



Sigurnost u računarskim mrežama

IDS sistemi: drugi deo
(IDS sistemi zasnovani na mašinskom učenju)

Nemanja Maček

- Veštačka inteligencija i mašinsko učenje
- Induktivno empirijsko učenje funkcionalnih preslikavanja
- Klasifikacija i problem prenaučivosti
- Anomalije
- Neke značajnije metode klasifikacije
- Analiza obučavajućih skupova: KDD Cup'99
- Praktična demonstracija
 - Sinteza obučavajućih skupova
 - Upotreba alata Weka i Matlab Statistical and Machine Learning Toolbox
 - Upotreba Python biblioteka

Šta je veštačka inteligencija?

- VI trenutno obuhvata mnoštvo podoblasti, od vrlo opštih, kao što su učenje i percepcija, do uskih zadataka kao što je:
 - Igranje šaha
 - Dokazivanje matematičkih teorema
 - Medicinska dijagnostika
 - Automatsko prevođenje
 - Prepoznavanje govora
 - Robotika
 - ...

Šta je veštačka inteligencija?

- I pored poluvekovne istorije VI je i dalje oblast koju je teško precizno definisati.
- Primeri nekih definicija dobijenih dihotomijom u odnosu na dimenzije rezonovanja:
 - **Sistemi koji razmišljaju kao ljudi** (ljudsko rezonovanje).
 - „[Automatizacija] aktivnosti koje asociramo sa ljudskim razmišljanjem, aktivnosti kao što su donošenje odluka, rešavanje problema, učenje...”
 - **Sistemi koji razmišljaju racionalno** (racionalno rezonovanje).
 - „Izučavanje računanja koje omogućava opažanje, rasuđivanje i delovanje.”
 - **Sistemi koji se ponašaju kao ljudi** (ljudsko ponašanje).
 - „Izučavanje kako naterati računare da rade stvari u kojima su, trenutno, ljudi bolji.”
 - **Sistemi koji se ponašaju racionalno** (racionalno ponašanje).
 - „Računarska inteligencija je nauka o dizajniranju inteligentnih agenata.”
 - „VI ... se bavi inteligentnim ponašanjem veštackih naprava.”
- Ljudski-centrirani pristupi dominantno moraju biti **empirijska nauka**.
 - Uključuje hipotezu i eksperimentalnu potvrdu o ljudskom ponašanju.
- Racionalistički pristup koristi kombinaciju matematike i inženjerstva.

Pristup zasnovan na Tjuringovom testu

- Alan Tjuring (1950): „*Computing Machinery and Intelligence*“
 - Umesto pitanja da li mašine mogu da misle, postavlja se pitanje da li mašina može da prodje test inteligentnog ponašanja.
 - Test je nakon toga nazvan Tjuringov test.
- Mašina prolazi Tjuringov test ako osoba ispitivač, posle postavljanja nekoliko pitanja u pisanoj formi, ne može da odredi da li je pisani odgovor dao čovek ili mašina.
- Mašina koja bi eventualno prošla Tjuringov test, morala bi da ima sledeće sposobnosti:
 - **Obrada prirodnih jezika** (da bi mogla uspešno da komunicira u prirodnom jeziku)
 - **Reprezentacija znanja** (da bi memorisala ono što zna i prima na osnovu senzora)
 - **Automatsko rezonovanje** (da bi koristila memorisane informacije za odgovaranje na pitanja i za donošenje novih zaključaka)
 - **Mašinsko učenje** (da bi se adaptirala novim okolnostima).



Pristup zasnovan na Tjuringovom testu

- Tjuringov test je namerno izbegavao direktnu fizičku interakciju između ispitivača i računara.
- Razlog: fizička simulacija čoveka nepotrebna za inteligenciju.
- Takozvani potpuni Tjuringov test uključuje video signal.
 - Ispitivač može da testira percepcijske i motorne sposobnosti ispitanika.
- Da bi prošao potpuni Turingov test racunar mora da ovlada:
 - **Računarskom vizijom** (u cilju vizuelene percepcije okoline i objekata u njoj)
 - **Robotikom** (radi kretanja u prostoru i manipulacijom objekata u njemu).
- Ovih 6 disciplina čine dominantan deo VI!



- **„U Boga verujemo, svi ostali neka donesu podatke.“**
 - Na Webu se ova izjava pripisuje podjednako i Vilijemu Demingu i Robertu Hajdenu.
 - Profesor Hajden tvrdi da ovo nije njegova izjava.
 - Ironija je u tome da se ne mogu naći „podaci“ koji bi potvrdili da je Deming zaista njen autor. [3]



- Učenje je proces koji se kod ljudi odvija gotovo neprekidno.
- Postoje različite vrste učenja:
 - Čisto memorisanje podataka
 - Učenje motornih veština
 - Sticanja sposobnosti analitičkog i kreativnog mišljenja
 - ...
- Sposobnost učenja se smatra osnovnom odlikom inteligentnih bića!
 - Nije iznenađujuće što je mašinsko učenje jedna od centralnih oblasti istraživanja u VI.
- **Mašinsko učenje** je oblast koja proučava procese na kojima se zasniva učenje kod ljudi i kod veštačkih sistema.
 - **Veštacki sistemi** koji su sposobni da uče evidentno poboljšavaju svoje performanse.
 - **Biološki sistemi** povećavaju verovatnoću svog opstanka i produžetka vrste.

- **Formalna definicija mašinskog učenja** (Tom Mičel):
 - Za jedan sistem VI kažemo da uči zadatu klasu zadataka T na osnovu iskustva E i zadate mere performansi P , ako se njegove performanse za rešavanje zadataka iz klase T , poboljšavaju sa iskustvom E .
- Da bi jedan problem učenja bio dobro definisan neophodno je identifikovati tri komponente:
 - **Klasu zadataka** (T)
 - **Meru performanse koju treba poboljšati** (P)
 - **Izvor iskustva** (E).
- Primer: problem učenja prepoznavanja rukom pisanih znakova.
 - Zadatak T : prepoznavanje i klasifikacija rukom pisanih reči u zadatim slikama
 - Mera performansi P : procenat tačno klasifikovanih reči.
 - Izvor iskustva E : baza rukom pisanih reči sa tačnom klasifikacijom (obučavajući skup).

- U savremenoj oblasti mašinskog učenja dominiraju sledeći pristupi:
 - **Induktivno učenje**
 - **Analitičko učenje** (analogija sa logikom)
 - **Učenje na slučajevima** (engl. *case-based learning* – analogija sa ljudskim pamćenjem)
 - **Neuralne mreže** (analogija sa neurobiologijom)
 - **Genetski algoritmi** (analogija sa evolucijom)
 - **Hibridni modeli** (kombinacija više pristupa).
- Od najvećeg značaja za tekuću praksu u domenu računarstva i VI je **induktivno učenje**.
- Suština ovog tipa učenja je **učenje na osnovu raspoloživih primera**.
 - U svakodnevnom jeziku to možemo da nazovemo: **učenje iz iskustva** (drugih).
- S obzirom na objekat učenja najopštije je učenje funkcionalnih, tj. **ulazno-izlaznih preslikavanja**.

Induktivno empirijsko učenje funkcionalnih preslikavanja

- Ključni elementi u induktivnom učenju funkcionalnih preslikavanja su:
 - Nepoznato preslikavanje
 - Obučavajući skup ulazno – izlaznih parova
 - Skup hipoteza unutar koga biramo finalnu hipotezu putem algoritma obučavanja.
- Ulazi su po pravilu n dimenzioni vektori.
 - U literaturi se pominju pod nazivima: **vektori obeležja**, uzorci, primeri i instance.
- Komponente ulaznih vektora se nazivaju **obeležja** ili atributi i mogu biti:
 - **Kontinualni** (beskonačan broj vrednosti)
 - **Diskretni** (konačan broj vrednosti).
- Ove komponente mogu biti tri različite prirode:
 - Realni brojevi, npr. $x_i = 0.34$
 - Diskretni brojevi, npr. $x_i \in \{0, 1, 2, 3\}$
 - Kategorijalne varijable, npr. komponenta x_i označava boju koja može uzeti vrednosti {crven, plav, zelen}.

Induktivno empirijsko učenje funkcionalnih preslikavanja

- Izlazni prostor može biti:
 - Kategorijalan sa K distiktnih vrednosti, kada obučeni sistem obavlja **klasifikaciju**, **prepoznavanje** ili **kategorizaciju**.
 - Izlaz se naziva oznaka, klasa, kategorija ili odluka.
 - Realan, kada obučeni sistem realizuje **regresiju** (funkcionalni estimator).
 - Vektorski, sa komponentama koje mogu biti realne ili kategorijalne varijable.
- Obučavanje se vrši na osnovu **obučavajućeg skupa** (N ulazno-izlaznih parova).
- Obučavanje možemo posmatrati kao pretragu u prostoru hipoteza u cilju **izbora najpogodnije hipoteze** koja je u saglasnosti sa obučavajućim skupom.
- Postoji više načina na koji se obučavajući skup može koristiti:
 - **Batch metod**: celokupan obučavajući skup se koristi u izračunavanju hipoteza.
 - **Inkrementalni metod**: koristi se sekvencijalno, po jedna instanca obučavajućeg skupa, koja modifikuje tekuću hipotezu.
 - **On-line metod**: korišćenje jedne instance obučavajućeg skupa u trenutku kada ona postane dostupna.

Obučavajući i test skup, generalizacija

- Pitanje **merenja kvaliteta obučenog sistema** je jedno od ključnih pitanja mašinskog učenja.
- Izabrana hipoteza koja je najbolja moguća u odnosu na dati obučavajući skup:
 - Može se pokazati kao dobra na novim primerima koji nisu učestvovali u obučavanju.
 - Može se međutim pokazati i kao loša.
- Opšteprihvacena mera kvaliteta jednog sistema mašinskog učenja je njegova sposobnost **generalizacije**.
 - Generalizacija: ponašanje sistema na instancama koje nisu vidjene u fazi obučavanja.
- Stoga tipično sintezu prate dva skupa: **obučavajući skup** (trening skup) i **test skup**.
 - Test skup se koristi samo za procenu generalizacionih sposobnosti sintetisanog sistema.
 - Test skup se NE SME koristiti u fazi obučavanja.
- Uobičajene numeričke mere performansi su ili srednjekvadratna greška između izlaza sistema i ciljnih vrednosti ili ukupan broj grešaka.

- **Obučavanje sa učiteljem**, nadgledano obučavanje (engl. *supervised learning*).
 - Obučavajući skup je oblika $\{x_i, f(x_i)\}$, gde je $f(x_i)$ ciljna vrednost vektora obeležja x_i .
 - Zadatak obučavanja: nalaženje aproksimacije za f .
 - Mera performansi: kvalitet aproksimacije u tačkama koje ne pripadaju obučenom skupu.
- Obučavanje sa učiteljem:
 - **Transduktivno**. Test primeri bez ciljne klasifikacije se znaju već u trenutku obučavanja.
 - Cilj je da se sistem dobro ponaša samo na tim test primerima.
 - **Induktivno**. Cilj je da se sistem dobro ponaša na svim primerima dobijenim iz iste raspodele kao i obučavajući skup.
- **Obučavanje bez učitelja**, nenadgledano obučavanje (engl. *unsupervised learning*).
 - U obučavajućem skupu su prisutne samo ulazne instance x_i .
 - Tipičan pristup je **klasterovanje**, odnosno grupisanje raspoloživih podataka u manji broj grupa unutar kojih su podaci sličniji u poređenju sa podacima iz ostalih grupa.
 - Imenovanjem klastera se dolazi posrednim putem do označenih uzoraka.


- **Obučavanje sa podsticanjem** (engl. *reinforcement learning*).
 - Poreklo vodi iz teorije upravljanja u kome je dinamičko okruženje opisano trojkom (**stanje, akcija, nagrada**).
 - U ovom tipu učenja potrebno je naučiti kako vršiti preslikavanja situacija u akcije a da se pri tome maksimizira nagrada.
 - Za razliku od obučavanja sa učiteljem algoritmu obučavanja nije rečeno koje akcije da preduzima u datoj situaciji.
 - Dobar primer da se shvati ovaj scenario je učenje igranja šaha.
 - Stanja: pozicije na table.
 - Akcije: mogući potezi za datu poziciju.
 - Nagrada za izabrani potez: pobeda.
 - Kazna: gubitak igre.
 - Nagrada i kazna **kasne u odnosu na trenutak izbora akcije**, što je tipično za ovu vrstu obučavanja.

- **Klasifikacija** je razvrstavanje nepoznate instance u jednu od unapred ponuđenih klasa.
 - Svaka instanca može se predstaviti **skupom njenih obeležja**.
 - Takođe, svakoj instanci se može dodati kao obeležje i **oznaka klase** kojoj instanca pripada.

sepalength	sepalwidth	petallength	petalwidth	class
5.3	3.7	1.5	0.2	Iris-setosa
5	3.3	1.4	0.2	Iris-setosa
7	3.2	4.7	1.4	Iris-versicolor
6.2	2.8	4.8	1.8	Iris-virginica




- Klasifikacija je određivanje vrednosti obeležja klase na osnovu preostalih obeležja instance.
- Postoji veliki broj metoda kojima se ovaj problem rešava: VNM, SVM, stabla odlučivanja, ...

- Primer:




* Slika preuzeta sa Web lokacije: <https://astrobites.org/2015/04/15/c-3po-phd-machine-learning-in-astronomy/>

- Prilikom obuke je moguće da se model **previše prilagodi specifičnostima obučavajućeg skupa**.
 - U tom slučaju model daje loše rezultate kada se primeni na test skupu ili drugim podacima.
 - Iako je potrebno da se prilikom obuke postigne visok nivo tačnosti neophodno je da se spreči **prenaučenost**.
- Zbog čega dolazi do prenaučivosti?
 - Osnovni razlog je bogatstvo prostora hipoteza, odnosno skupa dopustivih modela.
 - U bogatijem skupu je lakše naći model koji dobro odgovara podacima.




- Primer *underfitting*-a.
 - Prilikom učenja dopuštaju se samo **stabla odlučivanja dubine 1** koja testiraju samo jedan atribut svake instance.
 - Takva stabla ne mogu lako postići visoku preciznost klasifikacije.
- Primer *overfitting*-a.
 - Prilikom učenja dozvoljava se upotreba **stabala odlučivanja proizvoljne dubine**.
 - Moguće je naći stablo koje **precizno opisuju svaku (čak i najnebitniju) specifičnost obučavajućih podataka**.
 - Takvo stablo je u stanju da razlikuje bilo koje dve instance u obučavajućem skupu.
 - Takvo stablo postiže savršenu preciznost na obučavajućem skupu.
 - Ovakva stabla se u praksi pokazuju nepouzdanim!
 - Razlog: širi skupovi podataka **ne moraju uvek imati sve specifičnosti obučavajućeg skupa!**

- Ponašanje odstupanja greške na širem skupu podataka od greške na obučavajućim podacima (**greška validacije**). Validacija nije isto što i test!



- Anomalije su oblici u podacima koji ne pripadaju očekivanom ponašanju
- Nazivaju se i autlajeri, izuzeci, osobenosti, iznenađenja i sl.



- Detekcija anomalija obavlja se definisanjem regiona koji predstavlja normalno ponašanje, i pronalaženjem podataka koji ne pripadaju tim regionima.
- Nekoliko faktora čine ovaj, na prvi pogled jednostavan zadatak, znatno složenijim:
 - **Definisanje reprezentativnog normalnog ponašanja**, tj. regiona koji obuhvataju sve moguće varijacije normalnog ponašanja je komplikovan i težak zadatak.
 - **Određivanje granica između normalnog ponašanja i anomalija.**
 - Granice se često se ne mogu precizno odrediti, što dovodi do greške u detekciji.
 - **Evolviranje normalnog ponašanja sa vremenom.**
 - Normalno ponašanje se u realnim sistemima vremenom menja.
 - Skup regiona normalnog ponašanja može postati neadekvatan nakon nekog vremena.
 - **Broj obeleženih zapisa** u obučavajućem skupu i skupu za validaciju algoritama za detekciju može biti nedovoljan, jer su obeleženi podaci za obuku jednostavno nedostupni.


- **Egzaktna definicija autlajera.** Ne postoji jedinstven način definisanja granice odstupanja od normalnog ponašanja za različite problemske domene.
 - Primer: malo odstupanje telesne temperature u medicine ukazuje na anomaliju, dok u bankarstvu malo odstupanje valute ne mora ukazati na anomaliju.
 - Tehnike definisanja granice, odstupanja i detekcije anomalije razvijene za primene u jednom domenu ne moraju automatski biti primenljive i u drugom.
- **Postojanje šuma.**
 - Podaci koji ukazuju na normalno ponašanje mogu sadržati šum koji je sličan oblicima prisutnim u anomalijama, a koji se ne može se ukloniti.
- Specifičnost problema određuju:
 - **Priroda ulaznih podataka.**
 - **Dostupnost obeleženih podataka** u skupovima za obučavanje i validaciju
 - **Vrsta anomalije** koju treba detektovati.

- Jedan od najbitnijih aspekata detekcije anomalije je **priroda ulaznih podataka**.
- Svaka instanca podataka opisana je **vektorom obeležja**.
- Obeležja mogu biti:
 - Istog tipa (na primer, sva obeležja su realni brojevi)
 - Različitog tipa (na primer, kombinacija binarnih i kontinualnih obeležja).
- Priroda ulaznih podataka odnosi se na prirodu obeležja kojima su opisane instance.
- Time se određuje koja je tehnika pogodna za detekciju anomalije.
 - Primer: Support Vector Machines klasifikator radi samo sa numeričkim podacima koji su standardizovani.

- Ukoliko se jedna instanca podataka može smatrati anomalijom u odnosu na ostatak podataka, onda se takva instanca naziva **tačkasta anomalija**.
- Primer tačkaste anomalije: **detekcija prevare kreditnim karticama**.
 - Neka je skup podataka zadat kartičnim transakcijama određene osobe, i radi jednostavnosti opisan jednim atributom (količina potrošenog novca).
 - Region normalnog ponašanja definisan je donjom i gornjom granicom normalne potrošnje.
 - Ukoliko je nakon obavljene transakcije potrošena suma je znatno veća od opsega definisanog normalnom potrošnjom, transakcija se smatra tačkastom anomalijom.

- Ukoliko instanca podataka predstavlja anomaliju **u specifičnom kontekstu**, ali ne i na drugi način, onda se ta instanca naziva kontekstualnom ili **uslovnom** anomalijom.
- Primer uslovne anomalije:
 - Učestalost korišćenja sistemskih poziva ili slanja zahteva za otvaranjem TCP veza serveru u određenim vremenskim intervalima.
- Pojam konteksta je uslovljen strukturom skupa podataka i mora biti specificiran kao deo formulacije problema.
- Svaka instanca podataka je definisana pomoću dva skupa atributa:
 - **Kontekstualnim atributima** (određuju kontekst, tj. uslov).
 - **Atributima ponašanja** (definišu karakteristike instance ne uzimajući kontekst u obzir).
- Instanca podataka sa identičnim atributima ponašanja koja predstavlja anomaliju u datom kontekstu može u drugom kontekstu predstavljati normalno ponašanje.
- Istraživanja u oblasti detekcije kontekstualnih anomalija najčešće su vezana za podatke promenljive u vremenu i prostorne podatke.

- Primer uslovne anomalije nevezan za računarski sistem.



- Ukoliko **skup instanci** predstavlja anomaliju u odnosu na celokupan skup podataka, onda se takva anomalija naziva **kolektivna**.
 - Individualne instance u ovom slučaju ne predstavljaju anomaliju
 - Njihovo **zajedničko pojavljivanje** jeste anomalija.
- Primer kolektivne anomalije:
 - Sekvenca akcija koje se dešavaju u računarskom sistemu:
 - http-web, buffer-overflow, http-web, http-web, smtp-mail, ftp, http-web, ssh, smtp-mail, http-web, **buffer-overflow**, **ssh**, **ftp**, http-web, ftp, smtp-mail, http-web . . .
 - Sekvenca (buffer-overflow, ssh, ftp) opisuje napad na udaljeni sistem koji se izvršava:
 - Prepunjenjem bafera
 - Otvaranjem ssh veze
 - Kopiranjem podataka na udaljeni sistem koristeći ftp protokol.
 - Pojedine instance te sekvence ne predstavljaju tačkaste anomalije, niti kolektivne anomalije ukoliko se pojavljuju u drugim sekvencama.

- Tehnike **nenadgledane** (engl. *unsupervised*) detekcije anomalija ne zahtevaju obučavajći skup.
 - Mogu se primeniti u najvećem broju domena primene.
 - Pretpostavka: instance normalnog ponašanja mnogo se češće pojavljuju od anomalija.
 - Ukoliko pretpostavka nije tačna, algoritam će prijaviti veliki broj pogrešno detektovanih instanci.
- Tehnike **nadgledane** (engl. *supervised*) detekcije anomalija.
 - Instance obučavajućeg skupa su obeležene i pripadaju oblicima normalnog ili anomalnog ponašanja.
 - Problem se svodi na **binarnu klasifikaciju**.
 - Dva osnovna problema karakteristična za nadgledanu detekciju anomalija su:
 - Broj instanci koje opisuju anomalije je znatno manji od broja instanci koje opisuju normalno ponašanje.
 - Prikupljanje dovoljno tačnih i reprezentativnih instanci koje opisuju anomalije je najčešće veoma težak zadatak.


- Postoje dva pristupa **polu-nadgledanoj** (engl. *semi-supervised*) detekciji anomalija.
 - **Obeleženo normalno ponašanje.**
 - Obeležene su samo instance obučavajućeg skupa koje pripadaju oblicima normalnog ponašanja.
 - Pošto instance koje opisuju anomalije nisu obeležene, ove tehnike polu-nadgledane detekcija anomalija su **primenljive u većem broju domena primene** od nadgledanih tehnika.
 - Tipičan pristup u ovom slučaju je formiranje modela koji će instance svrstati u klasu normalnog ponašanja. Model se koristi za identifikaciju anomalija u test skupu.
 - **Obeleženo anomalno ponašanje.**
 - Drugi pristup polu-nadgledanoj detekciji je formiranje modela na osnovu obučavajućeg skupa u kome su obeležene samo instance koje opisuju anomalije.
 - Ovaj pristup se ne koristi često jer je jako teško formirati obučavajući skup u kome su opisane sve anomalije koje se mogu pojaviti u podacima.

Klasifikacija metoda mašinskog učenja

- Metode mašinskog učenja koje se koriste za klasifikaciju mogu se podeliti na:
 - **Osnovne** (veštačke neuronske mreže, Support Vector Machines, stabla odlučivanja, Naive Bayes)
 - **Hibridne** (na primer, stablo odlučivanja na čijim se listovima nalazi Naive Bayes klasifikator obučen instancama koje pripadaju tom listu)
 - **Inkrementalne** (Naive Bayes Updatable)
 - **Hibridne inkrementalne** (Hoeffding Tree)
 - **Osnovne ensemble** (Random Forest)
 - **Hibridne ensemble** (slaganje)
 - **Hibridne inkrementalne ensemble** (Ada Hoeffding Option Tree).


- Neuronska mreža je **masovno paralelizovan distribuirani procesor** sa prirodnom sposobnošću **memorisanja iskustvenog znanja** i obezbeđivanja njegovog korišćenja.
- VNM simuliraju način rada ljudskog mozga pri obavljanju datog zadatka ili neke funkcije.
- Veštačke neuronske mreže podsećaju na ljudski mozak u dva pogleda:
 - Neuronska mreža zahvata znanje kroz **proces obučavanja**.
 - Težine medjuneuronskih veza (**jačina sinaptičkih veza**) služe za memorisanje znanja.
- Obučavanjem se na algoritamski (sistematičan) način menjaju sinaptičke težine u cilju dostizanja željenih performansi mreže.
- Osnovnu računarsku snagu neuronskih mreža čini masivni paralelizam, sposobnost obučavanja i generalizacija.
- Neuronske mreže su u okviru mašinskog učenja već stekle status dobro teorijski obradjene oblasti, koja je stavlja u istu ravan sa ostalim top tehnikama, kao što su SVM.

- Funkcionisanje jednog biološkog neurona [3]:




- Model neurona:
 - **Skup sinaptičkih težina.** Pozitivne težine odgovaraju ekscitirajućim sinaptičkim vezama, a negativne inhibitornim.
 - **Sumator** (linearni kombajner). Formira težinsku sumu ulaza.
 - **Aktivaciona funkcija.** Limitira amplitudu izlaznog signala neurona. Tipično se uzima normalizacija izlaza na interval $[0,1]$ ili $[-1,1]$.

- Model neurona.




- Analogija.



Višeslojne neuronske mreže sa prostiranjem signala unapred

- *Feed forward multilayer neural network, FFANN.*




Hornik Stinchombe White-ova teorema

- Definicija Borel merljive funkcije. **Borel merljive funkcije** na kompaktnim skupovima obuhvataju sve neprekidne i u delovima neprekidne funkcije (sa konačno ili prebrojivo mnogo diskontinuiteta na skupovima mere nula).
- **HSW teorema**: višeslojna neuronska mreža sa najmanje jednim skrivenim slojem i aktivacionom funkcijom koja je neopadajuća, a čije vrednosti pripadaju intervalu $[0,1]$ ili $[-1,1]$ aproksimira bilo koju Borel merljivu funkciju na kompaktnim skupovima, sa proizvoljnom tačnošću, pod uslovom da je na raspolaganju dovoljan broj neurona u skrivenom sloju.
 - Odavde sledi da je FFANN **univerzalni aproksimator**.
 - Neuspeh FFANN da u nekom konkretnom slučaju restauriše preslikavanje implicitno zadato obučavajućim skupom ne potiče od osnovnog restauratorskog principa FFANN, već od:
 - Neadekvatnog izbora arhitekture
 - Parametara obučavanja
 - Obučavajućih skupova
 - ...

Obučavanje mreža algoritmom propagacije greške unazad

- **Algoritam propagacije greške unazad** (engl. *backpropagation*) traži minimum funkcije greške u polju težinskih koeficijenata korišćenjem **metode stepenastog opadanja** (engl. *gradient descent*).
 - Kombinacija težinskih koeficijenata koja minimizuje funkciju greške se smatra rešenjem problema učenja.
- Obzirom da ovaj metod zahteva izračunavanje stepena funkcije greške prilikom svakog iterativnog koraka, mora se garantovati kontinuitet i diferencijabilnost funkcije greške.
- Ovaj algoritam obuhvata dve faze:
 - Ulazni vektor se propagira od ulaznog ka izlaznom sloju, dajući izlaz.
 - Signal greške se od izlaznog ka ulaznom sloju u cilju **korigovanja sinaptičkih težina**.
- Algoritam propagiranja greške unazad ima **dobra svojstva generalizacije** (neuronska mreža dobro generalizuje ukoliko daje dobre interpolacije za nove ulaze, koji nisu bili prisutni u postupku obučavanja).


Obučavanje mreža algoritmom propagacije greške unazad



Obučavajući skup i generalizacija

- Neuronska mreža sa **isuvviše slobodnih parametara za zadati obučavajući skup** može biti dobro obučena, sa velikom verovatnoćom loše generalizacije.
- Pošto je generalizacija važno svojstvo, razvijeno je više procedura za njeno poboljšanje:
 - **Smanjivanje osetljivosti mreže.**
 - Da bi mreža posedovala dobra svojstva generalizacije, potrebno je da male promene ulazna ne izazivaju velike promene na izlazu mreže.
 - Primena ovog principa je proširivanje obučavajućeg skupa varijacijama ulaznih signala (dodavanje šuma oko svakog elementa obučavajućeg skupa).
 - **Regularizacija.**
 - Proširivanje kriterijumske funkcije tzv. regularizacionim članom.
 - **Rano zaustavljanje** (engl. *early stopping*).
 - **Kresanje** (engl. *prunning*).
 - Ideja kresanja se svodi na ostvarivanje što boljih performansi sa što siromašnijom arhitekturom.

Obučavajući skup i generalizacija



- Metoda vektora oslonca (*Support Vector Machines*, SVM) je linearna metoda učenja koja funkciju odluke traži u skupu funkcija (hipoteza) koje su linearna kombinacija ulaznih vrednosti.
- Podaci koji se u originalnom, ulaznom prostoru ne mogu podeliti linearnim funkcijama, preslikavaju se uz pomoć jezgra u **prostor atributa** (*kernel induced feature space*).
 - Prostor atributa je visokodimenzionalan.
 - U njemu se podaci mogu podeliti upotrebom linearnih hipoteza.
- Preslikavanje povećava ekspresivnost linearnih metoda, ali dovodi i do povećanja rizika od prenaučenosti.
- **Statistička teorija učenja** definiše koje parametre treba kontrolisati kako bi se dostigao odgovarajući stepen generalizacije i smanjio rizik od prenaučenosti.
- **Klasifikator maksimalne margine** ne dopušta pogrešnu klasifikaciju primera za učenje i primenljiv je samo na skupu podataka koji su linearno razdeljivi u prostoru atributa.
- Ovo ograničenje mogućnosti primene motivisalo je razvoj **klasifikatora meke margine**.

- **Formalna definicija.**
- Metoda vektora oslonca se u opštem slučaju definiše kao:
 1. Algoritam učenja korišćenjem linearnih metoda
 2. u prostoru formiranim funkcijom jezgra,
 3. pri čemu se greška generalizacije kontroliše upotrebom statističke teorije učenja i
 4. primenjuje teorija optimizacije za rešavanje konveksnog kvadratnog problema na čije se rešavanje svodi učenje metodom SVM.

Binarna Support Vector Machines klasifikacija

- Podaci za problem binarne klasifikacije sastoje se od objekata x_i označenih labelom y_i koja određuje klasu pripadnosti: +1 (pozitivna klasa) ili -1 (negativna klasa).
- Neka je $\mathbf{x}$ vektor čije su komponente x_i .
- Linearni klasifikator zasnovan je na **linearnoj funkciji razdvajanja** definisanom skalarnim proizvodom dva vektora:


$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = \sum w_i x_i + b$$

- Vektor w je težinski vektor, a b pristrasnost kojom je određena udaljenost hiper-ravni u odnosu na koordinatni početak.
- **Hiper-ravan** deli prostor na dva dela, dok znak funkcije $f(x)$ označava stranu hiper-ravni.

$$\{\mathbf{x}: f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = 0\}$$

Binarna Support Vector Machines klasifikacija

- Hiper-ravan deli prostor atributa na dva dela u binarnom klasifikatoru maksimalne margine.



Binarna Support Vector Machines klasifikacija

- **Težiski vektor** se može izraziti kao linearna kombinacija obučavajućih primera, što je poznato kao dualno predstavljanje granice odluke.
- Funkcija razdvajanja u tom slučaju ima oblik:

$$f(\mathbf{x}) = \sum \alpha_i x_i^T \mathbf{x} + b$$

- Ova jednačina u *feature space* ima oblik:

$$f(\mathbf{x}) = \sum \alpha_i k(\mathbf{x}, \mathbf{x}_i) + b = \sum \alpha_i \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}) + b$$

- Iako svaka funkcija koja zadovolji uslove date Mercerovom teoremom može biti korišćena kao jezgro, funkcija jezgra $k(\mathbf{x}, \mathbf{x}')$ mora biti efikasno izračunljiva pošto prostor atributa može biti visokodimenzionalan.

- **Klasifikator maksimalne margine** je funkcija razdvajanja koja maksimizuje geometrijsku marginu $1/\|\mathbf{w}\|$, gde je $\|\mathbf{w}\|$ norma težinskog vektora.
- To je ekvivalentno minimizaciji izraza $\|\mathbf{w}\|^2$, iz čega proizilazi problem uslovne optimizacije: minimizacija izraza $\frac{1}{2} \|\mathbf{w}\|^2$, uz ograničenje:

$$(\forall i=1,\dots,n) y_i(\mathbf{w}^T x_i + b) \geq 1$$

- Ograničenja u ovoj formulaciji obezbeđuju da će klasifikator maksimalne margine ispravno klasifikovati svaki primer, što je moguće samo ako su podaci apsolutno linearno razdvojivi.
- U praksi, podaci često nisu linearno razdvojivi, a čak i ako jesu, potrebno je tolerisati neispravnu klasifikaciju određenih tačaka.

- Da bi se dozvolila neispravna klasifikacija određenih tačaka, potrebno je prethodnu jednačinu izmeniti uvođenjem promenljive kojom se definiše **tolerancija**:

$$(\forall i=1,\dots,n) y_i(\mathbf{w}^T x_i + b) \geq 1 - \xi_i$$

- Na taj način se toleriše neispravna klasifikacija primera koji se nalaze u opsegu greške margine ($0 \leq \xi_i \leq 1$)
- Ukoliko nisu u okviru greške margine, primeri su pogrešno klasifikovani ($\xi_i > 1$).
- Granica pogrešno klasifikovanih primera je $\sum \xi_i$.
- **Konstantom meke margine** $C > 0$ određen je odnos između maksimizacije margine i minimizacije stepena tolerancije.
- Klasifikator koji toleriše ispravnu klasifikaciju primera koji se nalaze u opsegu greške naziva se **klasifikator meke margine**.

Binarna Support Vector Machines klasifikacija

- Problem optimizacije klasifikatora meke margine svodi se na minimizaciju izraza::

$$\frac{1}{2}\|\mathbf{w}\|^2 + C\sum \xi_i$$

- uz ograničenje: $(\forall i=1,\dots,n) y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i$
- Primenom Lagranžovih koeficijenata (dualna formulacija), problem optimizacije postaje maksimizovanje izraza:



$$\sum \alpha_i - \frac{1}{2} \sum_i \sum_j y_i y_j \alpha_i \alpha_j \mathbf{x}_i^T \mathbf{x}_j$$

- Na osnovu dualne formulacije težinski vektor može se predstaviti kao: $\mathbf{w} = \sum y_i \alpha_i \mathbf{x}_i = 0$
- Primeri $\mathbf{x}_i$ za koje je $\alpha_i > 0$ su tačke koje se nalaze na ili u okviru margine.
- Te tačke nazivaju se **vektori oslonca** (*Support Vectors*).
- Obučavanje klasifikatora svodi se na pronalaženje **optimalne margine hiper-ravni**, tj. na odabir optimalnih parametara α_i i b .

- Klasifikator je takođe definisan takozvanim **hiper-parametrima**:
 - Konstantom meke margine C
 - Parametrima konkretnog jezgra.
- Parametri se mogu odabrati empirijski ili upotrebom **unakrsne validacije** (engl. *cross-validation*) i metode ***grid-search*** (pretraga po rešetci).
- Za velike vrednosti parametra C , tačke najbliže hiper-ravni utiču na njenu orijentaciju, što za posledicu može imati hiper-ravan koja se nalazi blizu velikog broja drugih tačaka.
- Kada se parametar C smanji, te tačke postaju greške margine – orijentacija hiper-ravni se menja, što obezbeđuje dovoljno široku marginu za ostatak podataka.

Uticaj konstante meke margine na klasifikaciju

- Linearno jezgro, $C = 100$ (levo) i $C = 10$ (desno).



- Odabir jezgra **zavisi od konkretnog problema koji se rešava**.
- Na primer, gausovo tj. RBF (*Radial Basis Function*) jezgro definisano izrazom:



$$k(\mathbf{x}, \mathbf{x}') = e^{-\gamma \|\mathbf{x} - \mathbf{x}'\|^2}$$

postize bolje performanse po pitanju tačnosti klasifikacije i vremenu konvergencije u odnosu na polinomijalno.

- Parametar $\gamma = 1/2\sigma^2$ ima sličnu ulogu kao stepen u polinomnom jezgru i služi za kontrolu fleksibilnosti klasifikatora.
- Ukoliko je polinomijalno jezgro stepena dva dovoljno fleksibilno da diskriminiše klase, onda će jezgro stepena pet formirati sličnu granicu odlučivanja, ali sa većom zakrivljenošću.
- Slično, povećanje vrednosti parametra γ dovodi do veće lokalizacije vektora oslonaca i veće zakrivljenosti granice odlučivanja.
- Preterano velika vrednost parametra γ može dovesti klasifikator u stanje prenaučenosti.





Ponašanje polinomijalnog jezgra u odnosu na stepen

- Polinomijalno jezgro: $d = 2$ (levo) i $d = 5$ (desno).





Ponašanje RBF jezgra u odnosu na parametar γ

- RBF jezgro: $\gamma = 0,1$; $\gamma = 1$; $\gamma = 10$; $\gamma = 100$ (redom, s leve ka desnoj slici).




- **Stablo odlučivanja** (decision tree) je klasifikacioni algoritam u formi stablaste strukture.
- Stablo sadrži dva tipa čvorova povezanih granama.
 - **Krajnji čvor**, kojim se završava odredjena grana stabla, definiše klasu kojoj pripadaju primeri koji zadovoljavaju uslove na toj grani stabla.
 - **Čvor odluke** definiše uslov u formi vrednosti određenog atributa. Iz čvora odluke izlaze grane koje zadovoljavaju određene vrednosti tog atributa.
- Kretanjem po granama stabla koje instanca vrednostima svojih atributa zadovoljava, od čvora odlučivanja u korenu stabla do krajnjeg čvora koji klasifikuje instancu u jednu od postojećih klasa problema.
- Da bi se tehnika stabla odlučivanja upotrebila za klasifikaciju, instance moraju biti opisane konačnim brojem atributa, prethodno mora biti definisan konačan broj klasa.
- Svaka instanca može pripadati samo jednoj od postojećih klasa, kojih mora biti znatno manje od broja instanci.

Stabla odlučivanja



- Većina postojećih algoritama za formiranje stabla odlučivanja su varijacije osnovnog algoritma **ID3** (*Iterative Dichotomiser*).
 - ID3 pretražuje attribute svih instanci u skupu podataka.
 - Ukoliko atribut savršeno razdvaja klase, algoritam se zaustavlja.
 - U suprotnom, algoritam se rekurzivno izvršava na m podskupova (gde je m broj mogućih vrednosti atributa), tražeći najbolje attribute za njihovo razdvajanje.
 - Algoritam traži trenutno najbolji atribut i nikad ne proverava ispravnost prethodnih razdvajanja.
 - Osnovni deo algoritma je selekcija atributa sa najheterogenijom strukturom vrednosti za stvaranje čvora odlučivanja upotrebom koncepta entropije.
- Stabla odlučivanja imaju svoje nedostatke:
 - Mogućnost generalizacije je manja u odnosu na druge metode.
 - Empirijski je utvrđeno da su stabla odlučivanja jako osetljiva na podatke u obučavajućem skupu i da ne mogu da se obučavaju na neuravnoteženim skupovima.


- **Ensembli** koriste više algoritama učenja kako bi ostvarili bolje prediktivne performance od pojedinačnih konstitutivnih algoritama.
- Ensembli se najčešće formiraju upotrebom *boosting*, *bagging* i *stacking* tehnika.



Ensembli: boosting, bagging, stacking

- **Boosting** inkrementalno gradi ensembl.
 - Svaka nova instanca modela se obučava sa naglasom greške u prethodnoj instanci.
 - Naglašavaju se instance obučavajućeg skupa koje su prethodne instance modela pogrešno klasifikovale.
- **Bagging ensemblu** zasnovan je na tehnici glasanja (engl. voting).
 - Svaki model, obučen nasumično odabranim podskupom obučavajućeg skupa, ima jednako parvo glasa.
 - Primer: **random forest** je bagging ensembl koji kao modele koristi slučajno formirana stabla odlučivanja i veoma visoku tačnost klasifikacije.
- **Stacking** gradi hibridni ensembl obučavanjem kombajnera izlazima nekoliko drugih algoritama obučenih raspoloživim podacima.
 - Kombajner određuje konačnu predikciju koristeći izlaze ostalih algoritama kao dodatne ulaze.
 - U praksi se kao kombajner često koristi *single-layer logistic regression* model.


Random Forest



Miželova definicija mašinskog učenja u kontekstu IDS sistema

- Formalna definiciju mašinskog učenja po Tom Mižel-u: „program uči iz **iskustva E** u odnosu na **klasu zadataka T** i **meru performansi P**, ako se mera performansi P poboljšava u vezi zadatka T nakon iskustva E“.
- Shodno ovoj formalnoj definiciji:
 - IDS uči da klasifikuje događaje (zadatak T)
 - Mera performansi P ovog zadatka je tačnost klasifikacije
 - Iskustvo E je zadati obučavajući skup pravila.

Radni okvir IDS sistema zasnovanih na mašinskom učenju



- IDS **detektuje potpise** tako što:
 - prikuplja podatke sa senzora,
 - predprocesira podatke (uklanja šum, izdvaja attribute i normalizuje njihove vrednosti),
 - identifikuje pretnju na osnovu potpisa (poredi vrednosti atributa sa svim pravilima u bazi),
 - ažurira pravila,
 - oglašava se alarmom ili reaguje na napad.
- Tačnost sistema za detekciju potpisa zavisi od znanja koje je smešteno je u bazi pravila kojima su opisani napadi.
- Sistem zasnovan na jednostavnoj pretrazi baze potpisa ne može da otkrije napade koji nisu opisani ni jednim pravilom.

- Otkrivanje varijacije poznatih napada je moguće ukoliko se u sistem ugradi pogodna metoda mašinskog učenja u fazi predprocesiranja ili klasifikacije.
- Pošto su podaci u bazi pravila označeni, najčešće se koriste metode **nadgledanog učenja** (veštačke neuronske mreže, metode vektora oslonca, stabla odlučivanja).
- Tehnike detekcije u tom slučaju zasnovane su na **merama sličnosti** tekuće aktivnosti i potpisa poznatih napada.
- Aktivnost dovoljno slična nekom potpisu klasifikuje se kao napad.
- Nedostatak ovakvih sistema je nemogućnost otkrivanja napada koji nisu slični ni jednom potpisu.

- IDS **detektuje anomalije** tako što:
 - prikuplja podatke sa senzora,
 - predprocesira podatke,
 - gradi profil normalnog ponašanja mašinskim učenjem (najčešće su označeni podaci koji odgovaraju normalnom ponašanju, dok anomalije nisu),
 - identifikuje napad na osnovu odstupanja od profila normalnog ponašanja,
 - oglašava se alarmom ili reaguje na napad.
- Identifikacija napada najčešće se obavlja metodama mašinskog učenja koje klasifikuju instance pomoću mera sličnosti između ulaza i profila normalnog ponašanja.
 - Primer: metoda najbližih suseda.
- Osnovni nedostatak tehnika za detekciju anomalija je veliki broj lažnih alarma nastalih usled evolviranja normalnog ponašanja.

Analiza obučavajućih skupova: KDD Cup'99

- Skup podataka KDD Cup '99 sastoji se od:
 - potpunog obučavajućeg skupa (oko 4.900.000 instanci),
 - 10% obučavajućeg skupa (sadrži približno 10% instanci iz potpunog obučavajućeg skupa),
 - skupa za testiranje, koji sadrži nove tipove napada.
- Prema Kendalu, napadi iz skupa KDD Cup '99 mogu se klasifikovati u četiri kategorije:
 - ispitivački napadi (**probing**),
 - napadi odbijanja usluga (Denial of Service, **DoS**),
 - neovlašćeno povećanje privilegija (User to Root, **U2R**),
 - neovlašćenog sticanje pristupa udaljenom računaru (Remote to Local, **R2L**).

Analiza obučavajućih skupova: KDD Cup'99

- Obeležja instanci skupa KDD Cup'99
 - 32 numerička obeležja, na primer:
 - trajanje konekcije,
 - broj bajtova poslatih sa izvorišta ka odredištu,
 - broj neispravnih fragmenata,
 - broj operacija koje kreiraju nove datoteke,
 - broj operacija koje menjaju prava pristupa,
 - broj aktivnih komandnih interpretera.
 - 6 binarnih obeležja, na primer:
 - obeležje koji ukazuje na napad tipa „land“, tj proverava da li su odredišna i izvorišna adresa identične,
 - obeležje koje ukazuje na pokušaj pokretanja komande kojom se stiču administrativne privilegije na operativnom sistemu.
 - 3 kategorička obeležja (protokol, odredišni servis i fleg).

Analiza obučavajućih skupova: KDD Cup'99

- Kategorije obeležja kojima su opisane instance skupa KDD Cup'99:
 - **Osnovna obeležja** određuju se vrednostima iz zaglavlja paketa.
 - Primer: trajanje, protokol i servis.
 - **Obeležja zasnovana na sadržaju** određuju se analizom sadržaja TCP paketa.
 - Primeri:
 - „failed logins“, tj. broj neuspešnih pokušaja prijavljivanja na sistem.
 - „root shell“ koji određuje da li je otvoren komandni interpreter sa root privilegijama.
 - **Vremenska obeležja** saobraćaja opisuju osobine koje zastarevaju nakon isteka definisanog vremenskog intervala.
 - Primer: broj konekcija ka istom sistemu u zadatom vremenskom intervalu.
 - **Sistemska obeležja saobraćaja**, za razliku od vremenskih, zasnovani su na prozoru čiji je interval zadat brojem konekcija.
 - Sistemska obeležja su pogodna za opisivanje napada čije je trajanje duže od intervala propisanog vremenskim obeležjima.

Analiza obučavajućih skupova: KDD Cup'99

- **Kritička analiza.**
- Osnovni nedostatak: skup NIJE verodostojna simulacija realnog mrežnog saobraćaja.
 - Broj instanci napada je nerealistično veliki u odnosu na broj instanci normalnog saobraćaja.
 - Odnos instanci različitih kategorija napada u skupu je nerealan.
- Precizna definicija napada ne postoji.
 - Primer: ispitivanje mreže se ne smatra napadom ukoliko administrator proverava da li su zaštitni mehanizmi ispravno konfigurisani.
- Skupovi je isuviše složeni za formiranje modela zasnovanog na mašinskom učenju koji je sposoban da dovoljno tačno detektuje R2L i U2R napade.
 - Razlozi:
 - Jako mali broj instanci U2R napada.
 - Postojanje instanci R2L koje su identične ili veoma slične normalnom saobraćaju
 - Nepostojanje nekih R2L instanci u test skupu
- Postojanje duplikata.

Diskusija i praktična demonstracija

- Sinteza obučavajućih skupova.
- Praktična demonstracija.

1. D. Pleskonjić, N. Maček, B. Đorđević, M. Carić (2007): Sigurnost računarskih sistema i mreža. Mikro knjiga, Beograd.
2. M. Milosavljević (2015): Veštačka inteligencija. Univerzitet Singidunum.
3. M. Milosavljević: predavanja iz predmeta Veštačka inteligencija i Mašinsko učenje, Univerzitet Singidunum.
4. N. Maček, M. Milosavljević (2014): Reducing U2R and R2L False Positive Rates with Support Vector Machines. SJEE Vol. 11, Issue 1, pp 175-188.
5. N. Maček (2015): Detekcija upada mašinskim učenjem / Machine Learning in Intrusion Detection. Zadužbina Andrejević.

Pitanja su dobrodošla.