

# Otkrivanje lažnih vijesti pomoću stojnog učenja

---

Jurišić, Mirko

**Undergraduate thesis / Završni rad**

**2023**

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

*Permanent link / Trajna poveznica:* <https://urn.nsk.hr/um:nbn:hr:166:986499>

*Rights / Prava:* [Attribution 4.0 International/Imenovanje 4.0 međunarodna](#)

*Download date / Datum preuzimanja:* **2024-05-12**

*Repository / Repozitorij:*

[Repository of Faculty of Science](#)



Sveučilište u Splitu

Prirodoslovno-matematički fakultet

Odjel za informatiku

ZAVRŠNI RAD

**OTKRIVANJE LAŽNIH VIJESTI POMOĆU  
STROJNOG UČENJA**

Mirko Jurišić

Split, rujan 2023.

## Temeljna dokumentacijska kartica

Završni rad

Sveučilište u Splitu  
Prirodoslovno-matematički fakultet  
Odjel za informatiku  
Ruđera Boškovića 33, 21000 Split, Hrvatska

### OTKRIVANJE LAŽNIH VIJESTI POMOĆU STROJNOG UČENJA

Mirko Jurišić

#### SAŽETAK

Rad se bavi otkrivanjem lažnih vijesti pomoću strojnog učenja, što su zapravo lažne vijesti, koje vrste lažnih vijesti postoje i kako možemo identificirati lažne vijesti bez strojnog učenja. Također je detaljno objašnjeno kako rade algoritmi strojnog učenja za klasifikaciju vijesti. U trećem poglavlju je prikazan završni projekt. Projekt se sastoji od web stranice koja služi za unos tekstova vijesti i napravljena je pomoću React-a. Pomoću Python-a je napravljen model strojnog učenja koji služi za otkrivanje lažnih vijesti.

**Ključne riječi:** Lažne vijesti, strojno učenje, otkrivanje, algoritmi, klasifikacija, web stranice, React, Python, model

Rad je pohranjen u knjižnici Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

**Rad sadrži:** 37 stranica, 44 grafičkih prikaza, 0 tablica i 22 literarnih navoda.

Izvornik je na hrvatskom jeziku.

**Mentor:** **doc. dr. sc. Divna Krpan**, docent Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

**Ocenjivači:** **doc. dr. sc. Divna Krpan**, docent Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

**prof. dr. sc. Saša Mladenović**, redoviti profesor Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

**Dino Nejašmić, pred.**, predavač Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Rad prihvaćen: Rujan, 2023.

# **Basic documentation card**

Thesis

University of Split  
Faculty of Science  
Department of Computer Science  
Ruđera Boškovića 33, 21000 Split, Croatia

## **FAKE NEWS DETECTION USING MACHINE LEARNING**

Mirko Jurišić

### **ABSTRACT**

This paper is concentrated on the detection of fake news using machine learning, what fake news is, what types of fake news there are, and how we can identify fake news without machine learning. It also explains in detail how machine learning algorithms work for news classification. The final project is presented in the third chapter. The project consists of a web site that is used to enter news texts and was made using React. Using Python, a machine learning model was made to detect fake news.

**Key Words:** Fake news, machine learning, detection, algorithms, classification, web site, React, Python, model

Thesis deposited in library of Faculty of science, University of Split.

**Thesis consist of:** 37 pages, 44 figures, 0 tables and 22 references

Original language: Croatian

**Supervisor:** **Divna Krpan, Ph.D.** Assistant Professor of Faculty of Science, University of Split

**Reviewers:** **Divna Krpan, Ph.D.** Assistant Professor of Faculty of Science, University of Split,

**Saša Mladenović, Ph.D.** Full Professor of Faculty of Science, University of Split,

**Dino Nejašmić.** Lecturer of Faculty of Science, University of Split

Thesis accepted: September, 2023.

## Sadržaj

Uvod .....	1
1 Lažne vijesti.....	2
1.1 Definicija lažnih vijesti.....	2
1.2 Vrste lažnih vijesti.....	3
1.2.1 Satira ili parodija .....	4
1.2.2 Lažna veza .....	5
1.2.3 Obmanjujući sadržaj.....	5
1.2.4 Lažan kontekst .....	6
1.2.5 Lažni sadržaj .....	7
1.2.6 Manipulirani sadržaj.....	8
1.2.7 Izmišljeni sadržaj .....	8
1.3 Prepoznavanje lažnih vijesti .....	9
2 Strojno učenje .....	10
2.1 Tipovi strojnog učenja .....	11
2.1.1 Nadzirano učenje.....	11
2.1.2 Nenadzirano učenje .....	12
2.1.3 Podržano učenje .....	12
2.2 Algoritmi strojnog učenja za otkrivanje lažnih vijesti .....	13
2.2.1 Stablo odlučivanja .....	13
2.2.2 Slučajne šume .....	15
2.2.3 Metoda potpornih vektora.....	16
2.2.4 Naivan Bayes .....	20
2.2.5 Ekstremno pojačanje gradijenta .....	21
2.2.6 Obrada prirodnog jezika .....	22
3 Završni projekt .....	23
4 Zaključak .....	35
5 Literatura.....	36

## **Uvod**

Tradicionalno, ljudi konzumiraju vijesti i informacije putem novina i televizijskih kanala. Međutim, uz korištenje interneta i njegove prilagodbe u našem stilu života, korištenje novina i televizijskih kanala postalo je manje relevantno. Društveni mediji i live streaming platforme danas igraju važnu ulogu u usporedbi s televizijom i novinama kao glavni izvori vijesti.

Uz porast u korištenje društvenih medija poput Facebook, Instagram i Twitter, vijesti se brzo šire među milijunima ljudi korisnicima u vrlo kratkom vremenskom razdoblju. Široko dijeljenje lažnih vijesti ima takve posljedice stvaranje pristranih mišljenja kako bi se utjecalo na izbore ishode u korist određenih kandidata (Sharma., Saran., Pantil. 2021).

Uz toliko izvora informacija na internetu, postalo je teško identificirati koje se informacije temelje na istini, poluistinama ili lažima. Osim toga, čak se i alati umjetne inteligencije koriste za generiranje lažnih vijesti ili čak stranica s lažnim vijestima, što stoga može otežati otkrivanje lažnih vijesti.

Sada dolazi upotreba strojnog učenja, vrste umjetne inteligencije, koja se također može koristiti da nam pomogne identificirati koje se vijesti ili informacije temelje na istini, a koje na lažnim vijestima. Međutim, karakteristike koje se stalno mijenjaju i značajke lažnih vijesti u mrežama društvenih medija je izazov u kategorizaciji lažnih vijesti (Manzoor., Singla. 2019).

Ovaj završni rad bavit će se time kako pomoću strojnog učenja možemo otkriti lažne vijesti, što su zapravo lažne vijesti i koje vrste lažnih vijesti postoje, kako općenito prepoznati lažne vijesti bez korištenja strojnog učenja, što je strojno učenje te koji algoritmi strojnog učenja treba koristiti za otkrivanje lažnih vijesti.

Napravljen je i prototip aplikacije pomoću kojeg korisnici mogu otkriti lažne vijesti. Aplikacija je izrađena primjenom strojnog učenja. Više detalja o projektu bit će objašnjeno na kraju završnog rada.

# 1 Lažne vijesti

Lažne vijesti (eng. Fake News) je izraz koji se koristi za predstavljanje izmišljenih vijesti ili propagande koja sadrži dezinformacije priopćene putem tradicionalnih medijskih kanala poput novina i televizija kao i netradicionalnih medijskih kanala kao što su društveni mediji. Primjeri takvih platformi su Twitter, Instagram i Facebook. Ove platforme nude način na koji ljudi mogu podijeliti svoje mišljenja i stavove o pojedinim aspektima.

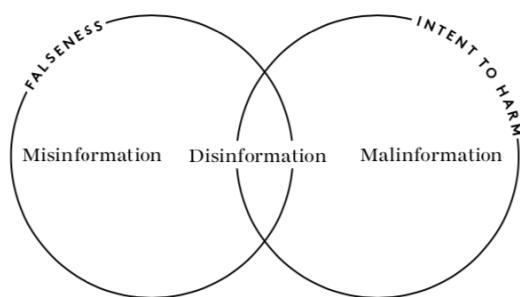
## 1.1 Definicija lažnih vijesti

Pojam „Fake News“ je neologizam (novi ili prenamijenjeni izraz koji ulazi u jezik, potaknut promjenama kulture ili tehnologije) i nema formalnu definiciju jer mnogi ljudi definiraju pojam drugačije (Wikipedia, 2023). Cambridgeov rječnik definira pojam kao „lažne priče koje izgledaju kao vijesti, šire se internetom ili korištenjem drugih medija, obično stvorene da utječu na politička stajališta ili kao šala“ (Cambridge Dictionary, 2023).

Pojam „Fake News“ je postao popularan 2016. godine tijekom predizborne kampanje u Sjedinjenim Državama, gdje su se Hilary Clinton i Donald Trump natjecali za mjesto predsjednika. Pojam se stalno koristi kada političari označavaju određene informacije kao lažne vijesti, čak i ako su te informacije točne. Stručnjaci sada preporučuju izbjegavanje pojma „Fake News“ ili barem ograničavanje njihove upotrebe jer je pojam usko povezan s politikom. Stoga su neki odlučili da više ne koriste taj pojam i umjesto toga koriste pojmove „misinformacija“ i „dezinformacija“ (Wardle, 2023).

Razlog neuspjeha pojma „Fake News“ je način na koji su ga političari diljem svijeta koristili za diskreditaciju i napad na profesionalno novinarstvo. Riječi su bitne i iz tog razloga, kada novinari u svom izvješćivanju koriste pojam „Fake News“, daju legitimitet beskorisnoj i sve opasnijoj frazi.

Zalažemo se za korištenje pojmove koji su najprikladniji za vrstu sadržaja: propaganda, laži, zavjere, glasine, prijevare, hyper-partisan sadržaj, neistine ili manipulirani mediji. Također koristimo pojmove dezinformacija, misinformacija i zlonamjerna informacija, koji zajedno nazivamo informacijskim poremećajem.



Slika 1. Odnos između misinformacija, dezinformacija i zlonamjernih informacija, [3]

**Dezinformacija** (eng. Disinformation) je sadržaj koji je namjerno lažan i osmišljen da nanese štetu. Motiviraju ga tri čimbenika: zaraditi novac; imati politički utjecaj, bilo strani ili domaći; izazvati nevolje radi toga. Kada se dezinformacije dijele, one se često pretvaraju u misinformacije.

**Misinformacija** (eng. Misinformation) također opisuje lažan sadržaj, ali osoba koja dijeli ne shvaća da je lažan ili obmanjujući. Često dezinformacija netko tko ne shvaća da je lažna i ta osoba je podijeli sa svojim mrežama, vjerujući da pomaže. Dijeljenje misinformacija je potaknuto socio-psihološkim čimbenicima. Na internetu ljudi izvode svoje identitete. Žele se osjećati povezanim sa svojim takozvanim plemenom, bilo da to znači članovima iste političke stranke, roditeljima koji ne cijepi svoju djecu, aktivistima zabrinutim zbog klimatskih promjena ili onima koji pripadaju određenoj vjeri, rasi ili etničkoj pripadnosti skupina.

**Zlonamjerne informacije** (eng. Malinformation) opisuju istinite informacije koje se dijele s namjerom nanošenja štete. Primjer za to je kada su 2016. godine ruski agenti hakirali e-poštu Demokratskog nacionalnog odbora i kampanje Hillary Clinton i iznijeli određene detalje u javnost kako bi naštetili ugledu.

## 1.2 Vrste lažnih vijesti



Slika 2. Sedam vrsta misinformacija i dezinformacija, [3]

Unutar ova tri sveobuhvatna tipa informacijskog poremećaja, također često spominjemo sedam kategorija, jer smatramo da to pomaže ljudima da razumiju složenost ovog ekosustava. Prvo ih je objavio First Draft u veljače 2017. kao način da se razgovor odmakne od oslanjanja na pojam „Fake News“. Još uvijek djeluje kao koristan način razmišljanja o različitim primjerima. Osim toga, različite vrste misinformacija i dezinformacija su rangirane od niskog do visokog rizika.

### 1.2.1 Satira ili parodija

Satira nema nanijetu štetu, ali ima namjeru zavarati. Razlog zašto je satira korištena na ovaj način tako moćan alat je taj što je često prvi koji je vide satiru česti shvaćaju kao takvu. Ali kako se ponovno dijeli, sve više ljudi gubi vezu s izvornim glasnikom i ne razumiju ga kao satiru. Jedan od primjera iz 2019. u SAD-u odnosi se na stvaranje web stranice dizajniran obliku službene web stranice Joea Bidena dok je bivši potpredsjednik vodio kampanju za demokratskog kandidata za predsjedničke izbore 2020.



Slika 3. Službena web stranica Joea Bidena (na vrhu) i parodijska verzija (na dnu), [3]

S URL-om „joebiden.info“, Google je parodijsku stranicu indeksirao više od Bidenove službene web stranice „joebiden.com“ za vrijeme kompanije u travnju 2019. Autor stranice, koji je prethodno stvarao sadržaj za Donalda Trumpa, rekao je da nije kreirao web stranicu za Trumpovu kampanju. Razlog zašto je autor stranice napravio parodijsku verziju stranice Jea Bidena je taj što je stranica namijenjena samo zabavi.

## 1.2.2 Lažna veza

Lažna veza (eng. False connection) opisuje se kao kada naslovi, vizualni elementi ili opisi ne podržavaju sadržaj. Jedna vrsta lažne veze je kada novinske kuće koriste senzacionalistički jezik kako bi potaknule klikove, odnosno jezik koji čitateljima ne odgovara kada dođu na stranicu. Ova vrsta lažne veze naziva se „mamac za klikove“ (eng. Clickbait).

Iako je moguće koristiti ove vrste tehnika za povećanje prometa u kratkom roku, nedvojbeno će postojati dugoročniji utjecaj na odnos ljudi s vijestima (Wardle, 2023). Moglo bi se tvrditi da je šteta minimalna kada je publika već upoznata s clickbaitom, ali kao tehniku treba je smatrati oblikom informacijskog poremećaja.

U 2014., Facebook je promijenio svoj novi algoritam feeda, posebno niže rangirane stranice koje su koristile clickbait naslove. Još jedno ažuriranje iz 2019. detaljno je opisalo kako je Facebook koristio rezultate ankete da bi odredio prioritete objava koje uključuju poveznice koje su korisnici smatrali vrjednjima. Studija koju je proveo Engaging News Project 2016. godine pokazala je da vrsta naslova i izvor naslova mogu utjecati na to hoće li osoba više-manje pozitivno reagirati na projekt vijesti i namjerava se ubuduće baviti tim proizvodom.

## 1.2.3 Obmanjujući sadržaj

Obmanjujući sadržaj (eng. Misleading content) definiran je kao obmanjujuća upotreba informacija za uokvirivanje problema ili pojedinca. Preoblikovanje priča u naslovima, korištenje fragmenata citata za podupiranje šire točke, navođenje statistike na način koji je u skladu sa stavom ili odluka da se nešto ne pokrije jer potkopava argument, sve su to priznate tehnike. Obmanjujući sadržaj može doći u mnogim oblicima, ali ovaj primjer iz The New York Timesa pokazuje kako su vizualni sadržaji također podložni optužbama da su obmanjujući.



Appellate Judgeships Confirmed During First Congressional Term. Ronald Reagan, 19; George Bush, 18; Bill Clinton, 18; George W. Bush, 16; Barack Obama, 15; Donald Trump, 24. Illustration by Tracy Ma

Slika 4. Ilustracija usporedbe predsjedničkih potvrda žalbenih sudstava, [3]

Ilustracija koja uspoređuje predsjedničke potvrde žalbenih sudstava prikazana na slici dovodi u zabludu jer čekići nisu nacrtani u mjerilu. Trumpov čekić bi trebao biti manji od dvostruko veći od Obaminog. Kad pogledate čekić koji predstavlja Baracka Obamu (potvrđeno je 15 žalbenih sudstava) i usporedite to s Donaldom Trumpom (potvrđeno je 24 žalbena sudstva), ljestvica dijagrama nije usklađena.

#### 1.2.4 Lažan kontekst

Lažan kontekst (eng. False context) definira se kao kada se pravi sadržaj dijeli s lažnim kontekstualnim informacijama. Ova kategorija se koristi za opisivanje sadržaja koji je autentičan, ali je preoblikovan na opasne načine. Jedan od najsnažnijih primjera ove tehnike objavljen je nedugo nakon terorističkog napada povezanog s islamistima na Westminsterskom mostu u Londonu 2017 godine. Automobil se popeo na rubnik i vozio duž cijelog mosta, pri čemu je ozlijedeno najmanje 50 ljudi, a pet ih je poginulo, prije nego što se zabio u vrata Parlamenta.



Slika 5.Lažni prikaz ignoriranja žrtava napada, [3]

Na Twitteru se nakon toga proširila jedna objava koja ima istinitu sliku o terorističkom napadu. Koristilo se okvire protiv islama s nizom hashtagova uključujući #banislam. Račun na Twitteru koji je povezano s ruskom kampanjom dezinformiranja implicira da je muslimanka prikazana na slici bila ravnodušna prema žrtvi napada. U stvarnosti, nije gledala žrtvu iz poštovanja. Račun na Twitteru je izbrisana, ali je o tome izvijestio The Guardian.

## 1.2.5 Lažni sadržaj

Lažni sadržaj (eng. Imposter content) je kada se lažno predstavlja pravi izvor. Naši mozgovi uvijek traže heuristiku kako bi razumjeli stvari poput vjerodostojnosti kada je riječ o informacijama. Heuristike su mentalne prečace koje nam pomažu shvatiti svijet. Vidjeti brend koji već poznajemo je vrlo moćna heuristika. Iz tog razloga vidimo porast lažnog sadržaja, na primjer lažnog sadržaja koji koristi dobro poznate logotipe ili vijesti poznatih osoba ili novinara. Imamo mnogo primjera agenata dezinformacija koji koriste logotipe etabliranih novinskih marki za širenje laži i sadržaja. Evo jedan primjer BBC-ja koji se koristi na ovaj način.



Slika 6. Lažna stranica koja se predstavlja kao BBC širila lažne informacije o izborima u Velikoj Britaniji, [3]

Jedan primjer se dogodio tijekom općih izbora u Velikoj Britaniji 2017. i obavljen je na društvenim mrežama. Na slici piše da izbori traju dva dana, a ovisno o vašoj stranačkoj pripadnosti, trebate glasovati na točan dan.

## 1.2.6 Manipulirani sadržaj

Manipulirani sadržaj (eng. Manipulated content) je kada se informacijama ili slikama manipulira kako bi se obmanula javnost. To je također kada se promijeni aspekt originalnog sadržaja koji se najčešće odnosi na fotografije ili videozapise. Evo primjera tijekom predsjedničkih izbora u SAD-u 2016., kada su spojene dvije originalne slike.



Slika 7. Dvije slike su bile preklapane kako bi izgledalo da su službenici ICE-a prisutni na glasačkom mjestu, [3]

Lokacija je Arizona, a slika ljudi koji stoje u redu za glasanje došla je s primarnih izbora u ožujku 2016. Slika službenika ICE-a koji je uhitio je slika koja je u to vrijeme bila prvi rezultat na Googleu Slike pri traženju "ICE hapšenje." Druga je slika bila izrezana i postavljena na prvu i široko rasprostranjena uoči izbora.

## 1.2.7 Izmišljeni sadržaj

Izmišljeni sadržaj (eng. Fabricated content) je kada je novi sadržaj 100% lažan i napravljen da zavara i nanese štetu. Na primjer, lažna tvrdnja da je papa Franjo podržao Donalda Trumpa koja se dijelila tijekom predsjedničkih izbora u SAD-u 2016. i koja je izazvala veliku pozornost.



Slika 8. Ovaj članak tvrdi da je papa Franjo podržao Donalda Trumpa za predsjednika, ali to nije istina, [3]

### 1.3 Prepoznavanje lažnih vijesti

Budući da su o lažnim vijestima već napisane knjige, možemo zamisliti da ih nije uvijek lako prepoznati. Lažne vijesti mogu se pojaviti više od onih istinitih, a mogu ih prenijeti čak i mediji kojima vjerujete, što nije uvijek njihova krivnja (Andreja, 2023).

IFLA (International Federation of Library Associations and Institutions) navodi 8 stvari koje morate provjeriti ako želite biti sigurni da je vijest točna.



Slika 9.IFLA - Kako prepoznati lažne vijesti, [4]

Europski parlament također je dao nekoliko smjernica za prepoznavanje lažnih vijesti.



Slika 10. EPRS - Kako prepoznati lažne vijesti?, [4]

## 2 Strojno učenje

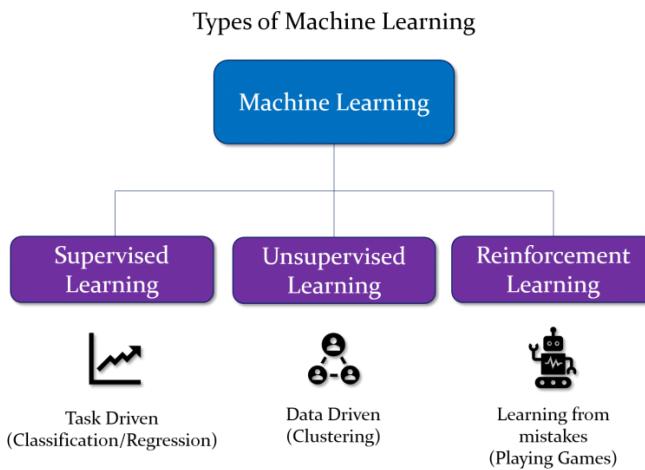
Sada kada znamo što su točno lažne vijesti, koje vrste lažnih vijesti postoje i kako možemo identificirati lažne vijesti, doći ćemo do drugog dijela teme, a to je strojno učenje.

Strojno učenje (eng. Machine learning) je grana umjetne inteligencije koja razvija algoritme učenjem skrivenih obrazaca skupova podataka koji su se koristili za izradu predviđanja novih podataka slične vrste, bez eksplicitnog programiranja za svaki zadatak.

Strojno učenje može se objasniti kao automatiziranje i poboljšanje procesa učenja računala na temelju njihovih iskustava bez stvarnog programiranja, tj. bez ikakve ljudske pomoći. Proces počinje unosom podataka, a zatim treniramo naše modele strojnog učenja pomoći podataka i različitih algoritama. Izbor algoritama ovisi o vrsti podataka koje imamo i kakvu vrstu zadataka pokušavamo automatizirati. Strojno učenje koristi se u mnogim različitim aplikacijama, od prepoznavanje slike i govora do obrade prirodnog jezika, sustava preporuka, otkrivanja prijevara, automatiziranih zadataka i mnogih drugih. Modeli strojnog učenja također se koriste za napajanje autonomnih vozila, dronova i robova, čineći ih inteligentnijima i prilagodljivijima promjenjivim okruženjima.

## 2.1 Tipovi strojnog učenja

Strojno učenje uključuje prikazivanje velike količine podatka stroju kako bi mogao učiti i stvarati predviđanja, pronalaziti obrazce ili klasificirati podatke. Tri glavne vrste strojnog učenja su nadzirano, nenadzirano i podržano učenje.



Slika 11. Tri glavna tipa strojnog učenja, [7]

### 2.1.1 Nadzirano učenje

Nadzirano učenje (eng. Supervised learning) je vrsta strojnog učenja u kojoj sustavu strojnog učenja pružamo podatke označene uzorcima kako bismo ga trenirali, a on na temelju toga predviđa izlaz. Sustav stvara model pomoću označenih podataka kako bi razumio skupove podataka i naučio o svakom podatku. Nakon što se završi treniranje i obrada podataka, tada testiramo model davanjem uzorka podataka kako bismo provjerili predvida li točan rezultat ili ne (Piyush & Rishabh, 2023). Cilj nadziranog učenja je mapiranje ulaznih podataka s izlaznim podacima. Nadzirano učenje temelji se na nadzoru, a isto je kao kada učenik uči stvari pod nadzorom nastavnika. Nastavnik daje dobre primjere koje učenik može upamtiti, odnosno naučiti, a učenik potom izvodi opća pravila iz tih konkretnih primjera koje koristi na novom primjeru.

Nadzirano učenje se može dalje grupirati u dvije kategorije algoritama: Klasifikacija i regresija.

**Klasifikacija** je predviđanje diskretnih odziva, pri čemu se ulazni podaci razvrstavaju u kategorije. Primjeri su je li e-mail originalna ili neželjena i sl.

**Regresija** je predviđanje kontinuiranih odziva. Regresijom se predviđaju kontinuirane varijable, poput promjene temperature, sastav i kvaliteta proizvoda i sl.

## 2.1.2 Nenadzirano učenje

Nenadzirano učenje (eng. Unsupervised Learning) je vrsta strojnog učenja u kojoj stroj uči bez ikakvog nadzora. Treniranje se omogućuje stroju sa skupom podataka koji nisu označeni, klasificirani ili kategorizirani, a algoritam treba djelovati na te podatke bez ikakvog nadzora. Cilj nenadziranog učenja je restrukturiranje ulaznih podataka u nove značajke ili grupu objekata sa sličnim uzorcima (Coursera, 2023). U nenadziranom učenju nemamo unaprijed određen rezultat. Stroj pokušava pronaći korisne uvide iz ogromne količine podataka.

Najčešća tehnika nenadziranog učenja je **grupiranje** (eng. clustering), pri čemu se traže skriveni obrasci ili grupe.

## 2.1.3 Podržano učenje

Podržano učenje (eng. Reinforcement Learning) je vrsta strojnog učenja temeljna na povratnim informacijama, u kojoj stroj učenja dobiva nagradu za svaku ispravnu radnju i kaznu za svaku pogrešnu radnju. Stroj automatski uči s tim povratnim informacijama i poboljšava svoju izvedbu. U podržanom učenju, stroj je u interakciji s okolinom i istražuje je. Cilj stroja je dobiti što više nagradnih bodova, a time i poboljšati svoju izvedbu (Potentiac, 2023).

Primjer podržanog učenja kada računala sama uče igrati videoigre. Algoritam nastavlja interakciju s okruženjem igre kroz niz akcija. Ovo okruženje daje nagradu ili kaznu na temelju poduzete radnje



The machine keeps on taking actions based on each reward it gets. This process keeps on iterating until a desired level of learning is not reached.

Slika 12. Primjer podržanog učenja, [7]

## 2.2 Algoritmi strojnog učenja za otkrivanje lažnih vijesti

Sada kada znamo što je točno strojno učenje i kako funkcioniraju različite vrste strojnog učenja, bavimo se kojim algoritmima strojnog učenja možemo otkriti lažne vijesti. Algoritmi strojnog učenja koje ćemo sada objasniti pripadaju vrsti nadziranog učenja. Sada moramo saznati koji algoritmi strojnog učenja možemo koristiti za otkrivanje lažnih vijesti.

Budući da je otkrivanje lažnih vijesti problem klasifikacije jer klasificiramo jesu li vijesti lažne vijesti ili istinite, moramo koristiti algoritme strojnog učenja koji su prikladni za klasifikaciju. Istraživači preporučuju 5 klasifikatora (eng. Classifier) strojnog učenja koji su prikladni za otkrivanje lažnih vijesti (Alghamdi. Lin. Luo., 2022).

Preporučeni klasifikatori su stablo odlučivanja, slučajne šume, metoda potpornih vektora, multinomski Naivan Bayes i ekstremno pojačanje gradijenta.

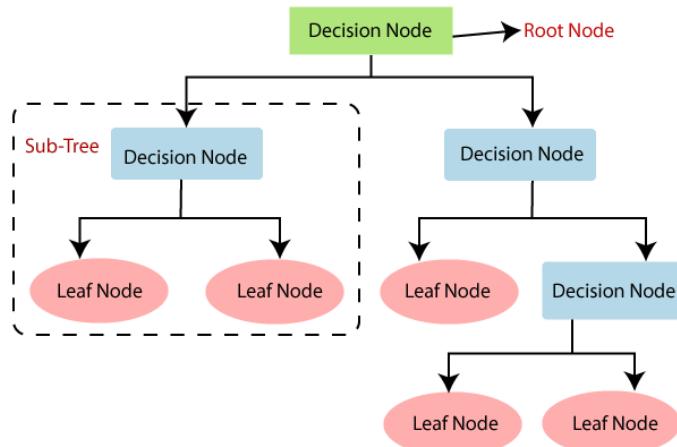
Također moramo koristiti jednu metodu strojnog učenja koja je važna za pripremnu obradu podataka (eng. Data Preprocessing), a to je obrada prirodnog jezika (eng. Natural Language Processing). Glavni razlog za korištenje obrade prirodnog jezika je razmatranje jedne ili više specijalizacija sustava ili algoritma. Ocjena obrade prirodnog jezika (eng. Natural Language Processing Rating) omogućuje kombinacija razumijevanja govora i generiranje govora (Khanam, Z., 2021).

Koji je točno klasifikator strojnog učenja najbolji za otkrivanje lažnih vijesti može varirati ovisno o skupu podataka i pripremnoj obradi podataka. Sada ćemo objasniti kako točno rade algoritmi strojnog učenja.

### 2.2.1 Stablo odlučivanja

Stablo odlučivanja (eng. Decision tree) je pristup nadziranom učenju koji se može koristiti za rješavanje problema klasifikacije ili regresije, no najčešće se koristi za rješavanje problema klasifikacije. Imamo **klasifikator** (eng. Classifier) s struktukom stabla, s unutarnjim **čvorovima** (eng. nodes) koji predstavljaju atributе skupa podataka, granama koje predstavljaju pravila odlučivanja, a svaki **lisni čvor** predstavlja rezultat. Kao rezultat toga, stablo odlučivanja je grafički prikaz svih mogućih rješenja problema ili odluke s određenim parametrima (Javatpoint, 2023).

Stablo odluke ima dva čvora, **čvor odluke** (eng. Decision node) i **čvor lista** (eng. Leaf node). Čvorovi odlučivanja koriste se za donošenje odluka i imaju nekoliko grana, dok lisni čvorovi predstavljaju posljedice tih odluka i nemaju više grana. Stablo odlučivanja postavlja pitanje i dijeli stablo na podstabla na temelju odgovora koji može biti DA ili NE.



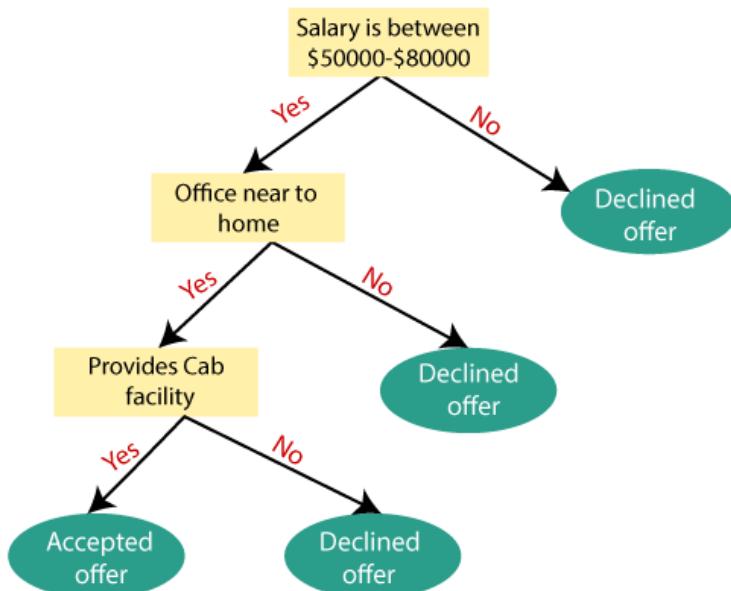
Slika 13. Struktura stabla odlučivanja, [10]

**Korijenski čvor** (eng. Root Node) je čvor gdje počinje stablo odlučivanja. On predstavlja cijeli skup podataka, koji se dalje dijeli na dva ili više skupova.

**Dijeljenje** (eng. Splitting) je proces dijeljenja korijenskog čvora u **podčvorove** (eng. Sub Nodes). Korijenski čvor stabla naziva se roditeljski čvor, a ostali čvorovi se nazivaju dječji čvorovi.

Najprije počinje algoritam od korijenskog čvora stabla. On uspoređuje vrijednosti korijenskog atributa s atributom zapisa, koji je stvarni skup podataka, i na temelju usporedbe prati granu, pa onda skače na sljedeći čvor. Za sljedeći čvor, algoritam ponovno uspoređuje vrijednost atributa s drugim podčvorovima i ide dalje. On nastavlja proces dok ne dođe do lisnog čvora stabla.

Za bolje razumijevanje algoritma imamo jedan primjer ponude za posao s određenom plaćom.

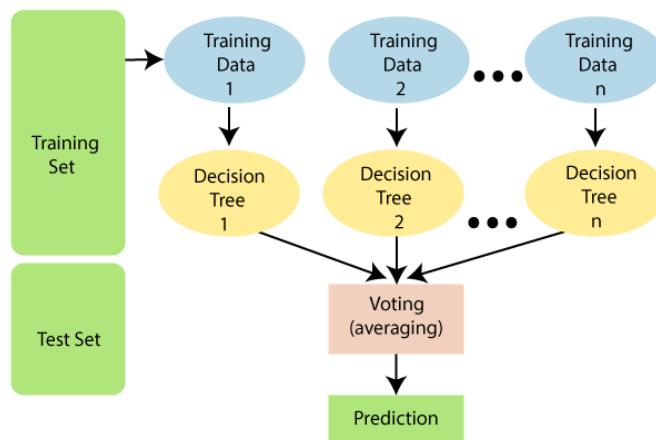


Slika 14. Ponude za posao s određenom plaćom, [10]

Pretpostavimo da postoji kandidat koji ima ponudu za posao i želi odlučiti treba li prihvati ponudu ili ne. Da bi se riješio ovaj problem, stablo odlučivanja počinje s korijenskim čvorom koji je atribut plaće. Korijenski čvor dalje se dijeli na sljedeći čvor odluke, što je udaljenost od ureda i jedan lisni čvor na temelju odgovarajućih oznaka. Sljedeći čvor odlučivanja dalje se dijeli na jedan čvor odlučivanja, koji je prijevozna usluga, i jedan lisni čvor. Na kraju se čvor dijeli na dva čvora lista koji su prihvaćena ponuda i odbijena ponuda.

## 2.2.2 Slučajne šume

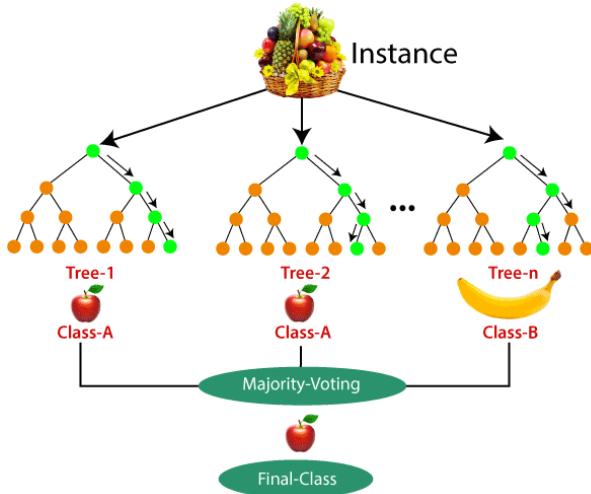
Slučajne šume (eng. Random Forest) su fleksibilan algoritam nadziranog učenja koji daje uglavnom izvrsne rezultate, čak i bez podešavanja **hiperparametara** (eng. hyper-paramter) (Donges, 2023). Također je jedan od najčešće korištenih algoritama, jer se može koristiti i za klasifikacijske i za regresijske zadatke. Šuma koju gradi je skup stabala odlučivanja, obično treniranih metodom „**bagging**“. Opća ideja metode bagging je da kombinacija modela učenja povećava ukupni rezultat. Stoga slučajna šuma gradi više stabala odlučivanja i spaja ih kako bi dobila točnije i stabilnije predviđanje.



Slika 15. Model algoritma slučajnih šuma, [13]

Slučajna šuma sadrži niz stabala odlučivanja na različitim podskupovima danog skupa podataka i uzima prosjek za poboljšanje točnosti predviđanja tog skupa podataka. Umjesto da se oslanja na jedno stablo odlučivanja, slučajna šuma uzima predviđanje iz svakog stabla i na temelju većina glasova predviđanja, on predviđa konačni rezultat (Javatpoint, 2023). Veći broj stabala u šumi dovodi do veće točnosti i sprječava problem prekomjernog opremanja (eng. overfitting).

Slučajna šuma dodaje dodatnu slučajnost modelu, dok raste stabla. Umjesto da traži najvažniju značajku dok dijeli čvor, traži najbolju značajku među nasumičnim podskupom značajki. To rezultira širokom raznolikošću (eng. diversity) koja općenito rezultira boljim modelom.



Slika 16. Primjer algoritma slučajnih šuma, [13]

Ovdje imamo primjer kako funkcioniра algoritam slučajnih šuma. Pretpostavimo da postoji skup podataka koji sadrži više slika voće. Ovaj se skup podataka daje klasifikatoru slučajnih šuma (eng. Random Forest classifier). Skupa podataka je podijeljen u podskupove i dan svakom stablu odlučivanja. Tijekom faze treniranja, svako stablo odlučivanja daje rezultat predviđanja, a kada se pojavi nova podatkovna točka, tada na temelju većine rezultata, klasifikator slučajnih šuma predviđa konačnu odluku.

### 2.2.3 Metoda potpornih vektora

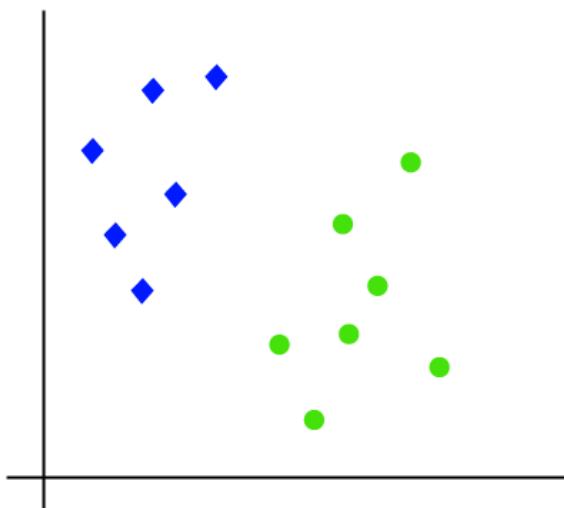
Metoda potpornih vektora (eng. Support Vector Machine) ili skraćeno SVM je algoritam nadziranog učenja koji se koristi za klasifikaciju i za regresiju. Glavni cilj SVM algoritma je pronaći optimalnu **hiperravninu** (eng. hyperplane) u N-dimenzionalnom prostoru koja može razdvojiti podatkovne točke u različitim klasama u prostoru značajki. Hiperravnina je granica odluke koja se koristi za odvajanje podatkovnih točaka različitih klasa u prostoru značajki (Javatpoint, 2023).

Postoje dvije vrste SVM-a, a to su linearni i nelinearni SVM.

**Linearni SVM** koristi se za podatke koji se mogu linearno odvojiti, što znači da ako se skup podataka može klasificirati u dvije klase pomoću jedne ravne linije, tada se takvi podaci nazivaju podacima koji se mogu linearno odvojiti, a klasifikator se naziva linearni SVM klasifikator.

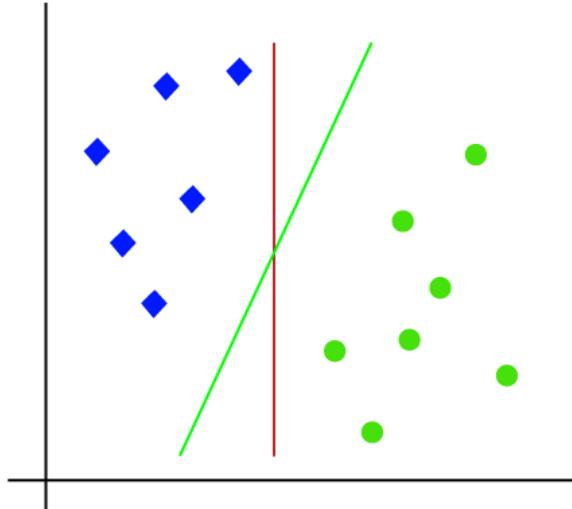
**Nelinearni SVM** koristi se za nelinearno odvojene podatke, što znači da ako se skup podataka ne može klasificirati pomoću ravne linije, tada se takvi podaci nazivaju nelinearnim podacima, a korišteni klasifikator naziva se nelinearni SVM klasifikator.

Rad linearnog SVM algoritma može se razumjeti pomoću primjera.



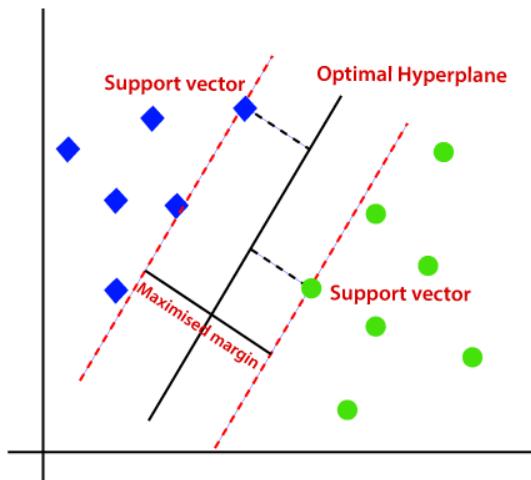
Slika 17. Primjer linearog SVM-a, [14]

Prepostavimo da imamo skup podataka koji ima dvije oznake, zelene i plave, a skup podataka ima dvije značajke, a to su  $x_1$  i  $x_2$ . Želimo klasifikator koji može klasificirati par koordinata u zelenu ili plavu boju.



Slika 18. Primjer linearog SVM-a, [14]

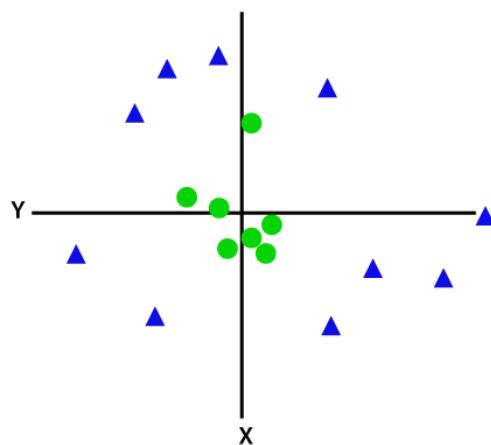
Kako je to dvodimenzionalni prostor, korištenjem samo ravne linije, možemo lako razdvojiti ove dvije klase. Ali može postojati više linija koje mogu odvojiti ove klase.



Slika 19. Primjer linearog SVM-a, [14]

SVM algoritam pomaže pronaći najbolju liniju ili granicu odluke, koja se najbolja granica ili regija naziva hiperravninom. SVM algoritam pronalazi najbližu točku pravaca iz obje klase, a ove točke se nazivaju **potporni vektori** (eng. support vectors). Udaljenost između vektora i hiperravnine naziva se **margina** ili **rub** (eng. margin), a cilj je maksimizirati marginu. Hiperravnina s maksimalnom marginom naziva se **optimalna hiperravnina** (eng. optimal hyperplane).

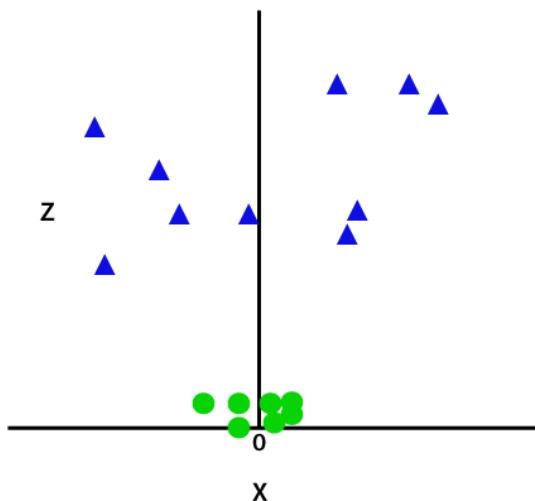
Za nelinearni SVM postoje nelinearni podaci i stoga ne možemo koristiti ravnu liniju za odvajanje klase.



Slika 20. Nelinearni SVM, [14]

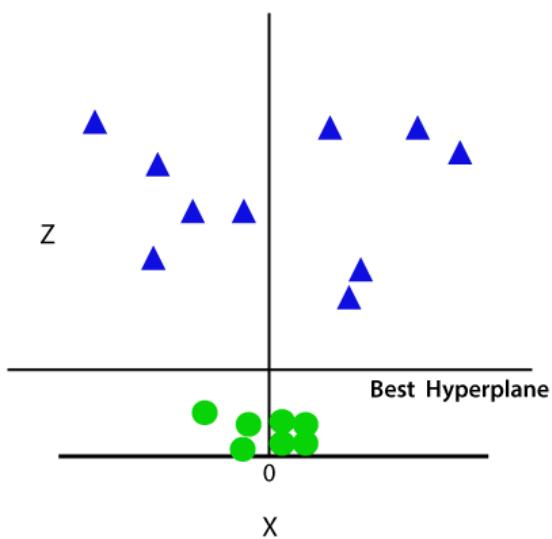
Da bismo razdvojili ove podatkovne točke, moramo dodati još jednu dimenziju. Za linearne podatke koristili smo dvije dimenzije x i y, tako da ćemo za nelinearne podatke dodati treću dimenziju z.

Treća dimenzija z može se izračunati sljedećom formulom:  $z = x^2 + y^2$



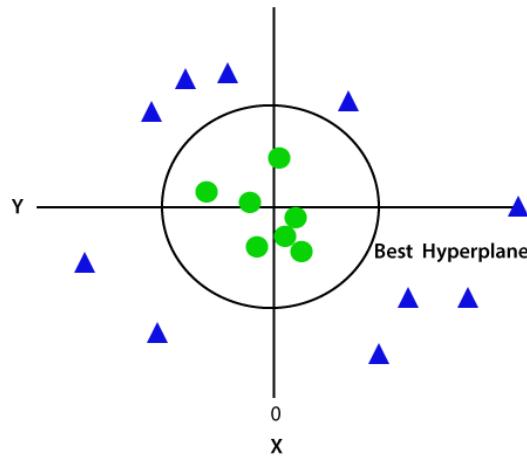
Slika 21. Nelinearni SVM, [14]

Nakon dodavanja treće dimenzije, prostor uzorka točaka podataka se promijenio jer je sada trodimenzionalan.



Slika 22. Nelinearni SVM, [14]

Sada će SVM podijeliti skupove podataka u klase na sljedeći način. Kao što vidite, plave podatkovne točke su iznad najbolje hiperravnine, a zelene podatkovne točke su ispod najbolje hiperravnine. Budući da se nalazimo u 3-dimenzionalnom prostoru, on izgleda kao ravnina koja je paralelna s x-osi.



Slika 23. Nelinearni SVM, [14]

Ako ga pretvorimo u 2-dimenzionalni prostor sa  $z=1$ , tada možemo vidjeti da će najbolja hiperravnina izgledati kao krug. Stoga dobivamo opseg polumjera 1 u slučaju nelinearnih podataka.

## 2.2.4 Naivan Bayes

Naivan Bayes (eng. Naive Bayes) je algoritam nadziranog učenja koji se temelji na Bayesovom teoremu i koristi se za rješavanje problema klasifikacije. Uglavnom se koristi u klasifikaciji teksta koja uključuje visoko-dimenzionalni skup podataka za treniranje. On je probabilistički klasifikator, što znači da predviđa na temelju vjerojatnosti objekta (Turing, 2023).

Algoritam Naivan Bayes sastoji se od dvije riječi Naivan i Bayes. Naziva se **Naivan** jer pretpostavlja da je pojava određene značajke neovisna o pojavi drugih značajki. Na primjer, ako se voće identificira na temelju boje, oblika i okusa, tada se crveno, sferično i slatko voće prepoznaće kao jabuka. Stoga svaka značajka zasebno pridonosi prepoznavanju da se radi o jabuci bez ovisnosti jedna o drugoj.

Naziva se **Bayes** jer ovisi o principu Bayesovog teorema (eng. Bayes Theorem). Bayesov teorem je također poznat kao Bayesovo pravilo ili Bayesov zakon, koji se koristi za određivanje vjerojatnosti hipoteze s prethodnim znanjem (Javatpoint, 2023). Ovisi o uvjetnoj vjerojatnosti.

Formula za **Bayesov teorem** je dana na sljedećoj slici.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

Slika 24. Formula za Bayesov teorem, [16]

$P(A|B)$  je **posteriorna vjerojatnost** (eng. Posterior probability), što znači vjerojatnost hipoteze A o promatranom događaju B.

$P(B|A)$  je **vjerojatnost vjerojatnosti** (eng. Likelihood probability), što znači vjerojatnost dokaza s obzirom da je vjerojatnost hipoteze istinita.

$P(A)$  je **prethodna vjerojatnost** (eng. Prior probability), što znači vjerojatnost hipoteze prije promatranja dokaza.

$P(B)$  je **granična vjerojatnost** (eng. Marginal probability), što znači vjerojatnost dokaza.

**Multinomski naivni Bayesov klasifikator** (eng. Multinomial Naive Bayes Classifier) se koristi za dodjelu dokumenata klasama na temelju statističke analize njihovog sadržaja. Klasifikacija ima za cilj dodijeliti fragmente teksta klasama određivanjem vjerojatnosti da dokument pripada klasi drugih dokumenata, koji imaju isti predmet (Ratz, 2023).

Svaki dokument sastoji se od više riječi koje doprinose razumijevanju sadržaja dokumenta. Klasa je oznaka jednog ili više dokumenata koji se odnose na istu temu. Označavanje dokumenata jednom od postojećih klasa vrši se provođenjem statističke analize, testiranjem hipoteze da su se termini dokumenta već pojavili u drugim dokumentima iz određene klase. Ovo povećava vjerojatnost da je dokument iz iste klase kao dokument, već klasificirani.

## 2.2.5 Ekstremno pojačanje gradijenta

Pojačanje gradijenta (eng. Gradient Boosting) je algoritam pojačanja (eng. boosting algorithm) u strojnog učenju koji se koristi za zadatke klasifikacije i regresije. **Boosting** je jedna vrsta skupine metode učenja koja uzastopno trenira model i svaki novi model pokušava ispraviti prethodni model (GeeksforGeeks,2023). Također kombinira nekoliko **slabih učenika** (eng. weak learners) u **snažne učenike** (eng. strong learners). Pojačanje gradijenta kombinira nekoliko slabih učenika u snažne učenike, pri čemu se svaki novi model trenira za minimiziranje funkcije gubitka kao što je **srednja kvadratna pogreška** (eng. mean squared error) ili unakrsna entropija (eng. cross-entropy) prethodnog modela korištenjem gradijentnog spuštanja (eng. gradient descent). U svakoj iteraciji algoritam izračunava gradijent funkcije gubitka s obzirom na predviđanja trenutnog skupa i zatim trenira novi slabi model za minimiziranje ovog gradijenta. Predviđanja novog modela zatim se dodaju skupu, a proces se ponavlja dok se ne ispunи kriterij zaustavljanja.

**Ekstremno pojačanje gradijenta** (eng. Extreme Gradient Boosting) ili skraćeno XGBoost je proširenje algoritma pojačanja gradijenta i posebno je dizajniran za poboljšanje brzine i performansi (Great Learning Team, 2023). Razvio ga je Tianqi Chen,a opisali su ga Chen i Carlos Guestrin u svom radu iz 2016. pod naslovom „XGBoost: A Scalable Tree Boosting System“. Ekstremno pojačanje gradijenta je postao popularan i dominira primjenjenim strojnim učenjem i Kaggle (platforma za natjecanje u znanosti o podacima) konkurencijom za strukturirane podatke zbog svoje skalabilnost.

## 2.2.6 Obrada prirodnog jezika

Obrada prirodnog jezika (eng. Natural Language Processing), ili skraćeno **NLP**, je metoda strojnog učenja koja računalima daje mogućnost tumačenja, manipuliranja i razumijevanja ljudskog jezika. Pripremna obrada teksta bitan je korak u obradi prirodnog jezika koji uključuje čišćenje i transformaciju nestrukturiranih tekstualnih podataka kako bi se pripremili za analizu. Obrada prirodnog jezika uključuje tokenizaciju, stemming, lematizaciju, uklanjanje zaustavne riječi i označavanje dijela govora.

**Tokenizacija** (eng. Tokenization) je proces rastavljanja zadanog teksta u obradi prirodnog jezika na najmanju jedinicu u rečenici koja se naziva token. Interpunkcijski znakovi (eng. Punctuation), znakovi, riječi i brojevi mogu se smatrati tokenima.

**Stemming** je proces pronalaženja korijena riječi. Upotreboom stemming, riječi se svode na svoje korijene riječi. Osnovna riječi ne mora biti isti korijen kao morfološki korijen temeljen na rječniku, to je samo jednak ili manji oblik riječi. (Kargin, 2023).

Kada rastavljate riječi pomoću korijenskih korijena, ponekad možete vidjeti da je pronalaženje korijena pogrešno i absurdno. Budući da Stemming radi na temelju pravila, on reže sufikse u rijećima prema određenom pravilu. Ovo otkriva nedosljednosti u vezi s korijenom. „**Overstemming**“ se događa kada su riječi previše skraćene. U takvim slučajevima, značenje riječi može biti iskrivljeno ili nema nikakvo značenje.

„**Understemming**“ se događa kada dvije riječi potječu iz istog korijena koji nije različitog korijena.

**Lematizacija** je proces pronalaženja oblika srodne riječi u rječniku koji uključuje dulje procese za izračunavanje od Stemming-a. Cilj je lematizacije, kao i stvaranja korijena, reduciranje fleksijskih oblika na zajednički osnovni oblik. Za razliku od korijena, lematizacija ne odsijeca jednostavno fleksije. Umjesto toga, koristi leksičke baze znanja kako bi dobio ispravne osnovne oblike riječi (Kargin, 2023).

**Označavanje dijela govora** (eng. Part of Speech Tagging) je riječi u tekstu prema njihovom vrstama riječi, na primjer imenica, pridjev, prilog, glagol i tako dalje. To je proces pretvaranja rečenice u oblike — popis riječi, popis torki (eng. tuple), gdje svaka torka ima oblik (rijec, oznaka). Oznaka u slučaju je oznaka dijela govora i označava je li riječ imenica, pridjev, glagol i tako dalje.

### 3 Završni projekt

Za svoj završni projekt sam napravio aplikaciju za otkrivanje lažnih vijesti. Aplikacija se sastoji od dva važna dijela, frontend i backend dijela. U frontend dijelu sam koristio okvir (eng. Framework) **React.js**. U backend dijelu sam koristio **Flask**, koji je mikro web okvir napisan u programskom jeziku Python. Backend dio također sadrži model strojnog učenja koji je treniran za otkrivanje lažnih vijesti. Aplikacija samo može otkriti vijesti na engleskom jeziku.

Prvi korak za moj projekt bio je napraviti model strojnog učenja za otkrivanje lažnih vijesti. Model je napisan pomoću Pythona u Google Colaboratoryju, hostirana Jupyter Notebook usluga koja ne zahtijeva postavljanje za korištenje i pruža besplatan pristup računalnim resursima. **Google Collaboratory** posebno je pogodan za strojno učenje i podatkovnu znanost. Također sam morao pronaći odgovarajući skup podataka koji je potreban za treniranje modela. Skup podataka je preuzet sa stranice Kaggle  
<https://www.kaggle.com/datasets/clmentbisaillon/fake-and-real-news-dataset>.

Sada ću korak po korak objasniti kako je napravljen model strojnog učenja za otkrivanje lažnih vijesti.

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.model_selection import train_test_split
import re
import nltk
from nltk.corpus import stopwords
from nltk.stem import PorterStemmer
from nltk.stem import WordNetLemmatizer
from nltk.tokenize import word_tokenize
from nltk import pos_tag
from sklearn.ensemble import RandomForestClassifier
from sklearn.svm import SVC
from sklearn.neighbors import KNeighborsClassifier
from xgboost import XGBClassifier
from sklearn.tree import DecisionTreeClassifier
from sklearn.naive_bayes import MultinomialNB
import xgboost as xgb
from sklearn.metrics import accuracy_score
from sklearn.metrics import f1_score
from sklearn.metrics import confusion_matrix
import joblib
```

Slika 25. Uvoz biblioteka potrebnih za naš model strojnog učenja

Prvo se uvoze važne biblioteke koje su nam potrebne za naš model strojnog učenja.

	title	text	subject	date	
0	As U.S. budget fight looms, Republicans flip t...	WASHINGTON (Reuters) - The head of a conservat...	politicsNews	December 31, 2017	
1	U.S. military to accept transgender recruits o...	WASHINGTON (Reuters) - Transgender people will...	politicsNews	December 29, 2017	
2	Senior U.S. Republican senator: 'Let Mr. Muell...	WASHINGTON (Reuters) - The special counsel inv...	politicsNews	December 31, 2017	
3	FBI Russia probe helped by Australian diplomat...	WASHINGTON (Reuters) - Trump campaign adviser ...	politicsNews	December 30, 2017	
4	Trump wants Postal Service to charge 'much mor...	SEATTLE/WASHINGTON (Reuters) - President Donal...	politicsNews	December 29, 2017	

	title	text	subject	date	
0	Donald Trump Sends Out Embarrassing New Year'...	Donald Trump just couldn't wish all Americans ...	News	December 31, 2017	
1	Drunk Bragging Trump Staffer Started Russian ...	House Intelligence Committee Chairman Devin Nu...	News	December 31, 2017	
2	Sheriff David Clarke Becomes An Internet Joke...	On Friday, it was revealed that former Milwauk...	News	December 30, 2017	
3	Trump Is So Obsessed He Even Has Obama's Name...	On Christmas day, Donald Trump announced that ...	News	December 29, 2017	
4	Pope Francis Just Called Out Donald Trump Dur...	Pope Francis used his annual Christmas Day mes...	News	December 25, 2017	

Slika 26. Dohvaćanje skupa podataka

Sada nam trebaju naš skup podataka. Koristimo dva skupa podataka, prvi skup podataka sastoji se samo od **pravih vijesti** (True.csv), a drugi samo od **lažnih vijesti** (Fake.csv). U oba skupa podataka nedostaje stupac označenja (eng. Label) s označama „Real“ i „Fake“.

	title	text	subject	date	label	
0	As U.S. budget fight looms, Republicans flip t...	WASHINGTON (Reuters) - The head of a conservat...	politicsNews	December 31, 2017	Real	
1	U.S. military to accept transgender recruits o...	WASHINGTON (Reuters) - Transgender people will...	politicsNews	December 29, 2017	Real	
2	Senior U.S. Republican senator: 'Let Mr. Muell...	WASHINGTON (Reuters) - The special counsel inv...	politicsNews	December 31, 2017	Real	
3	FBI Russia probe helped by Australian diplomat...	WASHINGTON (Reuters) - Trump campaign adviser ...	politicsNews	December 30, 2017	Real	
4	Trump wants Postal Service to charge 'much mor...	SEATTLE/WASHINGTON (Reuters) - President Donal...	politicsNews	December 29, 2017	Real	

	title	text	subject	date	label	
0	Donald Trump Sends Out Embarrassing New Year'...	Donald Trump just couldn't wish all Americans ...	News	December 31, 2017	Fake	
1	Drunk Bragging Trump Staffer Started Russian ...	House Intelligence Committee Chairman Devin Nu...	News	December 31, 2017	Fake	
2	Sheriff David Clarke Becomes An Internet Joke...	On Friday, it was revealed that former Milwauk...	News	December 30, 2017	Fake	
3	Trump Is So Obsessed He Even Has Obama's Name...	On Christmas day, Donald Trump announced that ...	News	December 29, 2017	Fake	
4	Pope Francis Just Called Out Donald Trump Dur...	Pope Francis used his annual Christmas Day mes...	News	December 25, 2017	Fake	

Slika 27. Dodavanje stupca označke u oba skupa podataka

Novi stupac možemo dodati ručno u oba skupa podataka. Oznake su važne jer nakon povezivanja oba skupa podataka moramo znati koje su vijesti lažne, a koje istinite.

```
data = pd.concat([T,F])
```

```
data
```

	title	text	subject	date	label	grid icon	more icon
0	As U.S. budget fight looms, Republicans flip t...	WASHINGTON (Reuters) - The head of a conservat...	politicsNews	December 31, 2017	Real		
1	U.S. military to accept transgender recruits o...	WASHINGTON (Reuters) - Transgender people will...	politicsNews	December 29, 2017	Real		
2	Senior U.S. Republican senator: 'Let Mr. Muell...	WASHINGTON (Reuters) - The special counsel inv...	politicsNews	December 31, 2017	Real		
3	FBI Russia probe helped by Australian diplomat...	WASHINGTON (Reuters) - Trump campaign adviser ...	politicsNews	December 30, 2017	Real		
4	Trump wants Postal Service to charge 'much mor...	SEATTLE/WASHINGTON (Reuters) - President Donald...	politicsNews	December 29, 2017	Real		
...	...	...	...	...	...	...	...
23476	McPain: John McCain Furious That Iran Treated ...	21st Century Wire says As 21WIRE reported earl...	Middle-east	January 16, 2016	Fake		
23477	JUSTICE? Yahoo Settles E-mail Privacy Class-ac...	21st Century Wire says It's a familiar theme. ...	Middle-east	January 16, 2016	Fake		
23478	Sunnistan: US and Allied 'Safe Zone' Plan to T...	Patrick Henningsen 21st Century WireRemember ...	Middle-east	January 15, 2016	Fake		
23479	How to Blow \$700 Million: Al Jazeera America F...	21st Century Wire says Al Jazeera America will...	Middle-east	January 14, 2016	Fake		
23480	10 U.S. Navy Sailors Held by Iranian Military ...	21st Century Wire says As 21WIRE predicted in ...	Middle-east	January 12, 2016	Fake		

44898 rows × 5 columns

Slika 28. Povezivanje oba skupa podataka

Pomoću funkcije „concat“ možemo povezati dva ili više skupova podataka. Nakon što smo povezali oba skupa podataka, vidimo da su lažne i istinite vijesti poredane jedna iznad druge u novom skupu podataka.

```
data.replace(' ', np.nan, inplace=True)
data.replace(' ',np.nan,inplace=True)
```

---

```
data.isnull().sum()
```

title	0
text	631
subject	0
date	0
label	0
dtype:	int64

```
data.dropna(inplace=True)
```

Slika 29. Projekta praznih podataka u skupu podataka

Također je važno provjeriti postoje li prazni podaci u skupu podataka. Tijekom provjere primjetio sam da postoje prazni tekstovi vijesti i nisu bili označeni kao **NaN** (Not a Number). Razlog je bio taj što su prazni tekstovi bili prazni stringovi s jednim ili dva razmaka. Zato sam promijenio sve prazne stringove kao NaN, a zatim su svi podaci koji su sadržavali NaN uklonjeni iz skupa podataka.

```

data.isnull().sum()

title      0
text       0
subject    0
date       0
label      0
dtype: int64

data.info()

<class 'pandas.core.frame.DataFrame'>
Int64Index: 44267 entries, 0 to 23480
Data columns (total 5 columns):
 #   Column   Non-Null Count Dtype  
--- 
 0   title    44267 non-null  object  
 1   text     44267 non-null  object  
 2   subject  44267 non-null  object  
 3   date     44267 non-null  object  
 4   label    44267 non-null  object  
dtypes: object(5)
memory usage: 2.0+ MB

```

Slika 30. Provjera praznih podataka u skupu podataka nakon uklanjanja praznih podataka.

Nakon uklanjanja praznih podataka, vidimo da više nema praznih podataka.

	ID	title	text	subject	date	label	
1314	0	Tesla CEO Elon Musk Sends A Massive Threat To...	As if Donald Trump didn't piss off world leade...	News	May 31, 2017	Fake	
11263	1	SMUG LIBERAL LAW PROFESSOR SHUT DOWN BY TUCKER...	Tucker to sanctuary city supporter: how did a ...	politics	Mar 29, 2017	Fake	
13147	2	TRUMP'S BEST CAMPAIGN AD EVER Just Came From B...	After watching this video, one thing is abunda...	politics	Aug 28, 2016	Fake	
19743	3	WOW! WIKILEAKS Emails Shows How Hillary Will B...	Clinton's radicalized rhetoric has championed...	left-news	Oct 24, 2016	Fake	
4614	4	This Tidbit Buried Inside Trump's 'Medical Re...	On Thursday, Donald Trump appeared on the Dr. ...	News	September 15, 2016	Fake	
...	...	...	...	...	...	...	
8987	44262	A Chick-Fil-A Got Shut Down In NYC Over Flies...	NYC's only Chick-Fil-A restaurant got shut dow...	News	January 4, 2016	Fake	
21244	44263	France sees talks on post-Iran nuclear deal, b...	PARIS (Reuters) - France suggested on Wednesd...	worldnews	August 30, 2017	Real	
21823	44264	SHOCKING VIDEOTAPED INTERVIEW WITH BARACK HUSS...	In a shocking interview with Joel Gilbert, pro...	left-news	Apr 26, 2015	Fake	
22781	44265	Undercutting the Nation State? Chicago Group S...	Mark Anderson TRUTH HOUNDCHICAGO, Ill. The ...	Middle-east	September 23, 2017	Fake	
2732	44266	Jimmy Carter recovers from dehydration scare i...	WINNIPEG, Manitoba (Reuters) - Former U.S. Pre...	politicsNews	July 14, 2017	Real	

44267 rows × 6 columns

Slika 31. Miješanje podataka u skupu podataka.

Kako podaci s lažnim i istinitim vijestima ne bi bili raspoređeni jedni na druge, miješamo podatke u skupu podataka. Nakon miješanja podataka vidimo da su ID-ovi svake datoteke također miješani. Kako bi preuređeni podaci imali nove ID-ove s sortiranim brojanjem, možemo dodati novi stupac pod nazivom ID i tako ručno dodati ID brojeve.

```

data['label'] = data['label'].apply(lambda x: x.strip())
data['label'] = data['label'].apply(lambda x: 0 if x == 'Real' else 1)
data

```

ID		title	text	subject	date	label	
1314	0	Tesla CEO Elon Musk Sends A Massive Threat To...	As if Donald Trump didn't piss off world leade...	News	May 31, 2017	1	
11263	1	SMUG LIBERAL LAW PROFESSOR SHUT DOWN BY TUCKER...	Tucker to sanctuary city supporter: how did a ...	politics	Mar 29, 2017	1	
13147	2	TRUMP'S BEST CAMPAIGN AD EVER Just Came From B...	After watching this video, one thing is abunda...	politics	Aug 28, 2016	1	
19743	3	WOW! WIKILEAKS Emails Shows How Hillary Will B...	Clinton's radicalized rhetoric has championed...	left-news	Oct 24, 2016	1	
4614	4	This Tidbit Buried Inside Trump's 'Medical Re...	On Thursday, Donald Trump appeared on the Dr. ...	News	September 15, 2016	1	
...	...	...	...	...	...	...	
8987	44262	A Chick-Fil-A Got Shut Down In NYC Over Flies...	NYC's only Chick-Fil-A restaurant got shut dow...	News	January 4, 2016	1	
21244	44263	France sees talks on post-Iran nuclear deal, b...	PARIS (Reuters) - France suggested on Wednesda...	worldnews	August 30, 2017	0	
21823	44264	SHOCKING VIDEOTAPED INTERVIEW WITH BARACK HUSS...	In a shocking interview with Joel Gilbert, pro...	left-news	Apr 26, 2015	1	
22781	44265	Undercutting the Nation State? Chicago Group S...	Mark Anderson TRUTH HOUNDSCHICAGO, Ill. The ...	Middle-east	September 23, 2017	1	
2732	44266	Jimmy Carter recovers from dehydration scare i...	WINNIPEG, Manitoba (Reuters) - Former U.S. Pre...	politicsNews	July 14, 2017	0	

44267 rows × 6 columns

Slika 32. Prebacivanja oznaka "Fake" i "Real" u brojeve.

Sada moramo promijeniti oznake „Fake“ i „Real“ u brojeve, jer ako kasnije želimo trenirati naš model onda oznake moraju biti brojevi, a ne riječi. Sve oznake „Real“ mijenjaju se s brojem „0“, a „Fake“ s brojem „1“.

```

data['text'] = data['title'] + ' ' + data['text']
data

```

ID		title	text	subject	date	label	
1314	0	Tesla CEO Elon Musk Sends A Massive Threat To...	Tesla CEO Elon Musk Sends A Massive Threat To...	News	May 31, 2017	1	
11263	1	SMUG LIBERAL LAW PROFESSOR SHUT DOWN BY TUCKER...	SMUG LIBERAL LAW PROFESSOR SHUT DOWN BY TUCKER...	politics	Mar 29, 2017	1	
13147	2	TRUMP'S BEST CAMPAIGN AD EVER Just Came From B...	TRUMP'S BEST CAMPAIGN AD EVER Just Came From B...	politics	Aug 28, 2016	1	
19743	3	WOW! WIKILEAKS Emails Shows How Hillary Will B...	WOW! WIKILEAKS Emails Shows How Hillary Will B...	left-news	Oct 24, 2016	1	
4614	4	This Tidbit Buried Inside Trump's 'Medical Re...	This Tidbit Buried Inside Trump's 'Medical Re...	News	September 15, 2016	1	
...	...	...	...	...	...	...	
8987	44262	A Chick-Fil-A Got Shut Down In NYC Over Flies...	A Chick-Fil-A Got Shut Down In NYC Over Flies...	News	January 4, 2016	1	
21244	44263	France sees talks on post-Iran nuclear deal, b...	France sees talks on post-Iran nuclear deal, b...	worldnews	August 30, 2017	0	
21823	44264	SHOCKING VIDEOTAPED INTERVIEW WITH BARACK HUSS...	SHOCKING VIDEOTAPED INTERVIEW WITH BARACK HUSS...	left-news	Apr 26, 2015	1	
22781	44265	Undercutting the Nation State? Chicago Group S...	Undercutting the Nation State? Chicago Group S...	Middle-east	September 23, 2017	1	
2732	44266	Jimmy Carter recovers from dehydration scare i...	Jimmy Carter recovers from dehydration scare i...	politicsNews	July 14, 2017	0	

44267 rows × 6 columns

```

data = data.drop(['subject', 'date', 'title'], axis=1)

```

Slika 33. Povezivanje naslova i teksta vijesti u skupu podataka.

Sada ćemo morati spojiti tekstove i naslove vijesti u stupcu „Text“. Razlog je taj što uz pomoć naslova vijesti imamo više informacija u tekstu i stoga nakon treniranja modela, predviđanje modela za otkrivanje lažnih vijesti može se značajno poboljšati. Nakon povezivanja naslova i teksta više nam ne trebaju stupci s nazivom „title“ (hrv. naslov), „subject“ (hrv. predmet) i „date“ (hrv. datum) pa ih uklanjamo iz skupa podataka.

```

data['text'] = data['text'].apply(lambda x: re.sub(r'[^a-zA-Z\s]', '', x).lower())
nltk.download('punkt')
nltk.download('stopwords')
nltk.download('wordnet')
nltk.download('averaged_perceptron_tagger')

```

*Slika 34. Korištenje biblioteka „RE“ i „NLTK“*

Za uklanjanje svih posebnih znakova i brojeva u tekstovima i pretvaranje teksta u mala slova koristimo biblioteku „**Regular Expression Support**“, ili skraćeno „RE“.

„**Natural Language Toolkit**“, ili skraćeno „**NLTK**“, je skup biblioteka i programa za simboličku i statističku obradu prirodnog jezika (eng. Natural Processing Language) za engleski jezik.

Za prethodnu obradu tekstova moramo preuzeti sljedeće stvari iz Natural Language Toolkit-a, a to su „punkt“, „stopwords“, „wordnet“ i „averaged\_perceptron\_tagger“.

**Punkt** nam je tokenizator rečenica (eng. Sentence tokenizer). Ovaj tokenizator dijeli tekst na popis rečenica korištenjem nenadziranog algoritma za izradu modela za riječi kratice, kolokacije (eng. collocations) i riječi koje počinju rečenice.

**Stopwords** (hrv. Zaustavne riječi) su riječi koje su toliko uobičajene da ih tipični tokenizatori uglavnom ignoriraju. Zatim on ima popis 40 engleskih zaustavnih riječi, na primjer: „a“, „an“, „the“, „of“, „in“ i tako dalje.

**Wordnet** je leksička baza podataka za engleski jezik. Koristi se za pronalaženje značenja riječi, sinonima, antonima i još mnogo toga.

**Average perceptron tagger** koristi se za označavanje riječi s njihovim dijelovima govora (eng. Parts of speech).

```

def preprocess_text(text):
    tokens = word_tokenize(text)

    stop_words = set(stopwords.words('english'))
    tokens = [word for word in tokens if word.lower() not in stop_words]

    pos_tags = pos_tag(tokens)
    stemmer = PorterStemmer()
    lemmatizer = WordNetLemmatizer()

    processed_tokens = []
    for word, pos in pos_tags:
        if pos.startswith('J'):
            processed_tokens.append(lemmatizer.lemmatize(stemmer.stem(word), pos='a'))
        elif pos.startswith('V'):
            processed_tokens.append(lemmatizer.lemmatize(stemmer.stem(word), pos='v'))
        elif pos.startswith('N'):
            processed_tokens.append(lemmatizer.lemmatize(stemmer.stem(word), pos='n'))
        elif pos.startswith('R'):
            processed_tokens.append(lemmatizer.lemmatize(stemmer.stem(word), pos='r'))
        else:
            processed_tokens.append(lemmatizer.lemmatize(stemmer.stem(word)))

    cleaned_text = ' '.join(processed_tokens)

    return cleaned_text

```

Slika 35. Funkcija za pripremnu obradu tekstualnih podataka.

Napišemo funkciju za pripremnu obradu teksta vijesti.

Najprije tokenizira se ulazni tekst u popis riječi i onda se uklanja zaustavne riječi s popisa tokena. Onda se radi **označavanje dijela govora** (eng. Part of Speech Tagging ili skraćeno POS) na preostalim tokenima. Ovaj korak označava svaku riječ njenom gramatičkom kategorijom, na primjer imenica, glagol, pridjev i prilog.

Inicijaliziramo „Porter Stemmer“ i „WordNetLemmatizer“.

**Porter Stemmer** je algoritam, odnosno postupak za uklanjanje sufiksa iz riječi u engleskom jeziku.

**WordNetLemmatizer** se koristi za izvođenje lematizacije (eng. lemmatization) riječi. Lematizacija je proces svođenja riječi na njezinu bazu ili rječnički oblik, poznat kao lema. Na primjer lema engleske riječi „cats“ je „cat“, a lema riječi „running“ je „run“.

Onda funkcija obrađuje svaki token na temelju njegove POS oznake. Ako je token pridjev, glagol, imenica, ili prilog, onda prema tome se primjenjuje „stemming“ i „lematizacija“. Ako POS oznake nije jedna od ovih, ona samo lematizira token bez navođenja POS-a. Konačno, ponovno se spaja obrađene tokene u očišćeni tekst i vraća ga.

```

data['text'] = data['text'].apply(preprocess_text)
data

```

ID		text	label
1314	0	tesla ceo elon musk send massiv threat trump b...	1
11263	1	smug liber law professor shut tucker carlson l...	1
13147	2	trump best campaign ad ever come barack obamae...	1
19743	3	wow wikileak email show hillari bankrupt gun m...	1
4614	4	tidbit buri insid trump medic report prove he ...	1
...	...	...	...
8987	44262	chickfila get shut nyc fli food conserv claim ...	1
21244	44263	franc see talk postiran nuclear deal ballist m...	0
21823	44264	shock videotap interview barack hussein obama ...	1
22781	44265	undercut nation state chicago group suggest gl...	1
2732	44266	jimmi carter recov dehydr scare canada winnipe...	0

44267 rows × 3 columns

```

x = data['text']
y = data['label']
X_train, X_test, y_train, y_test = train_test_split(x, y, test_size=0.2, random_state=42)

tfidf_vectorizer = TfidfVectorizer(max_features=5000)
X_train_tfidf = tfidf_vectorizer.fit_transform(X_train)
X_test_tfidf = tfidf_vectorizer.transform(X_test)

```

Slika 36. Tekst vijesti nakon pripremne obrade i podjela podataka u skupove za treniranje i testiranje

Nakon pripremne obrade teksta vijesti, 80% podataka sada podijelimo u skup za treniranje, a preostalih 20% u skup za testiranje.

Nakon toga moramo koristiti „**Term frequency-inverse document frequency**“, ili skraćeno **TFIDF**, a to je vektorizator (eng. vectorizer) koji pretvara tekst u upotrebljivi vektor (Luthfi Ramadhan, 2023). U našem slučaju tekstovi vijesti iz skupa za treniranje i za testiranje pretvaramo pomoću vektorizatora u vektore.

```

dt_model = DecisionTreeClassifier(random_state=42)
rf_model = RandomForestClassifier(random_state=42)
svm_model = SVC(kernel='linear', random_state=42)
nb_model = MultinomialNB()
xgb_model = XGBClassifier(random_state=42)

dt_model.fit(X_train_tfidf, y_train)
rf_model.fit(X_train_tfidf, y_train)
svm_model.fit(X_train_tfidf, y_train)
nb_model.fit(X_train_tfidf, y_train)
xgb_model.fit(X_train_tfidf, y_train)

dt_predictions = dt_model.predict(X_test_tfidf)
rf_predictions = rf_model.predict(X_test_tfidf)
svm_predictions = svm_model.predict(X_test_tfidf)
nb_predictions = nb_model.predict(X_test_tfidf)
xgb_predictions = xgb_model.predict(X_test_tfidf)

```

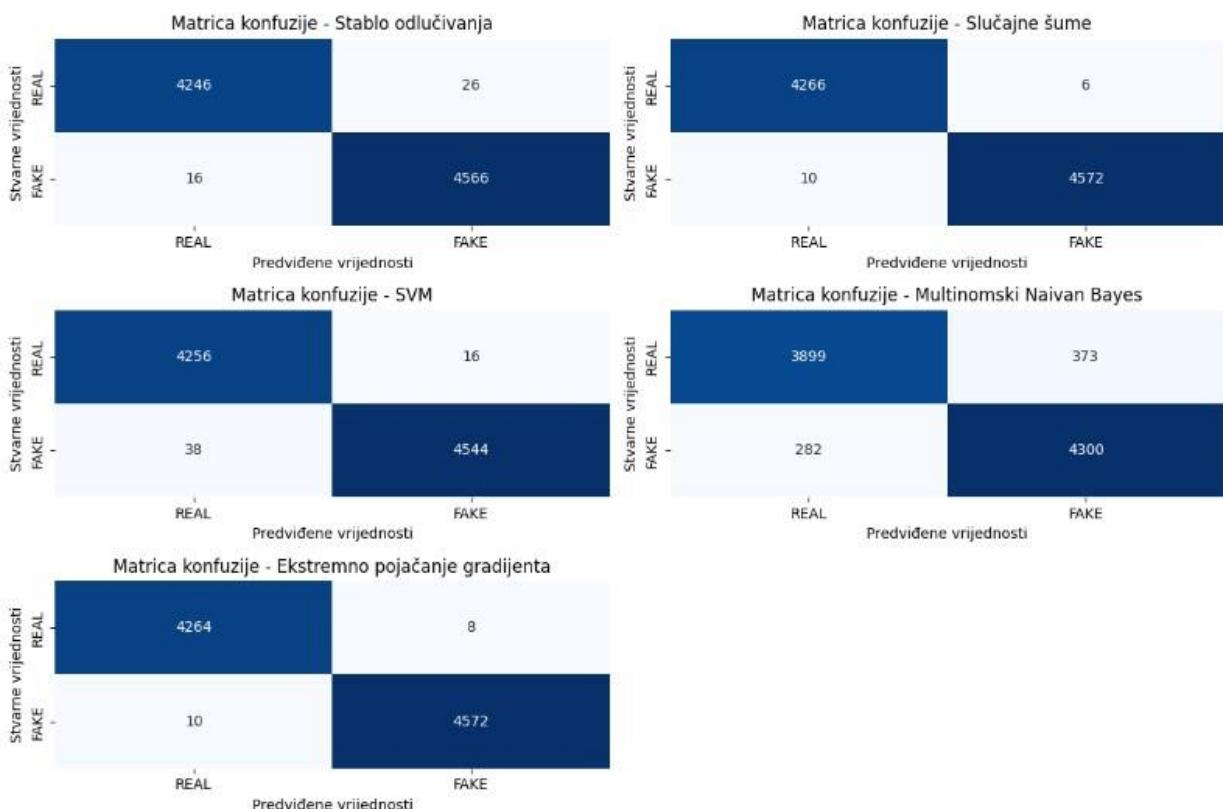
Slika 37. Izrada različitih modela strojnog učenje i predviđanje modela

Sada izrađujemo naše modele strojnog učenja koje ćemo zatim trenirati i evaluirati za otkrivanje lažnih vijesti.

Imamo pet različitih modela, a to su klasifikator stablo odlučivanja (eng. Decision Tree Classifier), klasifikator slučajne šume (eng. Random Forest Classifier), linearna metoda potpornih vektora (eng. Linear SVM), multinomski Naivan Bayes (eng. Multinomial Naive Bayes) i klasifikator ekstremnog pojačavanja gradijenta (eng. XGBoost Classifier).

Sada moramo odabratи jedan od ovih pet modela, koji je najbolji za našu aplikaciju za otkrivanje lažnih vijesti, odnosno koji model može najpreciznije otkritи lažne vijesti. To možemo učinitи izračunavanjem **rezultata točnosti** i F1, te stvaranjem matrice konfuzije (eng. Confusion Matrix) za sve modele.

**Matrica konfuzije** je tablica koja se koristi za definiranje performansa algoritma klasifikacije. Matrica konfuzije vizualizira i sažima performansu algoritma klasifikacije. **F1-rezultat** je mjera točnosti modela na skupu podataka. Koristi se za procjenu binarnih klasifikacijskih sustava, koji klasificiraju primjere u "pozitivne" ili "negativne".



Slika 38. Matrica konfuzije za modele strojnog učenja

Vidimo da kod skupa podataka za testiranje su svi modeli ispravno klasificirali, odnosno predviđali, većinu vijesti kao lažne i istinite.

```

dt_accuracy = accuracy_score(y_test, dt_predictions)
rf_accuracy = accuracy_score(y_test, rf_predictions)
svm_accuracy = accuracy_score(y_test, svm_predictions)
nb_accuracy = accuracy_score(y_test, nb_predictions)
xgb_accuracy = accuracy_score(y_test, xgb_predictions)

dt_f1_score = f1_score(y_test, dt_predictions)
rf_f1_score = f1_score(y_test, rf_predictions)
svm_f1_score = f1_score(y_test, svm_predictions)
nb_f1_score = f1_score(y_test, nb_predictions)
xgb_f1_score = f1_score(y_test, xgb_predictions)

print(f"Stablo odlučivanja - Točnost predviđanja: {dt_accuracy * 100:.4f}%, F1-score: {dt_f1_score * 100:.4f}%")
print(f"Slučajne šume - Točnost predviđanja: {rf_accuracy * 100:.4f}%, F1-score: {rf_f1_score * 100:.4f}%")
print(f"Metoda potpornih vektora - Točnost predviđanja: {svm_accuracy * 100:.4f}%, F1-score: {svm_f1_score * 100:.4f}%")
print(f"Naivan Bayes - Točnost predviđanja: {nb_accuracy * 100:.4f}%, F1-score: {nb_f1_score * 100:.4f}%")
print(f"Ekstremno pojačanje gradijenta - Točnost predviđanja: {xgb_accuracy * 100:.4f}%, F1-score: {xgb_f1_score * 100:.4f}%")

Stablo odlučivanja - Točnost predviđanja: 99.5256%, F1-score: 99.5422%
Slučajne šume - Točnost predviđanja: 99.8193%, F1-score: 99.8253%
Metoda potpornih vektora - Točnost predviđanja: 99.3901%, F1-score: 99.4093%
Naivan Bayes - Točnost predviđanja: 92.6022%, F1-score: 92.9227%
Ekstremno pojačanje gradijenta - Točnost predviđanja: 99.7967%, F1-score: 99.8035%

```

Slika 39. Točnost predviđanja i F1-score

Ovdje možemo vidjeti da slučajne šume imaju najveću točnost predviđanja (99.8193%) i F1 rezultat (99.5422%), a multinomski Naivan Bayes ima najmanju točnost predviđanja (92.6022%) i F1 rezultat (92.9227%).

Ali jedan veliki problem je nastao nakon testiranja modela da vidimo koliko dobro modeli mogu otkriti lažne vijesti. Kad testiramo 4 modela (Stablo odlučivanja, Slučajne šume, linearni SVM, ekstremno pojačanje gradijenta) s tekstom vijesti koja nije u skupu podataka za treniranje i skupu podataka za testiranje, na primjer tekstrom s web stranice s vijestima, tada modeli uvijek netočno klasificiraju vijesti kao lažna vijest. Pravi razlog zašto upravo ovi modeli krivo klasificiraju vijesti je nažalost nepoznat.

Ali možemo prepostaviti vjerojatni razlozi zašto model krivo klasificiraju vijesti, kao što da odabrani skup podataka nije dobar za treniranje modela, da pripremna obrada podataka nije ispravno izvršena ili da je došlo do prekomjernog opremanja (eng. Overfitting) modela.

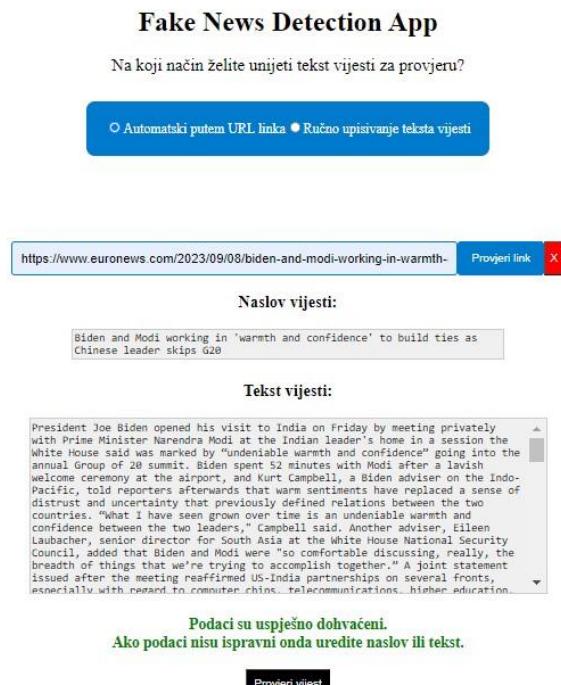
**Overfitting** znači da model ne daje točna predviđanja. U ovom slučaju pogreška treniranja je vrlo mala, a pogreška testa je velika.

Jedini model koji nije imao puno problema sa tekstovima vijesti, koji nisu u skupu podataka za treniranje i skupu za testiranje, je bio multinomski Naivan Bayes. Jedini problem s modelom je to što ne klasificira savršeno jer je rezultat predviđanje 92%, pa se u nekim slučajevima može dogoditi da model krivo klasificira vijesti. Zato sam odabrao ovaj model za otkrivanje lažnih vijesti i spremio trenirani model koristeći „**Joblib**“. Također sam preuzeo spremljeni model kao joblib datoteku i zatim ga implementirao u svoj backend dio.



Slika 40. Frontend aplikacija za otkrivanje lažnih vijesti

Sada dolazimo do našeg frontend dijela. Frontend dio je jednostavna web stranica u koju korisnik može unijeti tekst i naslov vijesti ili se pomoću URL veze može dohvatiti naslov i tekst vijesti.



Slika 41. Dohvaćanje naslova i teksta vijesti pomoću URL veze .

Nakon dohvaćanja teksta, korisnik ima mogućnost promijeniti tekst ako tekst nije ispravno dohvaćen.

## Fake News Detection App

Na koji način želite unijeti tekst vijesti za provjeru?

Automatski putem URL linka  Ručno upisivanje teksta vijesti

<https://www.euronews.com/2023/09/08/biden-and-modi-working-in-warmth> Provjeri link X

Naslov vijesti:

Biden and Modi working in 'warmth and confidence' to build ties as Chinese leader skips G20

Tekst vijesti:

President Joe Biden opened his visit to India on Friday by meeting privately with Prime Minister Narendra Modi at the Indian leader's home in a session the White House said was marked by "undeniable warmth and confidence" going into the annual Group of 20 summit. Biden spent 52 minutes with Modi after a lavish welcome ceremony at the airport, and Kushner said Biden and Modi of the Indo-Pacific told reporters afterwards that warm sentiments have replaced a sense of distrust and uncertainty that previously defined relations between the two countries. "What I have seen grow over time is an undeniable warmth and confidence between the two leaders," Kushner said. Another adviser, Eileen Laubacher, senior director for South Asia at the White House National Security Council, added that Biden and Modi were "so comfortable discussing, really, the breadth of things that we're trying to accomplish together." A joint statement issued after the meeting reaffirmed US-India partnerships on several fronts, especially with regard to counterterrorism, telecommunications, higher education, and science.

Vijest je istinita!

Provjeri vijest

Slika 42. Otkrivanje lažnih vijesti

Ako je s naslovom i tekstrom sve u redu, korisnik može kliknuti na botun „Provjeri vijest“ i zatim pomoću treniranog modela „Multinomski Naivan Bayes“ možemo otkriti je li vijest lažna ili stvarna.

## Fake News Detection App

Na koji način želite unijeti tekst vijesti za provjeru?

Automatski putem URL linka  Ručno upisivanje teksta vijesti

Unesi naslov vijesti...

Unesi tekst vijesti...

Provjeri vijest

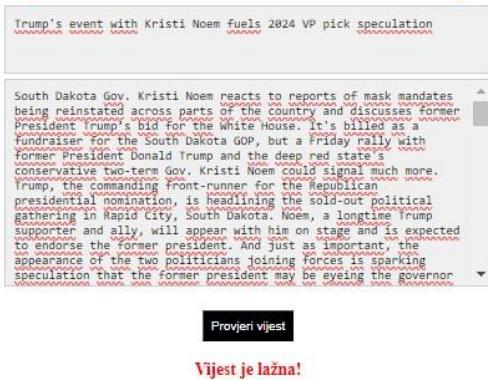
Slika 43. Ručno upisivanje teksta vijesti

Ako korisnik ne želi koristiti URL vezu onda on može ručno unijeti naslov i tekst vijesti.

## Fake News Detection App

Na koji način želite unijeti tekst vijesti za provjeru?

- Automatski putem URL linka
- Ručno upisivanje teksta vijesti



Slika 44. Primjer lažnih vijesti

Ovdje imamo i primjer kako to izgleda kada unesemo vijest koja je lažna. Model tada otkriva da se radi o lažnoj vijesti.

## 4 Zaključak

Sada kada imamo boji uvid u različite vrste lažnih vijesti i kako točno algoritmi strojnog učenja rade na otkrivanje lažnih vijesti, također možemo vidjeti da uspješno možemo otkriti lažne vijesti s našom aplikacijom pomoću strojnog učenja i obrade prirodnog jezika. Nažalost, projekt nije savršen i u nekim slučajevima može doći do netočne klasifikacije vijesti.

Također moramo istaknuti da se otkrivanje lažnih vijesti u današnje vrijeme još uvijek ne provodi savršeno, a u budućnosti će sigurno biti sve teže prepoznati lažne vijesti bez pomoći umjetne inteligencije.

Zato programeri i istraživači moraju dalje razvijati otkrivanje lažnih vijesti pomoću umjetne inteligencije, jer se umjetna inteligencija razvija vrlo brzo, i kao što već znamo, umjetna inteligencija se također može koristiti za izradu lažnih vijesti.

Osim toga, razlog zbog kojeg sam uopće odabrao ovu temu i napravio projekt za svoj završni rad je taj što sam želio, otkrivanjem lažnih vijesti, pomoći ljudima da sami nemaju poteškoća u prepoznavanju lažnih vijesti i da ne budu pod utjecajem ili izmanipuliran zbog lažnih vijesti.

Također bih volio dalje raditi na ovom projektu u budućnosti koristeći druge metode umjetne inteligencije u svom projektu kao što je duboko učenje (eng. Deep Learning).

## 5 Literatura

- [1] Wikipedia. (26.06.2023). *Fake News*.  
[https://en.wikipedia.org/wiki/Fake\\_news](https://en.wikipedia.org/wiki/Fake_news).
- [2] Cambridge Dictionary. (25.06.2023). *Definition of Fake News*.  
<https://dictionary.cambridge.org/dictionary/english/fake-news>.
- [3] Claire Wardle. (25.05.2023). *Understanding Information disorder*.  
<https://firstdraftnews.org/long-form-article/understanding-information-disorder/>.
- [4] Andreja. (27.06.2023) *Fake news – što su lažne vijesti, kako ih prepoznati i prijaviti?*.  
<https://klik.hr/novo/fake-news-sto-su-lazne-vijesti-kako-ih-prepoznati-i-prijaviti>.
- [5] Coursera. (27.07.2023). *3 Types of Machine Learning You Should Know*.  
<https://www.coursera.org/articles/types-of-machine-learning>
- [6] Potentiaco. (27.07.2023). *What is Machine Learning: Definition, Types, Applications and Examples*.  
<https://www.potentiaco.com/what-is-machine-learning-definition-types-applications-and-examples/>
- [7] Piyush & Rishabh. (27.07.2023). *3 Types of Machine Learning*.  
<https://www.newtechdojo.com/3-types-of-machine-learning/>
- [8] Niklas Donges. (03.08.2023). *Random Forest: A Complete Guide for Machine Learning*.  
<https://builtin.com/data-science/random-forest-algorithm>
- [9] Alghamdi, J. Lin, Y. Luo, S. (2022) *A Comparative Study of Machine Learning and Deep Learning Techniques for Fake News Detection*. MDPI
- [10] Javatpoint. (05.08.2023). *Decision Tree Classification Algorithm*.  
<https://www.javatpoint.com/machine-learning-decision-tree-classification-algorithm>
- [11] Khanam, Z. (2021). *Fake News Detection Using Machine Learning Approaches*. IOP Conference Series: Materials Science and Engineering.  
<https://iopscience.iop.org/article/10.1088/1757-899X/1099/1/012040>
- [12] Manzoor, S.I., Singla, J., Nikita. (2019). *Fake News Detection Using Machine Learning approaches: A systematic Review*. Proceedings of the Third International Conference on Trends in Electronics and Informatics (ICOEI).  
[https://www.researchgate.net/publication/336436870\\_Fake\\_News\\_Detection\\_Using\\_Machine\\_Learning\\_approaches\\_A\\_systematic\\_Review](https://www.researchgate.net/publication/336436870_Fake_News_Detection_Using_Machine_Learning_approaches_A_systematic_Review)
- [13] Javatpoint (06.08.2023). *Random Forest Algorithm*  
<https://www.javatpoint.com/machine-learning-random-forest-algorithm>
- [14] Javatpoint (07.08.2023). *Support Vector Machine Algorithm*.  
<https://www.javatpoint.com/machine-learning-support-vector-machine-algorithm>
- [15] Sharma, U., Saran, S., Pantil, S.M. (2021) *Fake News Detection using Machine Learning Algorithms*. International Journal of Engineering Research & Technology (IJERT).  
<https://www.ijert.org/fake-news-detection-using-machine-learning-algorithms>

[16] Javatpoint (07.08.2023). *Naive Bayes Classifier Algorithm*.  
<https://www.javatpoint.com/machine-learning-naive-bayes-classifier>

[17] Arthur V. Ratz (17.08.2023) *Multinomial Naïve Bayes' For Documents Classification and Natural Language Processing (NLP)*  
<https://towardsdatascience.com/multinomial-na%C3%AFve-bayes-for-documents-classification-and-natural-language-processing-nlp-e08cc848ce6>

[18] Turing. (11.08.2023). *An Introduction to Naive Bayes Algorithm*.  
<https://www.turing.com/kb/an-introduction-to-naive-bayes-algorithm-for-beginners>

[19] GeeksforGeeks. (12.08.2023). *Gradient Boosting in ML*.  
<https://www.geeksforgeeks.org/ml-gradient-boosting/>

[20] Great Learning Team. (13.08.2023). *Understanding XGBoost Algorithm | What is XGBoost Algorithm*. <https://www.mygreatlearning.com/blog/xgboost-algorithm/>

[21] Kerem Kargin (03.09.2023) *NLP: Tokenization, Stemming, Lemmatization and Part of Speech Tagging* <https://medium.com/mlearning-ai/nlp-tokenization-stemming-lemmatization-and-part-of-speech-tagging-9088ac068768>

[22] Luthfi Ramadhan (06.09.2023). *TF-IDF Simplified*  
<https://towardsdatascience.com/tf-idf-simplified-aba19d5f5530>