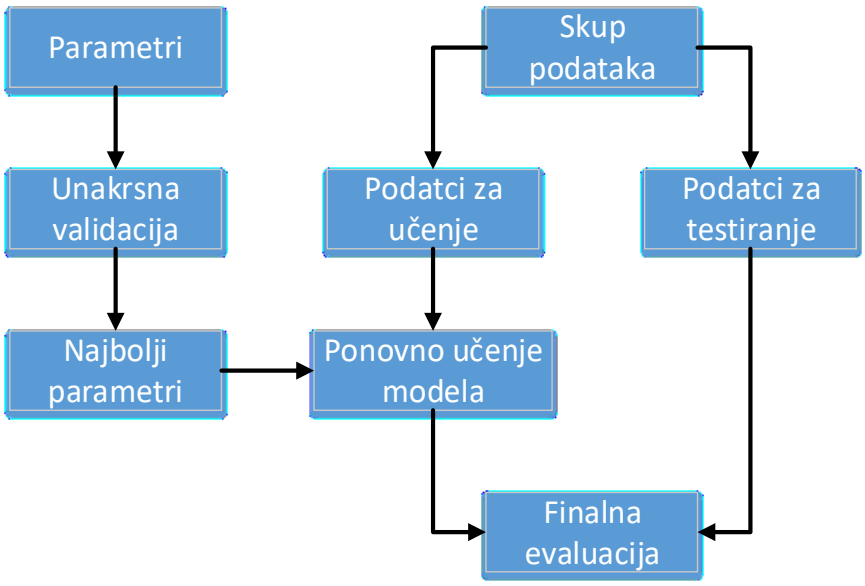

Slika 4.16 Unakrsna validacija i određivanje najboljih parametara modela [134]

Prilikom evaluacije različitih postavki (hiperparametara) za klasifikatore još uvijek postoji rizik od prekomjernog prilagođavanja testnog skupa jer znanje o skupu testnih podatka može "procuriti" u model. Da bi se riješio ovaj problem još jedan dio skupa podataka može se predstaviti kao tzv. "skup podataka za provjeru valjanosti". Učenje se izvodi na skupu podataka za učenje, nakon čega se vrši evaluacija na skupu za provjeru valjanosti i kada se postigne zadovoljavajući rezultat, konačna procjena se radi na testnom skupu podataka. Particioniranjem dostupnih podataka u tri podskupa (učenje, test, validacija), drastično smanjujemo broj uzoraka koji se mogu koristiti za učenje modela, a rezultati mogu ovisiti o određenom slučajnom izboru podskupova. Rješenje ovog problema je postupak koji se zove unakrsna validacija (eng. *Cross-Validation*) kako je prikazano Slikom 4.17. Testni skup podataka se i dalje zadržava za konačnu evaluaciju, ali skup za provjeru valjanosti više nije potreban u procesu unakrsne validacije. U temeljnom pristupu poznatom kao unakrsna validacija k-podskupovima (eng. *k-fold CV*), skup podataka za učenje je podijeljen na nekoliko manjih podskupova, odnosno *k* podskupova, nakon čega se postupak učenja primjenjuje na svaki od tih podskupova zasebno:

- Model se trenira korištenjem podataka iz *k-1* podskupa;
- Model se provjerava na preostalom dijelu podataka (tj. koristi se kao testni skup za izračunavanje mjere uspješnosti izvedbe kao što je točnost).

Mjera uspješnosti izvedbe koja se dobija putem unakrsne provjere k-podskupovima je prosjek vrijednosti izračunatih u petlji [134].

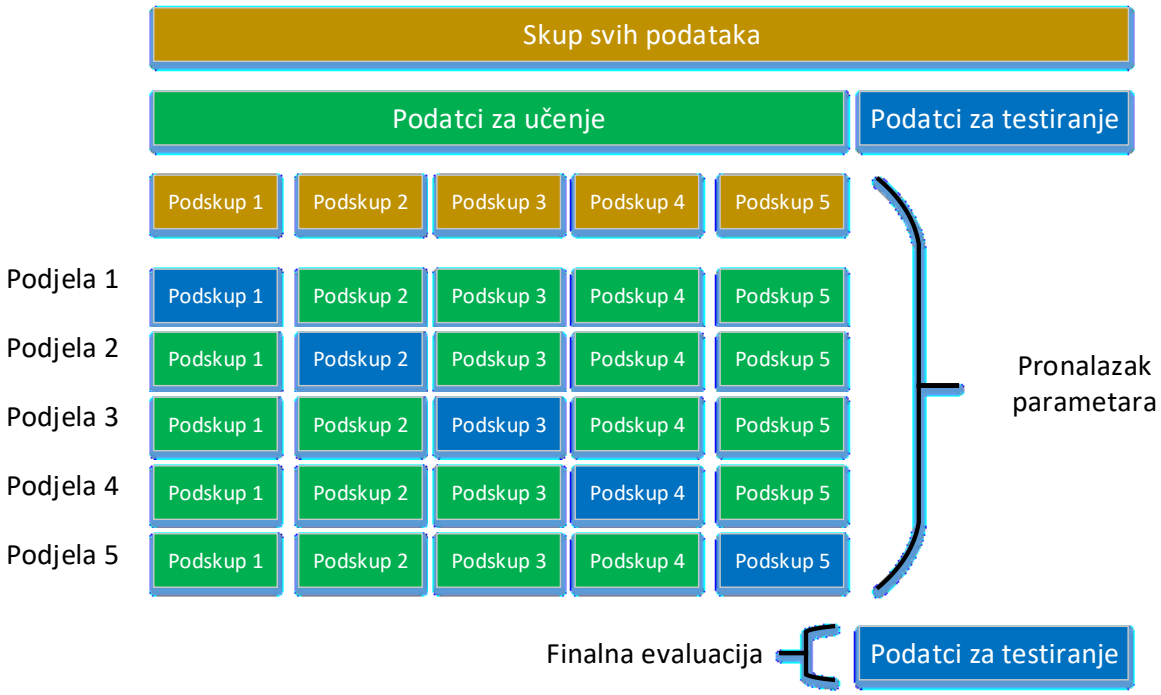

Slika 4.17 Određivanje najboljih hiperparametara klasifikatora unakrsnom validacijom [134]

Kako bi bila osigurana pouzdanost i generalizacija predloženog modela, primijenjena je unakrsna provjera k-podskupovima, koja je često korištena u području strojnog učenja [133], [135], [136]. Odabirom *StratifiedKFold* kao što je prikazano na Slici 4.18 postiže se jednakomjerna distribucija klasa tijekom iteracija u procesu traženja najboljih hiperparametara za klasifikator. Ova metoda osigurava da model bude pouzdan i dobro generaliziran za različite skupove podataka, a posebno je korisna za nebalansirane skupove podataka, jer osigurava da svaki podskup zadržava približno isti razmjer klasa kao i cijeli skup podataka. Time se osigurava da učenje i evaluacija modela budu pouzdaniji jer svaki preklop sadrži reprezentativnu distribuciju klasa, smanjujući rizik od pristranosti zbog nebalansiranih podataka.

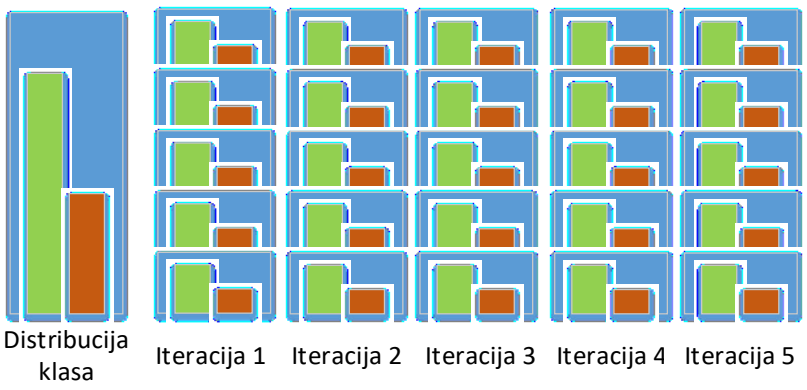

Slika 4.18 Određivanje najboljih hiperparametara klasifikatora unakrsnom validacijom uz jednaku distribuciju klasa (*StratifiedKFold*) [137]

4.1.4.2. Rezultati odabira hiperparametara klasifikatora

U većini projekata strojnog učenja, provodi se učenje različitih modela na odabranom skupu podataka i bira se onaj koji pokazuje najbolje performanse. Međutim, nije uvijek moguće sa sigurnošću utvrditi optimalne hiperparametre modela za rješavanje određenog problema. Stoga je cilj unaprijediti model na svaki mogući način. Hiperparametri modela mogu imati važnu ulogu u performansama modela, a postavljanjem optimalnih vrijednosti za hiperparametre može se značajno poboljšati točnost modela. Scikit-learn paket sadrži funkciju *GridSearchCV* koja omogućuje pronalaženje optimalnih vrijednosti hiperparametara modela radi poboljšanja njegovih performansi. Treba imati na umu da ne postoji način da se unaprijed znaju najbolje vrijednosti za hiperparametre, idealno bi bilo isprobati sve moguće vrijednosti kako bi se pronašle optimalne vrijednosti. Kada ručno podešavanje i ispitivanje hiperparametara zahtijeva značajnu količinu vremena i resursa, moguće je koristiti funkciju *GridSearchCV* za automatizaciju tog procesa koja se koristi za pretraživanje unaprijed definiranih vrijednosti hiperparametara kako bi se pronašle optimalne vrijednosti koje poboljšavaju performanse modela. *GridSearchCV* je funkcija koja omogućuje definiranje rječnika hiperparametara i njihovih vrijednosti koje se mogu koristiti za određeni model. Funkcija provjerava sve kombinacije ponuđenih vrijednosti, procjenjuje model za svaku kombinaciju koristeći metodu unakrsne provjere (eng. *Cross-Validation*), te na kraju daje točnost za svaku kombinaciju hiperparametara. Nakon toga, odabire se kombinacija hiperparametara s najboljim performansama za promatrani model. Algoritam odabira najboljih

hiperparametara je tzv. "*brute force*" metoda koja je vremenski vrlo zahtjevna budući da se ispituju sve kombinacije zadanih mogućih hiperparametara [138].

Ukratko su opisani važniji parametari *GridSearchCV* funkcije[139]:

- *estimator*: proslijeđuje instancu modela za koju se provjeravaju hiperparametri;
- *params_grid*: rječnik koji sadrži hiperparametre i njhove vrijednosti koji se isprobavaju;
- *scoring*: korištena metrika evaluacije;
- *cv*: broj unakrsnih provjera za svaki odabrani skup hiperparametara;
- *verbose*: detaljan ispis trenutnog rada;
- *n_jobs*: broj paralelnih procesa za ovaj zadatak (vrijednost -1 koristi sve dostupne procesore).

Za odabrani algoritam klasifikacije Slučajna šuma i referentni skup podataka LUFlow2021 istraženi su različiti hiperparametri kako bi se pronašle optimalne postavke koje osiguravaju najbolje rezultate točnosti. U nastavku su navedeni svi dostupni hiperparametri, pri čemu su crvenom bojom označeni parametri koji su testirani i evaluirani. Za sve ostale hiperparametre koji nisu bili ispitivani, korištene su predefinirane vrijednosti hiperparametara koje su optimizirane za postizanje najboljih rezultata. Hiperparametri koji nisu imali utjecaj na izračune točnosti, poput "*n_jobs*" ili "*verbose*", služili su samo kao pomoćne funkcije, gdje se "*n_jobs*" koristi za korištenje svih dostupnih procesora, a "*verbose*" služi za definiranje razine detalja prilikom ispisivanja stanja izračuna. Neki od predloženih vrijednosti hiperparametara su određeni nakon više iteracija kako bi se raspon vrijednosti mogao detaljnije odabrati. Prilikom optimiziranja hiperparametara korištena je funkcija:

GridSearchCV(estimator, params_grid, scoring='roc_auc', verbose=10, n_jobs=-1, cv=3)

Hiperparametri za algoritam Slučajne šume

- *n_estimators*: int, default=100;
- *criterion*: {“gini”, “entropy”, “log_loss”}, default=”gini”;
- *max_depth*: int, default=None;
- *min_samples*_split: int or float, default=2;
- *min_samples*_leaf: int or float, default=1;

- *max_features*: {“sqrt”, “log2”, None}, int or float, default=”sqrt”;
- *max_leaf_nodes*: int, default=None;
- *min_impurity_decrease*: float, default=0.0;
- *oob_score*: bool, default=False;
- *n_jobs*: int, default=None;
- *random_state*: int, RandomState instance or None, default=None;
- *verbose*: int, default=0;
- *warm_start*: bool, default=False;
- *class_weight*: {“balanced”, “balanced_subsample”}, default=None;
- *ccp_alpha*: non-negative float, default=0.0;
- *max_samples*: int or float, default=None;

Najbolji rezultat AUC točnosti od 0.9999 postiže se prilikom odabira ovih hiperparametara:

- *n_estimators*: **1130** (ispitan raspon vrijednosti 10 – 2000, korak 10);
- *criterion*: **'entropy';**
- *max_depth:* **None** (ispitan raspon 1,10,100, None vrijednost ide do maksimalne moguće vrijednosti);
- *min_samples*_split: **50** (ispitan raspon vrijednosti 2, 3, 4, 5, 10, 20, 50,100);
- *max_features*: 'sqrt';
- *class_weight*: 'balanced';

Prema Slici 4.19, koja prikazuje rezultate unakrsne validacije, crveni graf prikazuje AUC vrijednosti, a plavi vrijeme potrebno za izračune. Uočena su četiri najbolja AUC rezultata za hiperparametar n_estimators. U Tablici 4-13 prikazana su četiri najbolja rezultata za hiperparametar *n_estimators* koja pokazuje da je razlika AUC vrijednosti vrlo mala, gotovo zanemariva, dok su vrijednosti vremena utrošenog za izračunavanja veća pri korištenju većeg *n_estimators* parametra. Razmatrajući ove rezultate može se uzeti treći najbolji rezultat za AUC vrijednosti odnosno vrijednost 300 za *n_estimators* hiperparametar kako bi izračuni bili što kraći, a da točnost ostane dovoljno visoko prilikom klasifikacije.

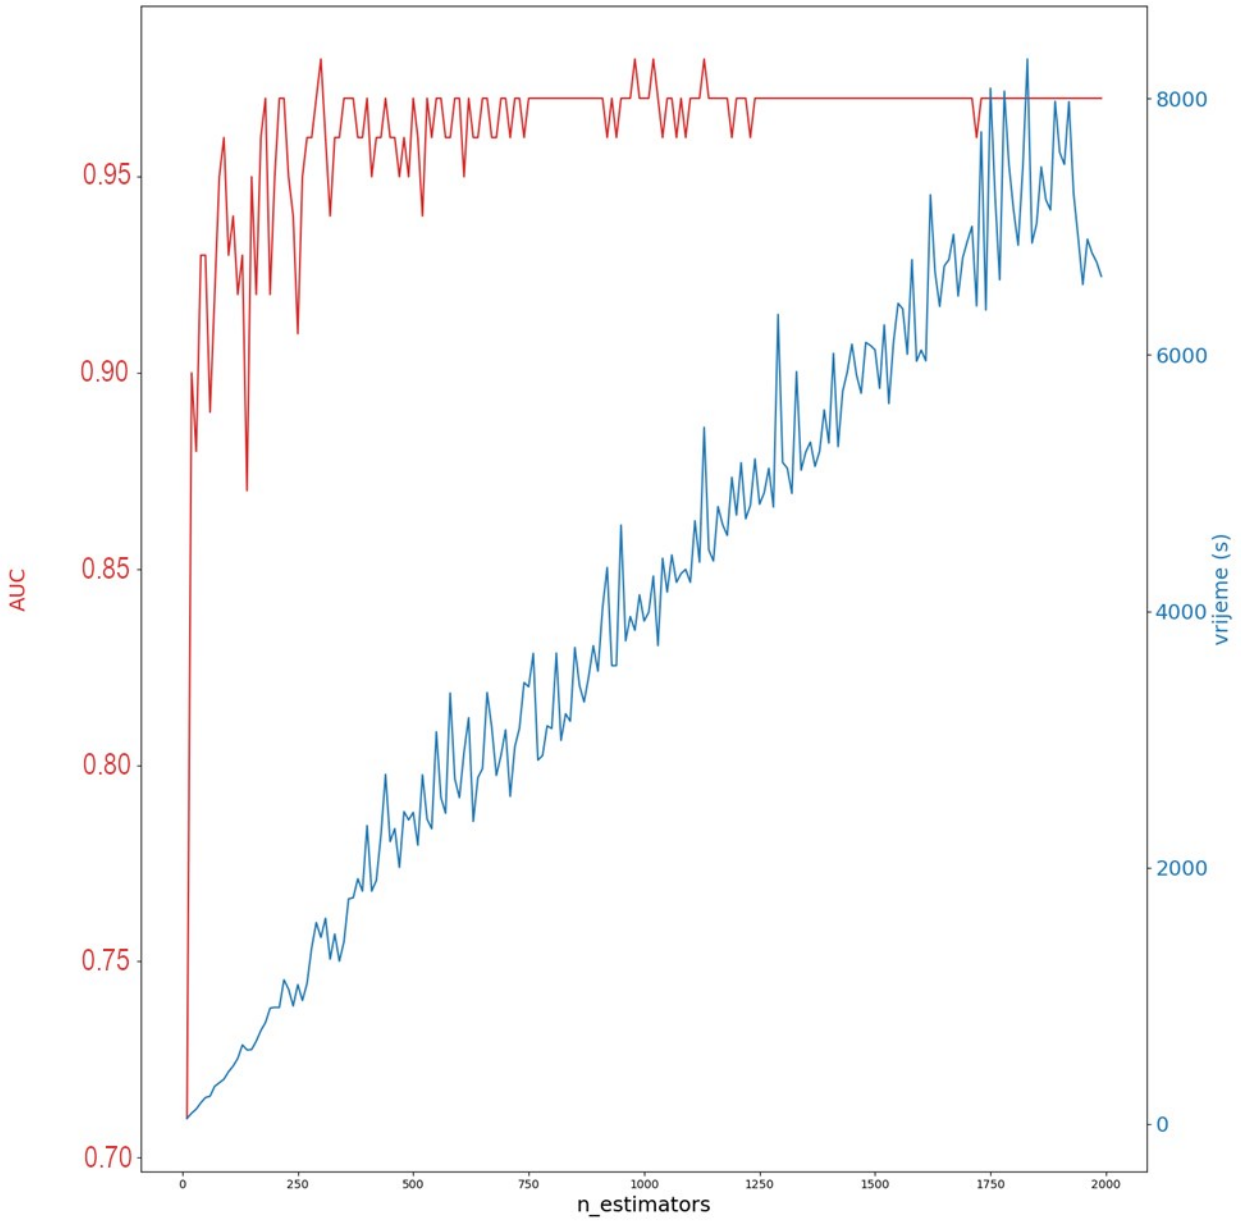

Slika 4.19 Rezultati AUC vrijednosti i vremena izračuna tijekom optimiziranja *n_estimators* hiperparametara algoritma Slučajne šume

Odabirom vrijednosti 300 za *n_estimators* hiperparametar, vrijeme izračuna se skraćuje 3 puta dok točnost ostaje gotovo nepromijenjena. Ostali ispitivani hiperparametri nisu imali veliki utjecaj na vrijeme izračunavanja te za njih nije rađena dodatna analiza već su se uzeli predloženi hiperparametri.

Tablica 4-13 Najbolji rezultati optimizacije hperparametara *n_estimators* algoritma Slučajne šume

AUC	Vrijeme izračuna (s)	pozicija	n_estimators
0.999997573	5434.62	1	1130
0.999997563	4274.18	2	1020
0.999997555	1455.28	3	300
0.999997522	3851.17	4	980

Svi rezultati unakrsne validacije u ovisnosti o *n_estimators* hiperparametru prikazani su u grafu na Slici 4.19. Primijećeno smanjenje vremena za ispitivanje vrijednosti hiperparametra "*n_estimators*" koje se događa kada se približimo gornjoj granici (*n_estimators=2000*) uzrokovan je smanjenim opterećenjem na poslužitelju koji obavlja izračunavanja. Zbog korištenja mogućnosti raspodjele izračunavanja na sve raspoložive procesore (32), kada se približi kraj ispitivanja, dolazi do rasterećenja poslužitelja, što omogućuje daljnju raspodjelu preostalih izračuna na oslobođene procesore. Ova silazna krivulja pri kraju raspona promatranih hiperparametara javljala se svaki put na kraju ekperimentalnog postupka optimiziranja hiperparametara. Ukoliko se zanemari ovaj nagli pad krivulje kod vremena izračunavanja, opravdano je uzeti vrijednost 300 za *n_estimators* hiperparametar.

Tablica 4-14 Usporedba točnosti klasifikacije s predefiniranim i optimiziranim vrijednostima hiperparametara klasifikatora Slučajne šume

ML alg	Predefinirane vrijednosti hiperparametara	Optimizirane vrijednosti hiperparametara
Acc	0.999897447	0.999893911
Precision	0.999798412	0.999683852
Recall	0.999857694	0.999960471
TN	595317	595288
FP	51	80
FN	36	**10**
TP	252940	252966
F2	0.999845837	0.999905135
BAcc	0.999886016	0.99991305
AUC	0.999886016	**0.99991305**
Cohen	**0.999754987**	0.999746554
Matthews	**0.999754988**	0.999746574

Ako se provede klasifikacija koristeći klasifikator Slučajne šume s optimiziranim hiperparametrima dobivenih putem postupka unakrsne validacije i usporedi s predefiniranim hiperparametrima, možemo zaključiti da se postiže veća točnost klasifikacije s korištenjem hiperparametara određenih unakrsnom validacijom kako pokazuje Tablica 4-14.

Bitan parametar za koji se uočava napredak je broj lažno negativnih rezultata (FN=10) koji se smanjio za 72.2%, a koji predstavlja anomalije odnosno neželjeni tok podataka koji se ne detektira. Prisutno je i povećanje lažno pozitivnih rezultata (56.9%), odnosno tokova prometa koji će nepotrebno alarmirati sustav jer je zapis toka prometa normalan. Mjera opoziva (*recall*) definirana i objašnjena u poglavlju 3.5.5 potvrđuje ovaj ishod smanjenja broja lažno negativnih klasifikacija. Također i ostale mjere, prvenstveno F2 i AUC pokazuju bolje rezultate korištenjem optimiziranih hiperparametara. Cohen kappa koeficijent ima zanemarivo manju vrijednost koristeći optimizirane hiperparametre isto kao i Matthewsov koeficijent, ali su vrlo visoko i blizu idealne vrijednosti 1 koja opisuje kvalitetu klasifikacije. Uravnotežena točnost i AUC mjera imaju identične vrijednosti jer se radi o binarnoj klasifikaciji te su načini njihovih izračuna u tom slučaju identični kao što je objašnjeno u poglavlju 3.5.3.

4.1.5. Prilagodba odabranog referentnog skupa podataka NetFlow strukturi

Metoda prikupljanja NetFlow mrežnog toka se razlikuje od izravnog snimanja paketa, poput tcpdump-a, po tome što stvara sažetak komunikacije između izvora i odredišta u mreži. Sažetak mrežnog toka koji se stvara pomoću NetFlow-a obuhvaća sav promet koji se odnosi na sedam specifičnih ključnih elemenata koji su važni za adresiranje. Ti elementi su: izvorna i odredišna IP adresa, izvorni i odredišni portovi, tip protokola, vrsta usluge i sučelje na mrežnom uređaju. Ovi atributi (ponekad se nazivaju 7-morka), zajedno s vremenom početka svakog mrežnog toka, razlikuju mrežne tokove jedne od drugih. Mrežni tok često pokriva više paketa, koji su grupirani zajedno pod zajedničkom oznakom toka. NetFlow zapis sadrži oznaku i statistiku o paketima koji se nalaze unutar mrežnog toka. Ova statistika uključuje broj paketa, broj bajtova, vrijeme trajanja i vrijeme stvaranja paketa. Budući da je mrežni tok samo sažetak prometa, ne sadrži podatke o sadržaju paketa koji su preneseni unutar mreže [140]. Analizom podataka o protoku, koji se prikuplja, pruža se vidljivost toka i volumena prometa, kao i trag odakle promet dolazi, kamo ide

i koliko prometa se generira u bilo kojem trenutku. Prikupljene informacije mogu se koristiti za praćenje korištenja mreže, otkrivanje anomalija i raznih drugih zadataka upravljanja mrežom. Prvi NetFlow format bio je podržan u svim početnim NetFlow uređajima. Verzije 2, 3 i 4 bile su dostupne samo kao interna izdanja dok je NetFlow verzije 5 najpopularnija verzija i još uvijek je podržavaju mnogi proizvođači mrežnih uređaja. NetFlow v5 ima fiksni format paketa, što olakšava praćenje i izvještavanje o mrežnom prometu budući da je sadržaj svakog paketa brzo prepoznatljiv. Verzija 5 donijela je višestruka poboljšanja kao što su informacije o BGP (eng. *Border Gateway Protocol*), AS (eng. *Autonomous System*) i brojevima sekvenci toka. Iako su verzije 7 i 8 imale nekoliko dodatnih poboljšanja, više se ne koriste. Aktualna verzija je NetFlow verzije 9. Glavna razlika između NetFlow verzije 9 i prethodnih verzija je što verzija 9 koristi obrasce, što znači da omogućava fleksibilnije prikupljanje podataka. Drugim riječima, omogućava izvoz prilagođenih podataka, izvan osnovnih polja koja su bila uključena u prethodne verzije. NetFlow verzije 9 također podržava IPv6, MPLS i druge napredne mrežne tehnologije, što je čini prikladnijom za modernu mrežu. Dodatno, može izvoziti podatke o tokovima u različitim formatima, uključujući binarni i XML format. NetFlow verzija 9 pruža snažan alat za mrežne administratore i sigurnosne stručnjake za dobivanje uvida u obrasce mrežnog prometa i identifikaciju potencijalnih sigurnosnih prijetnji ili problema s performansama. Svaki paket koji se prosljeđuje unutar preklopnika ili usmjerivača uključuje sljedeće informacije [141]:

- Izvorište IP paketa;
- Odredište IP paketa;
- Izvorni port;
- Odredišni port;
- Klasa usluge;
- Tip protokola;
- Sučelje.

Implementacija prikupljanja NetFlow zapisa mrežnog prometa kao što je prikazano Slikom 4.20 zahtijeva tri glavne komponente [142]:

- Izvoz toka prometa: mrežni uređaj poput preklopnika ili usmjerivača;
- Sakupljanje toka prometa: poslužitelj koji je odgovoran za primanje, pohranjivanje i pripremu podataka za analizu;

- Aplikacija za analizu: analizira podatke o protoku i omogućuje prikaz toka.

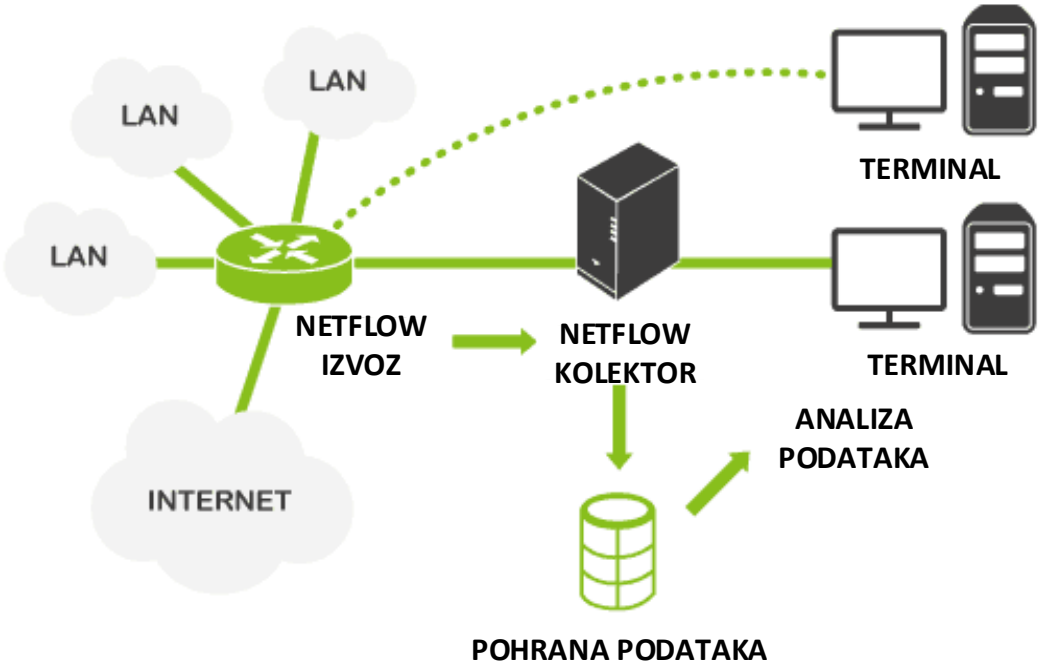

Slika 4.20 Osnovne komponente za prikupljanje i analizu NetFlow zapisa mrežnog prometa [143]

Mrežna propusnost potrebna za izvoz NetFlow podataka obično je manja od 0,5% ukupne potrošnje propusnosti sučelja [144].

Odabrani referentni skup podataka LUFlow2021 sadrži telemetrijske podatke izrađene pomoću Cisco Joy alata koji bilježi višestruka mjerenja povezana s tokovima mrežnog prometa. Iz tih mjerenja konstruirane su značajke ovog skupa podataka, a opisane su u Tablici 4-15 prema dokumentaciji [100].

Kako se LUFlow2021 skup podataka sastoji od više značajki od kojih su neke dobivene računski, potrebno je ujednačiti broj i tip značajki sa stvarnim izvozom NetFlow podataka iz mrežnog uređaja. Tijekom predobrade podataka obrisane su 4 značajke: *dest_ip, src_ip, time_end, time_start* koje su irelevantne za detekciju anomalija, za ostatak značajki napravljena je procjena važnosti pomoću algoritama strojnog učenja te su rezultati opisani u sljedećim potpoglavljima.

Tablica 4-15 Opis značajki LUFlow2021 skupa podataka

Značajka	**Opis**
src_ip	Izvorišna IP adresa povezana s tokom. Ova značajka je anonimizirana za odgovarajući autonomni sustav
src_port	Broj izvorišnog porta povezan s tokom
dest_ip	Odredišna IP adresa povezana s tokom. Značajka je također anonimizirana na isti način kao *src_ip*
dest_port	Broj odredišnog porta povezan s tokom
protocol	Broj protokola povezan s tokom
bytes_in	Broj bajtova prenesenih od izvora do odredišta
bytes_out	Broj bajtova prenesenih od odredišta do izvora
Num pkts in	Broj poslanih paketa od izvora do odredišta
Num pkts out	Broj poslanih paketa od odredišta do izvora
entropy	Entropija u bitovima po bajtu podatkovnih polja unutar toka. Ovaj broj je u rasponu od 0 do 8
total_entropy	Ukupna entropija u bajtovima nad svim bajtovima u podatkovnim poljima toka
mean_ipt	Srednja vrijednost vremena dolaska paketa u toku
time_start	Vrijeme početka toka
time_end	Vrijeme završetka toka
duration	Vrijeme trajanja toka, s preciznošću od mikrosekunde
label	Oznaka toka

Struktura NetFlow skupa podataka iz mrežnog uređaja dobivena je prema preporukama proizvođača mrežne opreme [145]. Mrežni uređaj za izvoz NetFlow-a konfiguriran je na način da se kreiraju obrasci za ulazni i izlazni tok „*flow record RECORD_IN*“ i „*flow record RECORD_OUT*“, izvoz ovako prikupljenih podataka definira se preko „*flow exporter EXPORTER*“ unosa. Cijeli proces prikupljanja NetFlow zapisa tada se definira na željenom fizičkom ili logičkom sučelju kao „flow monitor MONITOR_IN“ za ulazne podatke i „*flow monitor MONITOR_OUT*“ za izlazne podatke. Primjer cjelokupne konfiguracije potrebne za izvoz NetFlow podatak iz mrežnog uređaja nalazi se u prilogu A i prilogu B ovog istraživanja.

Usporedbom referentnog skupa podataka LUFlow2021 i NetFlow skupa podataka dobivenog iz mrežnog uređaja uočene su razlike u značajkama koje se trebaju ujednačiti kako bi proces klasifikacije stvarnog mrežnog prometa bio izvediv i usporediv s rezultatima dobivenih korištenjem referentnog skupa podataka. Ove razlike u značajkama prikazane su u Tablici 4-16.

Tablica 4-16 Razlike u značajkama LUFlow2021 referentnog skupa podataka i stvarnog NetFlow skupa podataka

LUFlow2021	**NetFlow**
src_ip	*sa*
src_port	*sp*
dest_ip	*da*
dest_port	*dp*
protocol	*pr*
bytes_in	*ibyt*
bytes_out	*obyt*
Num pkts in	*ipkt*
Num pkts out	*opkt*
entropy	
total_entropy	
mean_ipt	
time_start	*ts*
time_end	*te*
duration	*td*
label	

Prema usporedbi značajki iz Tablice 4-16, primijećeno je da NetFlow skup podataka dobiven iz mrežnog uređaja ne sadrži značajke kao što su *entropy, total_entropy* i *mean_ipt* stoga je u procesu klasifikacije potrebno izostaviti ove značajke iz skupa ulaznih podataka ili skup podataka iz mrežnog uređaja treba proširiti ovim značajkama. Utjecaj i izostanak ovih značajki u procesu klasifikacije istražen je i opisan u narednom poglavlju.

4.1.5.1. Smanjivanje broja značajki i prilagodba NetFlow strukturi

Izbor značajki je jedan od bitnih aspekata u modelima strojnog učenja jer se želi izbjeći uključivanje nepotrebnih značajki u izračune, a koje ne doprinose boljim rezultatima predviđanja predloženog modela. Pristup smanjivanju broja značajki koristi se za poboljšanje kvalitete skupa značajki u raznim zadacima strojnog učenja kao što su klasifikacija, grupiranje, regresija i drugi oblici predviđanja. Dodatne značajke mogu poboljšati prediktivne sposobnosti modela, ali samo do određene granice. Pojam "prokletstva dimenzionalnosti" često se koristi kako bi se naglasilo da će performanse modela opadati s povećanjem broja značajki. Stoga je bitno pažljivo odabrati relevantne značajke kako bi se postigla optimalna prediktivna točnost modela. Zato treba odabrati

samo one značajke koje su učinkovite i omogućuju kvalitetno predviđanje. Odabir značajki sličan je tehnici redukcije dimenzionalnosti, gdje je također cilj smanjiti broj značajki, ali u osnovi se razlikuju u tome što se metodom odabira značajki određuje koje treba zadržati ili ukloniti iz skupa podataka, dok smanjenje dimenzionalnosti stvara novu projekciju podataka što rezultira potpuno novim značajkama. Odabirom značajki može se smanjiti složenost podataka i izračunavanja te se također mogu dobiti i učinkovitiji podskupovi značajki. Prikupljeni neobrađeni podatci obično su veliki, pa je poželjno odabrati podskup podataka stvaranjem vektora značajki koji predstavljaju većinu informacija iz podataka [146], [147], [148]. Postoji mnogo metoda odabira značajki, ali korištene su i uspoređene metode odabira značajki prisutnih u scikit-learn programskom paketu.

Jednovarijatni odabir značajki sa SelectKBest metodom

SelectKBest metoda radi na način da ocjenjuje svaku značajku pojedinačno koristeći neki statistički test, poput chi-kvadrat ili ANOVA testa za kategorijske ili numeričke značajke. Nakon ocjenjivanja, značajke se rangiraju prema njihovoj važnosti ili informacijskoj vrijednosti. Najčešće se specificira željeni broj značajki (K), pa se odabir vrši na temelju tih najboljih K značajki. Odabir se vrši na temelju ocjene koja je izračunata za svaku značajku prema odabranom statističkom testu. Budući da je jednovarijantna metoda odabira značajki namijenjena algoritmima nadziranog strojnog učenja, dijelimo ih na nezavisne i zavisne [146]. Analizom različitih statističkih metoda za odabir značajki može se zaključiti da smanjeni skup značajki može poboljšati kvalitetu klasifikacije eliminiranjem manje relevantnih značajki. Ispitivanjem različitih metoda za odabir značajki, u nekim istraživanjima, pokazalo se da je statistička metoda "SelectKBest" s funkcijom "chi2" najučinkovitija. Upotrebom ove metode moguće je dobiti smanjeni skup značajki s točnošću klasifikacije od 90%, u usporedbi s punim skupom značajki koji daje točnost od 74% [149].

Rekurzivno uklanjanje značajki

Rekurzivno uklanjanje značajki je metoda odabira koja koristi model strojnog učenja uz eliminaciju najmanje važne značajke nakon rekurzivnog razmatranja sve manjeg i manjeg skupa

značajki. Prvo se važnost svake značajke određuje na početnom skupu, a dobiva se kroz atribute *coef_* ili *feature_importances_* atribute. Zatim se iz trenutnog skupa značajki odvajaju najmanje važne značajke. Taj se postupak rekurzivno ponavlja na reduciranom skupu sve dok se na kraju ne postigne željeni broj značajki. Ovom se metodom odabire *k* broj najboljih značajki. Prema zadanim postavkama u scikit-learn platformi, broj značajki odabranih ovom metodom je medijan ukupnih značajki, a korak (broj značajki koje se eliminiraju za svaku iteraciju) je jedan. Ove postavke podložne su promjeni ovisno o korištenom skupa podataka [146]. U istraživanju [107] je korištenjem ovog algoritma za smanjivanje broja značajki skup podataka smanjen za 95% prema originalnoj veličini skupa podataka. Predloženi model postao je smisleniji te je s manjim skupom podataka postignuta zadovoljavajuća točnost.

Sekvencijski odabir značajki

Sekvencijski odabir značajki je postupak koji iterativno odabire najbolje značajke na temelju unakrsne validacije. Tijekom svake iteracije, odabire se jedna značajka koja najbolje poboljšava performanse modela kada se koristi samo ta jedna značajka za učenje modela. Nakon što je prva značajka odabrana, postupak se ponavlja dodavanjem nove značajke, a zaustavlja se kada se utvrdi da je postignut željeni broj značajki. Sekvencijski odabir značajki može se izvoditi i u obrnutom smjeru, počevši s kompletnim setom značajki i postupno ih eliminirajući dok ne dostignemo željeni broj značajki. Tijekom svake iteracije, uklanjaju se značajke koje najmanje utječu na performanse modela, sve dok se ne postigne željena razina performansi s manjim brojem značajki. Ova metoda se razlikuje od metode rekurzivnog uklanjanja značajki i jednovarijatnog odabira značajki jer ne zahtijeva *coef_* ili *feature_importances_* atribute. Znatno je sporija jer ocjenjuje rezultat višestrukom provjerom modela [146]. U radu [150], uspoređene su performanse modela na skupu podataka s i bez sekvencijskog odabira značajki. Rezultati pokazuju da sekvencijski odabir smanjuje broj značajki za 80% te značajno poboljšava točnost klasifikacije, dok se istovremeno smanjuje vrijeme izračuna značajki iz ekstrahiranog toka podataka. Također, vrijeme potrebno za učenje modela strojnog učenja se smanjuje što je vrlo važno za proces učenja posebno kada se radi s velikim skupovima podataka. Ovaj primjer ukazuju na važnost odabira značajki u postizanju optimalnih performansi modela strojnog učenja.

4.1.5.2. Usporedba i primjena algoritama smanjivanja broja značajki

Rezultati usporedbe algoritama za odabir značajki prikazani su u Tablici 4-17 za ukupno 11 značajki: *avg_ipt, bytes_in, bytes_out, dest_port, entropy, num_pkts_out, num_pkts_in, proto, src_port, total_entropy* i *duration*, koje su korištene u referentnom skupu podataka LUFlow2021. Cilj redukcije značajki je procijeniti važnost i utjecaj osam značajki koje su dio NetFlow skupa podataka dobivenih iz mrežnih uređaja. Te značajke su: *src_port (sp), dest_port (dp), protocol (pr), bytes_in (ibyt), bytes_out (obyt), Num pkts in (ipkt), Num pkts out (opkt) i duration (td)*.

Tablica 4-17 prikazuje rezultate odabira značajki korištenjem različitih metoda: *SelectKBest, rekurzivnog* i *sekvencijskog* odabira značajki. U posljednjem stupcu (Σ), prikazano je koliko puta je svaka značajka odabrana kao jedna od osam najrelevantnijih značajki. Na temelju broja pojavljivanja (stupac Σ) za svaku metodu odabira značajki, identificirano je 8 najrelevantnijih značajki. U ovom odabiru, uz značajke "*entropy*" i "*avg_ipt*", također je isključena značajka "*num_pkts_out*" koja ima manji značaj prema Tablici 4-17.

Tablica 4-17 Usporedba metoda odabira značajki

Značajka	**SelectKBest funkcija odabira**			**RecursiveFE funkcija odabira**			**Sequential FS funkcija odabira**	**Σ**
	chi2	**f_classif**	**mi_classif**	**GB**	**DT**	**RF**	**K-NN**	
avg_ipt	x					x	x	3
bytes_in	x	x	x			x	x	5
bytes_out	x	x	x	x		x	x	6
dest_port	x	x	x	x	x	x	x	7
entropy			x	x	x			3
num_pkts_out	x	x			x			3
num_pkts_in	x	x		x	x	x	x	6
proto		x	x	x	x			4
src_port	x	x	x	x	x	x	x	7
total_entropy	x	x	x	x	x	x	x	7
duration			x	x	x	x	x	5

Izvršeno je uspoređivanje izvedbe klasifikacije koristeći tri različita skupa značajki u referentnom skupu podataka LUFlow2021: s cijelim skupom značajki (11), s odabranim značajkama (8) dobivenim pomoću algoritama za odabir značajki, te s korištenjem značajki koje

su karakteristične NetFlow protokolu (7) dobivenih iz mrežnih uređaja gdje ne postoje značajke *"avg_ipt2 , "entropy", "total entropy".*

Rezultati i usporedba provedene klasifikacije sa skupovima podataka i smanjenim brojem značajki prikazana je Tablicom 4-18.

Tablica 4-18 Klasifikacija s cijelim i smanjenim brojem značajki

	metoda odabira značajki		
	Cijeli set značajki (11)	**Odabir uz algoritme strojnog učenja (8)**	**Karakteristične NetFlow značajke (7)**
Klasična točnost	0.999892	0.999889	0.999895
Preciznost	0.999676	0.999664	0.999692
Opoziv	0.99996	0.999964	0.999957
TN	595286	595283	595290
FP	82	85	78
FN	10	9	11
TP	252966	252967	252965
F2	0.999904	0.999904	0.999904
Uravnotežena točnost	0.999911	0.999911	0.999913
AUC	0.999911	0.999911	0.999913
Cohen kappa koeficijent	0.999741	0.999735	0.999749
Matthews koeficijent	0.999741	0.999735	0.999749
Trajanje (sat:min:sek)	00:01:04.76	00:00:51.32	00:00:51.29

Usporedbom dobivenih rezultata u Tablici 4-18 s nedavnim istraživanjima [66], [129], [150], [151], [152] gdje se analiziraju stope lažno pozitivnih i lažno negativnih rezultata, može se zaključiti da smanjenje broja značajki ne smanjuje učinkovitost klasifikacije. Istovremeno, ukupno vrijeme klasifikacije se smanjuje, što dodatno poboljšava performanse modela. Prilikom odabira značajki specifičnih za NetFlow protokol, dobiveni rezultati su gotovo identični kao i kada se koriste značajke reducirane algoritmima strojnog učenja. Međutim, prednost je u tome što se izbjegava značajka „*total_entropy"*, koja zahtijeva dodatno računanje i informacije o sadržaju IP paketa koje nisu dostupne u NetFlow podatcima o toku mrežnog prometa. S obzirom na ove rezultate i analizu odabira značajki, opravdano je isključiti značajku *total_entropy* iz daljnjeg korištenja unutar ulaznog skupa podataka za klasifikaciju i detekciju anomalija putem strojnog učenja.

4.2. Prijedlog modela za otkrivanje anomalija mrežnog prometa primjenom strojnog učenja u hibridnoj programski definiranoj mreži

Predloženi model temelji se na klasifikaciji NetFlow mrežnog prometa, koja se postiže strojnim učenjem i referentnim skupovima podataka kako bi se postigla željena klasifikacija, odnosno predikcija za svaki novi NetFlow zapis koji se stvara na mrežnim uređajima. Kako bi se osigurala funkcija klasifikacije stvarnog mrežnog prometa u stvarnom vremenu, bitno je smanjiti vrijeme klasifikacije i odziva u slučaju pojave anomalija u mrežnom prometu. Korištenje NetFlow alata za analizu mrežnog prometa jedna je od metoda za detekciju takvih anomalija. Korištenjem NetFow nfcpad kolektora (Nfdump NSEL-NEL1.6.18), datoteke NetFlow zapisa se kreiraju i rotiraju svakih 60 sekundi, što omogućuje detekciju anomalija u mrežnom prometu unutar 60 sekundi. Međutim, novije inačice nfcpad kolektora omogućuju rotaciju datoteka unutar 2 sekunde, što značajno smanjuje vrijeme odziva na detekciju anomalija u Netflow prometu. Stoga, nadogradnja predloženog modela i korištenje novije inačice nfcpad kolektora može osigurati još bržu i učinkovitiju detekciju i reakciju na pojave anomalija mrežnog prometa u stvarnom vremenu. U literaturi [153], [154], [155], [156] se opisuje računalstvo u stvarnom vremenu kao sustavi koji su sposobni odgovoriti unutar određenog vremenskog okvira. i u stanju su reagirati na vremenski ograničene zadatke, posebno na one koji se ne javljaju u redovitim intervalima i imaju definirane rokove za odgovor. Oni se razlikuju od sustava koji se bave zadacima koji se izvršavaju skupno ili u vremenski neodređenim intervalima, jer sustavi u stvarnom vremenu pružaju usluge i kontrolu za neovisne procese, s mogućnošću prekida i hijerarhijskim sustavom prioriteta. Prema predloženom, model koji je opisan u ovom poglavlju može se smatrati sustavom blizu stvarnom vremenu jer postiže vremenski interval koji je mnogostruko brži od manualne intervencije prilikom detektiranja anomalija. Stoga, model pruža usluge i kontrolu neovisnim procesima, ima mogućnost prekida i shemu upravljanja prioritetima, što su ključne značajke sustava u stvarnom vremenu.

Model za otkrivanje anomalija i klasifikaciju prometa trebao bi biti sposoban nadzirati nekoliko različitih funkcija, kao što su one koje su odgovorne za praćenje prometa, klasifikaciju i ublažavanje posljedica kibernetičkog napada uzevši u obzir sljedeće aspekte [151]:

- sveobuhvatan uvid u mrežu i sposobnost prikupljanja detaljnih i neograničenih informacija o mreži i tokovima prometa, a koristi NetFlow tehnologiju za dobivanje informacija o tokovima iz različitih izvora;
- po potrebi omogućiti ljudsku intervenciju za dodatan nadzor i upravljanje sustavom, gdje mrežni administrator prati rad modela, klasifikaciju prometa te ima mogućnost analize zapisa, uz prilagodbu sustava koja je bitna za rekonfiguraciju detekcije prema dinamičnim promjenama u mrežnom okruženju;
- omogućiti automatsku konfiguraciju mrežnih resursa, gdje rekonfiguracija mrežnih uređaja pruža sredstva za rješavanje nepravilnosti, uz mogućnost prilagodbe prema specifičnim zahtjevima situacije;
- modularnost i podrška prilagodbama koja omogućuje ažuriranje s novim algoritmima strojnog učenja ili strategijama obrane od kibernetičkih napada.

4.2.1. Klasifikacija kombiniranog skupa podataka

Iz perspektive mrežnog IDS-a, kibernetički napad se manifestira kao kompleksan niz vremenski poredanih mrežnih paketa s određenim sadržajem. Najčešće se proces testiranja svodi na generiranje mrežnog prometa koji simulira aktivnosti kibernetičkih napada zajedno s pozadinskim mrežnim prometom. Reprodukcija prethodno zabilježenog mrežnog prometa računalnih napada na posebnom testnom okruženju na kojem je instaliran IDS omogućuje višestruko ponavljanje eksperimentalnih uvjeta tako da će promet računalnih napada biti identično reproduciran svaki put. Ovo je posebno važno kada je potrebno provesti usporedno testiranje sistema za detekciju upada. S druge strane, zahtjev za objektivnim rezultatima testiranja pretpostavlja da podatci mrežnog prometa moraju sadržavati statističku varijabilnost unutar određenih uvjeta funkcioniranja testiranja. Tu varijabilnost moguće je postići primjenom metoda sinteze mrežnog prometa ili putem metoda unosa anomalija u pripremljeni skup podataka mrežnog prometa [157].

Većina pristupa klasifikaciji mrežnog prometa može se prema [158] podijeliti u jednu od kategorija prema načinu korištenja pozadinskog prometa:

- klasifikacija s primjenom stvarnog pozadinskog prometa;

- klasifikacija s primjenom stvarnog i pročišćenog pozadinskog prometa;
- klasifikacija s primjenom simuliranog prometa.

Predloženi model u fazi učenja za potrebe klasifikacije koristi stvarni pozadinski promet uz primjenu simuliranog i generiranog mrežnog prometa. Prikupljanje stvarnog mrežnog prometa odvija se uz pomoć NetFlow kolektora odnosno kolekcije NFDUMP aplikacija koje podržavaju rad s NetFlow zapisima podataka verzije v5, v7 i v9. NFDUMP kolekcija aplikacija sadrži [159]:

nfcapd - prikuplja NetFlow zapise podataka i pohranjuje podatake u binarne datoteke. Datoteke se stvaraju i rotiraju u određenom vremenskom razdoblju (u korištenoj verziji od minimalno 60 sekundi). Aplikacija omogućuje jedinstveni nfcapd proces za više izvora NetFlow zapisa;

nfdump - omogućuje čitanje NetFlow zapisa tokova podataka iz datoteka koje je pohranila komponenta nfcapd. Osim podataka o NetFlow zapisu prikazuje i razne statističke podatke o tokovima mrežnog prometa;

nfprofile - filtrira podatke prema proizvoljnim skupovima filtera (profilima) i pohranjuje ih u datoteke za kasniju upotrebu;

nfreplay - omogućuje ponavljanje NetFlow podataka iz datoteka koje su pohranjene uz pomoć nfcapd komponente;

nfclean.pl - omogućuje čišćenje starih NetFlow podataka

U ovom istraživanju, najznačajnija aplikacija za predloženi NFMIDS model je **nfcapd**, s kojom se prikupljaju i spremaju NetFlow zapisi mrežnog prometa s mrežnih uređaja u datoteke. Podatci se zatim čitaju pomoću komponente **nfdump** i pretvaraju u CSV (eng. *coma separated values*) format datoteke kako bi bili prilagođeni za upotrebu u procesu strojnog učenja. Za pokretanje **nfcpad** servisa koristila se sintaksa:

nfcapd -p 2055 -l <file path> -I any -t 28800

gdje argument *–p 2055* označava port na kojem se osluškuju i prikupljaju podatci iz mrežnih uređaja, *-l <file path>* označava putanju datoteke za pohranu, *-I any* označava identitet sučelja odnosno mrežnog uređaja te *–t 28800* označava vrijeme rotacije datoteke od 28800 sekundi odnosno 8 sati.

Nakon prikupljanja NetFlow mrežnog prometa i spremanja u binarne datoteke, bilo je potrebno konvertirati ih u format čitljiv i drugim aplikacijama i programskim jezicima. U ovom slučaju, za konverziju se koristio CSV format datoteke, koji omogućava čitanje podataka u tabličnom obliku. Konverziju je bilo moguće izvršiti unutar **nfdump** aplikacije, gdje se pomoću argumenta *-o csv* označio željeni oblik izlazne datoteke u CSV formatu. Argumentom *–b* sažimaju se tokovi prometa kao bidirekcionalni tokovi.

nfdump -r <filename>-b -o csv > <output_filename>.csv

Ovako pripremljeni ulazni podatci spremni su za daljnju obradu za proces klasifikacije uz pomoć strojnog učenja.

Da bi se provjerila učinkovitost klasifikacije u stvarnom okruženju, kombinirao se referentni skup podataka LUFlow2021, koji ima smanjen broj značajki opisan u poglavlju 4.1.5.1, s prikupljenim stvarnim mrežnim prometom iz mrežnih uređaja. Stvarni mrežni promet definiran je kao normalni mrežni promet budući da se radi o sigurnoj mrežnoj okolini dok su anomalije mrežnog prometa uvezene iz referentnog skupa podataka LUFlow2021 i NF-UQ-NID. Stvarni mrežni promet prikupljan je tijekom razdoblja od pet tjedana te je prikupljeno ukupno 11.8 GB sirovih podataka podijeljenih u 105 datoteka (rotacija datoteka je bila svakih 8 sati). Kako bi se ostvario jednak omjer nebalansiranog ulaznog skupa podataka kao u početnim razmatranjima u poglavlju 4.1.1. gdje se udio normalnog prometa u referentnim skupovima podataka kreće u rasponu od 70% - 88% i time određuje svojstvo vrlo nebalansiranog skupa podataka, koristio se samo dio prikupljenog mrežnog prometa kojeg sačinjavaju NetFlow zapisi u vremenu velike mrežne aktivnosti korisnika (prijepodnevni sati). Ostali korišteni zapisi prikupljeni u vremenu manje mrežne aktivnosti korisnika (poslijepodnevni sati) određeni su i uzorkovani slučajnim odabirom. Svi zapisi anomalija iz referentnog skupa podataka LUFlow2021 i NF-UQ-NID (opisanih u poglavlju 4.1.1.1 i 4.1.1.2) pridodani su dijelu prikupljenog NetFlow prometa s mrežnih uređaja koji je označen kao normalan promet. Dobiveni skup podataka sadrži 70.9 % normalnog prometa i 29.1% anomalija što je u skladu s početnim razmatranjima nebalansiranih skupova u poglavlju 4.1.1. Ukupan broj zapisa kombiniranog skupa podataka iznosi 13885498, od čega je 9833772 zapisa normalnog prometa, a 4051726 zapisa su uvezene anomalije referentnih skupova. Tablica 4-19 sadrži detalje o rezultatima klasifikacije, a postignuti rezultati relevantnih metrika poput AUC (Područje ispod ROC krivulje) i F2 (F-beta mjera) od 98.09% i 99.13%

potvrđuju iznimnu uspješnost predloženog modela. Unatoč relativno visokim apsolutnim vrijednostima lažno pozitivnih i lažno negativnih klasifikacija, gledajući njihove relativne vrijednosti (eng. *FNRate i FPRate*) može se reći da je njihov broj u okvirima ostalih postignutih rezultata sličnih istraživanja opisanim u poglavlju 4.1.5.2. *FNRate* se prema [160] izračunava kao omjer lažno negativnih rezultata u odnosu na ukupan broj pozitivnih uzoraka te pri klasifikaciji stvarnog Netflow prometa s uvezenim anomalijama iz skupova podataka LUFlow2021 i NF-UQ-NIDS iznosi 0,017.

Tablica 4-19 Klasifikacija stvarnog Netflow prometa s uvezenim anomalijama iz skupova podataka LUFlow2021 i NF-UQ-NIDS

	Rezultati
Klasična točnost	0.98115
Preciznost	0.953911
Opoziv	0.982891
TN	1928272
FP	38483
FN	13864
TP	796481
F2	0.976955
Uravnotežena točnost	0.981662
AUC	0.981662
Cohen-kappa koeficijent	0.954797
Matthews koeficijent	0.955012
Trajanje (sat:min:sek)	00:04:53.11

Lažno pozitivne i lažno negativne rezultate moguće je smanjiti nakon analize i ponovnim učenjem modela. Predloženi model omogućuje detaljnu analizu lažno negativnih klasifikacija, odnosno potencijalnih anomalija koje model nije prepoznao. Lažno pozitivni rezultati u klasifikaciji mrežnog prometa nisu toliko kritični za sigurnost IT sustava, jer predstavljaju normalne tokove prometa koji nisu prepoznati kao takvi. Međutim, mogu opteretiti sustav nepotrebnim dodatnim analizama prometa. Smanjenje broja lažno pozitivnih i lažno negativnih rezultata postiže se ponovnim učenjem modela s dodatnim podatcima. Za izračunavanje metrika uspješnosti klasifikacije opisanog procesa koristio se algoritam pisan u Python skriptnom jeziku prema pseudokodu Algoritam 2.

Algoritam 2: Klasifikacija uvezenih anomalija unutar stvarnog mrežnog prometa

Input: skup podataka za učenje, skup podataka Netflow mrežnog toka
Output: AUC, F2
Function: učitavanje podataka
    data1 ← prikupljeni stvarni Netflow zapis prometa
    data2 ← anomalije
Return data1, data2
Function: Predobrada podataka (data1, data2)
    Odabir značajki
    Čišćenje nepotpunih zapisa
    Konverzija kategorijskih značajki
    Spajanje podataka data ← data1, data2
    Function: razdvajanje podataka (data, omjer razdvajanja)
        X ← skup podataka svih zanačajki bez oznake klase
        y ← značajka oznake klase
    Return X_train, X_test, y_train, y_test
    Skaliranje podataka
Return X_train_scale, X_test_scale, y_train, y_test
Function: strojno učenje (X_train_scale, X_test_scale, y_train, y_test)
    y_pred ← Random Forest
Return y_pred
Izračunavanje klasifikacijskih metrika AUC, F2 ← $f_{(y\_pred,\ y\_test)}$
Kraj

Predloženi model za detekciju anomalija u stvarnom vremenu u hibridnoj programski definiranoj mreži prikazan je na Slici 4.21, a sastoji se od hardverskih i softverskih komponenti opisanih prema Tablici 4-20.

Tablica 4-20 Hardverske i sofverske komponente NFMIDS modela

hardver	**model**	**softver**
SDN kontroler	Cisco Application Policy Infrastructure Controller	4.2(7v)
SDN preklopnik	Cisco N9K-C93108TC-FX	Cisco NX-OS(tm) aci, Version 14.2(7v)
poslužitelj za strojno učenje i Netflow kolektor	ESXi virtualni poslužitelj (64 GB RAM, 32 x CPU Intel(R) Xeon(R) CPU E5-2690 v3 @ 2.60GHz, 400 GB HDD)	Ubuntu 20.04.5 LTS Nfdump NSEL-NEL1.6.18 Python 3.8.10 Sci-kit Learn 1.1.1
Host - napadač	HP Probook 6570b	Kali Linux 5.18.0
Host – žrtva1	HP 455 G2	Windows 10 Enterprise 20H2
Host – žrtva2	Lexmark CX510	
Host – žrtva3	HP EliteDesk 800 G4	Windows 10 Pro 22H2 FileZilla FTP Server 1.6.7

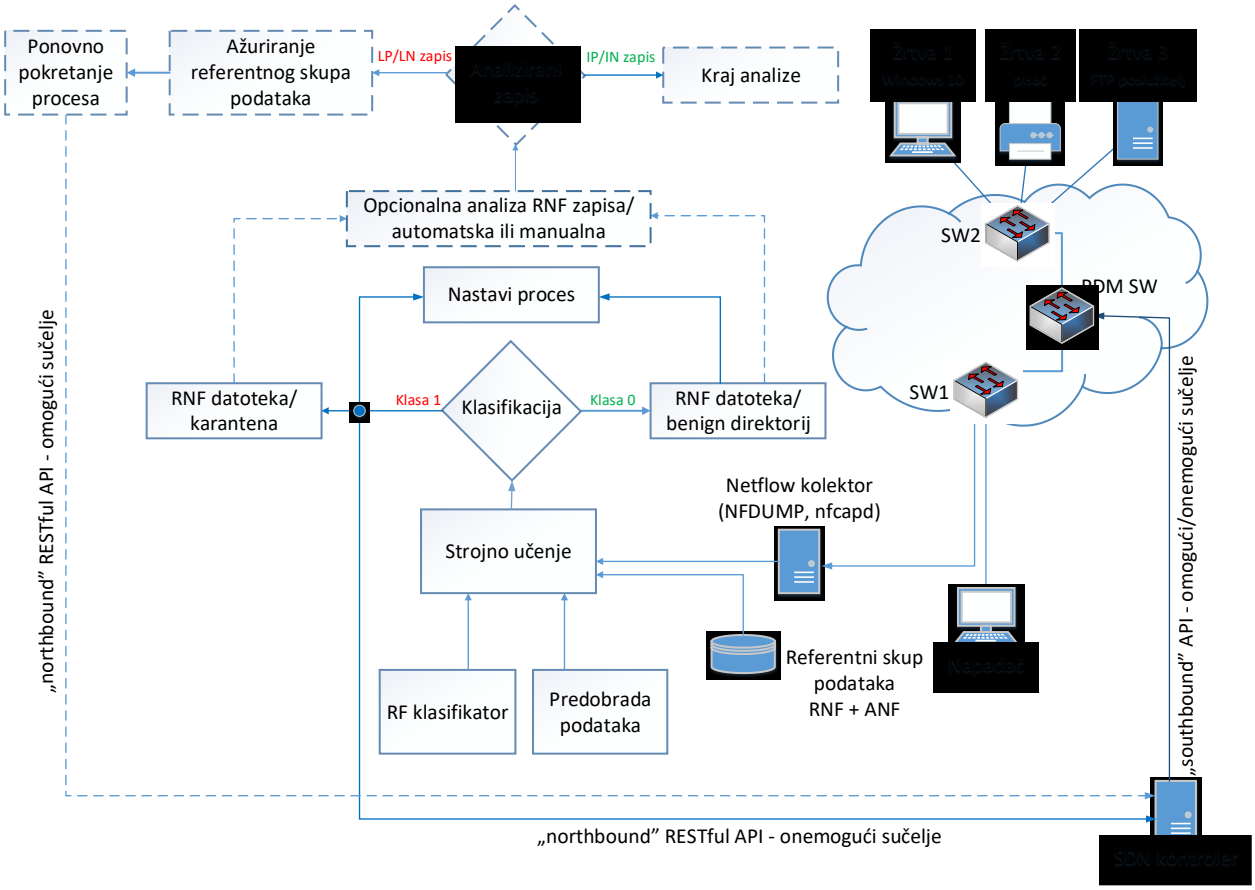

Slika 4.21 NFMIDS model detekcije anomalija u stvarnom vremenu

Predloženi model naučen je na temelju klasifikacije kombiniranim mrežnim prometom s jedinom razlikom - nema potrebe za podjelom ulaznih podataka na skup za učenje i skup za testiranje. To je zato što je model već naučen s ulaznim podatcima kombiniranog skupa podataka, a prikupljeni NetFlow podatci postaju podatci za testiranje te se obrađuju i klasificiraju neposredno nakon prikupljanja, što predstavlja osnovnu svrhu rada modela u stvarnom vremenu. Referentni skup podataka je kombinacija stvarnog mrežnog prometa (RNF) i anomalija (ANF) iz skupova podataka LUFlow2021 i NF-UQ-NID kako je opisano ranije u ovom poglavlju.

U okviru ovog istraživanja, predloženi NFMIDS model klasificira NetFlow podatke iz mrežnih uređaja. Model omogućuje automatsku klasifikaciju podataka u stvarnom vremenu, uzimajući u obzir ulazne podatke koji su prikupljeni pomoću nfcpad NetFlow kolektora, a dobiveni su unutar 60 sekundi iz stvarnog mrežnog uređaja. Model periodično provjerava postoji li novi NetFlow skup zapisa, odnosno datoteka koju treba klasificirati i detektirati anomalije mrežnog prometa.

Svaka datoteka se automatski konvertira iz originalnog binarnog .nfcpad formata u .csv format, kako bi se mogla učitati u proces strojnog učenja. U procesu predobrade novih podataka, opisanim u poglavlju 4.1.2, stvaraju se preduvjeti za klasifikaciju novih NetFlow zapisa. Ovisno o detekciji anomalija, datoteka se sprema u poseban direktorij karantene ili se sprema u direktorij benignog prometa. Spremanje datoteka omogućuje dodatnu detaljniju analizu NetFlow zapisa. Ukoliko se u dodatnoj analizi ustanove lažno pozitivni ili lažno negativni rezultati klasifikacije vraćaju se postavke blokiranog sučelja, ažuriraju se ulazni podatci te se takvi zapisi uvrštavaju u ponovni proces strojnog učenja kako bi se izbjegle daljnje pogrešne klasifikacije i unaprijedio model. Detekcija odnosno klasifikacija NetFlow zapisa kao anomalije pokreće proces automatskog zaustavljanja prometa na sučelju na kojem je detektirana anomalija. Ugrađeni REST API zahtjevi s informacijom o sučelju koje generira anomalije šalju se prema SDN kontroleru koji automatski stavlja sučelje u *„disabled“* način rada. Na ovaj način se automatski zaustavljaju neželjeni tokovi mrežnog prometa u stvarnom vremenu. U normalnom režimu rada predloženog NFMIDS modela, u slučaju detekcije anomalija tijekom klasifikacije mrežnog prometa aktivira se zahtjev za onemogućavanjem sučelja SDN preklopnika putem API zahtjeva prema SDN kontroleru. API zahtjevu za određenu radnju na sučelju SDN prekopnika prethodi API zahtjev autentifikacije korisnika čiji odgovor (*cookie*) je sastavni dio API-ja za onemogućavanje sučelja. Primjer API zahtjeva iz Python skripte prema SDN kontroleru sastoji se od nekoliko dijelova:

*url = https://<**ip_address**>/api/node/mo/uni/fabric/outofsvc.json*

- gdje se koristi *https* protokol za izvršavanje zahtjeva kako bi komunikacija prema SDN kontroleru na adresi ***ip_address*** bila sigurna.

*headers = {'Content-Type': **'application/json'**, 'Cookie': **cookie**}*

- definira se *json* tip podataka koji slijedi u zahtjevu i *cookie* zapis dobiven prilikom API zahtjeva za autentifikacijom

*payload={"fabricRsOosPath":{"attributes":{"tDn":"topology/pod-1/paths-1121/pathep-[**target_interface**]","lc":"**blacklist**"},"children": []}}*

- označava se sučelje (*target_interface*) i radnja (*blacklist*) koja se izvršava nad sučeljem

response = requests.request("POST", url, headers=headers, json=payload, verify=False)

- izvršava se API kao POST metoda koja izvršava željenu akciju nad sučeljem.

Ranije korišten i opisan pseudokod „Algoritam 2“, za ocjenu uspješnosti klasifikacije, modificiran je u „Algoritam 3“ za klasifikaciju NetFlow zapisa tokova mrežnog prometa u stvarnom vremenu.

Algoritam 3: Detekcija anomalija mrežnog prometa u stvarnom vremenu

Input: skup podataka za učenje (referentni NetFlow skup podataka s anomalijama), Netflow promet u stvarnom vremenu
Output: klasa 1, klasa 2

```
1.  Function: učitavanje podataka za učenje
2.      data1 ← prikupljeni stvarni NetFlow zapis prometa
3.      data2 ← anomalije referentnog skupa podataka
4.  Return data1, data2
5.  Function: Predobrada podataka (data1, data2)
6.      Odabir značajki
7.      Čišćenje nepotpunih zapisa
8.      Konverzija kategorijskih značajki
9.      Spajanje podataka data ← data1, data2
10.     Skaliranje podataka
11. Return X_train_scale, y_train
12. Strojno učenje (klasifikator Slučajne šume, X_train_scale, y_train)
13. Ponavljaj
14.     Učitaj podatke data3 ← stvarni Netflow zapis podataka
15.     Predobrada podatka (data3)
16.     Strojno učenje (Random Forest, X_scale_data3)
17.         Ako je y_pred = klasa 1
18.             sučelje = zapis iz data3
19.             Netflow Datoteka → direktorij za karantenu
20.             Izvrši API = disable sučelje
21.         Ako je y_pred = klasa 0
22.             Netflow Datoteka → direktorij za normalan promet
23.     Sačekaj n sekundi
24. Ponovi
25. Kraj
```

Algoritam 3 proširiv je s funkcijama ponovnog učenja i vraćanja sučelja na prvobitno stanje prosljeđivanja paketa ukoliko se pojavi potreba npr. lažno pozitivan rezultat klasifikacije. Ponovno učenje modela vrši se kombiniranim referentnim skupom podataka za učenje koji se nadopunjuje odabranim zapisima iz pohranjenih RNF (stvarnih NetFlow zapisa) datoteka u direktorijima „benign“ ili „karantena“.

4.2.2. Rezultati detekcije anomalija u stvarnom vremenu

Za kompleksni kibernetički napad treba uzeti u obzir da se napad sastoji od niza osnovnih napadačkih akcija, odnosno pojedinačnih akcija napadača koje se provode korištenjem različitih softverskih sustava s ciljem postizanja konačnog cilja složenog napada. Kriterij koji povezuje akcije napadača koristeći osnovne napadačke akcije je određeni tip ranjivosti, primjerice, ranjivost prelijevanja međuspremnika u mrežnoj usluzi ili primjena određenog softverskog alata, kao što je softver za pogađanje lozinki. Tijekom napada, napadač donosi odluke o odabiru određenih napadačkih akcija kako bi postigao svoj konačni cilj. Pri odabiru, uzima u obzir očekivane rezultate akcija i informacije o ciljanom sustavu. Svaka napadačka akcija zahtijeva ispunjenje određenih uvjeta, poput prisutnosti otvorenog TCP porta ili ranjivosti softvera. Neki napadi zahtijevaju i specifična znanja o korisničkim podatcima poput imena ili lozinki. Ove akcije imaju posljedice koje mogu utjecati na parametre sustava i omogućiti napadaču pristup dodatnim informacijama. Napadi se odvijaju tijekom vremena i mogu se odvijati sinkrono ili asinkrono. Većina vremenskih odgoda tijekom napada je nasumične prirode, ovisno o različitim faktorima poput brzine prijenosa mrežnih paketa [157].

Prema shemi na Slici 4.21 i Algoritmu 3 testiran je model na tri vrste kibernetičkih napada u kontroliranom okruženju hibridne SDN mreže. Inicijalno testiranje detekcije anomalija mrežnog prometa uključivalo je NFMIDS model bez IPS funkcionalnosti kako bi se učinkovitost modela mogla provjeriti nakon uključivanja IPS funkcionalnosti. Na Slici 4.22 je prikazan graf propusnosti sučelja na SDN uređaju tijekom rada računala napadača u normalnom režimu te u vremenima kibernetičkih napada.

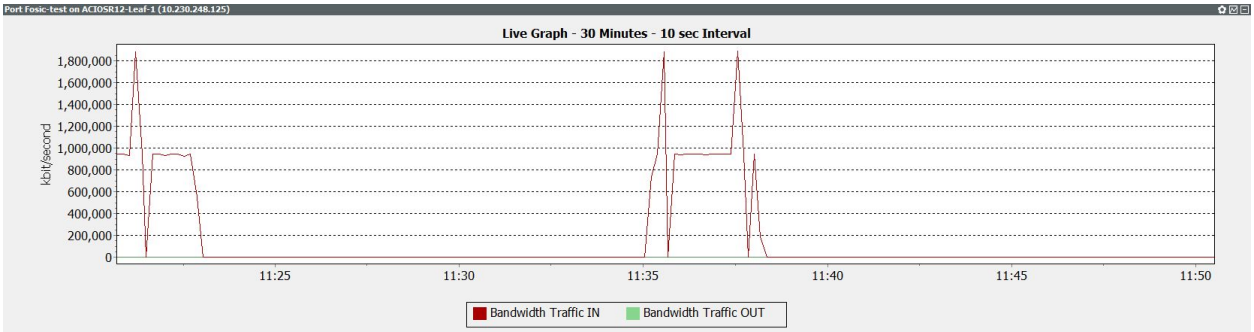

Slika 4.22 Graf propusnosti sučelja SDN uređaja tijekom inicijalnog testiranja bez IPS funkcionalnosti

Kao primjer kibernetičkih napada koristili su se sljedeći tipovi:

- Tip 1 - DoS – uskraćivanje usluge;
- Tip 2 - Otkrivanje korisničkih imena i lozinki – dobivanje neovlaštenog pristupa;
- Tip 3 - Skeniranje portova na udaljenom uređaju;

Razlozi odabira ovih vrsta kibernetičkih napada je učestalost i lakoća korištenja. U današnjem okruženju opće povezanosti na Internet, Denial-of-Service (DoS) ili Distributed Denial-of-Service (DDoS) napadi su se jako proširili i napadači čine online sustave nedostupnim legitimnim korisnicima slanjem ogromnog broja paketa ciljanom sustavu. Otkrivanje korisničkih imena i lozinki putem rječnika uobičajeni su napadi koji često uspiju jer mnogi korisnici koriste uobičajene varijacije nekoliko lozinki te nije potrebno dodatno iskorištavanje sigurnosnih propusta, jer su sve sigurnosne kontrole zaobiđene. Uspješan brute-force napad ili napad rječnikom osobito je koristan za napadača kada kompromitirani račun pripada administratoru sustava, koji ima veće privilegije od običnog korisničkog računa. Skeniranje portova jedna je od najpopularnijih tehnika izviđanja koju mnogi napadači koriste za profiliranje pokrenutih usluga na potencijalnoj meti prije pokretanja napada.

Normalan promet uključivao je mrežne aktivnosti:

- http i https promet (rad u internet pregledniku);
- ftp promet (spajanje na udaljene poslužitelje, preuzimanje i pohranjivanje datoteka raznih veličina);
- icmp promet (standardni ping udaljenih mrežnih uređaja);
- modificirani icmp promet (ping udaljenih mrežnih uređaja s većim paketima);
- traceroute promet (ispitivanje čvorova uključenih u promet paketa od izvorišne do odredišne adrese);
- rad s nekoliko mrežnih aplikacija u korporativnom poslovnom procesu.

Spomenuta tri kibernetička napada samo su dio lepeze poznatih kibernetičkih napada, za koje se može reći da su česti načini pripreme za ozbiljnije kibernetičke napade opisanih u literaturi [161], [162], [163], [164].

Tijek inicijalnog testiranja NFMIDS modela bez IPS funkcionalnosti je prikazan Tablicom 4-21 dok je propusnost SDN sučelja napadača prikazana Slikom 4.22.

Tablica 4-21 Tijek inicijalnog testiranja NFMIDS modela bez IPS funkcionalnosti

Vrijeme početka	**Vrsta prometa**	**Vrijeme Detekcije**	**Vrijeme završetka**
11:35:00	Kibernetički napad tip 1	11:35:43	11:38:00
11:38:00	Normalan promet	11:39:50	11:41:00
11:41:00	Kibernetički napad tip 2	11:42:30	11:44:00
11:44:00	Normalan promet	11:45:41	11:47:10
11:47:10	Kibernetički napad tip 3	11:47:32	11:47:58
11:47:58	Normalan promet	11:49:45	11:50:00

Na temelju analize Tablice 4-21, pokazuje se da je predloženi NFMIDS model uspješno otkrio tri različita kibernetička napada. Prvi napad je pokrenut u 11:35:00, drugi u 11:41:00, a treći u 11:47:10. Svaki od napada je trajao nekoliko minuta prije nego što je namjerno prekinut, nakon čega se sustav vratio u normalno stanje i nastavio bilježiti uobičajeni promet. Vrijeme otkrivanja napada variralo je od nekoliko sekundi do nekoliko minuta, s najdužim kašnjenjem od oko 90 sekundi za drugi tip napada. Ova kašnjenja proizlaze iz vremena pokretanja napada te vremena u kojem je NFMIDS radio klasifikaciju prometa iz kreirane nfcpad datoteke. Kašnjenje detekcije bilo kibernetičkog napada bilo normalnog prometa nakon prestanka kibernetičkog napada uvelike ovisi o vremenu početka događaja i vremenu rotacije i kreiranja nfcpad datoteka. Što je početak napada vremenski bliže završetku formiranja nfcpad datoteke to model može brže detektirati anomaliju jer će prije započeti obrada NetFlow zapisa. Razlika u vremenima početka i detekcije kibernetičkog napada u Tablici 4-21 objašnjava se načinom rada nfcpad kolektora i prikupljanja NetFlow zapisa koji omogućava klasifikaciju paketa skupljenih tijekom vremena od 60 sekundi. Također, razlika u vremenima stvarnog zaustavljanja kibernetičkog napada i ponovne detekcije normalnog prometa rezultat je zaostatka podataka u međuspremniku mrežnog uređaja koji šalje NetFlow zapise, što dovodi do odgođenog slanja zapisa u kolektor.

Brže rotacije ncfpad datoteka omogućuje novija inačica NFDUMP kolekcije aplikacija koja prema dokumentaciji ima minimalno vrijeme rotacije 2 sekunde te bi se nadogradnjom predloženog modela problem kašnjenja mogao značajnije umanjiti. Ažuriranje NFDUMP

kolekcije aplikacija tijekom izrade ove disertacije nije napravljeno iz razloga praktične primjene, stabilnosti i optimalno podešenih postavki parametara strojnog učenja trenutne konfiguracije modela. Budući da je Python programski jezik korišten za strojno učenje na istoj platformi kao i NFDUMP aplikacije, postoji vjerojatnost nekompatibilnosti različitih verzija korištenih aplikacija na zajedničkoj hardverskoj platformi. Da bi se izbjegla potencijalna nekompatibilnost, NFDUMP nije ažuriran već je ostao na verziji koja omogućava minimalnu vrijednost od 60 sekundi za rotaciju datoteka.

Predočeni rezultati u Tablici 4-21 ukazuju na to da je predloženi sustav učinkovit u otkrivanju kibernetičkih napada i zaštiti mrežne sigurnosti. Analizom podataka u Tablici 4-22 zajedno s grafom na Slici 4.22 o propusnosti sučelja na SDN preklopniku, gdje je spojeno računalo napadača, proizlazi da se samo kibernetički napad tipa 1 (DoS) može povezati s povećanjem prometa na sučelju, dok druga dva napada nisu uzrokovala takvo povećanje. Tablica 4-22 također prikazuje detaljan ispis volumena mrežnog prometa na promatranom sučelju SDN preklopnika tijekom inicijalnog testiranja gdje su crveno označeni vremenski isječci kibernetičkih napada iz aplikacije za nadzor propusnosti mrežnog sučelja.

Tablica 4-22 Propusnost promatranog SDN sučelja tijekom inicijalnog testiranja

Vrijeme	Propusnost sučelja (kbit/s)	Tip mrežnog prometa
3/28/2023 11:49 - 11:50	257.300	normalan
3/28/2023 11:48 - 11:49	267.748	normalan
3/28/2023 11:47 - 11:48	341.132	Kibernetički napad tip 3
3/28/2023 11:46 - 11:47	228.131	normalan
3/28/2023 11:45 - 11:46	303.815	normalan
3/28/2023 11:44- 11:45	238.582	Kibernetički napad tip 2
3/28/2023 11:43 - 11:44	339.185	Kibernetički napad tip 2
3/28/2023 11:42- 11:43	296.233	Kibernetički napad tip 2
3/28/2023 11:41 - 11:42	303.227	Kibernetički napad tip 2
3/28/2023 11:40 - 11:41	256.510	normalan
3/28/2023 11:39 - 11:40	273.544	normalan
3/28/2023 11:38 - 11:39	120,459.411	normalan
3/28/2023 11:37 - 11:38	998,839.698	Kibernetički napad tip 1
3/28/2023 11:36 - 11:37	943,143.776	Kibernetički napad tip 1
3/28/2023 11:35 - 11:36	843,298.254	Kibernetički napad tip 1

Prema podatcima u Tablici 4-22, vidljivo je da je u vremenskom intervalu od 11:35 do 11:38 došlo do značajnog povećanja prometa, što se može tumačiti kao indikacija kibernetičkog napada. Zaostatak povećanog prometa u vremenskom razdoblju 11:38 do 11:39 kada je kibernetički napad završio posljedica je petominutnog prosjeka vrijednosti u nadzornom alatu koji se koristio za bilježenje podataka o propusnosti sučelja. Međutim, predloženi model s uključenom IPS funkcionalnošću može otkriti i blokirati kibernetičke napade na temelju prvog otkrivanja anomalije mrežnog prometa. Blokiranjem sučelja SDN mrežnog uređaja na kojem je primijećena anomalija eliminira se mogućnost pogrešnog detektiranja povećanog prometa.

Tijekom inicijalnog testiranja i operativnog rada predloženog NFMIDS modela u normalnom režimu bez mrežne aktivnosti kibernetičkih napada, primijećena je pojava lažno pozitivne klasifikacije svakih deset minuta, što je iznosilo jednu lažno pozitivnu klasifikaciju od ukupno 1317 prispjelih NetFlow zapisa mrežnog prometa. Analizom datoteka u kojima je detektirana anomalija potvrđena je lažno pozitivna klasifikacija. Uvrštavanjem ovog zapisa u proces ponovnog učenja gdje je ovakav zapis označen kao normalan promet, nije se više ponovila lažno pozitivna klasifikacija unutar promatranog razdoblja od 60 minuta kada je sustav mirovao bez ikakve ili s malom mrežnom aktivnosti. Ovaj postupak potvrđuje mogućnost smanjenja lažno pozitivnih klasifikacija ponovnim učenjem modela uz dodatne označene ulazne podatke za strojno učenje. Svaka anomalija koja se otkrije u bloku NetFlow zapisa (nfcpad datoteka) koji se obrađuje, pohranjuje se u zaseban direktorij u svrhu pregledavanja zapisa s detektiranom anomalijom. Ovakav pristup ima za cilj otkriti lažno pozitivne klasifikacije i omogućiti ponovno učenje modela s novim ulaznim podatcima koji sadrže sve lažno pozitivne klasifikacije označene kao normalan promet. To je važno jer će poboljšati točnost budućih klasifikacija predloženog modela. Korištenjem ovog pristupa, moguće je unaprijediti kvalitetu klasifikacije i osigurati veću preciznost u prepoznavanju anomalija mrežnog prometa.

Uključivanje IPS funkcionalnosti u NFMIDS model omogućuje se automatsko blokiranje kibernetičkih napada putem API zahtjeva, kako je opisano u prethodnom potpoglavlju. Tijekom obrade podataka u klasifikaciji, za svaki obrađeni zapis privremeno se pohranjuje broj sučelja na kojima je detektirana anomalija. Ova informacija koristi se prilikom slanja API zahtjeva kontroleru kako bi se onemogućio mrežni promet na kompromitiranom sučelju SDN uređaja.

Tablica 4-23 prikazuje rezultate testiranja NFMIDS modela s uključenom IPS funkcionalnosti u hibridnoj programski definiranoj mreži u stvarnom vremenu, dok graf na Slici 4.23 prikazuje zabilježenu propusnost sučelja. U tablici se za svaki testni scenarij prikazuje vrijeme početka, vrsta prometa, vrijeme detekcije, vrijeme blokiranja sučelja i vrijeme odblokiranja sučelja. Rezultati pokazuju sposobnost modela u detektiranju i automatskom blokiranju kibernetičkih napada, kao i vraćanje sučelja u normalan režim rada nakon što je napad prekinut radi pokretanja i detekcije novog kibernetičkog napada.

Tablica 4-23 Tijek testiranja NFMIDS modela s uključenom IPS funkcijom

Vrijeme početka	**Vrsta prometa**	**Vrijeme Detekcije**	**Vrijeme blokiranja sučelja**	**Vrijeme vraćanja sučalja u normalan režim rada**
3/28/2023 12:05:00	Kibernetički napad tip 1	12:06:22	12:06:29	12:08:00
3/28/2023 12:08:00	Normalan promet	/	/	/
3/28/2023 12:12:00	Kibernetički napad tip 2	12:12:15	12:12:22	12:15:00
3/28/2023 12:15:00	Normalan promet	/	/	/
3/28/2023 12:18:00	Kibernetički napad tip 3	12:19:03	12:19:10	12:21:00
3/28/2023 12:21:00	Normalan promet	/	/	/

U vrijeme normalnog prometa bez kibernetičkih napada nisu se mjerila vremena budući da je sučelje prije toga bilo blokirano i nije se pojavljivao nikakav promet na sučelju.

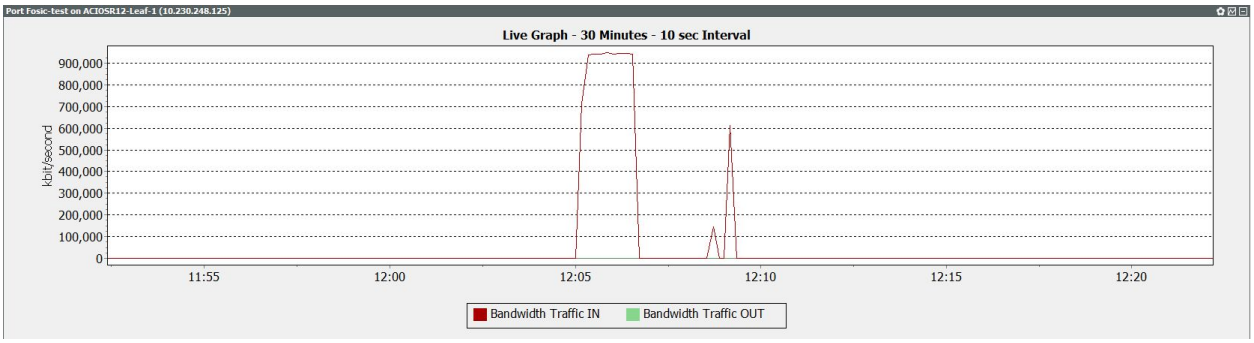

Slika 4.23 Graf propusnosti sučelja SDN uređaja tijekom testiranja s uključenom IPS funkcijom

Uspoređujući grafove prikazane na Slikama 4-22 i 4-23 te analizirajući Tablice 4-22 i 4-23, vidljivo je da je NFMIDS model uspješno detektirao kibernetičke napade te ih blokirao unutar vremena rotacije NetFlow datoteka koje prikuplja NetFlow kolektor. U Tablici 4-24 prikazani su rezultati mjerenja propusnosti SDN sučelja tijekom testiranja predloženog NFMIDS modela s aktiviranom IPS funkcionalnošću.

Tablica 4-24 Propusnost SDN sučelja tijekom testiranja s IPS funkcijom

Vrijeme	Propusnost sučelja (kbit/s)	Tip mrežnog prometa
3/28/2023 12:22 - 12:23	123.115	normalan
3/28/2023 12:21 - 12:22	43.741	normalan
3/28/2023 12:20 - 12:21	0	blokirano sučelje – nema prometa
3/28/2023 12:19 - 12:20	**75.461**	Kibernetički napad tip 3
3/28/2023 12:18 - 12:19	**116.510**	Kibernetički napad tip 3
3/28/2023 12:17 - 12:18	124.818	normalan
3/28/2023 12:16 - 12:17	266.108	normalan
3/28/2023 12:15 - 12:16	45.017	normalan
3/28/2023 12:14 - 12:15	0	blokirano sučelje – nema prometa
3/28/2023 12:13 - 12:14	0	blokirano sučelje – nema prometa
3/28/2023 12:12 - 12:13	**123.350**	Kibernetički napad tip 2
3/28/2023 12:11 - 12:12	63.549	normalan
3/28/2023 12:10 - 12:11	114.461	normalan
3/28/2023 12:09 - 12:10	105,744.867	normalan
3/28/2023 12:08 - 12:09	24,753.438	normalan
3/28/2023 12:07 - 12:08	0	blokirano sučelje – nema prometa
3/28/2023 12:06 - 12:07	**596,296.814**	Kibernetički napad tip 1
3/28/2023 12:05 - 12:06	**818,809.846**	Kibernetički napad tip 1
3/28/2023 12:04 - 12:05	297.778	normalan

Dobiveni rezultati u Tablici 4-24 jasno pokazuju očekivani prekid u mjerenju propusnosti sučelja, koji je posljedica automatskog blokiranja sučelja putem API zahtjeva prema kontroleru SDN uređaja nakon što je detektiran kibernetički napad. Također se potvrđuje uspješna detekcija i blokiranje kibernetičkih napada, što naglašava učinkovitost IPS funkcionalnosti u okviru NFMIDS modela za osiguranje mreže od kibernetičkih prijetnji. Mjerenje propusnosti sučelja u

istoj tablici dodatno potvrđuje da se automatsko blokiranje sučelja tijekom napada odražava na smanjenje ukupne propusnosti mreže u tom trenutku.

Predloženi model može pružiti značajnu vrijednost u praćenju mrežnog prometa, održavanju sigurnosti i funkcionalnosti u različitim okruženjima, posebno onima koja su od kritične važnosti. Dobiveni rezultati daju uvid u učinkovitost NFMIDS modela s uključenom IPS funkcionalnošću i sugeriraju mogućnost primjene ovakvog sustava za zaštitu mreža od kibernetičkih napada. Rezultati klasifikacije stvarnog mrežnog prometa jasno demonstriraju važnost kontinuiranog testiranja i razvoja sigurnosnih sustava te potencijalne prednosti upotrebe strojnog učenja u detekciji anomalija u mrežnom prometu. Na temelju dobivenih rezultata možemo zaključiti da dodavanje označenih podataka u proces ponovnog učenja značajno unaprjeđuje preciznost detekcije, smanjujući broj lažno pozitivnih i lažno negativnih klasifikacija te poboljšavajući cjelokupnu pouzdanost predloženog modela.

5. PRIJEDLOG METODE VERIFIKACIJE MODELA ZA DETEKCIJU ANOMALIJA U HIBRIDNOJ PROGRAMSKI DEFINIRANOJ MREŽI

Verifikacija i validacija su osnovni procesi za kvantificiranje i izgradnju povjerenja (ili vjerodostojnosti) za modele. Definicije pojmova verifikacije i validacije prema [165] su:

- Verifikacija je proces utvrđivanja točnosti implementacije modela u odnosu na konceptualni opis i rješenje prema zamisli autora;
- Validacija je proces utvrđivanja u kojoj mjeri je model točan prikaz stvarnog okruženja s obzirom na namjene modela.

Procesi verifikacije i validacije ključni su za prikupljanje dokaza o ispravnosti i točnosti modela u određenim scenarijima. Važno je napomenuti da se ovim procesima ne može apsolutno dokazati točnost i preciznost modela za sve moguće uvjete i primjene, ali mogu pružiti dokaze da je model upotrebljiv i dovoljno precizan. Proces verifikacije i validacije smatra se završenim kada se postigne zadovoljavajuća razina preciznosti. Verifikacija modela predstavlja glavni aspekt razvoja simulacijskih modela i provodi se paralelno s procesom dizajna modela. Glavni cilj je osigurati da simulacijski model bude koristan u rješavanju stvarnih problema u specifičnim situacijama. Iako verifikacija ne može jamčiti potpunu točnost modela za sve moguće primjene, može pružiti dokaze o njegovoj točnosti u određenim stvarnim problemima. Istraživanja često obrađuju različite aspekte i metode verifikacijskog i validacijskog procesa, no primjeri njihove primjene u stvarnim okruženjima su ograničeni [165], [166].

Slikom 5.1. prikazan je postupak verifikacije i potrebnih aktivnosti u rješavanju problema kako je definirano prema [166] :

1. Definiranje istraživačkog problema gdje se razrađuju i identificiraju stvarni problemi i usklađuju očekivanja od istraživačkih rezultata;
2. Određivanje svrhe istraživanja i simulacijskih eksperimenata;
3. Specifikacija podataka i informacija potrebnih za definiciju konceptualnih i simulacijskih modela;

4. Definiranje konceptualnog modela u skladu s određenom istraživačkom svrhom koristeći prikupljene podatke i informacije kako bi se predstavile relevantne veze s istraživačkim problemom;
5. Odabir metode modeliranja i simulacije za reprezentaciju definiranog istraživačkog problema;
6. Odabir alata u kojem će se implementirati simulacijski model. Ovaj proces odabira uključuje razmatranje dostupnosti i prilagodljivosti alata;
7. Razvija se simulacijski model iz konceptualnog modela pomoću odabrane simulacijske metode i alata;
8. Provode se verifikacijski eksperimenti sa simulacijskim modelom i provjerava se pouzdanost i očekivani rezultati za dane ulazne podatke;
9. Pregled rezultata verifikacijskih eksperimenata. Ako je potrebno, koraci 3, 4, 5, 6, 7 i 8 mogu se ponoviti;
10. Dokumentiraju se upute i izrađuju dokumenti koji prate simulacijski model i eksperimente.

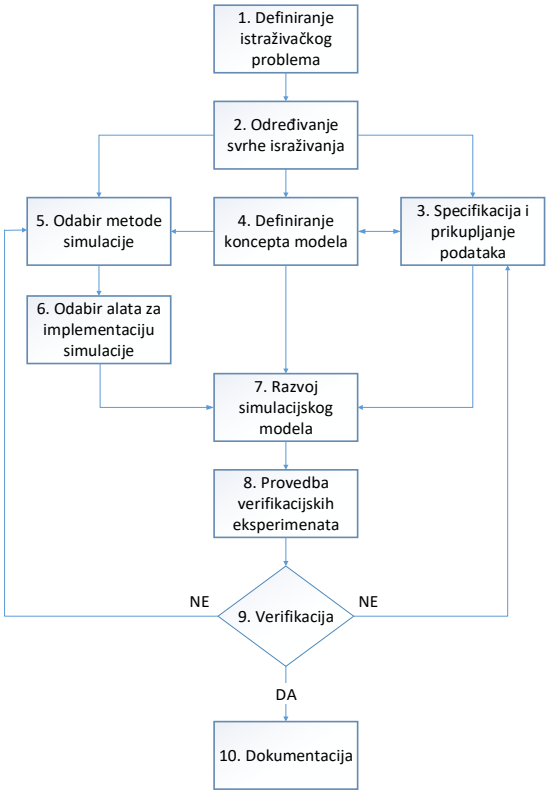

Slika 5.1 Procedura verifikacije modela [166]

5.1. Pregled postojećih metoda verifikacije

Najčešći pristup verifikaciji IDS sustava uključuje upotrebu stvarnog prometa iz stvarnih mreža ili javno dostupnih skupova podataka mrežnog prometa. Izuzetak su privatne korporativne mreže, kojima je pristup ograničen na vrlo malen broj istraživača, zbog čega se javno dostupni skupovi podataka često koriste kao prva opcija za verifikaciju nekog rješenja, međutim, ne postoji zajednički test koji bi pokazao da generirani skup podataka sadrži instance stvarnog mrežnog prometa. Također, ne postoji univerzalni verifikacijski test koji bi potvrdio da detektirani napadi odražavaju stvarne mrežne napade. Važno je temeljito evaluirati IDS u smislu pronalaženja odgovarajućih podataka za učenje i klasifikaciju, kao i za interpretaciju rezultata radi pouzdane detekcije napada. Unatoč brojnim istraživanjima u području IDS-a, uspjeh metoda verifikacije izuzetno ovisi o realnom testnom okruženju [167].

Tablica 5-1 Pregled literature s naglaskom na metode verifikacije IDS-a

#	Godina	Metode verifikacije	Testno okruženje verifikacije	Pozicija IDS/IPS	SDN
[168]	2017.	usporedba s drugim sustavima i testiranje s uzorcima podataka	stvarno	pasivna	ne
[169]	2017.	testiranje s uzorcima podataka	simulirano	/	ne
[170]	2015.	testiranje s uzorcima podataka	simulirano	aktivna	ne
[171]	2018.	testiranje s uzorcima podataka	/	/	/
[172]	2005.	usporedba s drugim sustavima i testiranje s uzorcima podataka	simulirano	/	ne
[173]	2022.	testiranje s uzorcima podataka	simulirano	/	da
[174]	2023.	testiranje s napadima	stvarno i simulirano	pasivna	ne
[175]	2021.	testiranje s napadima i testiranje s ranjivostima sustava	stvarno	aktivna	ne
[176]	2021.	testiranje s uzorcima podataka i testiranje s napadima	simulirano	/	ne
[177]	2020.	usporedba s drugim sustavima i testiranje s uzorcima podataka	simulirano	/	ne

U istraživanju [168] analizirana su tri popularna open-source NIDS alata: Snort, Suricata i Bro, te je provodena usporedna analiza njihovih performansi. Fokus je bio na faktorima koji ograničavaju primjenu ovih NIDS-ova u velikim mrežama, uključujući iskorištavanje sistemskih resursa, brzinu obrade paketa i stopu gubitka paketa. Istraživanje je provedeno s podatcima stvarne mreže gdje je sveukupni mrežni promet kopiran na uređaje namijenjene provedbi testiranja. Tijekom testiranja primjećene se promjene u performansama NIDS-ova ovisno o različitim konfiguracijama i pri različitim vrstama prometa.

U [169] autori predlažu arhitekturu za testiranje i vrednovanje IDS sustava unutar vozila kako bi se omogućilo stvaranje realističnog mrežnog prometa i napada uzimajući u obzir specifične izazove u automobilskoj industriji. Koncept pruža mogućnost dijeljenja podataka bez dodatne anonimizacije, čime se poboljšava suradnja i reproducibilnost rezultata testiranja. Iako je osnovni cilj bio dizajnirati alat za procjenu IDS-a u automobilima, isti se može koristiti i za izvođenje funkcionalnih i sigurnosnih testova komunikacijskih mreža u automobilima. Kroz scenarije je moguće generirati benigni i zlonamjerni promet, primijeniti ih na različite konfiguracije vozila i podržati složene scenarije, uključujući napade poput "man-in-the-middle" napada. Za model zlonamjernog opterećenja razmotreno je pet scenarija napada, a postavljeni su i zahtjevi za generiranje stvarnog prometa u Ethernet baziranim automobilskim mrežama, uključujući i prioritizaciju različitih tokova prometa.

U radu [170] predložen je sustav koji koristi više IDS-ova koji rješava problem centralizirane pohrane podataka. Za rješavanje ovog problema, razvijen je glavni čvor koji centralizira upravljanje IDS-ovima i pruža primarnu bazu podataka za pohranu identificiranih prijetnji i nepravilnosti u mreži. Model testiranja uključuje kategorizaciju testova prema karakteristikama IDS-a koje se ispituju te cilja na stvaranje skupa testova koji omogućuju određivanje primjene IDS-a i konfiguracije parametara koji utječu na njegove performanse. Ispitivanje IDS-ova podijeljeno je u kategorije koje se bave performansama IDS-a, točnošću detekcije napada te arhitekturom IDS-a. Rezultati testova ukazuju na prednosti arhitekture Suricata IDS-a u brzoj obradi podataka i boljoj točnosti detekcije napada u usporedbi s Snort IDS-om. Također, predložena arhitektura pokazuje potencijal za obradu mrežnog prometa visokog kapaciteta i smanjenje gubitka paketa.

Često se u testiranjima koristi stvarni snimljeni promet komunikacijskih mreža. U praksi, prikupljanje stvarnih mrežnih podataka u značajnim količinama često predstavlja izazov. Ovaj nedostatak stvarnih i sveobuhvatnih podataka o mrežnom prometu može predstavljati ograničenje u istraživanjima detekcije kibernetičkih prijetnji, posebno u kontekstu analize ponašanja na razini aplikacije. Izostanak relevantnih podataka može rezultirati smanjenom preciznošću i relevantnošću modela. Dodatno, sadrže vrlo malo zlonamjernog prometa što nije dovoljno za potpuno testiranje IDS-a. Ovaj problem autori u [171] rješavaju predloženim sustavom za generiranje prometa koji kombinira stvarni promet s korisnički definiranim zlonamjernim HTTP prometom s ciljem evaluacije IDS-a. U istraživanju je predstavljen sustav za generiranje kombiniranog prometa, s naglaskom na evaluaciju IDS-ova temeljenih na potpisima za otkrivanje mrežnih napada. Za kreiranje stvarnog prometa koristio se TRex generator prometa u kombinaciji sa zlonamjernim HTTP prometom stvorenim putem GENESIDS generatora prometa, koji koristi definicije napada u obliku Snort pravila. Time se osigurava stvaran promet pomiješan s velikim brojem događaja iz stvarnog svijeta.

U radu [172] je opisan okvir za generiranje prometa koji je namijenjen za online ispitivanje sustava za otkrivanje mrežnih upada. Svrha sustava je generiranje stvarnih i raznolikih tokova normalnog i zlonamjernog prometa. Predložena je metodologija za generiranje normalnog prometa temeljenog na empirijskim skupovima podataka ili standardnih DARPA podataka. Predstavljeni pristup je koristan za testiranje i podešavanje vlastitih sustava detekcije upada. Okvir za generiranje prometa implementiran je u alatu koji je nazvan Trident, a njegova korisnost prikazana je kroz niz eksperimenata na open-source NIDS-ovima provedenih u kontroliranom laboratorijskom okruženju. Rezultati tih eksperimenata naglašavaju da sadržaj, kombinacija i obujam podataka imaju ogroman utjecaj na performanse NIDS-ova.

U radu [173] provođeni su testovi IDS-a koristeći InSDN skup podataka, koji je prikupljen iz okoline s programski definiranom mrežom (SDN) i omogućuje provjeru učinkovitosti modela na SDN prometu. Za izgradnju strukture modela korišten je Tensorflow okvir, a eksperimenti su izvedeni na platformi Jupyter Notebook unutar Anaconda okruženja. Podatci korišteni u ovom radu potječu iz virtualnog okruženja sa softverski definiranom mrežom (SDN). Ubuntu sustavi predstavljaju normalne korisnike, dok su Linux Kali sustavi korisnici koji izvode različite vrste napada na SDN mrežu. Izvedena su dva usporedna eksperimenta: jedan za binarnu klasifikaciju i

drugi za višeklasnu klasifikaciju. Korišteni skup podataka sadrži različite vrste kibernetičkih napada, kao što su DDoS napadi, Probe i drugi. U simuliranom scenariju napadač izvodi različite vrste kibernetičkih napada na SDN mrežu, dok ista ta mreža provodi normalan komunikacijski promet. Svrha predloženog modela testiranja s mješovitim tokovima prometa je razlikovanje normalnog prometa od zlonamjernog, dok je druga svrha analiza prometa i dodjela oznaka prometu za svaku vrstu napada.

U istraživanju [174] se predlaže sustav za otkrivanje upada temeljen na kvantitativnoj logaritamskoj transformaciji (QLT) za identifikaciju neželjenih aktivnosti u mrežama velikog opsega u stvarnom vremenu. Predloženi sustav, nazvan QLT-IDS, prikuplja i analizira NetFlow zapise, te analizira pojedinačna ponašanja tokova unutar tih zapisa koristeći statističku metodu temeljenu na QLT. Predloženi QLT-IDS izvodi otkrivanje upada na temelju statističkih značajki mrežnih tokova, ne zahtijeva upotrebu unaprijed definiranih pravila niti prethodni postupak obuke, a vrijeme otkrivanja je manje od jedne minute. Eksperimentalni rezultati pokazuju da QLT-IDS može obraditi masovne NetFlow zapise i postići preciznost otkrivanja zlonamjernih upada od 95,7% uključujući skeniranje portova, SSH i RDP upade.

Autori u [175] koriste NetFlow skup podataka tokova mrežne komunikacije kako bi testirali IDS-a za SCADA sustave. Predloženi IDS sustav temeljen je algoritmu umjetne neuronske mreže dubokog učenja, a NetFlow skup podataka korišten je za učenje i testiranje algoritama. U testnom SCADA sustavu izveli su dva različita kibernetička napada. Promatrane su performanse IDS-a u offline i online načinima rada u testnoj SCADA mreži. Performanse tijekom DoS kibernetičkog napada pokazale su slične rezultate tijekom online i offline evaluacije. S druge strane, za reconnaissance kibernetički napad, online performanse bile su lošije od offline performansi. Istraživanje je poslužilo kako bi se simulirali stvarni scenariji kibernetičkih napada na SCADA sustave.

U radu [176] predložen je inovativan okvir za generiranje bidirekcijskih skupova podataka temeljenih na tokovima mrežnog prometa radi evaluacije sustava za otkrivanje upada (IDS). Generirani skup podataka sadrži kombinaciju normalnog pozadinskog prometa i kibernetičkih napada. Pozadinski promet temelji se na standardnim karakteristikama mrežnog prometa, dok se generirani promet kibernetičkih napada temelji na njihovim statističkim karakteristikama.

Predloženim okvirom generiran je skup podataka bidirekcijskog prometa temeljenog na tokovima koji se koristi za evaluaciju učinkovitosti sustava za otkrivanje upada.

U istraživanju [177] predstavljena je metodologija koja obuhvaća obvezne korake u procjeni NIDS-a. Primjenjivost predloženog okvira testirana je s klasičnim ML algoritmima i stvarnim skupom podataka. Osim toga, izvršena je i usporedba s najnovijim NIDS sustavima temeljenim na strojnom učenju. Rezultati su pokazali da predložena metodologija može pomoći u izgradnji boljih NIDS rješenja kako bi omogućila njihove usporedbe. Međutim, definiranje konačnog okvira za procjenu nije trivijalno, jer može postojati više od jedne valjane metodologije ovisno o primjeni ili cilju, npr., za borbu protiv određene vrste napada u specifičnim mrežnim okolinama.

U pregledu znanstvenih radova o metodama verifikacije za IDS/IPS sustave primijećeni su različiti pristupi i tehnike korištene za procjenu učinkovitosti i pouzdanosti tih sustava. Proučeni radovi obuhvaćaju recentno razdoblje, a metode verifikacije uključuju usporedbu s drugim sustavima, testiranje s uzorcima podataka, kibernetičkim napadima i ranjivostima sustava. Jedan od zaključaka iz analize je da postoji naglasak na korištenju simuliranih testnih okruženja, dok je stvarno okruženje manje zastupljeno. Također, većina proučenih sustava nije prilagođena za rad u okruženju programski definirane mreže (SDN). Unatoč raznolikosti metoda verifikacije, u nekim slučajevima primjetan je nedostatak testiranja sa stvarnim kibernetičkim napadima ili ranjivostima. Sukladno proučenoj literaturi prijedlog za metodu verifikacije treba obuhvaćati sve nedostatke u dosadašnjim metodama. Potrebno je primijeniti metodu verifikacije na stvarno okruženje, umjesto isključivog fokusa na simulirane scenarije. Također, potrebno je koristiti stvarne mrežne podatke kako bi se bolje ocijenila stvarna učinkovitost IDS-a u praktičnim situacijama. Predloženo rješenje verifikacije treba biti prilagođeno dinamičnim i promjenjivim karakteristikama SDN okruženja. Uključivanje stvarnih kibernetičkih napada i ranjivosti predstavlja važan aspekt u verifikaciji IDS-a kako bi se simulirali stvarni scenariji sigurnosnih prijetnji i načini ublažavanja neželjenog efekta kibernetičkih napada. Uočeno je da većina postojećih IDS/IPS sustava preferira pasivnu poziciju. Ova česta orijentacija prema pasivnom nadzoru sugerira naglasak na ulozi sustava u analizi i praćenju prometa umjesto izravnom sudjelovanju u obrambenim aktivnostima. IDS/IPS sustavi mogu se pozicionirati u mrežnom okruženju kroz aktivni ili pasivni način rada [178]. Aktivni način uključuje postavljanje uređaja

izravno na putanju mrežnog prometa, omogućujući im analizu i brze akcije poput odbacivanja paketa ako se otkrije prijetnja. Ova metoda pruža bržu zaštitu, ali može uzrokovati kašnjenje u komunikaciji [179]. S druge strane, pasivni način rada uključuje nadzor kopije prometa, generiranje upozorenja na zlonamjerne aktivnosti, ali ne poduzimanje izravnih mjera zaštite mrežne komunikacije [180]. U oba načina rada, IDS/IPS se implementira kao uređaj na 2. sloju mreže, osiguravajući transparentnost i mogućnost dodavanja sigurnosne komponente bez temeljnih promjena u konfiguraciji ili dizajnu mreže. Ova transparentnost omogućava integraciju sigurnosnih mjera bez narušavanja stabilnosti i funkcionalnosti postojeće mreže, pružajući tako dodatnu sigurnost i obranu od prijetnji [181]. Stoga, pristup pozicioniranja IDS/IPS-a može ovisiti o specifičnim sigurnosnim zahtjevima i ciljevima kiberetičke sigurnosti pojedine organizacije.

Ukupno gledano, ovi prijedlozi sugeriraju korake za unapređenje metodologije verifikacije IDS-a, stvarajući poveznicu između teorijskih istraživanja i praktičnih izazova u stvarnim mrežnim scenarijima.

5.2. Prijedlog metode verifikacije modela za detekciju anomalija višestrukim NetFlow zapisima mrežnog prometa

Pregled literature rezultirao je uočavanjem nedostataka u metodama i procesu verifikacije modela za detekciju anomalija u mrežnom prometu, otvarajući mogućnost razvijanju nove metode verifikacije za predloženi NFMIDS model. Primjena predložene metode verifikacije obuhvatila je nekoliko bitnih koraka, uključujući:

- Usporedbu s drugim IDS/IPS sustavom kako bi se stekle detaljnije informacije o performansama predloženog modela.
- Testiranje kombiniranim uzorcima NetFlow podataka koji se sastoje od referentnih skupova podataka i stvarnog mrežnog prometa.
- Simulaciju stvarnih kibernetičkih napada radi oponašanja stvarnog scenarija.

Prijedlog nove motode verifikacije usmjeren je na verifikaciju za predloženi model detekcije anomalija temeljen na strojnom učenju i klasifikaciji NetFlow podataka mrežnog prometa.

Prema Slici 5.1 i definiranom tijeku procesa verifikacije, predložena metoda verifikacije na Slici 5.2 uvodi dodatne korake kako bi se prilagodila različitim mrežnim arhitekturama, uključujući hibridnu SDN arhitekturu.

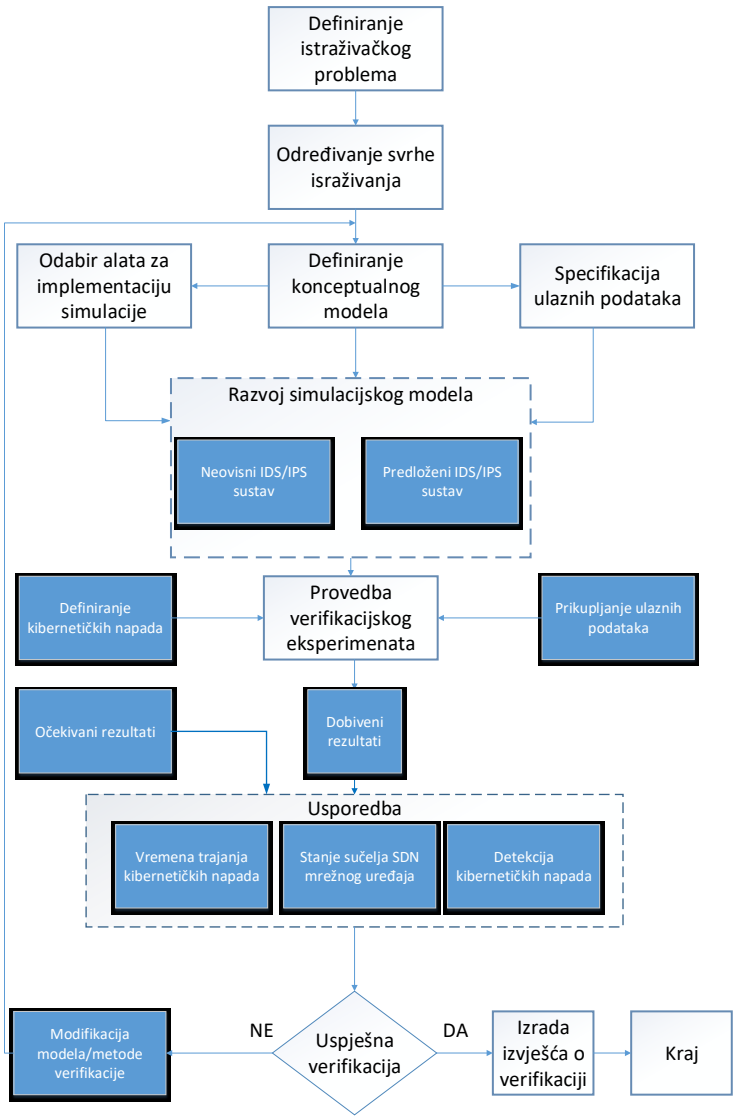

Slika 5.2 Predložena metoda verifikacije

Metoda verifikacije prikazana na Slici 5.2., uključuje sljedeće korake:

1. Definiranje istraživačkog problema: detekcija anomalija u hibridnoj programski definiranoj mreži;
2. Određivanje svrhe istraživanja: osiguranje kritičnih sustava od kibernetičkih napada;

3. Definiranje konceptualnog modela: predloženi NFMIDS model integrira se u stvarnu mrežnu okolinu. Određuju se mrežni uređaji koji sudjeluju u simulaciji kibernetičkih napada, uz razlikovanje uloge ovisno o tipu mrežnog uređaja (tradicionalni ili SDN);
4. Specifikaciju ulaznih podataka: ulazni podatci variraju ovisno o fazi procesa. Tijekom učenja NFMIDS modela, koristi se kombinirani promet referentnih skupova podataka i NetFlow zapisi iz mrežnih uređaja. U fazi verifikacije, ulazni podatci su isključivo izvezeni NetFlow zapisi mrežnog prometa s odabranih mrežnih uređaja;
5. Odabir alata za implementaciju simulacije: integracija predloženog NFMIDS modela s Python skriptama za klasifikaciju mrežnog prometa i funkcionalnostima SDN kontrolera i mrežnih uređaja. Paralelno se u verifikacijski proces uvodi neovisni IDS/IPS sustav radi usporedbe i potvrde uspješnosti detekcije anomalija;
6. Razvoj simulacijskog modela: uz predloženi NFMIDS model koji povezuje Python skripte za klasifikaciju mrežnog prometa s API funkcionalnošću SDN kontrolera i SDN mrežnih uređaja, paralelno se u proces verifikacije ubacuje neovisni IDS/IPS sustav pomoću kojega se može potvrditi i usporediti uspješnost predloženog modela za detekciju anomalija mrežnog prometa;
7. Provedbu verifikacijskog eksperimeta: slijedno se u određenim vremenskim intervalima provode ranije definirani kibernetički napadi, klasifikacijom dolaznih NetFlow podataka dobijaju se rezultati detekcije anomalija. Na temelju unaprijed zadanih vremenskih intervala određenih kibernetičkih napada uspoređuju se očekivani rezultati s dobivenim rezultatima provedenog verifikacijskog eksperimenta;
8. Usporedbu rezultata: uspoređuju se očekivani i dobiveni rezultati tri parametra verifikacijskog procesa: vrijeme izvršenja i trajanje kibernetičkih napada, stanje sučelja SDN uređaja tijekom detekcije anomalija te uspješnost detekcije pojedinih kibernetičkih napada;
9. Verifikaciju predloženog IDS/IPS modela: na temelju usporedbe rezultata donosi se ocjena verifikacije modela. U slučaju negativne ocjene, proces se vraća na fazu definiranja konceptualnog modela radi primjene drugih ulaznih vrijednosti i načina provedbe verifikacijskog postupka;

10. Dokumentiranje: za pozitivno ocijenjenu verifikaciju modela preporučuje se detaljno dokumentiranje procesa i rezultata kako bi se omogućio razvoj novih komponenata predloženog modela.

Predložena metoda verifikacije modela za detekciju anomalija u hibridnoj programski definiranoj mreži donosi nekoliko značajnih prednosti u odnosu na postojeće metode opisane u recentnoj literaturi.

Implementacija u hibridnom SDN okruženju predstavlja primarnu prednost, posebno zbog karakteristika hibridnih programski definiranih mreža koje integriraju klasičnu i SDN arhitekturu. To omogućuje promjenu statusa sučelja u SDN preklopniku, što je jedan od relevantnih podataka za ocjenu verifikacije. S obzirom na upotrebu strojnog učenja i NetFlow podataka u predloženom modelu, nužno je osigurati arhitekturu koja će optimalno iskoristiti ove komponente i biti primjenjiva u različitim sustavima.

Kroz korištenje višestrukih NetFlow zapisa podataka, metoda simulira raznolike scenarije koji uključuju normalan mrežni promet i različite kibernetičke napade. Ovaj pristup omogućava precizno oblikovanje NetFlow zapisa potrebnih za efikasnu detekciju anomalija. Predložena metoda omogućava slijedno testiranje različitih scenarija kibernetičkih napada, uz usporedbu rezultata detekcije drugih, neovisnih IDS/IPS sustava.

Predložena metoda verifikacije transparentna je u pogledu pozicije IDS/IPS sustava, omogućujući oba načina pozicioniranja koji su striktno definirani u postojećim rješenjima. Prednost ove transparentnosti očituje se u mogućnosti SDN uređaja da se programski prilagode novonastalim uvjetima na mreži, poput detekcije anomalija i kibernetičkih napada. Implementacija modela za detekciju anomalija u stvarno okruženje također povlači implementaciju verifikacije u stvarno okruženje, što pridonosi vjerodostojnosti rezultata ove metode.

Kombinirani skup podataka stvarnog mrežnog prometa s izazvanim kibernetičkim napadima pruža prednost u odnosu na testiranje samo s napadima ili fiksnim uzorcima podataka što je uobičajeno u postojećim metodama verifikacije. Osim što omogućuje širu pokrivenost mogućih scenarija, kombinirani skup podataka pruža realističniji prikaz stvarnih mrežnih uvjeta i ponašanja. Također, omogućuje verifikaciju modela pod različitim uvjetima opterećenja i promjenjivim mrežnim okolinama. S druge strane, testiranje samo s napadima ili fiksnim uzorcima podataka

može propustiti složenije scenarije ili neobične situacije koje se mogu pojaviti u stvarnim mrežnim uvjetima. Stoga je korištenje kombiniranog skupa podataka prednost za provjeru sigurnosti i performansi promatranog modela.

Konačno, dokumentacija procesa verifikacije pruža transparentnost i olakšava daljnje unapređenje modela, čime se postiže integracija ovog modela u stvarne svakodnevne operacije osiguranja kritičnih sustava od kibernetičkih prijetnji.

Predložena metoda verifikacije je potpuno adekvatna za model detekcije anomalija u hibridnoj programski definiranoj mreži jer obuhvaća sve relevantne komponente modela i njihovu funkcionalnost. Ovaj postupak verifikacije jasno pokazuje aktivnu ulogu NFMIDS modela u detekciji anomalija mrežnog prometa putem onemogućavanja sučelja koje napadač koristi za izvršavanje kibernetičkih napada. Dodatno, omogućuje precizno definiranje konfiguracije izvoza NetFlow podataka; u slučaju neispravnog NetFlow zapisa, verifikacija ne može biti potvrđena, što usmjerava model prema ispravnom konfiguriranju izvoza NetFlow zapisa.

Mogućnost paralelne usporedbe očekivanih i stvarnih rezultata s neovisnim IDS/IPS sustavom doprinosi važnosti procesa verifikacije i dobivenih rezultata. Ipak, u predloženoj metodi verifikacije postoji ograničenje u usporedbi s neovisnim IDS/IPS sustavom zbog nedostupnosti informacija o stanju sučelja SDN preklopnika. Budući da neovisni IDS/IPS sustav nema pristup tim informacijama, usporedba rezultata s njim ostaje na informativnoj razini, unatoč tome pridonosi relevantnosti rezultata verifikacije.

5.3. Verifikacija predloženog modela za otkrivanje anomalija mrežnog prometa predloženom metodom višestrukih Netflow zapisa

Prema predloženoj metodi verifikacije, koja obuhvaća korake definirane u poglavlju 5.2, prikazanim na Slici 5.2, izvršena je verifikacija NFMIDS modela. Detaljno objašnjenje implementacije pojedinih koraka opisane metode nalazi se u nastavku.

5.3.1. Definiranje istraživačkog problema

Istraživački problem definiran je kao detekcija anomalija u mrežnom prometu unutar hibridne programski definirane mreže korištenjem tehnika strojnog učenja.

5.3.2. Određivanje svrhe istraživanja

Svrha istraživanja je osigurati kritične sustave poslovanja, reprezentirane kroz tri različita uređaja nazvana Žrtva 1, Žrtva 2 i Žrtva 3, kako je prikazano na Slici 5.3.

5.3.3. Definiranje konceptualnog modela

Konceptualni model, opisan prethodno, podvrgnut je verifikaciji implementacijom predloženog NFMIDS modela u stvarnoj mrežnoj okolini. Uključeni su stvarni mrežni uređaji korporativne IP mreže koji omogućuju komunikacijsko povezivanje i prikupljanje NetFlow zapisa radi klasifikacije mrežnog prometa i detekcije anomalija. Cisco N9K-C93108TC-FX (SDN SW) preklopnik i SDN kontroler dio su hibridne programski definirane mreže, dok su Cisco C9300 uređaji (SW1 i SW2) tradicionalni uređaji. Korporativni NIDS integriran je u verifikacijski proces za usporedbu vremena i detekcije anomalija.

Verifikacija NFMIDS modela detekcije anomalija mrežnog prometa obuhvaćala je NetFlow zapise s tri preklopnika koji su na putu napadača prema jednoj od žrtava. Svi rezultati detekcija uspoređeni su s detekcijama Cisco Secure Network Analytics NIDS-a u korporativnoj mreži. Cisco Secure Network Analytics, nekada poznat kao Stealthwatch [182], alat je za analizu sigurnosti i praćenje prijetnji unutar komunikacijske mreže koristeći složeno modeliranje ponašanja, strojno učenje i globalne informacije o kibernetičkim prijetnjama. Sve aktivnosti provedene su unutar stvarne hibridne programski definirane mreže, što osigurava relevantnost rezultata u kontekstu specifičnog okruženja.

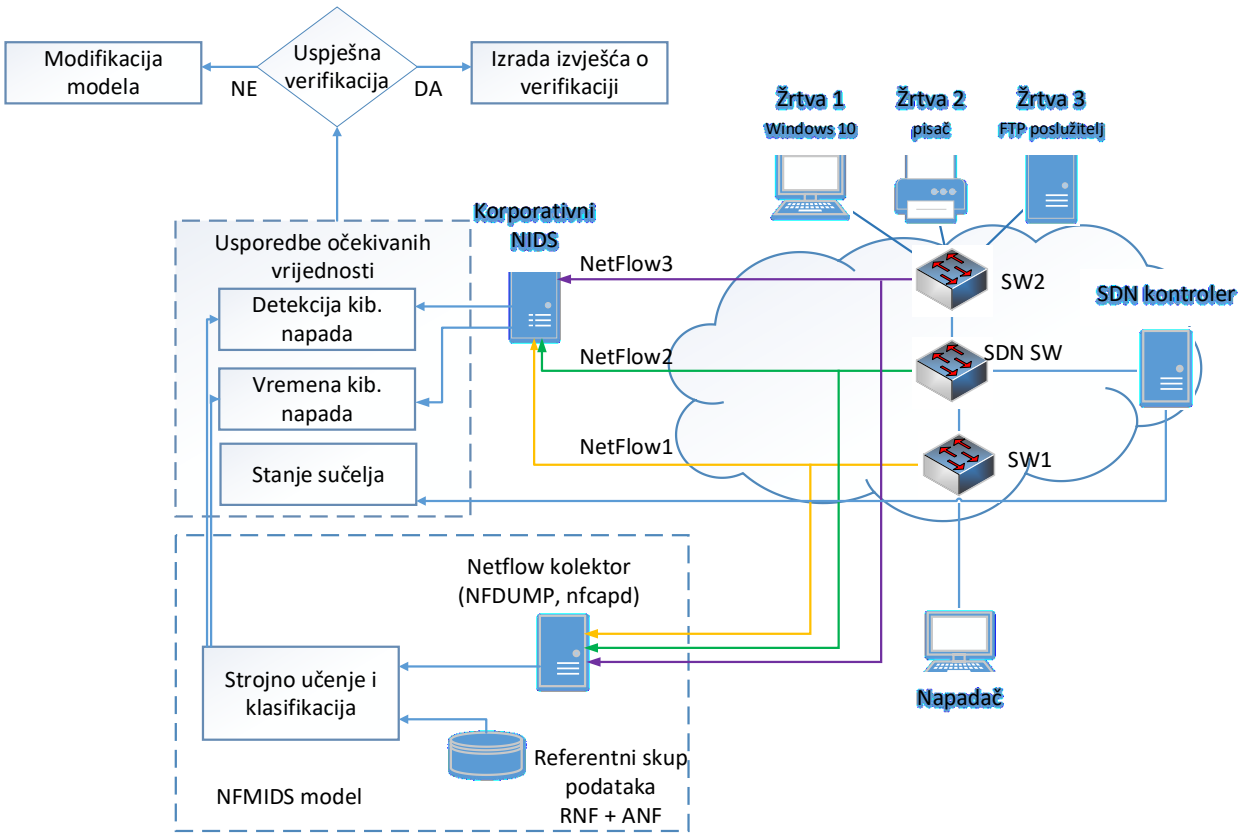

Slika 5.3 Arhitektura mrežne okoline prilikom verifikacije NFMIDS modela

Na Slici 5.3 prikazana je arhitektura mrežnog okruženja i procesa na kojoj je primijenjena verifikacija NFMIDS modela korištenjem predložene metode višestrukih NetFlow zapisa. Glavna karakteristika prikazanog mrežnog okruženja je hibridna programski definirana mreža koja obuhvaća tradicionalne preklopnike (SW1 i SW2) te SDN preklopnik (SDN SW). Putem ovih preklopnika povezani su uređaji-žrtve kibernetičkih napada i računalo napadača, kako je prikazano na Slici 5.3. Konfiguracija izvoza NetFlow zapisa na svakom preklopniku prilagođena je specifičnim mogućnostima pojedinog uređaja, što je detaljno opisano u Prilogu A za preklopnike SW1 i SW2, te u Prilogu B za SDN SW preklopnik. Svi NetFlow zapisi usmjereni su na obradu (klasifikaciju) u NFMIDS te na neovisni korporativni NIDS sustav prije samog postupka verifikacije. NFMIDS je prethodno naučen za klasifikaciju putem kombiniranog skupa podataka koji sadrži stvarne NetFlow zapise i zapise referentnog skupa podataka (anomalije).

Specifikacija i karakteristike uređaja korištenih u procesu verifikacije predloženog modela opisane su u Tablici 5-2.

Tablica 5-2 Specifikacija korištenih uređaja tijekom procesa verifikacije

Uređaj	Model	Operativni sustav/aplikacija
Napadač	HP Probook 6570b	Kali Linux
Žrtva1	HP Probook G455	Windows 10
Žrtva2	Pisač Lexmark CX510de	/
Žrtva3	HP EliteDesk 800 G4	Windows 10/FileZilla FTP Server 1.6.7
NIDS	Cisco Secure Network Analytics	Version 7.4.1
NFMIDS	Virtualni VMware ESXi poslužitelj	Linux Ubuntu 20.04, Python 3.8
SDN kontroler	CiscoAPIC Server M1	APIC Version 4.2(7v)
NetFlow kolektor	nfcapd	Version: NSEL-NEL1.6.18;
SW1	Cisco Catalyst 9300 Switch	Cisco IOS Software [Everest], Catalyst L3 Switch Software (CAT9K_IOSXE), Version 16.6.6
SW2	Cisco Catalyst 9300 Switch	Cisco IOS Software [Everest], Catalyst L3 Switch Software (CAT9K_IOSXE), Version 16.6.6
SDN SW	Cisco Nexus 93108TC-FX	Cisco NX-OS(tm) aci, Software (aci-n9000-system), Version 14.2(7v)

Kibernetički napadi su trajali tri minute, s intervalima od također tri minute za uspostavljanje normalnog režima rada i eventualno detektiranje lažnih klasifikacija. Napad skeniranja portova bio je kraći jer je skeniranje završilo u roku od samo dvije minute. Usporedba i analiza detekcije obuhvatila je jedan od tri tipa kibernetičkih napada izvršenih s računala napadača prema jednoj od žrtava, ovisno o vrsti napada definiranoj u poglavlju 4.2.2:

- Tip 1 - DoS – uskraćivanje usluge;
- Tip 2 - Otkrivanje korisničkih imena i lozinki – dobivanje neovlaštenog pristupa;
- Tip 3 - Skeniranje portova na udaljenom uređaju.

Tijekom postupka verifikacije pojedinačno su propuštani Netflow zapisi sa svakog preklopnika. Ciljano stanje u stvarnoj infrastrukturi je prikupljanje NetFlow zapisa sa svih uređaja koji podržavaju slanje NetFlow zapisa u kolektor. Tijekom verifikacije, IPS funkcionalnost u predloženom NFMIDS modelu nije bila aktivna kako bi se izbjeglo prekidanje verifikacijskog procesa. Umjesto toga, programiran je API zahtjev prema SDN kontroleru za blokiranje ili ponovno omogućavanje sučelja na SDN preklopniku.

5.3.4. Specifikacija ulaznih podataka

Ulazni podaci su definirani prema njihovoj upotrebi tijekom procesa verifikacije. U fazi učenja, korišten je kombinirani skup podataka koji obuhvaća stvarni mrežni promet i anomalije iz referentnog skupa podataka. Za klasifikaciju, ulazni podaci sastoje se isključivo od NetFlow zapisa koje izvoze mrežni uređaji. Tijekom učenja, ovi podaci su direktno učitani u Python skripte za strojno učenje, dok su u fazi klasifikacije podaci proslijeđeni preko NetFlow kolektora u iste skripte.

Proces verifikacije provođen je u stvarnoj mrežnoj okolini, prikazanoj na Slici 5.2, koristeći NetFlow zapise s tri preklopnika, od kojih je jedan u SDN paradigmi (SDN SW). Različite konfiguracije NetFlow zapisa, opisane u Prilogu A i Prilogu B disertacije, variraju prema mogućnostima svakog preklopnika. Na primjer, NetFlow1 i NetFlow3 zapisima promatraju se ulazno i izlazno sučelje paketa, dok se u NetFlow2 zapisu promatraju samo ulazni paketi. Konfiguracije se razlikuju i po mogućnostima "MATCH" i "COLLECT" naredbi koje određuju koji paketi i koje podatke NetFlow zapisa prikupljaju.

Uspoređujući rezultate vremena izvođenja, detekcije kibernetičkih napada i stanje sučelja SDN preklopnika tijekom aktiviranja napada uz određene NetFlow zapise, može se verificirati predloženi IDS/IPS model. Ova metoda verifikacije karakterizira se robustnošću jer ne ovisi o broju različitih NetFlow zapisa, što može poboljšati preciznost odluka. Također, omogućuje usporedbu različitih tipova neovisnih IDS-ova.

Prije bilo kakvog kibernetičkog napada, važno je provjeriti ispravnost izvoza NetFlow zapisa i njihovo uspješno prikupljanje od strane testiranih NFMIDS i korporativnog NIDS-a. To je

presudno za efikasno otkrivanje i analizu napada, jer problemi s izvozom NetFlow zapisa mogu otežati detekciju i smanjiti učinkovitost sigurnosnih mjera. Korištenjem traceroute alata (Prilog C), pruža se detaljan uvid u rute prometa kroz mrežu i potvrđuju se očekivane putanje mrežnog prometa, što je bitno za verifikaciju, kao što je prikazano na Slici 5.2.

5.3.5. Odabir alata za implementaciju simulacije

Python programski jezik odabran je za implementaciju klasifikacije putem strojnog učenja. Također, Python se koristio za izvršavanje API zahtjeva prema SDN kontroleru. Za provođenje različitih kibernetičkih napada na kritični sustav, korištena je Kali Linux distribucija operativnog sustava računala napadača.

5.3.6. Razvoj simulacijskog modela

U sklopu razvoja simulacijskog modela, implementiran je NFMIDS model koji integrira Python skripte za klasifikaciju mrežnog prometa s API funkcionalnostima SDN kontrolera i SDN mrežnih uređaja. Uz predloženi model, proces verifikacije je obogaćen uključivanjem neovisnog korporativnog NIDS sustava, što omogućuje potvrdu i usporedbu učinkovitosti predloženog modela u detekciji anomalija mrežnog prometa. Slika 5.4 prikazuje isječak rada NFMIDS-a u stvarnom vremenu, uz prisutnost pozadinskog prometa. Na slici su označeni dijelovi koji se odnose na prikupljanje NetFlow zapisa, detekciju anomalija, prebacivanje datoteke u karantenu, API zahtjeve za blokiranje sučelja te vrijeme normalnog rada mreže (bez prisutnosti kibernetičkih napada). Prikaz cjelokupnog testiranja nalazi se u prilogu F ove disertacije, zajedno s komentarima o vremenima početka i završetka generiranih kibernetičkih napada, kao i trajanju normalnog režima rada mreže. Tijekom normalnog režima rada mreže, identificirane su i označene i lažne detekcije. Pozadinski promet uključuje uobičajene aktivnosti korisnika korporativne mreže, koji

nisu bili obaviješteni o testiranju NFMIDS-a, te na taj način, normalan promet predstavlja reprezentativni uzorak stvarne mrežne okoline.

Slika 5.4 Isječak prikaza rada NFMIDS-a u stvarnom vremenu s kombiniranim pozadinskom prometom

5.3.7. Provedba verifikacijskog eksperimeta

Tijekom verifikacijskog eksperimenta, unaprijed definirani kibernetički napadi (DoS – uskraćivanje usluge, otkrivanje korisničkih imena i lozinki – dobivanje neovlaštenog pristupa, skeniranje portova na udaljenom uređaju) su se sukcesivno izvodili u točno određenim vremenskim intervalima. Klasifikacijom dolaznih NetFlow podataka dobiveni su rezultati detekcije anomalija. Sva tri mrežna uređaja konfigurirana su prema svojim mogućnostima za izvoz NetFlow podataka u kolektor kako je opisano u prilozima A i B. Ovisno o klasifikaciji dolaznih NetFlow podataka sa svakog mrežnog uređaja, spremaju se datoteke NetFlow zapisa u direktorije karantene ili benignog prometa, kako bi se naknadno verifikacijski eksperiment mogao poboljšati, ukoliko se pokaže potreba.

Tijekom procesa testiranja odnosno verifikacije predloženog modela s NetFlow1 konfiguracijom, NFMIDS i NIDS sustavi su detektirali sve tri vrste kibernetičkih napada, s malim postotkom lažno pozitivnih rezultata detekcije (1,15%) za NFMIDS model. Međutim, za korporativni NIDS nije bilo moguće odrediti postotak lažno pozitivnih detekcija (oznaka * u Tablici 5-3 za NIDS rezultate lažno pozitivnih rezultata) budući da ne postoji uvid u ukupan broj NetFlow zapisa prispjelih iz preklopnika SW1 kao niti koliko takvih zapisa je rezultiralo kao lažno pozitivne klasifikacije koje su stavljene u grupu detektiranih kibernetičkih napada. Korporativni NIDS pruža samo grupirane podatke o detektiranim sigurnosnim incidentima, što je prikazano na Slici 5.5.

Jedan od značajnih nedostataka korporativnog NIDS sustava leži u činjenici da su sigurnosni incidenti prikazani po specifičnim računalima ili IP adresama, a u ovom kontekstu nužno je poznavati IP adresu napadača (10.193.91.100) kako bi se dobila kompletna lista sigurnosnih incidenata, kao što je prikazano na Slici 5.5.

Slika 5.5 Prikaz detekcija sigurnosnih incidenata u korporativnom NIDS-u

Vremena detekcija kibernetičkih napada u predloženom NFMIDS modelu te u korporativnom NIDS sustavu u skladu su s vremenom izvršavanja kibernetičkih napada. Stanje sučelja SDN preklopnika na koji je spojeno računalo napadača odnosno izvršitelja kibernetičkih napada, praćeno je putem programiranog API zahtjeva za onemogućavanjem sučelja, vidljivo na Slici 8.2. Korporativni IDS nema mogućnost praćenja stanja sučelja SDN preklopnika stoga usporedba ovog podatka nije dio odluke za uspješnost verifikacije što je objašnjeno u poglavlju 7.2.

Uz NetFlow2 konfiguraciju i SDN preklopnik (SDN SW), predloženi NFMIDS nije dao jasne rezultate s obzirom da su detekcije sigurnosnih incidenata upitne zbog velikog broja lažno pozitivnih detekcija, čak 85%, dok NIDS sustav nije otkrio niti jednu vrstu kibernetičkog napada. Razlog ovako velikom postotku lažno pozitivnih detekcija leži u razlici konfiguracije NetFlow izvoza iz SDN mrežnog uređaja. Za korištenje predloženog NFMIDS-a potrebna je konfiguracija po ulaznom i izlazom sučelju te s više parametara NetFlow zapisa, u SDN preklopniku s postojećom verzijom pripadajućeg softvera nije moguće podesiti izvoz NetFlow zapisa po željenoj specifikaciji. Visok postotak lažno pozitivnih detekcija izračunat je na temelju detaljne analize rada NFMIDS-a tijekom testiranja, koja pokazuje koliko je zapisa unutar NetFlow zapisa klasificirano kao anomalije u odnosu na ukupan broj zapisa. Proces klasifikacije strojnog učenja optimiziran je za zadani skup podataka (NetFlow zapisi) kako bi se postigli najbolji rezultati detekcije. Vremena detekcije nisu bila u očekivanim vrijednostima zbog velikog broja lažno

pozitivnih klasifikacija, što je rezultiralo konstantnim API zahtjevima za onemogućavanjem sučelja SDN preklopnika, što nije usklađeno s vremenima izvršenja stvarnih kibernetičkih napada. Proces verifikacije uz NetFlow2 konfiguraciju pokazuje da takva konfiguracija nije pogodna za predložen model detekcije anomalija mrežnog prometa. Za očekivati je da će se konfiguracije NetFlow zapisa za SDN uređaje u budućnosti unaprijediti i omogućiti precizniju detekciju anomalija u predloženom modelu.

Konačno, za NetFlow3 konfiguraciju s SW2 preklopnikom, NFMIDS je uspješno detektirao sve tri vrste kibernetičkih napada, dok je korporativni NIDS identificirao samo dvije od tri vrste kao što je prikazano na Slici 5.6.. NFMIDS se istaknuo niskim postotkom lažno pozitivnih rezultata detekcije (0,12%), što ukazuje na preciznost modela u identifikaciji stvarnih sigurnosnih prijetnji.

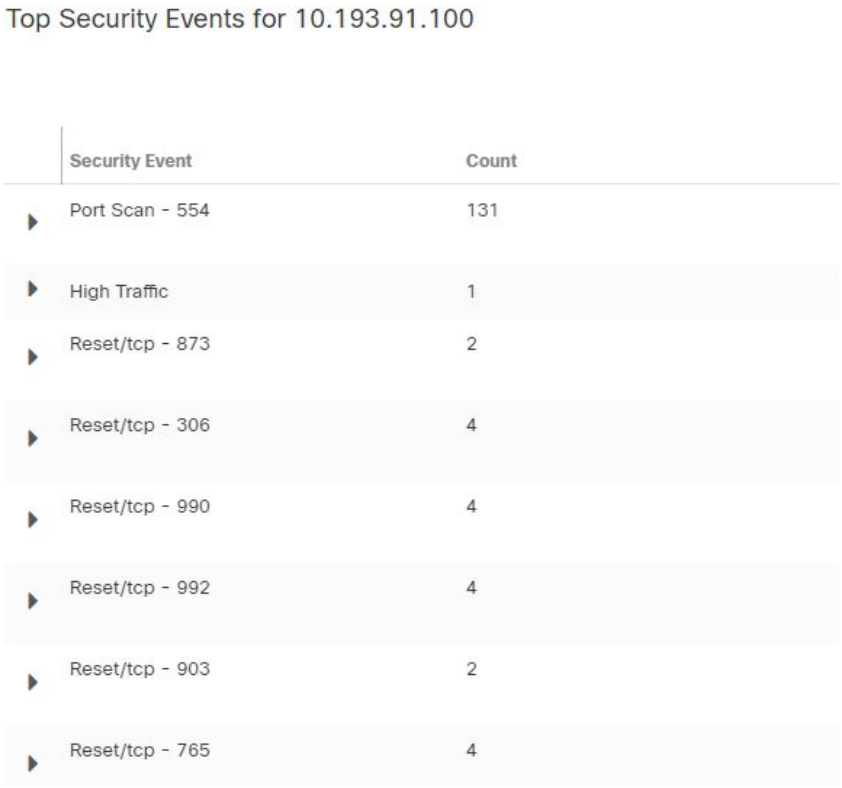

Slika 5.6 prikaz sigurnosnih incidenata i lažno pozitivnih detekcija u aplikaciji korporativnog NIDS-a

S druge strane, za NIDS sustav nije moguće odrediti postotak lažno pozitivnih detekcija zbog nedostatka informacija o ukupnom broju prikupljenih NetFlow zapisa tijekom normalnog režima rada bez kibernetičkih napada. U Tablici 5-3 je označeno prisustvo lažnih detekcija Reset/tcp (**) koje su grupirane i prikazane ukupnim brojem tijekom cijelog eksperimenta, što otežava određivanje specifičnog vremenskog intervala u kojem su se te lažne detekcije dogodile. Reset/tcp u aplikaciji korporativnog NIDS-a opisan je kao: "*Izvorišno računalo je poslalo TCP paket koji je odbijen od strane ciljnog računala. Ovaj sigurnosni događaj obično je posljedica neispravnih aplikacija, prepoznavanja operativnog sustava ili skeniranja TCP porta.*".

5.3.8. Usporedba rezultata

Uspoređeni su očekivani i dobiveni rezultati tri parametra verifikacijskog procesa: vrijeme izvršenja i trajanje kibernetičkih napada, stanje sučelja SDN preklopnika prilikom detekcije anomalija mrežnog prometa ili kibernetičkih napada te uspješnost detekcije pojedinog kibernetičkog napada. Očekivani rezultati su definirani provedbom verifikacijskog procesa, gdje su poznata vremena izvršenja i trajanja kibernetičkih napada s računala napadača. Također, poznato je sučelje na SDN preklopniku koje je povezano s računalom napadača.

Dodatna usporedba s rezultatima korporativnog NIDS-a pospješuje verifikacijski proces, ali nije moguće usporediti stanje sučelja SDN preklopnika jer korporativni NIDS ne pruža takve informacije. Usporedba je provedena ručno (zapisivanjem i pregledom promatranih parametara) zbog manjeg broja promatranih parametara, ali u slučaju povećanja broja parametara preporuča se automatizirana usporedba radi ubrzanja procesa.

Vremena detekcije u predloženom NFMIDS-u poklapaju se s očekivanim vremenima izvršenja sva tri kibernetička napada, kao i vremena API zahtjeva za onemogućavanjem sučelja SDN preklopnika. Korporativni NIDS je pokazao očekivana vremena detekcije kibernetičkih napada koji su bili detektirani, osim kibernetičkog napada tipa 3 (Otkrivanje korisničkih imena i lozinki – dobivanje neovlaštenog pristupa), koji nije bio detektiran u očekivanom vremenu izvršenja.

U Tablici 5-3 su sažeti rezultati testiranja izvršenih i detektiranih kibernetičkih napada, koji su se odnosili na različite konfiguracije izvoza NetFlow zapisa svih mrežnih preklopnika. Za izračun

apsolutnog i relativnog broja lažno pozitivnih detekcija analizirane su detekcije tijekom razdoblja normalnog prometa, kada kibernetički napadi nisu bili aktivni.

Tablica 5-3 Rezultati i usporedba detekcija kibernetičkih napada tijekom procesa verifikacije

Vrsta NetFlow konfiguracije	**IDS sustav**	**Detekcija kibernetičkih napada**			**Lažno pozitivni rezultati detekcije**
		Tip1	Tip2	Tip3	
NF1 (SW1)	NFMIDS	da	da	da	4/345 (1.15%)
	NIDS	da	da	da	ne *
NF2 (SDN SW)	NFMIDS	da	da	da	1900/2218 (85%)
	NIDS	ne	ne	ne	ne
NF3 (SW2)	NFMIDS	da	da	da	17/13906 (0,12%)
	NIDS	da	da	ne	da**

Važno je napomenuti da je analiza lažnih detekcija provedena samo za predloženi NFMIDS, jer je moguć detaljan uvid u NetFlow zapise. Nažalost, korporativni NIDS nije pružio istu mogućnost za dublji uvid u pristigle NetFlow zapise. Detaljan pregled NetFlow zapisa od strane NFMIDS-a omogućio je preciznije izračune apsolutnog i relativnog broja lažno pozitivnih klasifikacija, što je ključno za bolje razumijevanje učinkovitosti sustava detekcije.

Iz Tablice 5-3 se može zaključiti da su rezultati detekcije kibernetičkih napada varirali ovisno o konfiguraciji izvoza NetFlow zapisa i IDS sustavu korištenom u procesu verifikacije. Primijećeno je da je u testiranju s pozadinskim prometom (NetFlow3 zapisi) postotak lažno pozitivnih detekcija bio povoljniji (manji) u usporedbi s testiranjem bez pozadinskog prometa (NetFlow1 zapisi). To je rezultat većeg broja pristiglih NetFlow zapisa u nfcapd kolektor, što je omogućilo bolju klasifikaciju i detekciju neželjenog prometa. Visoka apsolutna i relativna stopa lažno pozitivnih rezultata tijekom testiranja predloženog NFMIDS-a s NetFlow2 konfiguracijom izvoza NetFlow zapisa proizlazi iz neadekvatno prilagođene konfiguracije izvoza NetFlow2 zapisa. Ova konfiguracija nije se pokazala povoljnom za detekciju anomalija, ni u predloženom NFMIDS-u ni u korporativnom NIDS-u, koji nije uspio identificirati nijedan kibernetički napad. Iako je NFMIDS model uspješno identificirao sva tri kibernetička napada, problem leži u nedostatku jasne separacije između stvarnih prijetnji i lažno pozitivnih detekcija. Ovaj visoki postotak lažno pozitivnih rezultata čini ovakvu detekciju anomalija nepovoljnom za donošenje relevantnih odluka o sprječavanju i prevenciji kibernetičkih napada.

5.3.9. Verifikacija predloženog IDS/IPS modela

Na temelju usporedbe rezultata, daje se ocjena verifikacije modela prema Tablici 5-4. U slučaju negativne ocjene, kao što je bio slučaj s korištenjem NetFlow zapisa za klasifikaciju dobivenih iz SDN SW preklopnika, postupak se vraća na fazu definiranja konceptualnog modela. U toj fazi je potrebno razmotriti primjenu drugih ulaznih vrijednosti ili izmijeniti način provedbe verifikacijskog postupka. Kod pozitivne ocjene verifikacije, predloženi model je spreman za implementaciju i upotrebu u stvarnoj produkcijskoj okolini, pružajući zaštitu kritičnog sustava od kibernetičkih napada. U skladu s predloženom metodom verifikacije, Tablica 5-4 prikazuje postignute rezultate tijekom verifikacije u odnosu na očekivane vrijednosti promatranih parametara za ocjenu verifikacije predloženog NFMIDS modela za detekciju anomalija.

Tablica 5-4 Ocjena verifikacije predloženog NFMIDS modela

				Detekcija kib. napada	**Stanje sučelja SDN preklopnika**	**Očekivano vrijeme i trajanje detekcije kib. napada**	**Verifikacija**
Vrsta NetFlow konfiguracije	NF1 (SW1)	Tip kib. napada	1	da	blokiran	da	da
			2	da	blokiran	da	
			3	da	blokiran	da	
	NF2 (SDN SW)	Tip kib. napada	1	da	blokiran	ne	ne
			2	da	blokiran	ne	
			3	da	blokiran	ne	
	NF3 (SW3)	Tip kib. napada	1	da	blokiran	da	da
			2	da	blokiran	da	
			3	da	blokiran	da	

Prema predloženoj metodi verifikacije, NFMIDS model je uspješno verificiran u dva slučaja kada je izvoz NetFlow zapisa na preklopniku bio konfiguriran na preporučeni način. U slučaju negativne ocjene verifikacije prilikom korištenja NF2 konfiguracije NetFlow zapisa, sučelje je konstantno bilo onemogućeno (off) zbog izrazito visokog broja lažno pozitivnih rezultata klasifikacije, što je detaljno objašnjeno u Tablici 5-3. Iako su svi kibernetički napadi bili

detektirani u tom slučaju, treba napomenuti da je zabilježen izrazito visok broj lažno pozitivnih klasifikacija, što nije u skladu s očekivanim vremenima i trajanjima detekcija kibernetičkih napada. Iz tog razloga, verifikacija predloženog modela nije ocijenjena pozitivno prilikom korištenja NF2 konfiguracije NetFlow izvoza podataka. S druge strane, kada su korištene NF1 ili NF3 konfiguracije NetFlow izvoza podataka, model je postigao očekivane rezultate detekcije i trajanja sva tri kibernetička napada, uz adekvatno stanje sučelja SDN preklopnika tijekom detekcije kibernetičkih napada.

Predložena metoda verifikacije ističe da uspješnost detekcije kibernetičkih napada tijekom procesa verifikacije, kao i postotak lažno pozitivnih rezultata detekcije, značajno ovise o odabiru konfiguracije izvoza NetFlow zapisa i IDS sustava. Verifikacija je obuhvatila kombinaciju metoda s i bez pozadinskog prometa, uključujući generički promet predstavljen kibernetičkim napadima. Korišteno je pasivno pozicioniranje NFMIDS modela, no uključivanjem IPS funkcionalnosti omogućeno je aktivno djelovanje koje reagira na detektirane anomalije.

5.3.10. Dokumentiranje

Pozitivno ocijenjena verifikacija je dokumentirana detaljnim opisom postupka, uključujući shemu topologije mrežne arhitekture, korištene Python skripte te konfiguracije NetFlow izvoza na svakom tipu mrežnih preklopnika.

Tijekom verifikacije su identificirani nedostatci i prednosti ispitivanog NFMIDS-a, što može usmjeriti daljnji razvoj i poboljšanje modela. Uspoređujući ga s postojećim korporativnim IDS sustavom, NFMIDS model je pokazao veću fleksibilnost u korištenju NetFlow zapisa, što omogućuje smanjenje lažno pozitivnih detekcija putem dodatne inspekcije NetFlow zapisa koji uzrokuju takve lažno pozitivne alarme. Uključivanje takvih zapisa u proces ponovnog strojnog učenja značajno doprinosi smanjenju broja lažno pozitivnih detekcija.

Uz pravilnu detekciju sigurnosnih incidenata korporativni NIDS pruža i opis detektirane anomalije, u slučaju provedenog procesa verifikacije kibernetički napadi su opisani kao:

- High Traffic: Prosječna stopa prometa na računalu tijekom petominutnog razdoblja premašila je ograničenje prihvatljivih vrijednosti prometa - za kibernetički napad tipa 1.

- Port Scan: Izvor IP adrese je pokušao povezati se s prekomjernim brojem vrata na ciljnoj IP adresi – za kibernetički napad tipa 2.
- Brute Force Login - 21: Računalo detektira niz kratkih TCP veza koje se podudaraju s pokušajem grubog probijanja lozinke kroz ponavljane prijave – za kibernetički napad tipa 3.

Ovi opisi mogu pružiti detaljnije smjernice za moguće strategije obrane od budućih sigurnosnih incidenata te su korisni za nadogradnju NFMIDS modela. U budućim fazama učenja, model će trebati koristiti označene skupove podataka koji detaljno opisuju svaki kibernetički napad u ulaznim zapisima kako bi se osigurala preciznost procesa strojnog učenja. Nadalje, preporučuje se proširenje predloženih algoritama pseudokoda, tj. Algoritma 2 i Algoritma 3.

Alati i metodologije potrebni za standardizirano testiranje sustava za otkrivanje upada još uvijek nisu dovoljno razvijeni u javno dostupnom prostoru kako bi omogućili potrebne usporedne testove i evaluacije novih algoritama. Postoji značajna potreba za otvorenim okruženjem koje bi omogućilo generiranje prometa i umetanje napada na način koji se može uniformno koristiti za evaluaciju detekcije upada. Većina prijedloga za verifikaciju IDS sustava navedenih u literaturi ostaje na razini koncepta i često nisu implementirani u stvarnim okruženjima. Nasuprot tome, NFMIDS predstavljen u ovoj disertaciji implementiran je u stvarnoj korporativnoj mreži i dokazao se kao učinkovito rješenje za klasifikaciju prometa te sposoban za otkrivanje anomalija mrežnog prometa u stvarnom vremenu.

6. ZAKLJUČAK

U okviru doktorske disertacije razmatran je model za otkrivanje napada u mreži temeljen na strojnom učenju te se istražila njegova efikasnost u zaštiti mreža od kibernetičkih prijetnji. Proces izrade modela klasifikacije mrežnog prometa za otkrivanje anomalija uključivao je prikupljanje podataka o toku prometa, ispitivanje algoritama strojnog učenja na javno dostupnim skupovima podataka, te predobradu podataka s ciljem optimizacije performansi modela. Korištena su tri cjelovita skupa podataka (UNSW-NB15, CSE-CIC-IDS2018, LUFlow2021) i pet prilagođenih NetFlow skupova podataka. Analiza utjecaja različitih postupaka predobrade identificirala je postupke za optimizaciju ulaznih podataka. Postupci predobrade podataka uključivali su eliminaciju nepotrebnih značajki, čišćenje i uklanjanje neispravnih vrijednosti, kodiranje kategorijskih značajki, odabir omjera podataka za učenje i testiranje, te skaliranje podataka kako bi poboljšali performanse modela strojnog učenja.

Ispitivanjem četiri često korištena klasifikatora (Slučajna šuma, Stroj s potpornim vektorima, Naivni Bayes i K-najbliži susjed) na javno dostupnim skupovima podataka ukazalo je na najveću učinkovitost klasifikatora Slučajne šume, postižući AUC točnost od 99.98% na skupu podataka LUFlow2021. Optimizacija hiperparametara za klasifikator Slučajne šume provedena je kroz unakrsnu validaciju pomoću funkcije GridSearchCV, postižući najbolje rezultate AUC točnosti od 99.99% s odabranim parametrima. Redukcijom i odabirom najrelevantnijih značajki pokazalo je da osam odabranih značajki rezultira jednakom točnosti klasifikacije kao kada se koristi cijeli skup od jedanaest značajki na referentnom skupu podataka LUFlow2021. Predloženi NFMIDS model, temeljen na optimiziranom klasifikatoru Slučajne šume i referentnom skupu podataka LUFlow2021 sa smanjenim brojem značajki, pokazuje visoku točnost klasifikacije. Integracija ovog modela u tradicionalno mrežno okruženje nadograđeno programski definiranim mrežnim uređajima omogućava brzu reakciju na otkrivene prijetnje. Predloženi model je testiran s prikupljenim stvarnim mrežnim prometom, a rezultati potvrđuju njegovu uspješnost s visokim vrijednostima AUC i F2 točnosti od 98,09% i 99,13%.

Kibernetički napadi, uključujući DoS, otkrivanje korisničkih podataka i skeniranje portova, bili su dio procesa verifikacije. Svi napadi su uspješno identificirani, a vremena detekcije su se kretala od nekoliko sekundi do minute. Razlike u vremenima detekcije mogu se objasniti

karakteristikama mrežnog uređaja te dizajnom predloženog modela za detekciju anomalija. Implementacijom predloženog NFMIDS modela u hibridnoj programski definiranoj mreži postignuta je visoka učinkovitost u otkrivanju i zaustavljanju kibernetičkih napada. Integracijom IPS funkcionalnosti omogućilo se uspješno blokiranje napada, čime su istaknute prednosti implementacije modela u hibridnoj programski definiranoj mreži..

Implementacija predloženog modela za detekciju anomalija u stvarnom mrežnom prometu je kompleksan proces koji uključuje temeljito testiranje, verifikaciju i prilagodbu. Završna faza ovog istraživanja usmjerena je na verifikaciju i sposobnost detekcije anomalija putem analize NetFlow zapisa s tri preklopnika između napadača i žrtve, dodatno uspoređujući rezultate s postojećim korporativnim NIDS-om. Predložena je verifikacija višestrukim NetFlow zapisima koja je obuhvatila tri vrste kibernetičkih napada: DoS, pokušaje otkrivanja korisničkih imena i lozinki te skeniranje portova na udaljenim uređajima. NetFlow zapisi korišteni u istraživanju bili su definirani za ulazni i izlazni promet (NetFlow1 i NetFlow3) te samo za ulazni promet (NetFlow2). Bitna razlika u konfiguraciji NetFlow zapisa proizlazi iz različitih mogućnosti tradicionalnih i SDN preklopnika. U procesu verifikacije, IPS funkcionalnost NFMIDS modela nije bila aktivna kako bi se izbjeglo prekidanje procesa. Metoda predložene verifikacije uključivala je testiranje modela s dva scenarija: jedan bez prisustva pozadinskog prometa (samo preklopnik SW1) i drugi s kombiniranim stvarnim pozadinskim prometom (NetFlow zapisi iz SDN preklopnika ili preklopnika SW2). NFMIDS model bio je postavljen u pasivnom načinu rada kako bi minimalno utjecao na normalnu propusnost korporativne mreže tijekom verifikacije.

Ostvareni znanstveni doprinosi ove disertacije su sljedeći:

1. Postupak odabira i prilagodbe skupa ulaznih podataka za algoritam klasifikacije u svrhu otkrivanja anomalija u hibridnoj programski definiranoj mreži
2. Model za otkrivanje anomalija mrežnog prometa u hibridnoj programski definiranoj mreži primjenom algoritma za klasifikaciju putem strojnog učenja
3. Metoda verifikacije predloženog modela u stvarnom okruženju

Znanstveni doprinos ove disertacije obuhvaća postupak odabira i prilagodbe skupa ulaznih podataka s ciljem optimizacije algoritma klasifikacije za otkrivanje anomalija u hibridnoj programski definiranoj mreži. Ovim putem omogućava se sustavno i učinkovito upravljanje ulaznim podatcima kako bi se poboljšale performanse klasifikacije, posebno u kontekstu hibridnog

programski definiranog okruženja. Kroz integraciju algoritama klasifikacije s posebnim naglaskom na strojnom učenju, istraživački doprinos temelji se na razvoju modela za otkrivanje anomalija u hibridnoj programski definiranoj mreži. Predloženi model postavlja temelj za daljnja istraživanja u području otkrivanja anomalija u hibridnim programski definiranim mrežama. Doprinos ovog istraživanja ogleda se i u razvoju i primjeni metode verifikacije koja se temelji na analizi očekivanih i postignutih rezultata detekcije anomalija, vremena trajanja kibernetičkih napada te stanja sučelja SDN preklopnika pomoću višestrukih NetFlow zapisa u stvarnom mrežnom okruženju.

NFMIDS model detektiranja anomalija, predstavljen u ovoj disertaciji, nije samo teorijski koncept, već je implementiran i testiran u stvarnoj korporativnoj mreži. Rezultati su potvrdili izvrsnu klasifikaciju mrežnog prometa i sposobnost otkrivanja anomalija u stvarnom vremenu. Ova praktična implementacija čini predloženi model relevantnim i učinkovitim za stvarne mrežne okoline, što je ključno za efikasno otkrivanje i obranu od kibernetičkih prijetnji.

Buduća istraživanja fokusirat će se na proučavanje nenadziranih algoritama strojnog učenja, usporedbu njihovih performansi s nadziranim algoritmima korištenim u ovoj disertaciji te analizu vremenskog trajanja potrebnog za učenje i klasifikaciju. Cilj je bolje razumjeti prednosti i nedostatke nenadziranih metoda u odnosu na nadzirane, istražujući ponašanje različitih algoritama u različitim scenarijima mrežne sigurnosti. Ovo će pridonijeti boljem odabiru algoritama za buduća istraživanja o detekciji i zaštiti od kibernetičkih prijetnji. Dodatne mogućnosti poboljšanja detekcije anomalija predloženog modela uključuju prilagodbu postupka onemogućavanja sučelja mrežnog uređaja uz uzimanje u obzir vremenskih okvira i zadrški kako bi se smanjile posljedice lažno pozitivnih klasifikacija. Umjesto trenutnog isključivanja sučelja pri otkrivanju anomalija, moguća je nadogradnja sustava koja uključuje dodatne provjere prije donošenja konačne odluke, uključujući praćenje kontinuiranosti anomalija kroz vremenske intervale. Ovakav pristup omogućio bi sustavu bolje razlikovanje stvarnih prijetnji od privremenih fluktuacija ili nepravilnosti u mrežnom prometu. Buduća istraživanja će također razmotriti podršku za IPFIX protokol radi kompatibilnosti s otvorenim rješenjima za programski definirane mreže, poput OpenDaylight kontrolera i OpenFlow protokola za integraciju algoritama strojnog učenja izravno u SDN kontrolere. Nadalje, buduće istraživanje će se fokusirati na razvoj novih metoda i tehnika

za optimizaciju algoritama strojnog učenja u SDN okruženju kako bi se osigurala učinkovita obrada velike količine mrežnog prometa u stvarnom vremenu.

Kontinuirano poboljšanje i testiranje NFMIDS modela predstavljaju ključnu komponentu njegove održivosti i učinkovitosti, s obzirom na širok spektar kibernetičkih prijetnji koje se konstantno pojavljuju. Buduća unaprjeđenja, uključujući i proširenje postojeće IPS funkcionalnosti, donose dodatne prednosti u stvaranju snažnijeg i otpornijeg sustava za zaštitu mreža od potencijalnih prijetnji. Kroz ovaj proces unaprjeđenja, mogu se identificirati potencijalne slabosti i izazovi te razviti nove strategije za njihovo rješavanje.

LITERATURA

[1] N. al Khater and R. E. Overill, “Network traffic classification techniques and challenges,” in *2015 Tenth International Conference on Digital Information Management (ICDIM)*, IEEE, Oct. 2015, pp. 43–48. doi: 10.1109/ICDIM.2015.7381869.

[2] A. Malik, R. de Frein, M. Al-Zeyadi, and J. Andreu-Perez, “Intelligent SDN Traffic Classification Using Deep Learning: Deep-SDN,” in *2020 2nd International Conference on Computer Communication and the Internet (ICCCI)*, IEEE, Jun. 2020, pp. 184–189. doi: 10.1109/ICCCI49374.2020.9145971.

[3] N. Ahmed *et al.*, “Network Threat Detection Using Machine/Deep Learning in SDN-Based Platforms: A Comprehensive Analysis of State-of-the-Art Solutions, Discussion, Challenges, and Future Research Direction,” *Sensors*, vol. 22, no. 20, p. 7896, Oct. 2022, doi: 10.3390/s22207896.

[4] U. Ghosh, P. Chatterjee, S. S. Shetty, C. Kamhoua, and L. Njilla, “Towards Secure Software-Defined Networking Integrated Cyber-Physical Systems: Attacks and Countermeasures,” *Cybersecurity and Privacy in Cyber-Physical Systems*, no. February, pp. 103–132, 2019, doi: 10.1201/9780429263897-6.

[5] F. N. Khan, Y. Saleem, and M. K. Bashir, “Migration of Multiplatform Legacy Network to Single Software-Defined-Network (SDN),” *Proceedings - 2018 International Conference on Computing, Electronics and Communications Engineering, iCCECE 2018*, pp. 333–338, 2019, doi: 10.1109/iCCECOME.2018.8658652.

[6] C. Lorenz *et al.*, “An SDN/NFV-Enabled Enterprise Network Architecture Offering Fine-Grained Security Policy Enforcement,” *IEEE Communications Magazine*, vol. 55, no. 3, pp. 217–223, 2017, doi: 10.1109/MCOM.2017.1600414CM.

[7] J. H. Cox *et al.*, “Advancing software-defined networks: A survey,” *IEEE Access*, vol. 5, pp. 25487–25526, 2017, doi: 10.1109/ACCESS.2017.2762291.

[8] V. H. Dixit, S. Kyung, Z. Zhao, A. Doupé, Y. Shoshitaishvili, and G.-J. Ahn, “Challenges and Preparedness of SDN-based Firewalls,” in *Proceedings of the 2018 ACM International Workshop on Security in Software Defined Networks & Network Function Virtualization*, New York, NY, USA: ACM, Mar. 2018, pp. 33–38. doi: 10.1145/3180465.3180468.

[9] R. Amin, M. Reisslein, and N. Shah, “Hybrid SDN networks: A survey of existing approaches,” *IEEE Communications Surveys and Tutorials*, vol. 20, no. 4. pp. 3259–3306, 2018. doi: 10.1109/COMST.2018.2837161.

[10] M. Canini, A. Feldmann, D. Levin, F. Schaffert, and S. Schmid, “Software-defined networks: Incremental deployment with panopticon,” *Computer (Long Beach Calif)*, vol. 47, no. 11, pp. 56–60, 2014, doi: 10.1109/MC.2014.330.

[11] K. Humayun, “Software Defined Networking (SDN): A Revolution in Computer Network,” *IOSR J Comput Eng*, vol. 15, no. 5, pp. 103–106, 2013, doi: 10.9790/0661-155103106.

[12] I. Alsmadi and D. Xu, “Security of Software Defined Networks: A survey,” *Comput Secur*, vol. 53, pp. 79–108, 2015, doi: 10.1016/j.cose.2015.05.006.

[13] “Software-Defined Networking (SDN) Definition.” [Online]. Available: https://www.opennetworking.org/sdn-definition/

[14] “APIC Enterprise Module API Overview.” Accessed: Jan. 26, 2023. [Online]. Available: https://developer.cisco.com/docs/apic-em/#!overview/cisco-apic-em-northbound-interface

[15] O. N. F. Solution, B. September, and ONF, “SDN in the Campus Environment,” *ONF workshpop*, 2013.

[16] X. Huang, S. Cheng, K. Cao, P. Cong, T. Wei, and S. Hu, “A Survey of Deployment Solutions and Optimization Strategies for Hybrid SDN Networks,” *IEEE Communications Surveys & Tutorials*, vol. 21, no. 2, pp. 1–25, 2018.

[17] M. Nkosi, A. Lysko, L. Ravhuanzwo, T. Nandeni, and A. Engelberencht, “Classification of SDN distributed controller approaches: A brief overview,” *Proceedings - 2016 3rd International Conference on Advances in Computing, Communication and Engineering, ICACCE 2016*, pp. 342–344, 2017, doi: 10.1109/ICACCE.2016.8073772.

[18] P. Vijay Tijare and D. Vasudevan, “THE NORTHBOUND APIs OF SOFTWARE DEFINED NETWORKS,” © *International Journal of Engineering Sciences & Research Technology*, vol. 501, no. January 2019, 2016, doi: 10.5281/zenodo.160891.

[19] S. Bailey *et al.*, “SDN Architecture Overview,” *EPC and 4G Packet Networks*, pp. 17–64, 2013, doi: 10.1016/b978-0-12-394595-2.00002-5.

[20] J. N. Binlun, T. S. Chin, L. C. Kwang, Z. Yusoff, and R. Kaspin, “Challenges and Direction of Hybrid SDN Migration in ISP networks,” *2018 IEEE International Conference on Electronics and Communication Engineering, ICECE 2018*, pp. 60–64, 2019, doi: 10.1109/ICECOME.2018.8644812.

[21] S. Vissicchio, L. Vanbever, and O. Bonaventure, “Opportunities and research challenges of hybrid software defined networks,” *Computer Communication Review*, vol. 44, no. 2, pp. 70–75, 2014, doi: 10.1145/2602204.2602216.

[22] S. Vissicchio, L. Vanbever, L. Cittadini, G. G. Xie, and O. Bonaventure, “Safe update of hybrid SDN networks,” *IEEE/ACM Transactions on Networking*, vol. 25, no. 3, pp. 1649–1662, 2017, doi: 10.1109/TNET.2016.2642586.

[23] J. Galán-Jiménez, “Exploiting the control power of SDN during the transition from IP to SDN networks,” *International Journal of Communication Systems*, vol. 31, no. 5, pp. 1–19, 2018, doi: 10.1002/dac.3504.

[24] W. Wang, W. He, and J. Su, “Boosting the Benefits of Hybrid SDN,” *Proc Int Conf Distrib Comput Syst*, pp. 2165–2170, 2017, doi: 10.1109/ICDCS.2017.302.

[25] Sandhya, Y. Sinha, and K. Haribabu, “A survey: Hybrid SDN,” *Journal of Network and Computer Applications*, vol. 100, no. March, pp. 35–55, 2017, doi: 10.1016/j.jnca.2017.10.003.

[26] L. F. Carvalho, T. Abrão, L. de S. Mendes, and M. L. Proença, “An ecosystem for anomaly detection and mitigation in software-defined networking,” *Expert Syst Appl*, vol. 104, pp. 121–133, Aug. 2018, doi: 10.1016/j.eswa.2018.03.027.

[27] P. Radoglou-Grammatikis *et al.*, “Modeling, Detecting, and Mitigating Threats against Industrial Healthcare Systems: A Combined Software Defined Networking and Reinforcement Learning Approach,” *IEEE Trans Industr Inform*, vol. 18, no. 3, 2022, doi: 10.1109/TII.2021.3093905.

[28] H. A. Alamri, V. Thayananthan, and J. Yazdani, “Machine Learning for Securing SDN based 5G Network,” *Int J Comput Appl*, vol. 174, no. 14, 2021, doi: 10.5120/ijca2021921027.

[29] L. Zhang, G. Shou, Y. Hu, and Z. Guo, “Deployment of Intrusion Prevention System based on Software Defined Networking,” *International Conference on Communication Technology Proceedings, ICCT*, pp. 26–31, 2013, doi: 10.1109/ICCT.2013.6820345.

[30] H. Wang and B. Wu, “SDN-based hybrid honeypot for attack capture,” *Proceedings of 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference, ITNEC 2019*, no. Itnec, pp. 1602–1606, 2019, doi: 10.1109/ITNEC.2019.8729425.

[31] W. Fan and D. Fernandez, “A novel SDN based stealthy TCP connection handover mechanism for hybrid honeypot systems,” *2017 IEEE Conference on Network Softwarization: Softwarization Sustaining a Hyper-Connected World: en Route to 5G, NetSoft 2017*, 2017, doi: 10.1109/NETSOFT.2017.8004194.

[32] J. Chukwu, O. Osamudiamen, and A. Matrawy, “IDSaaS in SDN: Intrusion Detection System as a service in software defined networks,” *2016 IEEE Conference on Communications and Network Security, CNS 2016*, pp. 356–357, 2017, doi: 10.1109/CNS.2016.7860509.

[33] M. Monshizadeh, V. Khatri, and R. Kantola, “Detection as a service: An SDN application,” *International Conference on Advanced Communication Technology, ICACT*, pp. 285–290, 2017, doi: 10.23919/ICACT.2017.7890099.

[34] J. E. Varghese and B. Muniyal, “An Efficient IDS Framework for DDoS Attacks in SDN Environment,” *IEEE Access*, vol. 9, pp. 69680–69699, 2021, doi: 10.1109/ACCESS.2021.3078065.

[35] M. Al Razib, D. Javeed, M. T. Khan, R. Alkanhel, and M. S. A. Muthanna, “Cyber Threats Detection in Smart Environments Using SDN-Enabled DNN-LSTM Hybrid Framework,” *IEEE Access*, vol. 10, pp. 53015–53026, 2022, doi: 10.1109/ACCESS.2022.3172304.

[36] M. Ammar, M. Rizk, A. Abdel-Hamid, and A. K. Aboul-Seoud, “A framework for security enhancement in SDN-based datacenters,” *2016 8th IFIP International Conference on New Technologies, Mobility and Security, NTMS 2016*, pp. 3–6, 2016, doi: 10.1109/NTMS.2016.7792427.

[37] C. Birkinshaw, E. Rouka, and V. G. Vassilakis, “Implementing an intrusion detection and prevention system using software-defined networking: Defending against port-scanning and denial-of-service attacks,” *Journal of Network and Computer Applications*, vol. 136, no. February, pp. 71–85, 2019, doi: 10.1016/j.jnca.2019.03.005.

[38] C. V. Neu, C. G. Tatsch, R. C. Lunardi, R. A. Michelin, A. M. S. Orozco, and A. F. Zorzo, “Lightweight IPS for port scan in OpenFlow SDN networks,” *IEEE/IFIP Network Operations and Management Symposium: Cognitive Management in a Cyber World, NOMS 2018*, pp. 1–6, 2018, doi: 10.1109/NOMS.2018.8406313.

[39] R. F. Pratama, N. A. Suwastika, and M. A. Nugroho, “Design and implementation adaptive Intrusion Prevention System (IPS) for attack prevention in software-defined network (SDN) architecture,” *2018 6th International Conference on Information and Communication Technology, ICoICT 2018*, vol. 0, no. c, pp. 299–304, 2018, doi: 10.1109/ICoICT.2018.8528735.

[40] J. Xie *et al.*, “A survey of machine learning techniques applied to software defined networking (SDN): Research issues and challenges,” *IEEE Communications Surveys and Tutorials*, vol. 21, no. 1. Institute of Electrical and Electronics Engineers Inc., pp. 393–430, Jan. 01, 2019. doi: 10.1109/COMST.2018.2866942.

[41] P. K. Mondal, L. P. Aguirre Sanchez, E. Benedetto, Y. Shen, and M. Guo, “A dynamic network traffic classifier using supervised ML for a Docker-based SDN network,” *Conn Sci*, vol. 33, no. 3, pp. 693–718, Jul. 2021, doi: 10.1080/09540091.2020.1870437.

[42] D. Jankowski and M. Amanowicz, “A study on flow features selection for malicious activities detection in software defined networks,” *2018 International Conference on Military Communications and Information Systems, ICMCIS 2018*, pp. 1–9, 2018, doi: 10.1109/ICMCIS.2018.8398697.

[43] N. Mazhar, R. Salleh, M. Zeeshan, M. M. Hameed, and N. Khan, “R-IDPS: Real time SDN based IDPS system for IoT security,” in *HONET 2021 - IEEE 18th International Conference on Smart Communities: Improving Quality of Life using ICT, IoT and AI*, 2021. doi: 10.1109/HONET53078.2021.9615449.

[44] K. S. Sahoo *et al.*, “An Evolutionary SVM Model for DDOS Attack Detection in Software Defined Networks,” *IEEE Access*, vol. 8, 2020, doi: 10.1109/ACCESS.2020.3009733.

[45] M. A. Mohsin and A. H. Hamad, “Performance Evaluation of SDN DDoS Attack Detection and Mitigation Based Random Forest and K-Nearest Neighbors Machine Learning Algorithms,” *Revue d’Intelligence Artificielle*, vol. 36, no. 2, pp. 233–240, Apr. 2022, doi: 10.18280/ria.360207.

[46] S. Wang *et al.*, “Detecting flooding DDoS attacks in software defined networks using supervised learning techniques,” *Engineering Science and Technology, an International Journal*, vol. 35, p. 101176, Nov. 2022, doi: 10.1016/j.jestch.2022.101176.

[47] N. M. Yungaicela-Naula, C. Vargas-Rosales, and J. A. Perez-Diaz, “SDN-Based Architecture for Transport and Application Layer DDoS Attack Detection by Using Machine and Deep Learning,” *IEEE Access*, vol. 9, pp. 108495–108512, 2021, doi: 10.1109/ACCESS.2021.3101650.

[48] P. Krishnan, K. Jain, A. Aldweesh, P. Prabu, and R. Buyya, “OpenStackDP: a scalable network security framework for SDN-based OpenStack cloud infrastructure,” *Journal of Cloud Computing*, vol. 12, no. 1, p. 26, Feb. 2023, doi: 10.1186/s13677-023-00406-w.

[49] M. Maray *et al.*, “Optimal Deep Learning Driven Intrusion Detection in SDN-Enabled IoT Environment,” *Computers, Materials & Continua*, vol. 74, no. 3, pp. 6587–6604, 2023, doi: 10.32604/cmc.2023.034176.

[50] H.-M. Chuang, F. Liu, and C.-H. Tsai, “Early Detection of Abnormal Attacks in Software-Defined Networking Using Machine Learning Approaches,” *Symmetry (Basel)*, vol. 14, no. 6, p. 1178, Jun. 2022, doi: 10.3390/sym14061178.

[51] S. R, A. Kanavalli, A. Gupta, A. Pattanaik, and S. Agarwal, “Real-time DDoS Detection and Mitigation in Software Defined Networks using Machine Learning Techniques,” *International Journal of Computing*, pp. 353–359, Sep. 2022, doi: 10.47839/ijc.21.3.2691.

[52] Javaid Nabi, “Machine Learning —Fundamentals.” Accessed: Mar. 07, 2022. [Online]. Available: https://towardsdatascience.com/machine-learning-basics-part-1-a36d38c7916

[53] H. Singh, *Practical Machine Learning with AWS*. 2021. doi: 10.1007/978-1-4842-6222-1.

[54] S. Chibani and F.-X. Coudert, “Machine learning approaches for the prediction of materials properties,” *APL Mater*, vol. 8, no. 8, Aug. 2020, doi: 10.1063/5.0018384.

[55] “Machine Learning Classification Algorithm.” [Online]. Available: https://www.javatpoint.com/machine-learning

[56] J. E. van Engelen and H. H. Hoos, “A survey on semi-supervised learning,” *Mach Learn*, vol. 109, no. 2, pp. 373–440, 2020, doi: 10.1007/s10994-019-05855-6.

[57] P. C. Sen, M. Hajra, and M. Ghosh, *Supervised Classification Algorithms in Machine Learning: A Survey and Review*, vol. 937. Springer Singapore, 2020. doi: 10.1007/978-981-13-7403-6_11.

[58] G. Louppe, “Understanding Random Forests: From Theory to Practice,” Jul. 2014, [Online]. Available: http://arxiv.org/abs/1407.7502

[59] T. Zhang, *Mathematical Analysis of Machine Learning Algorithms*. Cambridge University Press, 2023. doi: 10.1017/9781009093057.

[60] O. F.Y, A. J.E.T, A. O, H. J. O, O. O, and A. J, “Supervised Machine Learning Algorithms: Classification and Comparison,” *International Journal of Computer Trends and Technology*, vol. 48, no. 3, pp. 128–138, Jun. 2017, doi: 10.14445/22312803/IJCTT-V48P126.

[61] “Decision Trees.” [Online]. Available: https://scikit-learn.org/stable/modules/tree.html

[62] Farrukh Nizam Arain, “Decision Tree Classification Algorithm.” Accessed: Mar. 09, 2022. [Online]. Available: https://www.devops.ae/decision-tree-classification-algorithm/

[63] J. Pustejovsky and A. Stubbs, *Natural Language Annotation for Machine Learning -- A guide to Corpus-building for applications*. 2013.

[64] Md. A. M. Hasan, M. Nasser, B. Pal, and S. Ahmad, “Support Vector Machine and Random Forest Modeling for Intrusion Detection System (IDS),” *Journal of Intelligent Learning Systems and Applications*, vol. 06, no. 01, pp. 45–52, 2014, doi: 10.4236/jilsa.2014.61005.

[65] “Random Forest Algorithm.” Accessed: Aug. 01, 2023. [Online]. Available: https://www.javatpoint.com/machine-learning-random-forest-algorithm

[66] M. A. Umar and C. Zhanfang, “Effects of Feature Selection and Normalization on Network Intrusion Detection,” pp. 1–25, 2020, doi: 10.36227/techrxiv.12480425.

[67] L. Breiman, “Consistency for a simple model of random forests,” 2004.

[68] L. Breiman, “Random Forests,” *Mach Learn*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.

[69] L. Breiman, “Some infinity theory for predictor ensembles,” 2000.

[70] L. Breiman, “Bagging predictors,” *Mach Learn*, vol. 24, no. 2, pp. 123–140, Aug. 1996, doi: 10.1007/BF00058655.

[71] Y. Amit and D. Geman, “Shape Quantization and Recognition with Randomized Trees,” *Neural Comput*, vol. 9, no. 7, pp. 1545–1588, Oct. 1997, doi: 10.1162/neco.1997.9.7.1545.

[72] Tin Kam Ho, “The random subspace method for constructing decision forests,” *IEEE Trans Pattern Anal Mach Intell*, vol. 20, no. 8, pp. 832–844, 1998, doi: 10.1109/34.709601.

[73] T. G. Dietterich, “An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting, and Randomization,” *Mach Learn*, vol. 40, no. 2, pp. 139–157, 2000, doi: 10.1023/A:1007607513941.

[74] L. Breiman, “Random Forests,” *Mach Learn*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.

[75] L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone, *Classification And Regression Trees*. Routledge, 2017. doi: 10.1201/9781315139470.

[76] G. Biau, “Analysis of a Random Forests Model,” May 2010, [Online]. Available: http://arxiv.org/abs/1005.0208

[77] A. Cano, “A survey on graphic processing unit computing for large-scale data mining,” *Wiley Interdiscip Rev Data Min Knowl Discov*, vol. 8, no. 1, p. e1232, Jan. 2018, doi: 10.1002/widm.1232.

[78] A. Mammone, M. Turchi, and N. Cristianini, “Support vector machines,” *Comput Stat*, pp. 283–289, 2009, Accessed: Dec. 06, 2023. [Online]. Available: https://d1wqtxts1xzle7.cloudfront.net/45694827/wics.4920160517-26685-10le7kw-libre.pdf?1463470793=&response-content-disposition=inline%3B+filename%3DSupport_vector_machines.pdf&Expires=1701863797&Signature=dcFT8ynf9VneoH7yk9pF~h~lZppHvm1v0TXvVYfdhEJs6G~mLmhkHiVN0c-ffsOLq8-wXwO5KHaAuFxr8APy-ueUqJ2ZAjH~jfduXNtw-aLUmmbf-WysoWNliap6JMb8UzqJ1NzNDMrBvFftmkfVTUEI5I~TJ0yjdlgVsdLf4BsQpO13XN~oIjNAmQehiEyBQFfih2chVNVb1ra~fGZWAIf8Fm2crLyMSNz3508bmlfqhap5KjpIWpncbScSiJ5PB4ATKo9IPo4pSzuy82DE66GBo~qY6H5tzfEaJ2CibmI7i24wlTm3xp2NJbXkJTg-1OfrvxoOfmWXX8X-Zef-8Q__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA

[79] D. Nelson, “Overview of Classification Methods in Python with Scikit-Learn.” [Online]. Available: https://stackabuse.com/overview-of-classification-methods-in-python-with-scikit-learn/

[80] X. Wu *et al.*, *Top 10 algorithms in data mining*, vol. 14, no. 1. 2008. doi: 10.1007/s10115-007-0114-2.

[81] “Support Vector Machines.” [Online]. Available: https://scikit-learn.org/stable/modules/svm.html

[82] B. Vivek, “Naive Bayes algorithm.” Accessed: Dec. 06, 2023. [Online]. Available: https://www.topcoder.com/thrive/articles/naive-bayes-algorithm

[83] V. Metsis, I. Androutsopoulos, and G. Paliouras, “Spam filtering with Naive Bayes - Which Naive Bayes?,” *3rd Conference on Email and Anti-Spam - Proceedings, CEAS 2006*, 2006.

[84] K. Taunk, S. De, S. Verma, and A. Swetapadma, “A Brief Review of Nearest Neighbor Algorithm for Learning and Classification,” in *2019 International Conference on*

Intelligent Computing and Control Systems (ICCS), IEEE, May 2019, pp. 1255–1260. doi: 10.1109/ICCS45141.2019.9065747.

[85] L. Y. Hu, M. W. Huang, S. W. Ke, and C. F. Tsai, "The distance function effect on k-nearest neighbor classification for medical datasets," *Springerplus*, vol. 5, no. 1, 2016, doi: 10.1186/s40064-016-2941-7.

[86] P. Cunningham and S. J. Delany, "k-Nearest neighbour classifiers 2nd edition (with python examples)," *ArXiv*, no. 1, pp. 1–22, 2020.

[87] K. Stąpor, "Evaluating and Comparing Classifiers: Review, Some Recommendations and Limitations," in *Advances in Intelligent Systems and Computing*, vol. 578, no. February, 2018, pp. 12–21. doi: 10.1007/978-3-319-59162-9_2.

[88] M. Hossin and M. N. Sulaiman, "A Review on Evaluation Metrics for Data Classification Evaluations," *International Journal of Data Mining & Knowledge Management Process*, vol. 5, no. 2, pp. 01–11, Mar. 2015, doi: 10.5121/ijdkp.2015.5201.

[89] "Metrics and scoring: quantifying the quality of predictions." [Online]. Available: https://scikit-learn.org/stable/modules/model_evaluation.html#

[90] K. H. Brodersen, C. S. Ong, K. E. Stephan, and J. M. Buhmann, "The balanced accuracy and its posterior distribution," *Proceedings - International Conference on Pattern Recognition*, pp. 3121–3124, 2010, doi: 10.1109/ICPR.2010.764.

[91] J. Brownlee, *Imbalanced Classification with Python Better Metrics, Balance Skewed Classes, Cost-Sensitive Learning*, V1.3. Machine Learning Mastery, 2021. [Online]. Available: https://books.google.hr/books?id=jaXJDwAAQBAJ&printsec=copyright#v=onepage&q&f=false

[92] S. Narkhede, "Understanding AUC - ROC Curve," Towards Data Science. [Online]. Available: https://towardsdatascience.com/understanding-auc-roc-curve-68b2303cc9c5

[93] Y. Kim, K. A. Toh, A. B. J. Teoh, H. L. Eng, and W. Y. Yau, "An online AUC formulation for binary classification," *Pattern Recognit*, vol. 45, no. 6, pp. 2266–2279, 2012, doi: 10.1016/j.patcog.2011.11.020.

[94] J. L. Leevy and T. M. Khoshgoftaar, "A survey and analysis of intrusion detection models based on CSE-CIC-IDS2018 Big Data," *J Big Data*, vol. 7, no. 1, Dec. 2020, doi: 10.1186/s40537-020-00382-x.

[95] M. Buda, A. Maki, and M. A. Mazurowski, "A systematic study of the class imbalance problem in convolutional neural networks," *Neural Networks*, vol. 106, pp. 249–259, Oct. 2018, doi: 10.1016/j.neunet.2018.07.011.

[96] J. S. Lee, "AUC4.5: AUC-Based C4.5 Decision Tree Algorithm for Imbalanced Data Classification," *IEEE Access*, vol. 7, pp. 106034–106042, 2019, doi: 10.1109/ACCESS.2019.2931865.

[97] M. Widmann, “Cohen’s Kappa: What It Is, When to Use It, and How to Avoid Its Pitfalls.” [Online]. Available: https://thenewstack.io/cohens-kappa-what-it-is-when-to-use-it-and-how-to-avoid-its-pitfalls/

[98] T. Janarthanan, “Feature Selection in UNSW-NB15 and KDDCUP ’ 99 datasets,” 2017.

[99] “CSE-CIC-IDS2018 on AWS.” Accessed: Apr. 12, 2022. [Online]. Available: https://www.unb.ca/cic/datasets/ids-2018.html

[100] “LUFlow Network Intrusion Detection Data Set.” Accessed: Apr. 20, 2022. [Online]. Available: https://www.kaggle.com/datasets/mryanm/luflow-network-intrusion-detection-data-set

[101] T.-H. Chua and I. Salam, “Evaluation of Machine Learning Algorithms in Network-Based Intrusion Detection System,” Mar. 2022, [Online]. Available: http://arxiv.org/abs/2203.05232

[102] “NetFlow overview.” Accessed: Feb. 15, 2023. [Online]. Available: https://documentation.meraki.com/MX/Monitoring_and_Reporting/NetFlow_Overview

[103] S. and M. N. and P. M. Sarhan Mohanad and Layeghy, “NetFlow Datasets for Machine Learning-Based Network Intrusion Detection Systems,” in *Big Data Technologies and Applications*, H. and H. R. and R. S. and C. N. Deze Zeng and Huang, Ed., Cham: Springer International Publishing, 2021, pp. 117–135.

[104] “Classification: ROC Curve and AUC.” Accessed: Oct. 05, 2022. [Online]. Available: https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc

[105] R. Sehrawat, “Data Preparation.”

[106] “Data science report.” Accessed: Apr. 13, 2022. [Online]. Available: https://visit.figure-eight.com/2015-data-scientist-report.html

[107] S. Ustebay, Z. Turgut, and M. A. Aydin, “Intrusion Detection System with Recursive Feature Elimination by Using Random Forest and Deep Learning Classifier,” in *2018 International Congress on Big Data, Deep Learning and Fighting Cyber Terrorism (IBIGDELFT)*, IEEE, Dec. 2018, pp. 71–76. doi: 10.1109/IBIGDELFT.2018.8625318.

[108] S. Ü. M. A. A. T. A. D. Aksu, “Intrusion detection with comparative analysis of supervised learning techniques and fisher score feature selection algorithm,” in *International symposium on computer and information sciences*, Springer, 2018, pp. 141–149.

[109] C. Song, Y. Park, K. Golani, Y. Kim, K. Bhatt, and K. Goswami, “Machine-learning based threat-aware system in software defined networks,” *2017 26th International Conference on Computer Communications and Networks, ICCCN 2017*, 2017, doi: 10.1109/ICCCN.2017.8038436.

[110] S. Seth, G. Singh, and K. Kaur Chahal, “A novel time efficient learning-based approach for smart intrusion detection system,” *J Big Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1186/s40537-021-00498-8.

[111] R. Atefinia and M. Ahmadi, “Network intrusion detection using multi-architectural modular deep neural network,” *Journal of Supercomputing*, vol. 77, no. 4, pp. 3571–3593, Apr. 2021, doi: 10.1007/s11227-020-03410-y.

[112] Cornellius Yudha Wijaya, “5 Feature Selection Method from Scikit-Learn you should know.” Accessed: Jun. 03, 2022. [Online]. Available: https://towardsdatascience.com/5-feature-selection-method-from-scikit-learn-you-should-know-ed4d116e4172

[113] Kishan Maladkar, “5 Ways To Handle Missing Values In Machine Learning Datasets.” Accessed: Apr. 13, 2022. [Online]. Available: https://analyticsindiamag.com/5-ways-handle-missing-values-machine-learning-datasets/

[114] R. B. Basnet, R. Shash, C. Johnson, L. Walgren, and T. Doleck, “Towards Detecting and Classifying Network Intrusion Traffic Using Deep Learning Frameworks.” [Online]. Available: https://rambasnet.github.io

[115] J. Gong and T. Chen, “Does Configuration Encoding Matter in Learning Software Performance? An Empirical Study on Encoding Schemes,” Mar. 2022, doi: 10.1145/3524842.3528431.

[116] C. Seger, “An investigation of categorical variable encoding techniques in machine learning: binary versus one-hot and feature hashing,” *Degree Project Technology*, p. 41, 2018, [Online]. Available: http://urn.kb.se/resolve?urn=urn:nbn:se:kth:diva-237426%0Ahttp://www.diva-portal.org/smash/get/diva2:1259073/FULLTEXT01.pdf

[117] K. K. Dobbin and R. M. Simon, “Optimally splitting cases for training and testing high dimensional classifiers,” *BMC Med Genomics*, vol. 4, no. 1, p. 31, 2011, doi: 10.1186/1755-8794-4-31.

[118] Y. Xu and R. Goodacre, “On Splitting Training and Validation Set: A Comparative Study of Cross-Validation, Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning,” *J Anal Test*, vol. 2, no. 3, pp. 249–262, 2018, doi: 10.1007/s41664-018-0068-2.

[119] W. Xu, Y. Fan, and C. Li, “I2DS: Interpretable Intrusion Detection System Using Autoencoder and Additive Tree,” *Security and Communication Networks*, vol. 2021, no. 3, 2021, doi: 10.1155/2021/5564354.

[120] M. Ahsan, R. Gomes, Md. M. Chowdhury, and K. E. Nygard, “Enhancing Machine Learning Prediction in Cybersecurity Using Dynamic Feature Selector,” *Journal of Cybersecurity and Privacy*, vol. 1, no. 1, pp. 199–218, 2021, doi: 10.3390/jcp1010011.

[121] G. Kocher and G. Kumar, “Performance Analysis of Machine Learning Classifiers for Intrusion Detection using UNSW-NB15 Dataset,” pp. 31–40, 2020, doi: 10.5121/csit.2020.102004.

[122] T. Ahmad, D. Truscan, J. Vain, and I. Porres, “Early Detection of Network Attacks Using Deep Learning,” Jan. 2022, [Online]. Available: http://arxiv.org/abs/2201.11628

[123] N. Elmrabit, F. Zhou, F. Li, and H. Zhou, “Evaluation of Machine Learning Algorithms for Anomaly Detection,” in *2020 International Conference on Cyber Security and Protection of Digital Services (Cyber Security)*, IEEE, Jun. 2020, pp. 1–8. doi: 10.1109/CyberSecurity49315.2020.9138871.

[124] J. Brownlee, “Train-Test Split for Evaluating Machine Learning Algorithms.” [Online]. Available: https://machinelearningmastery.com/train-test-split-for-evaluating-machine-learning-algorithms/

[125] M. Nawir, A. Amir, O. B. Lynn, N. Yaakob, and R. Badlishah Ahmad, “Performances of Machine Learning Algorithms for Binary Classification of Network Anomaly Detection System,” *J Phys Conf Ser*, vol. 1018, no. 1, 2018, doi: 10.1088/1742-6596/1018/1/012015.

[126] “sklearn.preprocessing.StandardScaler.” Accessed: Jun. 09, 2022. [Online]. Available: https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html#sklearn.preprocessing.StandardScaler

[127] “sklearn.preprocessing.RobustScaler.” Accessed: Jun. 09, 2022. [Online]. Available: https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.RobustScaler.html#sklearn.preprocessing.RobustScaler

[128] “sklearn.preprocessing.MinMaxScaler.” Accessed: Jun. 09, 2022. [Online]. Available: https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html#sklearn.preprocessing.MinMaxScaler

[129] P. Dahiya and D. K. Srivastava, “Network Intrusion Detection in Big Dataset Using Spark,” *Procedia Comput Sci*, vol. 132, pp. 253–262, 2018, doi: 10.1016/j.procs.2018.05.169.

[130] R. Mills, A. K. Marnerides, M. Broadbent, and N. Race, “Citrus Practical Intrusion Detection of Emerging Threats,” *IEEE Transactions on Network and Service Management*, vol. 19, no. 1, pp. 582–600, Mar. 2022, doi: 10.1109/TNSM.2021.3091517.

[131] S. Zwane, P. Tarwireyi, and M. Adigun, “Performance Analysis of Machine Learning Classifiers for Intrusion Detection,” in *2018 International Conference on Intelligent and Innovative Computing Applications (ICONIC)*, IEEE, Dec. 2018, pp. 1–5. doi: 10.1109/ICONIC.2018.8601203.

[132] R. Kumar and R. Singh, “Netflow based cyber threat classification using J48 and random forest machine learning algorithms,” *Int J Eng Adv Technol*, vol. 9, no. 1, pp. 2973–2979, Oct. 2019, doi: 10.35940/ijeat.A1326.109119.

[133] C. A. Ramezan, T. A. Warner, and A. E. Maxwell, “Evaluation of sampling and cross-validation tuning strategies for regional-scale machine learning classification,” *Remote Sens (Basel)*, vol. 11, no. 2, Jan. 2019, doi: 10.3390/rs11020185.

[134] “Cross-validation: evaluating estimator performance.” Accessed: Mar. 16, 2022. [Online]. Available: https://scikit-learn.org/stable/modules/cross_validation.html

[135] D. J. V. Lopes, G. W. Burgreen, and E. D. Entsminger, “North American hardwoods identification using machine-learning,” *Forests*, vol. 11, no. 3, Mar. 2020, doi: 10.3390/f11030298.

[136] N. Darapureddy, N. Karatapu, and T. K. Battula, “Research of machine learning algorithms using k-fold cross validation,” *Int J Eng Adv Technol*, vol. 8, no. 6 Special issue, 2019, doi: 10.35940/ijeat.F1043.0886S19.

[137] “Cross Validation.” Accessed: Feb. 13, 2024. [Online]. Available: https://medium.com/@ompramod9921/cross-validation-623620ff84c2

[138] P. Liashchynskyi and P. Liashchynskyi, “Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS,” Dec. 2019, [Online]. Available: http://arxiv.org/abs/1912.06059

[139] “sklearn.model_selection.GridSearchCV.” Accessed: Mar. 07, 2022. [Online]. Available: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html

[140] “What is network flow data?” Accessed: Jun. 29, 2022. [Online]. Available: https://tools.netsa.cert.org/silk/faq.html#what-is-flow

[141] “What is NetFlow?” Accessed: Jun. 28, 2022. [Online]. Available: https://www.manageengine.com/products/netflow/what-is-netflow.html

[142] “The Evolution of Network Flow Monitoring, from NetFlow to IPFIX.” Accessed: Jun. 28, 2022. [Online]. Available: https://www.noction.com/blog/network-flow-monitoring

[143] “NetFlow probe using Raspberry,” Pandora FMS team. [Online]. Available: https://pandorafms.com/blog/netflow-probe-using-raspberry/

[144] Steve Petryschuk, “NetFlow Basics: An Introduction to Monitoring Network Traffic.” Accessed: Feb. 17, 2023. [Online]. Available: https://www.auvik.com/franklyit/blog/netflow-basics/

[145] “Network Management Configuration Guide, Cisco IOS XE Everest 16.6.x (Catalyst 9300 Switches).” Accessed: Jun. 28, 2022. [Online]. Available: https://www.cisco.com/c/en/us/td/docs/switches/lan/catalyst9300/software/release/16-

6/configuration_guide/nmgmt/b_166_nmgmt_9300_cg/b_166_nmgmt_9300_cg_chapter_0111.html

[146] Cornellius Yudha Wijaya, "5 Feature Selection Method from Scikit-Learn you should know." Accessed: Jun. 29, 2022. [Online]. Available: https://towardsdatascience.com/5-feature-selection-method-from-scikit-learn-you-should-know-ed4d116e4172

[147] M. Bahrololum, E. Salahi, and M. Khaleghi, "Machine Learning Techniques for Feature Reduction in Intrusion Detection Systems: A Comparison," in *2009 Fourth International Conference on Computer Sciences and Convergence Information Technology*, IEEE, 2009, pp. 1091–1095. doi: 10.1109/ICCIT.2009.89.

[148] B. Xue, M. Zhang, W. N. Browne, and X. Yao, "A Survey on Evolutionary Computation Approaches to Feature Selection," *IEEE Transactions on Evolutionary Computation*, vol. 20, no. 4, pp. 606–626, Aug. 2016, doi: 10.1109/TEVC.2015.2504420.

[149] O. I. Sheluhin and V. P. Ivannikova, "COMPARATIVE ANALYSIS OF INFORMATIVE FEATURES QUANTITY AND COMPOSITION SELECTION METHODS FOR THE COMPUTER ATTACKS CLASSIFICATION USING THE UNSW-NB15 DATASET," *T-Comm*, vol. 14, no. 10, pp. 53–60, 2020, doi: 10.36724/2072-8735-2020-14-10-53-60.

[150] A. Pasyuk, E. Semenov, and D. Tyuhtyaev, "Feature Selection in the Classification of Network Traffic Flows," in *2019 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon)*, IEEE, Oct. 2019, pp. 1–5. doi: 10.1109/FarEastCon.2019.8934169.

[151] A. Santos da Silva, J. A. Wickboldt, L. Z. Granville, and A. Schaeffer-Filho, "ATLANTIC: A framework for anomaly traffic detection, classification, and mitigation in SDN," in *NOMS 2016 - 2016 IEEE/IFIP Network Operations and Management Symposium*, IEEE, Apr. 2016, pp. 27–35. doi: 10.1109/NOMS.2016.7502793.

[152] M. M. Isa and L. Mhamdi, "Native SDN Intrusion Detection using Machine Learning," in *2020 IEEE Eighth International Conference on Communications and Networking (ComNet)*, IEEE, Oct. 2020, pp. 1–7. doi: 10.1109/ComNet47917.2020.9306093.

[153] "Real Time." Accessed: Jan. 26, 2023. [Online]. Available: https://www.gartner.com/en/information-technology/glossary/real-time

[154] "Definition Real-Time." Accessed: Jan. 26, 2023. [Online]. Available: https://www.suse.com/suse-defines/definition/real-time/

[155] C. Leng, Y. Qiao, X. S. Hu, and H. Wang, "Co-scheduling aperiodic real-time tasks with end-to-end firm and soft deadlines in two-stage systems," *Real-Time Systems*, vol. 56, no. 4, pp. 391–451, Oct. 2020, doi: 10.1007/s11241-020-09352-1.

[156] W. A. Halang, R. Gumzej, M. Colnaric, and M. Druzovec, “Measuring the Performance of Real-Time Systems,” *Real-Time Systems*, vol. 18, no. 1, pp. 59–68, 2000, doi: 10.1023/A:1008102611034.

[157] D. A. Khorkov, “Methods for testing network-intrusion detection systems,” *Scientific and Technical Information Processing*, vol. 39, no. 2, pp. 120–126, Apr. 2012, doi: 10.3103/S0147688212020128.

[158] P. Mell, R. Lippmann, J. Haines, and M. Zissman, “An Overview of Issues in Testing Intrusion Detection Systems.” Accessed: Apr. 11, 2023. [Online]. Available: https://www.govinfo.gov/content/pkg/GOVPUB-C13-12311f1b97702aad61bee4378916ab9e/pdf/GOVPUB-C13-12311f1b97702aad61bee4378916ab9e.pdf

[159] “NFDUMP tools overview.” Accessed: Nov. 14, 2022. [Online]. Available: https://nfdump.sourceforge.net/

[160] “False negative rate difference in Watson OpenScale fairness metrics.” Accessed: Aug. 31, 2023. [Online]. Available: https://www.ibm.com/docs/en/cloud-paks/cp-data/4.7.x?topic=metrics-false-negative-rate-difference

[161] A. Basuki and A. Adriansyah, “Response time optimization for vulnerability management system by combining the benchmarking and scenario planning models,” *International Journal of Electrical and Computer Engineering*, vol. 13, no. 1, pp. 561–570, Feb. 2023, doi: 10.11591/ijece.v13i1.pp561-570.

[162] L. E. J. Guterres and A. Ashari, “THE ANALYSIS OF WEB SERVER SECURITY FOR MULTIPLE ATTACKS IN THE TIC TIMOR IP NETWORK,” *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 14, no. 1, p. 103, Jan. 2020, doi: 10.22146/ijccs.53265.

[163] I. Cisco Systems, “What Are the Most Common Cyber Attacks?,” Products and Services. [Online]. Available: https://www.cisco.com/c/en_au/products/security/common-cyberattacks.html

[164] J. Melnick, “Top 10 Most Common Types of Cyber Attacks,” *Netwrix*. pp. 1–2, 2022. [Online]. Available: https://blog.netwrix.com/2018/05/15/top-10-most-common-types-of-cyber-attacks/%0Ahttps://blog.netwrix.com/2018/05/15/top-10-most-common-types-of-cyber-attacks/#Eavesdropping attack

[165] B. H. Thacker, S. W. Doebling, F. M. Hemez, M. C. Anderson, J. E. Pepin, and E. A. Rodriguez, “Concepts of Model Verification and Validation.” 2004. Accessed: Jan. 25, 2024. [Online]. Available: https://inis.iaea.org/search/search.aspx?orig_q=RN:36030870

[166] C. Yin and A. McKay, “Model verification and validation strategies and methods: An application case study,” in *ISCIIA and ITCA 2018 - 8th International Symposium on Computational Intelligence and Industrial Applications and 12th China-Japan International Workshop on Information Technology and Control Applications*, 2018.

[167] A. Thakkar and R. Lohiya, “A survey on intrusion detection system: feature selection, model, performance measures, application perspective, challenges, and future research directions,” *Artif Intell Rev*, vol. 55, no. 1, pp. 453–563, Jan. 2022, doi: 10.1007/s10462-021-10037-9.

[168] Q. Hu, M. R. Asghar, and N. Brownlee, “Evaluating network intrusion detection systems for high-speed networks,” in *2017 27th International Telecommunication Networks and Applications Conference (ITNAC)*, IEEE, Nov. 2017, pp. 1–6. doi: 10.1109/ATNAC.2017.8215374.

[169] C. Corbett, T. Basic, T. Lukaseder, and F. Kargl, “A Testing Framework Architecture Concept for Automotive Intrusion Detection Systems,” 2017.

[170] M. Ennert, E. Chovancová, and Z. Dudláková, “Testing of IDS model using several intrusion detection tools,” *Journal of Applied Mathematics and Computational Mechanics*, vol. 14, no. 1, pp. 55–62, Mar. 2015, doi: 10.17512/jamcm.2015.1.05.

[171] F. Erlacher and F. Dressler, “Testing IDS using GENESIDS,” in *Proceedings of the ACM SIGCOMM 2018 Conference on Posters and Demos*, New York, NY, USA: ACM, Aug. 2018, pp. 153–155. doi: 10.1145/3234200.3234204.

[172] J. Sommers, V. Yegneswaran, and P. Barford, “Toward comprehensive traffic generation for online ids evaluation,” 2005.

[173] L. Kou, S. Ding, T. Wu, W. Dong, and Y. Yin, “An Intrusion Detection Model for Drone Communication Network in SDN Environment,” *Drones*, vol. 6, no. 11, p. 342, Nov. 2022, doi: 10.3390/drones6110342.

[174] B. Lan, T.-C. Lo, R. Wei, H.-Y. Tang, and C.-K. Shieh, “A Quantitative Logarithmic Transformation-Based Intrusion Detection System,” *IEEE Access*, vol. 11, pp. 20351–20364, 2023, doi: 10.1109/ACCESS.2023.3248261.

[175] M. A. Teixeira, M. Zolanvari, K. M. Khan, R. Jain, and N. Meskin, “Flow-based intrusion detection algorithm for supervisory control and data acquisition systems: A real-time approach,” *IET Cyber-Physical Systems: Theory and Applications*, vol. 6, no. 3, 2021, doi: 10.1049/cps2.12016.

[176] K. Wilailux and S. Ngamsuriyaroj, “Novel Bi-directional Flow-based Traffic Generation Framework for IDS Evaluation and Exploratory Data Analysis,” *Journal of Information Processing*, vol. 29, no. 0, pp. 256–265, 2021, doi: 10.2197/ipsjjip.29.256.

[177] R. Magán-Carrión, D. Urda, I. Díaz-Cano, and B. Dorronsoro, “Towards a Reliable Comparison and Evaluation of Network Intrusion Detection Systems Based on Machine Learning Approaches,” *Applied Sciences*, vol. 10, no. 5, p. 1775, Mar. 2020, doi: 10.3390/app10051775.

[178] “Deploying IPS engines in IDS or IPS mode.” Accessed: Mar. 30, 2023. [Online]. Available: https://help.stonesoft.com/onlinehelp/StoneGate/SMC/6.5.0/GUID-3DDAC105-041F-44FB-854F-E52B8F57B6CB.html

[179] P. Vanin *et al.*, “A Study of Network Intrusion Detection Systems Using Artificial Intelligence/Machine Learning,” *Applied Sciences*, vol. 12, no. 22, p. 11752, Nov. 2022, doi: 10.3390/app122211752.

[180] Z. Ahmad, A. Shahid Khan, C. Wai Shiang, J. Abdullah, and F. Ahmad, “Network intrusion detection system: A systematic study of machine learning and deep learning approaches,” *Transactions on Emerging Telecommunications Technologies*, vol. 32, no. 1, Jan. 2021, doi: 10.1002/ett.4150.

[181] “TEST METHODOLOGY Next Generation Intrusion Prevention System (NGIPS),” Jan. 2019.

POPIS SLIKA

POPIS TABLICA

SAŽETAK

Ova disertacija predstavlja inovativan pristup kibernetičkoj sigurnosti u kontekstu hibridnih programski definiranih mreža (SDN), s naglaskom na integraciju tehnika strojnog učenja za detekciju anomalija u mrežnom prometu. Istraživanje je usmjereno na rješavanje sigurnosnih izazova u SDN arhitekturama kroz razvoj sustava za otkrivanje napada (NIDS) temeljenog na strojnom učenju, koji omogućava učinkovito prepoznavanje i odgovor na prijetnje u stvarnom vremenu. Predloženi model kombinira prednosti tradicionalnih mrežnih arhitektura s fleksibilnošću i prilagodljivošću SDN-a, pružajući skalabilnu i efikasnu detekciju anomalija. Postupak odabira i prilagodbe ulaznih podataka, zajedno s optimizacijom algoritma klasifikacije, omogućava visoku točnost modela, što je vrlo važno za zaštitu kritičnih segmenata IT sustava unutar korporativne mreže. Disertacija također uključuje detaljan pregled postojeće literature, istraživanje metoda integracije strojnog učenja sa SDN-om te rezultate verifikacije modela u stvarnom mrežnom okruženju. Dodatni istraživački doprinos uključuje razvoj metode verifikacije temeljene na analizi višestrukih NetFlow zapisa, čime se dodatno potvrđuje učinkovitost predloženog modela.

Znanstveni doprinosi ove disertacije uključuju:

1. Postupak odabira i prilagodbe skupa ulaznih podataka za algoritam klasifikacije radi otkrivanja anomalija u hibridnoj programski definiranoj mreži.
2. Predložen je model za detekciju anomalija u mrežnom prometu hibridne SDN mreže, koji koristi algoritme strojnog učenja.
3. Osmišljena je metoda za verifikaciju predloženog modela u stvarnom mrežnom okruženju.

Disertacija donosi značajan doprinos području mrežne sigurnosti, s posebnim naglaskom na napredna i inteligentna sigurnosna rješenja unutar hibridnih SDN arhitektura.

Ključne riječi: kibernetička sigurnost, hibridna programski definirana mreža, detekcija anomalija, strojno učenje, algoritam klasifikacije, metoda verifikacije modela, NetFlow.

ABSTRACT

Anomaly Detection in Network Traffic Using Machine Learning Classification in a Hybrid Software-Defined Network

This dissertation presents an innovative approach to cybersecurity in the context of hybrid Software-Defined Networks (SDN), with a focus on integrating machine learning techniques for anomaly detection in network traffic. The research is aimed at addressing security challenges in SDN architectures through the development of a Network Intrusion Detection System (NIDS) based on machine learning, enabling effective real-time threat recognition and response. The proposed model combines the strengths of traditional network architectures with the flexibility and adaptability of SDN, providing scalable and efficient anomaly detection. The process of selecting and adapting input data, along with the optimization of the classification algorithm, enables high model accuracy, which is crucial for protecting critical segments of IT systems within corporate networks. The dissertation also includes a detailed review of existing literature, an exploration of methods for integrating machine learning with SDN, and results from the model's verification in a real network environment. An additional research contribution includes the development of a verification method based on the analysis of multiple NetFlow records, further confirming the effectiveness of the proposed model.

The scientific contributions of this dissertation include:

1. The development of a process for selecting and adapting the input data set for the classification algorithm to detect anomalies in a hybrid Software-Defined Network.
2. A proposed model for anomaly detection in the network traffic of a hybrid SDN, utilizing machine learning algorithms.
3. The design of a method for verifying the proposed model in a real network environment.

The dissertation makes a significant contribution to the field of network security, with a particular emphasis on advanced and intelligent security solutions within hybrid SDN architectures.

Keywords: cybersecurity, hybrid Software-Defined Network, anomaly detection, machine learning, classification algorithm, model verification method, NetFlow.

ŽIVOTOPIS

Igor Fosić rođen je 26. svibnja 1976. godine u Osijeku. Oženjen je i otac troje djece. Nakon završenog srednjoškolskog obrazovanja u III. Gimnaziji u Osijeku upisuje studij Elektrotehnike, smjer elektronika i automatizacija, na Elektrotehničkom fakultetu Sveučilišta J.J. Strossmayera u Osijeku, gdje uspješno diplomira 2001. godine. 2002. godine zapošljava se u Hrvatskoj Elektroprivredi d.d., u Sektoru za informatiku i telekomunikacije, Područna služba Osijek, gdje radi na poslovima održavanja i dizajniranja mrežne i serverske infrastrukture. Paralelno s radom, 2007. godine upisuje, a 2011. završava Poslijediplomski specijalistički studij Napredne komunikacijske tehnologije, također na Elektrotehničkom fakultetu u Osijeku. Krajem 2017. godine upisuje Poslijediplomski doktorski studij, modul Komunikacije i informatika, na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek. U svojem znanstveno-istraživačkom radu bavi se kibernetičkom sigurnošću, s posebnim naglaskom na detekciju anomalija mrežnog prometa primjenom strojnog učenja. Objavio je više znanstvenih radova u međunarodnim i domaćim časopisima te na konferencijama. Trenutno je zaposlen kao rukovoditelj Područne službe Osijek, Sektora za održavanje i izgradnju mreže u HEP Telekomunikacije d.o.o.

PRILOZI

Prilog A

Konfiguracija Cisco 9300 (SW1 i SW2) preklopnika za izvoz i slanje NetFlow zapisa u nfcpad kolektor

```
flow record RECORD_IN
match flow direction
match interface input
match ipv4 destination address
match ipv4 protocol
match ipv4 source address
match ipv4 tos
match transport destination-port
match transport source-port
collect counter bytes long
collect counter packets long
collect interface output
collect transport tcp flags
collect timestamp absolute first
collect timestamp absolute last
exit

flow record RECORD_OUT
match flow direction
match interface output
match ipv4 destination address
match ipv4 protocol
match ipv4 source address
match ipv4 tos
match transport destination-port
match transport source-port
collect counter bytes long
collect counter packets long
collect interface input
collect transport tcp flags
collect timestamp absolute first
collect timestamp absolute last
exit

flow exporter EXPORTER
 destination 10.193.20.162
 source Vlan91
 transport udp 2055
 export-protocol netflow-v9
 template data timeout 30
exit
flow monitor MONITOR_IN
 exporter EXPORTER
cache timeout inactive 10
cache timeout active 60
record RECORD_IN
exit
flow monitor MONITOR_OUT
 exporter EXPORTER
cache timeout inactive 10
cache timeout active 60
record RECORD_OUT
exit
vlan configuration 91
ip flow monitor MONITOR_IN input
ip flow monitor MONITOR_OUT output
```

Prilog B

Konfiguracija Cisco N9K-C93108TC-FX (SDN SW) preklopnika za izvoz i slanje NetFlow zapisa u nfcpad kolektor

NetFlow Records

<?xml version="1.0" encoding="UTF-8"?><imdata totalCount="1">
<netflowRecordPol
annotation=""
childAction=""
collect="count-bytes,count-pkts,pkt-disp,sampler-id,src-intf,tcp-flags,ts-first,ts-recent"
descr=""
dn="uni/tn-HEP_TK_ZP/recordpol-NF_REC_test"
extMngdBy=""
lcOwn="local"
match="dst-ipv4,dst-port,proto,src-ipv4,src-port"
modTs="2023-02-10T10:36:20.743+02:00"
name="NF_REC_test"
nameAlias=""
ownerKey=""
ownerTag=""
status=""
uid="16002"/></imdata>

NetFlow Exporters

<?xml version="1.0" encoding="UTF-8"?>
<imdata totalCount="1">
<netflowExporterPol
annotation=""
childAction=""
descr=""
dn="uni/tn-HEP_TK_ZP/exporterpol-NF_EXP_test"
dscp="VA"
dstAddr="10.193.20.162"
dstPort="2055"
extMngdBy=""
lcOwn="local"
modTs="2023-04-24T13:54:37.028+02:00"
monPolDn="uni/tn-common/monepg-default"
name="NF_EXP_test"
nameAlias=""
ownerKey=""
ownerTag=""
sourceIpType="inband-mgmt-ip"
srcAddr="0.0.0.0"
status=""
uid="16002"
ver="v9"/></imdata>

NetFlow Monitors

<?xml version="1.0" encoding="UTF-8"?>
<imdata totalCount="1">
<netflowMonitorPol
annotation=""
childAction=""
descr=""
dn="uni/tn-HEP_TK_ZP/monitorpol-NF_MON_test"
extMngdBy=""
lcOwn="local"
modTs="2023-02-10T10:37:55.460+02:00"
monPolDn="uni/tn-common/monepg-default"
name="NF_MON_test"
nameAlias=""
ownerKey=""
ownerTag=""
status=""
uid="16002"/></imdata>

Prilog C

Provjera puta paketa od računala napadača do računala žrtvi

```
└─$ traceroute 10.193.53.21
traceroute to 10.193.53.21 (10.193.53.21), 30 hops max, 60 byte packets
 1  10.193.91.1 (10.193.91.1)  0.523 ms  0.700 ms  0.912 ms
 2  10.230.250.61 (10.230.250.61)  0.602 ms 10.230.250.57 (10.230.250.57)  0.503 ms  0.718 ms
 3  10.230.250.62 (10.230.250.62)  0.297 ms 10.230.250.58 (10.230.250.58)  0.300 ms 10.230.250.62 (10.230.250.62)  0.195 ms
 4  tkos-teren.data.centar (10.193.53.21)  0.522 ms * *

└─$ traceroute 10.193.52.12
traceroute to 10.193.52.12 (10.193.52.12), 30 hops max, 60 byte packets
 1  10.193.91.1 (10.193.91.1)  0.514 ms  0.696 ms  0.853 ms
 2  10.230.250.61 (10.230.250.61)  0.442 ms 10.230.250.57 (10.230.250.57)  0.455 ms 10.230.250.61 (10.230.250.61)  0.624 ms
 3  10.230.250.58 (10.230.250.58)  0.292 ms  0.244 ms 10.230.250.62 (10.230.250.62)  0.299 ms
 4  10.193.52.12 (10.193.52.12)  0.337 ms  0.422 ms  0.501 ms

└─$ traceroute 10.193.52.200
traceroute to 10.193.52.200 (10.193.52.200), 30 hops max, 60 byte packets
 1  10.193.91.1 (10.193.91.1)  0.651 ms  0.861 ms  1.032 ms
 2  10.230.250.57 (10.230.250.57)  0.600 ms 10.230.250.61 (10.230.250.61)  0.497 ms 10.230.250.57 (10.230.250.57)  0.808 ms
 3  10.230.250.58 (10.230.250.58)  0.272 ms 10.230.250.62 (10.230.250.62)  0.223 ms 10.230.250.58 (10.230.250.58)  0.209 ms
 4  TKOS-ifosic.data.centar (10.193.52.200)  0.685 ms * *
```

Prilog D

Python glavni kod primjenjen za pseudokod Algoritam 2 i Algoritam 3

```
import os
os.chdir('/home/igor/ML/scripts/')
#Ucitavanje podataka
from ML_script_real_function1 import fn_dataset
#data=fn_dataset(baza, data_num, baza_name) #(baza, broj_datoteka, ime baze)
#data1=fn_dataset(1, 6, 'LUFlow2021') # LUFlow2021
#data2=fn_dataset(2, 0, 'RealNFExp') # Real Netflow snimka iz srpnja,kolovoza 2022
#data3=fn_dataset(3, 1, 'NF-UQ-NIDS-v1') # Netflow anomalies from CSE-CIC-IDS2018, BoT-IoT, ToN-IoT, UNSW-NB15
#data4=fn_dataset(4, 0, 'RealNF-FalsePositive') # Real Netflow za FP u produkciji
data5=fn_dataset(5, 0, 'RealNF-attack') # Real Netflow laptop attack
data6=fn_dataset(6, 0, 'RealNF-normal') # Real Netflow laptopn normal

#Feature selection
from ML_script_real_function1 import fn_feature_select
#data1=fn_feature_select(data1, 1)
#data2=fn_feature_select(data2, 2)
#data3=fn_feature_select(data3, 3)

#Feature convert
#brise sve redove koji imaju NaN vrijednosti
from ML_script_real_function1 import fn_feature_convert
#data1=fn_feature_convert(data1, 'LUFlow2021')
#data2=fn_feature_convert(data2, 'RealNF')
#data3=fn_feature_convert(data3, 'NF-UQ-NIDS-v1')
data5=fn_feature_convert(data5, 'NF-Real-attack')
data6=fn_feature_convert(data6, 'NF-Real-normal')

#Feature encoding LUFlow
from ML_script_real_function1 import fn_feature_encoding_LUFlow
#data1=fn_feature_encoding_LUFlow(data1)

#Feature encoding RealNF
from ML_script_real_function1 import fn_feature_encoding_realNF
#data2=fn_feature_encoding_realNF(data2)
data5=fn_feature_encoding_realNF(data5)
data6=fn_feature_encoding_realNF(data6)

#Anomaly merge, selection and combining
#from ML_script_real_function1 import fn_anomaly_merge
import pandas as pd
#data=fn_anomaly_merge(data1, data2, data3, data4)
#extract anomalies
#data_anomaly_LUFlow2021=data1[data1['label']==1]
#data_anomaly_NF_UQ_NIDS_v1=data3[data3['label']==1]
#data = pd.concat([data_anomaly_LUFlow2021, data_anomaly_NF_UQ_NIDS_v1, data5, data6]).reset_index(drop=True)
#data = pd.concat([data_anomaly_LUFlow2021, data5, data6]).reset_index(drop=True)
data = pd.concat([data5, data6]).reset_index(drop=True)

#Podatci za ucenje
X_train = data.iloc[:,:-1] #sve osim target stupca
y_train = data.iloc[:,-1:] #target stupac
import numpy as np
y_train = np.ravel(y_train)

#Skaliranje podtaka za ucenje
from sklearn.preprocessing import MinMaxScaler
var_sc = MinMaxScaler()
X_train_scale = var_sc.fit_transform(X_train)

#ML initial
from sklearn.ensemble import RandomForestClassifier
clf = RandomForestClassifier(criterion='entropy', class_weight='balanced',max_features= 'sqrt', n_estimators=300, n_jobs=-1)
clf.fit(X_train_scale, y_train)

#Real-time detection
import numpy as np
```

```
import time
from ML_script_real_function1 import fn_timer

#brisanje svih pocetnih datoteka
from ML_script_real_function1 import fn_delete_files #pozivam funkciju fn_ iz file-a ML_
fn_delete_files('/home/igor/ML/input/')
fn_delete_files('/home/igor/ML/benign/')
fn_delete_files('/home/igor/ML/quarantine/')
fn_delete_files('/home/igor/ML/check/')
fn_delete_files('/home/igor/ML/info/')

os.chdir('/home/igor/ML/input/')
from ML_script_real_function1 import fn_convert_files
from ML_script_real_function1 import fn_load_dataset
from ML_script_real_function1 import fn_load_dataset_info
from ML_script_real_function1 import fn_API_interface

while True:
    time_start = time.time() #pocetak procesa detekcije
    raw_files = [f for f in os.listdir('/home/igor/ML/input/') if f.startswith('nfcapd') and 'current' not in f]
    if raw_files:
        src = str(raw_files[0])             #u input direktoriju, treba kod prebacivanja i brisanja datoteka
        src_csv = str(raw_files[0]+'.csv')  #u input direktoriju, treba kod prebacivanja i brisanja datoteka
        csv_file=fn_convert_files(raw_files[0])
        X_test = fn_load_dataset(csv_file)
        X_info = fn_load_dataset_info(csv_file)
        if X_test.empty:
            fn_delete_files('/home/igor/ML/input/')
        else:
            #Encoding features
            X_test=fn_feature_encoding_realNF(X_test)
            #Scaling
            X_test_scale = var_sc.transform(X_test.values)
            #print('Izvrseno je skaliranje')

            num_rec=len(X_test_scale)
            #Machine learning algoritam
            y_pred = clf.predict(X_test_scale)
            #y_pred_log_proba=clf.predict_log_proba(X_test_scale)
            y_pred_proba=clf.predict_proba(X_test_scale)


            count = np.count_nonzero(y_pred == 1) #racuna broj jedinica u predikciji
            pos = np.where(y_pred == 1) #array pozicija gdje se nalaze anomalije
            if (np.size(pos) > 0):
                print('pronadjeno je '+ str(np.size(pos))+'/'+str(y_pred.shape[0])+' anomalija u zapisu ')

                #spremam anomalije ako su FP rezultati u csv datoteku
                import csv
                import pandas as pd
                anomaly_record=X_test.loc[pos[0],:]
                anomaly_record_info=X_info.loc[pos[0],:]
                anomaly_record_merge = pd.merge(anomaly_record, anomaly_record_info, on=anomaly_record.index)
                anomaly_record_merge.set_index('key_0', inplace=True)
                anomaly_record_merge=anomaly_record_merge.reset_index(drop=True)
                var_filename = '/home/igor/ML/check/check_anomalies'+'_'+src + '.csv'
                var_filename_info = '/home/igor/ML/info/check_anomalies_info'+'_'+src + '.csv'
                anomaly_record.to_csv(var_filename, index=False)
                anomaly_record_merge.to_csv(var_filename_info, index=False)

                #prebacivanje datoteke u karantenu
                import shutil
                dst = '/home/igor/ML/quarantine/'+ src
                dst_csv = '/home/igor/ML/quarantine/'+ src_csv
                shutil.move(src, dst)
                shutil.move(src_csv, dst_csv)
                #os.remove(src_csv)
                print('Datoteka '+os.path.abspath(os.getcwd())+'/'+src+' je obrisana i premjestena u karantenu za daljnju analizu!')

                #zovem API za blokiranje interface-a
```

```
            import time
            #timestr = time.strftime("%Y%m%d-%H%M%S")
            anomaly_interface_unique_values = anomaly_record_info['if_out'].unique()
            for if_num in range(anomaly_interface_unique_values.shape[0]):
                print ('zovem disable API za interface ' + str(anomaly_interface_unique_values[if_num]) + ' '+str(time.strftime("%H:%M:%S")))
                controllerIP='10.230.249.11'
                interface=str(anomaly_interface_unique_values[if_num])
                #fn_API_interface('disable',controllerIP,interface)
        else:
            import shutil
            os.chdir('/home/igor/ML/input/')
            dst = '/home/igor/ML/benign/'+ str(raw_files[0])
            shutil.move(src, dst)
            os.remove(src_csv)
            print('Datoteka '+os.path.abspath(os.getcwd())+'/'+src+' je obrisana i premjestena u benign direktorij!')
            print('Datoteka '+os.path.abspath(os.getcwd())+'/'+src_csv+' je obrisana!')
        time_end = time.time() #kraj procesa detekcije
        str_trajanje=fn_timer(time_start, time_end)
        print('proces detekcije za '+str(num_rec)+' zapisa je trajao '+str_trajanje )
else:
    print("Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.")

#print('Cekam 15 sekundi za novu provjeru')
time.sleep(15)
```

Prilog E
Python funkcije glavnog koda primjenjenog za pseudokod Algoritam 2 i Algoritam 3

```
def fn_timer(time_start, time_end):
    import time
    hours, rem = divmod(time_end-time_start, 3600)
    minutes, seconds = divmod(rem, 60)
    str_trajanje="{:0>2}:{:0>2}:{:05.2f}".format(int(hours),int(minutes),seconds)
    return str_trajanje

def fn_time():
    import time
    return time.time()

def fn_dataset(baza,data_num, baza_name):
    import pandas as pd
    data = pd.DataFrame() #blank dataframe
    # raspored stupaca: bytes_in  bytes_out  dest_port  num_pkts_in  proto  src_port  duration     label

    if (baza == 1):
        print ('Ucitavanje seta podataka LUFlow2021...')
        path="/home/igor/ML/dataset/LUFlow2021/"
        for x in range(1,data_num+1):
        #for x in [i for i in range(1,data_num+1) if i != 4]: #izostavlja se datoteka 4 jer je prevelika
            #datapart = pd.read_csv(path+"LUFlow2021 ("+str(x)+").csv", header=None, low_memory=False, skiprows=1) #skiprows - ne ucitava se 1 red jer je nepotreban, a cijeli dataset bude dtypes=object pa treba raditi konverziju u float
            datapart = pd.read_csv(path+"LUFlow2021 ("+str(x)+").csv", header=None, low_memory=False, usecols=[1,2,4,7,8,10,14,15],skiprows=1) #skiprows - ne ucitava se 1 red jer je nepotreban, a cijeli dataset bude dtypes=object pa treba raditi konverziju u float
            data = pd.concat([data, datapart]).reset_index(drop=True)
            print ('Ucitano ',str(x),'/',str(data_num),' datoteka')
        print('Koristi se set podataka prvih', data_num,'datoteka LUFlow2021, broj zapisa:',len(data.index))

        #reorder columns
        column_names = [1,2,4,7,8,10,15,14] #pozicije kolona
        data = data.reindex(columns=column_names)
        #rename columns
        data.rename({1: 'bytes_in', 2: 'bytes_out', 4:'dest_port', 7:'num_pkts_in', 8:'proto', 10:'src_port', 15:'duration', 14:'label'}, axis=1, inplace=True)
        return data

    elif (baza == 2):
        print ('Ucitavanje NF seta podataka', str(baza_name),'...')
        path="/home/igor/ML/netflow/"

        import glob, os
        os.chdir(path)
        fileCounter = len(glob.glob1(path,"*.csv"))
        fileNum = 1
        for file in glob.glob("*.csv"):
            #print(file)
            datapart = pd.read_csv(file, header=None, usecols=[2,5,6,7,11,12,14],skiprows=1, skipfooter=3, engine='python') #7 features, bez prvog i zadnja 3 reda
            #datapart = pd.read_csv(file, header=None, usecols=[2,5,7,11,12,14], skipfooter=3, engine='python')
            #datapart = pd.read_csv(file, header=None, low_memory=False) #full features
            data = pd.concat([data, datapart]).reset_index(drop=True)
            print ('Ucitana je datoteka ', file, fileNum,' od ukupno ',fileCounter)
            fileNum+=1
        #reorder columns
        column_names = [12,14,6,11,7,5,2] #pozicije kolona prema LUFlow2021
        data = data.reindex(columns=column_names)
        data['label']=0 #dodaje novu kolonu i oznacava kao benigni promet
        #rename columns
        data.rename({12: 'bytes_in', 14: 'bytes_out', 6:'dest_port', 11:'num_pkts_in', 7:'proto', 5:'src_port', 2:'duration'}, axis=1, inplace=True)
        print('Koristi se set podataka datoteke RealNetflow, broj zapisa:',len(data.index))
        return data

    elif (baza==3):
        print ('Ucitavanje NF seta podataka', str(baza_name),'...')
```

```
        path="/home/igor/ML/dataset/NFDatasets/"
        data = pd.read_csv(path+str(baza_name)+".csv", header=None, usecols=[1,3,4,6,7,8,11,12],skiprows=1, engine='python')
        #reorder columns
        column_names = [6,8,3,7,4,1,11,12] #pozicije kolona
        data = data.reindex(columns=column_names)
        #rename columns
        data.rename({6: 'bytes_in', 8: 'bytes_out', 3:'dest_port', 7:'num_pkts_in', 4:'proto', 1:'src_port', 11:'duration', 12:'label'}, axis=1, inplace=True)
        print('Koristi se set podataka datoteke NF-UQ-NIDS-v1, broj zapisa:',len(data.index))
        return data

    elif (baza == 4):
        print ('Ucitavanje NF seta podataka za RealNetFlowFalsePositive', str(baza_name),'...')
        path="/home/igor/ML/check/"

        import glob, os
        os.chdir(path)
        fileCounter = len(glob.glob1(path,"*.csv"))
        fileNum = 1
        for file in glob.glob("*.csv"):
            #print(file)
            datapart = pd.read_csv(file, header=None,skiprows=1, engine='python')
            data = pd.concat([data, datapart]).reset_index(drop=True)
            print ('Ucitana je datoteka ', file, fileNum,' od ukupno ',fileCounter)
            fileNum+=1
        data['label']=0 #dodajem novu kolonu i oznacavam kao benigni promet
        data.rename({0: 'bytes_in', 1: 'bytes_out', 2:'dest_port', 3:'num_pkts_in', 4:'proto', 5:'src_port', 6:'duration'}, axis=1, inplace=True)
        print('Koristi se set podataka datoteke RealNetflowFalsePositive, broj zapisa:',len(data.index))
        return data

    elif (baza == 5):
        print ('Ucitavanje NF seta podataka', str(baza_name),'...')
        path="/home/igor/ML/netflow_attack/"

        import glob, os
        os.chdir(path)
        fileCounter = len(glob.glob1(path,"*.csv"))
        fileNum = 1
        for file in glob.glob("*.csv"):
            #print(file)
            datapart = pd.read_csv(file, header=None, usecols=[2,5,6,7,11,12,14],skiprows=1, skipfooter=3, engine='python') #7 features, bez prvog i
zadnja 3 reda
            #datapart = pd.read_csv(file, header=None, usecols=[2,5,7,11,12,14], skipfooter=3, engine='python')
            #datapart = pd.read_csv(file, header=None, low_memory=False) #full features
            data = pd.concat([data, datapart]).reset_index(drop=True)
            print ('Ucitana je datoteka ', file, fileNum,' od ukupno ',fileCounter)
            fileNum+=1
        #reorder columns
        column_names = [12,14,6,11,7,5,2] #pozicije kolona prema LUFlow2021
        data = data.reindex(columns=column_names)
        data['label']=1 #dodajem novu kolonu i oznacavam kao benigni promet
        #rename columns
        data.rename({12: 'bytes_in', 14: 'bytes_out', 6:'dest_port', 11:'num_pkts_in', 7:'proto', 5:'src_port', 2:'duration'}, axis=1, inplace=True)
        print('Koristi se set podataka datoteke RealNetflowattack, broj zapisa:',len(data.index))
        return data

    elif (baza == 6):
        print ('Ucitavanje NF seta podataka', str(baza_name),'...')
        path="/home/igor/ML/netflow_normal/"

        import glob, os
        os.chdir(path)
        fileCounter = len(glob.glob1(path,"*.csv"))
        fileNum = 1
        for file in glob.glob("*.csv"):
            #print(file)
            datapart = pd.read_csv(file, header=None, usecols=[2,5,6,7,11,12,14],skiprows=1, skipfooter=3, engine='python') #7 features, bez prvog i
zadnja 3 reda
            #datapart = pd.read_csv(file, header=None, usecols=[2,5,7,11,12,14], skipfooter=3, engine='python')
            #datapart = pd.read_csv(file, header=None, low_memory=False) #full features
            data = pd.concat([data, datapart]).reset_index(drop=True)
```

```
            print ('Ucitana je datoteka ', file, fileNum,' od ukupno ',fileCounter)
            fileNum+=1
        #reorder columns
        column_names = [12,14,6,11,7,5,2] #pozicije kolona prema LUFlow2021
        data = data.reindex(columns=column_names)
        data['label']=0 #dodaje novu kolonu i oznacava kao benigni promet
        #rename columns
        data.rename({12: 'bytes_in', 14: 'bytes_out', 6:'dest_port', 11:'num_pkts_in', 7:'proto', 5:'src_port', 2:'duration'}, axis=1, inplace=True)
        print('Koristi se set podataka datoteke RealNetflowNormal, broj zapisa:',len(data.index))
        return data

def fn_feature_select(data,baza):
    print ('Brisanje nepotrebnih znacajki...')

    if (baza == 1): # LUFlow2021
        data=data[data['label'].str.contains("label|outlier")==False] #brise sve redove koji sadrze string "label" i "outlier" u stupcu label
        print ("LUFlow2021 dataset feature selection")
    elif (baza == 2): # Real NetFlow
        #ostaju samo stupci sp,dp,pr,ibyt,obyt,ipkt,td -> 5,6,7,12,14,11,2

#data.drop(columns=[0,1,3,4,8,9,10,13,15,16,17,18,19,20,21,22,23,24,25,26,27,28,29,30,31,32,33,34,35,36,37,38,39,40,41,42,43,44,45,46,47],
inplace=True)
        print ("Real NetFlow dataset feature selection - none")
    elif (baza == 3): # NF-UQ-NIDS-v1
        print ("NF-UQ-NIDS-v1 dataset feature selection - none")
    return data

def fn_feature_convert(data, baza_name):
    import pandas as pd
    TotalDataBefore=len(data)
    print ('Konverzija i ciscenje NaN vrijednosti baze ', baza_name)
    data = data.dropna() #brise sve redove koji imaju NaN vrijednosti
    data = data.reset_index(drop=True) #reindex redova
    TotalDataAfter=len(data)
    print ('Obrisano ukupno ',str(TotalDataBefore-TotalDataAfter),' zapisa, odnosno ',str((TotalDataBefore-
TotalDataAfter)/TotalDataBefore*100),'%')
    return data

def fn_feature_encoding_realNF(data):
    import pandas as pd
    #print ('Kodiranje kategorijskih znacajki, proto znacajka')
    le_name_mapping = {'L2TP': 115, 'ETHIP': 97,'IGMP': 2, 'GRE': 47, 'ICMP': 1, 'IPIP': 94, 'OSPF': 89, 'TCP': 6, 'UDP': 17, 'VRRP': 112}
    #data.iloc[: , -1:].value_counts() #unique vrijednosti
    data["proto"].replace(le_name_mapping, inplace=True)
    return data

def fn_feature_encoding_LUFlow(data):
        # za bazu LUFlow2021 treba target prebaciti u binarni oblik
        # data.iloc[: , -1:].value_counts() #imena unique vrijednosti
        import pandas as pd
        num=len(data.columns)-1 #kolona label je pod rednim brojem 'num' tj. 7
        data.iloc[:,num].replace(to_replace=r'^benign', value=0, regex=True, inplace=True) # sve Bening pretvara u 0
        data.iloc[:,num].replace(to_replace=r'malicious', value=1, regex=True, inplace=True) # sve ostalo u pretvara u 1
        data.iloc[:,num] = data.iloc[:,num].apply (pd.to_numeric, errors='coerce') #prebacuje target u dtypes.integer
        return data

def fn_anomaly_merge(data1, data2, data3, data4):
    import pandas as pd
    #extract anomalies
    #data_anomaly_LUFlow2021=data1[data1['label']==1]
    #data_anomaly_NF_UQ_NIDS_v1=data3[data3['label']==1]
    #data = pd.concat([data_anomaly_LUFlow2021, data_anomaly_NF_UQ_NIDS_v1, data2, data4]).reset_index(drop=True)
    data = pd.concat([data1, data3, data2, data4]).reset_index(drop=True)
    #data = pd.concat([data1, data_anomaly_NF_UQ_NIDS_v1, data2]).reset_index(drop=True)
    return data

def fn_data_splitting(data):
    print ('Splitting...')
    import numpy as np
    y = data.iloc[:,-1:] #target kolona
```

```
    y = np.ravel(y)
    X = data.iloc[:,:-1] #sve osim target kolone
    var_test_percentage = 0.2 #train size 80%, test size 20%
    from sklearn.model_selection import train_test_split
    #random_state = 1 da svaki puta bude isti raspored, stratify =y da se ravnomjerno raspodjele klase po train i test datasetu
    print ("Radi se splitting s omjerom test_size:", var_test_percentage)
    X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=var_test_percentage, random_state=1, stratify=y)
    return X_train, X_test, y_train, y_test, var_test_percentage

def fn_email(var_start):
    print ('Saljem e-mail...')
    import smtplib
    import datetime
    from email.message import EmailMessage
    body_string = 'ML skripta pocela u:' + var_start + ' ML skripta zavrsila u:' + datetime.datetime.now().strftime("%Y-%m-%d %H:%M:%S")
    msg = EmailMessage()
    msg.set_content(body_string)
    msg['Subject'] = 'ML algoritam CVSearch'
    msg['From'] = 'MachineLearning@sos02ml'
    msg['To'] = 'igor.fosic@hep.hr'

    s = smtplib.SMTP('10.10.20.10', 25)
    s.send_message(msg)
    s.quit()
    return

def fn_filename(baza_name,var_ekstenzija):
    import time
    timestr = time.strftime("%Y%m%d-%H%M%S")
    var_filename = '/home/igor/ML/scripts/'+baza_name+'_'+timestr + var_ekstenzija #koristi datum+vrijeme+imeskripte za png file, putanja ista
gdje su skripte
    return var_filename

def fn_delete_files(path):
    import os
    raw_files_input_dir = [f for f in os.listdir(path) if 'current' not in f]
    if raw_files_input_dir:
        os.chdir(path)
        for i in range(len(raw_files_input_dir)):
            os.remove(raw_files_input_dir[i])
            print('Obrisana datoteka '+ str(path)+str(raw_files_input_dir))

def fn_convert_files(raw_file):
    import subprocess
    convert_action = "nfdump -r " + raw_file + " -b -o csv > "+raw_file+".csv"
    output = subprocess.check_output(convert_action, shell=True)
    csv_file=raw_file+".csv"
    return csv_file

def fn_load_dataset(csv_file):
    import pandas as pd
    data4 = pd.read_csv(
            csv_file,
            header=None,
            usecols=[2,5,6,7,11,12,14,15],
            skiprows=1,
            skipfooter=3,
            engine='python'
            )#7 features, bez prvog i zadnja 3 reda, 15 je input interface
    column_names = [12,14,6,11,7,5,2] #pozicije kolona prema LUFlow2021
    data4 = data4.reindex(columns=column_names)
    data4.rename({12: 'bytes_in', 14: 'bytes_out', 6:'dest_port', 11:'num_pkts_in', 7:'proto', 5:'src_port', 2:'duration'}, axis=1, inplace=True)
    return data4

def fn_load_dataset_info(csv_file):
    import pandas as pd
    data = pd.read_csv(
            csv_file,
            header=None,
            usecols=[3,4,15,16,44],
```

```
            skiprows=1,
            skipfooter=3,
            engine='python'
            )#7 features, bez prvog i zadnja 3 reda, 15 je input interface
    data.rename({3: 'src', 4: 'dst', 15:'if_in', 16:'if_out', 44:'device'}, axis=1, inplace=True)
    return data

def fn_API_interface(action,controllerIP,interface):
    import urllib3
    import json
    import requests
    import time
    urllib3.disable_warnings()
    #url = "https://10.230.249.11/api/aaaLogin.json"

    #authentication
    url = "https://"+str(controllerIP)+"/api/aaaLogin.json"
    payload={"aaaUser":{"attributes":{"name":"fosictest","pwd":"testfosic"}}}
    headers = {'Content-Type': 'application/json'}
    response = requests.request("POST", url, headers=headers, json=payload, verify=False)
    #response.status_code
    r_json = response.json()
    token = r_json["imdata"][0]["aaaLogin"]["attributes"]["token"]
    cookie = 'APIC-cookie='+token
    interface='eth1/1' # interface se dobije iz NetFlow-a

    #disable
    if (action =='disable'):
        payload2={"fabricRsOosPath":{"attributes":{"tDn":"topology/pod-1/paths-1121/pathep-["+interface+"]","lc":"blacklist"},"children": []}}

    #enable
    elif (action=='enable'):
        payload2={"fabricRsOosPath":{"attributes":{"dn":"uni/fabric/outofsvc/rsoosPath-[topology/pod-1/paths-1121/pathep-
["+interface+"]","status":"deleted"},"children": []}}

    url="https://"+str(controllerIP)+"/api/node/mo/uni/fabric/outofsvc.json"
    headers = {'Content-Type': 'application/json', 'Cookie': cookie}
    response2 = requests.request("POST", url, headers=headers, json=payload2, verify=False)
    #print(action+' status: '+str(response2.status_code))
```

Prilog F

Rad NFMIDS modela bez IPS funkcionalnosti u stvarnom vremenu s kombiniranim pozadinskim prometom

Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
'/home/igor/ML/benign/nfcapd.202304270950'
Datoteka /home/igor/ML/input/nfcapd.202304270950 je obrisana i premjestena u benign direktorij!
Datoteka /home/igor/ML/input/nfcapd.202304270950.csv je obrisana!
proces detekcije za 358 zapisa je trajao 00:00:00.64
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
*** komentar **** Početak kibernetičkog napada uskraćivanjem usluge – tip 1.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
pronadjeno je 21261/57773 anomalija u zapisu
'/home/igor/ML/quarantine/nfcapd.202304270951'
'/home/igor/ML/quarantine/nfcapd.202304270951.csv'
Datoteka /home/igor/ML/input/nfcapd.202304270951 je obrisana i premjestena u karantenu za daljnju analizu!
zovem disable API za interface 0 09:53:00
zovem disable API za interface 32 09:53:00
zovem disable API za interface 41 09:53:00
proces detekcije za 57773 zapisa je trajao 00:00:07.36
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
pronadjeno je 54709/65850 anomalija u zapisu
'/home/igor/ML/quarantine/nfcapd.202304270952'
'/home/igor/ML/quarantine/nfcapd.202304270952.csv'
Datoteka /home/igor/ML/input/nfcapd.202304270952 je obrisana i premjestena u karantenu za daljnju analizu!
zovem disable API za interface 0 09:53:54
zovem disable API za interface 41 09:53:54
zovem disable API za interface 32 09:53:54
proces detekcije za 65850 zapisa je trajao 00:00:08.43
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
pronadjeno je 54922/65891 anomalija u zapisu
'/home/igor/ML/quarantine/nfcapd.202304270953'
'/home/igor/ML/quarantine/nfcapd.202304270953.csv'
Datoteka /home/igor/ML/input/nfcapd.202304270953 je obrisana i premjestena u karantenu za daljnju analizu!
zovem disable API za interface 0 09:55:02
zovem disable API za interface 32 09:55:02
zovem disable API za interface 41 09:55:02
proces detekcije za 65891 zapisa je trajao 00:00:08.56
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
*** komentar **** Kraj kibernetičkog napada uskraćivanjem usluge – tip 1.
*** komentar **** Početak režima normalnog prometa
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
pronadjeno je 65520/65916 anomalija u zapisu
'/home/igor/ML/quarantine/nfcapd.202304270954'
'/home/igor/ML/quarantine/nfcapd.202304270954.csv'
*** komentar **** bufferirani promet s mrežnih uređaja
Datoteka /home/igor/ML/input/nfcapd.202304270954 je obrisana i premjestena u karantenu za daljnju analizu!
zovem disable API za interface 0 09:55:56
proces detekcije za 65916 zapisa je trajao 00:00:08.85
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
'/home/igor/ML/benign/nfcapd.202304270955'
Datoteka /home/igor/ML/input/nfcapd.202304270955 je obrisana i premjestena u benign direktorij!
Datoteka /home/igor/ML/input/nfcapd.202304270955.csv je obrisana!
proces detekcije za 371 zapisa je trajao 00:00:00.74
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
'/home/igor/ML/benign/nfcapd.202304270956'
Datoteka /home/igor/ML/input/nfcapd.202304270956 je obrisana i premjestena u benign direktorij!

Datoteka /home/igor/ML/input/nfcapd.202304270956.csv je obrisana!
proces detekcije za 314 zapisa je trajao 00:00:00.69
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
'/home/igor/ML/benign/nfcapd.202304270957'
Datoteka /home/igor/ML/input/nfcapd.202304270957 je obrisana i premjestena u benign direktorij!
Datoteka /home/igor/ML/input/nfcapd.202304270957.csv je obrisana!
proces detekcije za 438 zapisa je trajao 00:00:00.70
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
*** komentar **** Početak kibernetičkog napada otkrivanja korisničkog imena i lozinke – tip 2.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
pronadjeno je 17/453 anomalija u zapisu
'/home/igor/ML/quarantine/nfcapd.202304270958'
'/home/igor/ML/quarantine/nfcapd.202304270958.csv'
Datoteka /home/igor/ML/input/nfcapd.202304270958 je obrisana i premjestena u karantenu za daljnju analizu!
zovem disable API za interface 0 09:59:59
zovem disable API za interface 32 09:59:59
proces detekcije za 453 zapisa je trajao 00:00:00.80
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
pronadjeno je 20/495 anomalija u zapisu
'/home/igor/ML/quarantine/nfcapd.202304270959'
'/home/igor/ML/quarantine/nfcapd.202304270959.csv'
Datoteka /home/igor/ML/input/nfcapd.202304270959 je obrisana i premjestena u karantenu za daljnju analizu!
zovem disable API za interface 32 10:01:00
proces detekcije za 495 zapisa je trajao 00:00:00.76
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
pronadjeno je 1/469 anomalija u zapisu
'/home/igor/ML/quarantine/nfcapd.202304271000'
'/home/igor/ML/quarantine/nfcapd.202304271000.csv'
Datoteka /home/igor/ML/input/nfcapd.202304271000 je obrisana i premjestena u karantenu za daljnju analizu!
zovem disable API za interface 32 10:02:01
proces detekcije za 469 zapisa je trajao 00:00:00.72
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
*** komentar **** Početak režima normalnog prometa
'/home/igor/ML/benign/nfcapd.202304271001'
Datoteka /home/igor/ML/input/nfcapd.202304271001 je obrisana i premjestena u benign direktorij!
Datoteka /home/igor/ML/input/nfcapd.202304271001.csv je obrisana!
proces detekcije za 408 zapisa je trajao 00:00:00.67
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
'/home/igor/ML/benign/nfcapd.202304271002'
Datoteka /home/igor/ML/input/nfcapd.202304271002 je obrisana i premjestena u benign direktorij!
Datoteka /home/igor/ML/input/nfcapd.202304271002.csv je obrisana!
proces detekcije za 338 zapisa je trajao 00:00:00.66
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
'/home/igor/ML/benign/nfcapd.202304271003'
Datoteka /home/igor/ML/input/nfcapd.202304271003 je obrisana i premjestena u benign direktorij!
Datoteka /home/igor/ML/input/nfcapd.202304271003.csv je obrisana!
proces detekcije za 1626 zapisa je trajao 00:00:00.99
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
*** komentar **** Početak kibernetičkog napada skeniranja portova – tip 3.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
pronadjeno je 32/1798 anomalija u zapisu
'/home/igor/ML/quarantine/nfcapd.202304271004'
'/home/igor/ML/quarantine/nfcapd.202304271004.csv'
Datoteka /home/igor/ML/input/nfcapd.202304271004 je obrisana i premjestena u karantenu za daljnju analizu!
zovem disable API za interface 0 10:05:50
proces detekcije za 1798 zapisa je trajao 00:00:01.12
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.

Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
pronadjeno je 13/612 anomalija u zapisu
'/home/igor/ML/quarantine/nfcapd.202304271005'
'/home/igor/ML/quarantine/nfcapd.202304271005.csv'
Datoteka /home/igor/ML/input/nfcapd.202304271005 je obrisana i premjestena u karantenu za daljnju analizu!
zovem disable API za interface 0 10:06:50
proces detekcije za 612 zapisa je trajao 00:00:00.80
*** komentar **** Početak režima normalnog prometa
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
'/home/igor/ML/benign/nfcapd.202304271006'
Datoteka /home/igor/ML/input/nfcapd.202304271006 je obrisana i premjestena u benign direktorij!
Datoteka /home/igor/ML/input/nfcapd.202304271006.csv je obrisana!
proces detekcije za 371 zapisa je trajao 00:00:00.66
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.
Nema .csv datoteka u input direktoriju. Cekam 15 sekundi za novu provjeru.