



APLIKACIJA ZA KLASIFIKACIJU VREMENSKIH PRILIKI NA SLICI

APPLICATION FOR CLASSIFYING WEATHER CONDITIONS ON THE PICTURE

Srđan Gajić, *Fakultet tehničkih nauka, Novi Sad*

Oblast - INFORMACIONI SISTEMI

Kratak sadržaj – U ovom radu je prikazano kreiranje i rad aplikacije za klasifikaciju slika na osnovu vremenskih prilika, kao i teorijska podloga i trenutno stanje u relevantnim oblastima.

Ključne reči: Mašinsko učenje, duboko učenje, konvolucionala neuronska mreža (CNN).

Abstract – This paper shows how to make and use an application that classifies pictures according to weather conditions and it shows the theoretical background and the current state in the relevant fields.

Keywords: Machine learning, Deep learning, MATLAB, Convolutional Neural Network (CNN).

1. UVOD

Desktop aplikacija je razvijena u MATLAB razvojnog okruženju primenom posebne grane discipline mašinskog učenja (*machine learning*) koja se naziva duboko učenje (*deep learning*). Mašinsko učenje omogućava računarima da „nauče“ iz iskustva, odnosno algoritmi mašinskog učenja pružaju softveru način da ovladaju informacijama i razviju određene izvršne funkcije direktnom upotreboti ili analizom podataka. Duboko učenje je podoblast mašinskog učenja. Razvijeno je sa ciljem da reši probleme koji su previše kompleksni za tradicionalan pristup mašinskog učenja. Odabir pristupa zavisi od problema koji se rešava i od konačnog kvaliteta izlaznih podataka.

Aplikacija koja je razvijena za potrebe ovog rada koristi kombinovan pristup. Pre svega se koristi duboko učenje jer je osnova već kreirana neuronska mreža Resnet-50, međutim određeni delovi koda se oslanjaju na elemente mašinskog učenja. Korisnik kroz GUI interfejs izabere sliku da se učita u prostor za sliku i pomoću dugmeta aktivira se proces klasifikacije slike pomoću definisane neuronske mreže i komandi implementiranih u pozadini MATLAB programskog jezika. Rezultat je tekst u kojem su navedene vremenske prilike na odabranoj slici.

2. MAŠINSKO UČENJE

Mašinsko učenje je jedna grana nauke koja se ubrzano razvija: veštačke inteligencije (*AI - artificial intelligence*). Ono što je ključno razumeti jeste da veštačku inteligenciju od kompleksnih i sofisticiranih programa razdvaja to što je autonomna i sposobna za samostalno učenje. Mašinsko

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Andraš Anderla, vanr.prof.

učenje koristi algoritme i analitičke tehnike da bi izgradilo prediktivne modele u cilju rešavanja nekog problema.

2.1. Istorija mašinskog učenja

Proučavanje mašinskog učenja počinje 1950-ih godina sa korenima u zajednicama okupljenih oko dve naučne discipline: veštačke inteligencije i obrade signala [1].

Mada postoje i raniji radovi na temu veštačke inteligencije i mašinskog učenja, kao početno doba kada su se ove naučne discipline razvijale se smatra druga polovina dvadesetog veka. Istorija mašinskog učenja se može podeliti u tri perioda aktivnosti: istraživanje (1950-te i 1960-te godine), razvoj praktičnih algoritama (1970-te godine) i eksplozija istraživačkih pravaca (1980-te godine i kasnije) [2].

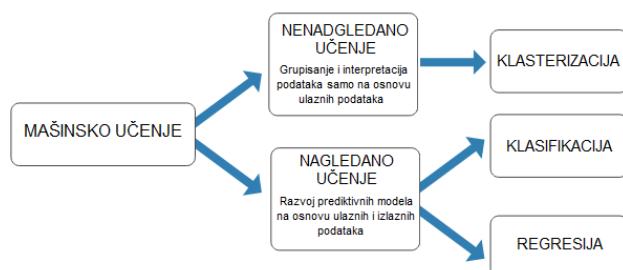
Vremenom se veštačka inteligencija odvajala od mašinskog učenja. Nauka o mašinskom učenju morala je da se reorganizuje i da se definiše kao posebna oblast. Cilj se promenio iz treninga modela za potrebe veštačke inteligencije u rešavanje praktičnih problema.

2.2. Karakteristike mašinskog učenja

Fokus mašinskog učenja jeste razvijanje algoritama pomoću kojeg se obrađuju podaci sa ciljem da se simulira način učenja čoveka i sticanje inteligencije.

Algoritmi mašinskog učenja se koriste da bi se trenirali modeli mašinskog učenja. Model je u suštini datoteka ili skup datoteka koji je naučen da prepozna određeni obrazac. Kada je model istreniran onda on može da prepozna obrazac među podacima i da formira predikciju odnosno procenu. Koliko je procena tačna se utvrđuje (ako postoji situacija gde se već izračunala željena vrednost ili željeno stanje) tako što se upoređuje data procena sa pređašnjim rezultatima pre nego što je model istreniran. Ovo se zove proces validacije.

Na slici 1 je prikazana osnovna podela tehnika ili metoda mašinskog učenja.



Slika 1. Tehnike mašinskog učenja

Dve glavne kategorije su nagledano (*supervised*) i nenagledano (*unsupervised*) učenje. Ove dve kategorije se mogu formulisati na sledeći način: nadgledano učenje predstavlja pristup problemu učenja koji se odnosi na situacije u kojima se algoritmu zajedno sa podacima iz kojih uči daju i željeni izlazi, a nenagledano učenje predstavlja pristup problemu učenja koji se odnosi na situacije u kojima se algoritmu koji uči pružaju samo podaci bez izlaza, a od algoritma koji uči očekuje se da sam uoči neke zakonitosti u podacima koji su mu dati [3].

Pored nadgledanih i nenagledanih, tehnike mašinskog učenja se dalje mogu deliti na tehnike koje su grupisane po vrsti problema koji se rešava. Nadgledane tehnike se dele na tehnike klasifikacije i regresije. Tehnike klasifikacije koriste algoritme da klasifikuju podatke u različite kategorije. Tehnike regresije koriste algoritme da bi dale procenu koja je kontinualne prirode.

Nameće se pitanje kako izabratи koji model je najpogodniji za zadati problem [4]. Ovo se rešava evaluacijom modela [4]. Evaluacija modela jeste ocenjivanje kvaliteta modela [4]. Većina mera kvaliteta kod klasifikacije se zasnivaju na matrici konfuzije [4]. Na slici 2 je prikazana matrica konfuzije za binarnu klasifikaciju.

		Procenjena 0	Procenjena 1
Stvarna 0	TN	FP	
	FN		TP

Slika 2. Matrica konfuzije

Binarna klasifikacija suštinski ima dva stanja: uspešna i neuspešna procena. One procene koje su se ispostavile tačnim se označavaju sa TN (*True negative*) ili TP (*True positive*). One procene koje su se ispostavile netačnim se označavaju sa FN (*False negative*) ili FP (*False positive*).

2.3. Primena mašinskog učenja

Model mašinskog učenja se može primeniti u raznim industrijama i naučno-tehnološkim poljima. Danas su zastupljeni u različitim oblastima, kao što su: proizvodnja, marketing, zdravstvo, digitalni mediji, industrija zabave, e-trgovina, energetski sektor, bankarsko-finansijski sektor, automobilska industrija, odbrambeni sistemi, osiguravajuća društva, transport, sektor ljudskih resursa, umetnost,...

Potrebljeno je razmatrati upotrebu mašinskog učenja kada se rešava složen zadatak ili problem sa velikim brojem promenljivih i bez postojeće odnosno definisane metode ili načina za rešavanje, a postoji pristup velikim količinama podataka.

Sa razvojem i implementacijom mašinskog učenja, kao i veštačke inteligencije, pojavila se i određena mera zabrinutosti zbog negativnih efekata koje oni stvaraju. Uticaj veštačke inteligencije i mašinskog učenja na poslove

odnosno radnu snagu izaziva zabrinutost. Procena je da će mnogi poslovi postati redundantni sa povećanom implementacijom mašinskog učenja. Takođe se postavlja pitanje poštovanja privatnosti korisnika i zaštite podataka.. Mašinsko učenje daje mogućnost preduzećima da na brz i efikasan način obrade lične podatke korisnika, što može da predstavlja problem ako se oni koriste u zlonamerne svrhe.

3. DUBOKO UČENJE

Duboko učenje je specijalan oblik mašinskog učenja. Zasniva se na arhitekturi neuronskih mreža, zbog čega se modeli dubokog učenja često nazivaju i duboke neuronske mreže. Neuronske mreže pokušavaju da simuliraju moždanu aktivnost čoveka čime oni "uče" procesirajući podatke na osnovu kojih daju određene predikcije. One su sastavljenje od slojeva, gde svaki sloj izvršava određenu operaciju (matematičku ili logičku) nad podacima. Reč duboko se odnosi na broj skrivenih slojeva u arhitekturi mreže.

3.1. Istorija dubokog učenja

Duboko učenje je relativno mlada naučna oblast, sam termin se pojavljuje 2000-te godine. Međutim korenji ove nauke potiču od 1940-tih godina dvadesetog veka. Ono što je bilo pokretač su pokušaji istraživača da prošire mogućnosti mašinskog učenja. Vremenom se duboko učenje formiralo kao posebna naučno-tehnološka disciplina. Zbog toga se kaže da je duboko učenje podoblast mašinskog učenja.

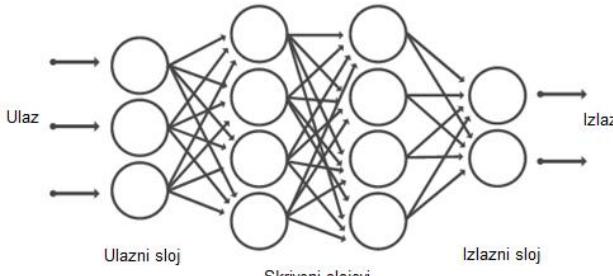
3.2. Karakteristike dubokog učenja

Duboko učenje teži da simulira moždane aktivnosti čoveka pri rešavanju složenih zadataka. Glavni uzorni model pri dizajniranju sistema koji su sposobne da izvedu ovu simulaciju je biološki nervni sistem. Na osnovu nervnog sistema su osmišljene i kreirane strukture koje se nazivaju veštačke neuronske mreže.

Veštačke neuronske mreže simuliraju moždane aktivnosti čoveka, koristeći ulazne podatke, parametre (*weights*) i mere korekcije (*bias*). Ulagani podaci se dele na podatke za trening modela i podatke za test modela. Parametri se odnose na same vrednosti koje se kreću i akumuliraju u samoj mreži. Mera korekcije je vrednost koja služi da se krajnji rezultat predstavi u onom redu veličine koji je najpogodniji za prikaz. Glavna razlika između parametara i mere korekcije je ta da parametri interaguju i zavise od ulaznih podataka, dok se mera korekcije primenjuje samo na izlazne vrednosti.

Neuronske mreže se sastoje od slojeva i u svakom sloju se nalaze neuroni odnosno čvorovi. Čvorovi između slojeva su međusobno povezani. Mreža je dublja što više slojeva sadrži. Procesirani podaci se kreću iz jednog čvora u drugi i sa svakim novim čvorom se vrednost parametra povećava, odnosno akumulira se vrednost. Samo procesiranje podataka zapravo predstavlja matematičke i logičke funkcije i operacije koje se izvršavaju nad njima.

Ulagani i izlazni sloj su vidljivi delovi mreže. Svi ostali slojevi između su skriveni slojevi i u njima se izvode proračuni nad podacima. Primer neuronske mreže je prikazan na slici 3.



Slika 3. Veštačka neuronska mreža

Dva tipa najčeće korišćenih mreža su *convolutional neural network* (CNN) i *recurrent neural network* (RNN).

CNN je tip neuronske mreže koja uči direktno iz podataka jer ne zahtevaju ručnu ekstrakciju karakteristika podataka. Jedina značajna razlika između CNN-ova i tradicionalnih veštačkih neuronskih mreža je ta da se CNN-ovi primarno koriste u polju prepoznavanja obrazaca unutar slika [5].

Recurrent neural network (RNN) je tip neuronske mreže koja procesira serijabilne (redne) podatke i koristi se za rešavanje problema koje je moguće razložiti na celine koje imaju serijabilni raspored ili za rešavanje vremenski hronoloških problema. RNN mreže imaju u sebi određenu strukturu koja se može nazvati memorijom koja pamti sve informacije koje su do sadašnjeg trenutka izračunate. Ova struktura ima oblik petlje oko samog sloja, a sama vrednost u memoriji se naziva skriveno stanje. Memorija je veoma bitna jer kod ovih mreža izlazna vrednost kod svih slojeva zavisi od proračuna u svakom prethodnom sloju.

Postoji više načina da se trenira veštačka neuronska mreža, odnosno model dubokog učenja. Dva najpoznatija načina su treniranje od početka i transfer učenje. Treniranje od početka (*training from scratch*) se odnosi na slučaj kada se ne preuzima već postojeća neuronska mreža nego ju je potrebno dizajnirati od početka. Pošto će nova neuronska mreža biti bez treninga, potrebno je skupiti veoma veliku količinu označenih podataka koje će služiti kao trening set. Transfer učenje (*transfer learning*) je pristup gde se preuzima model (neuronska mreža) koji je istreniran da reši određeni problem i izvršava se modifikacija tog modela da bi se rešio sličan problem. Ako se na primer uzme postojeća mreža *AlexNet* koja može da klasificiše veći broj predmeta i ako joj se ubace podaci sa nekim novim objektima, onda se *AlexNet* može modifikovati da klasificiše samo te nove objekte. Postavlja se pitanje kada se odlučiti za treniranje od početka, a kada za transfer učenje? U opštem slučaju je očekivano da će neuronska mreža koja je već istrenirana nad mnoštvom podataka imati bolje performanse od apsolutno nove neuronske mreže. Treniranje od početka može eventualno da ima bolje performanse ako se koristi za neki usko specifičan zadatak za koji ne postoji već predefinisani model, ali i u tom slučaju nužno je obezbediti veliku količinu trening podataka ako se želi postići visoka tačnost.

Potrebno je napomenuti da se danas koriste grafičke kartice (*Graphical Processing Units* (GPUs)) u svrsi dramatično bržeg procesiranja podataka za treniranje i testiranje veštačkih neuronskih mreža. Glavna prednost je ta što GPU omogućava masivnu paralelnu obradu podataka.

3.3. Primena dubokog učenja

Duboko učenje je uspelo da uneše revolucionarne rezultate u okviru veštačke inteligencije. Pošto je potencijal veoma velik, tehnološka preduzeća ulažu u razvoj ove discipline. Duboko učenje je prisutno u mnogim oblastima, kao što su: proizvodnja, trgovina, saobraćaj, odbrambena industrija, poljoprivreda, finansijsko-bankarski sektor, sektor korisničke podrške, industrija zabave, zdravstvo, logistika, sport, obrazovanje, umetnost...

Međutim kod primene modela dubokog učenja postoje određene poteškoće i takođe mogu da nastanu i određeni problemi. Glavna poteškoća je ta da je potrebno izuzetno velika količina podataka da se obradi da bi duboko učenje bilo efikasnije od neke druge metode.

Prikupljanje masivnih količina podataka nije jednostavno. Izbor odgovarajućeg modela je takođe problematičan. Ne postoji vodič koji objašnjava koji model, odnosno neuronsku mrežu izabrati. Postoje opšte preporuke, ali potrebno je istestirati da li je određeni model odgovarajuć za rešavanje problema korisnika.

4. MAŠINSKO UČENJE I DUBOKO UČENJE

Duboko učenje se može smatrati evolucijom mašinskog učenja. Rade po sličnom principu, modeli obe discipline moraju biti istrenirani i testirani i oba modela donose neku predikciju. Tako da modeli imaju slične sposobnosti, ali razlikuju se u strukturi, načinu na koji se model trenira i koje su sve mogućnosti koje nude.

Sami mehanizmi učenja i provere znanja su drugačiji između algoritma i slojeva neuronske mreže. Kod algoritma mašinskog učenja, proces učenja se deli na manje delove i vrši se spajanje svih naučenih delova u jedan izlazni rezultat, a kod slojeva neuronske mreže ceo proces učenje se odvija povezano od sloja do sloja i kod izlaznog sloja nema spajanja delova nego se samo dobije izlazni rezultat.

Iako modeli mašinskog učenja vremenom postaju tačniji kako se se povećava broj iteracija donošenja procene, ako se desi pogrešna procena onda inženjer mora da izvrši nova podešavanja modela. Kod modela dubokog učenja nije potrebna intervencija, sam model može da prepozna da li je doneo tačnu procenu.

Modeli dubokog učenja ne pokazuju dobre rezultate ako su količine podataka male, jer su im potrebne velike količine podataka da bi mogli da razumeju podatke savršeno [6]. Sa druge strane, modeli mašinskog učenja pokazuju dobre rezultate i sa malim i srednjim setom podataka.

Modeli mašinskog učenja su manje zahtevni. Mogu da rade na mašinama koje imaju manje resursa. Ne zahtevaju jaku procesorsku moć. Modeli dubokog učenja zahtevaju više resursa od mašina na kojima rade.

Trening faza kod mašinskog učenja traje kraće nego kod dubokog učenja, jer modeli dubokog učenja imaju više slojeva i parametara. Obrnuto je kod test faze. Modeli dubokog učenja se mogu brzo istestirati.

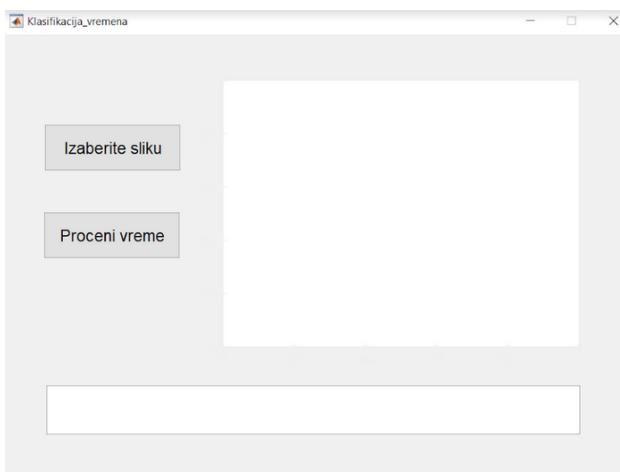
5. APLIKACIJA

Aplikacija koja je razvijena za potrebe ovog master rada je aplikacija koja vrši klasifikaciju slika na osnovu vremenskih prilika koje su na slici. Razvijena je u MATLAB razvojnom okruženju kao desktop aplikacija. Za potrebe klasifikacije preuzeta je već razvijena konvolucionna neuronska mreža koja se naziva ResNet-50. Nad ovom mrežom je izvršena modifikacija tako da može da posluži u svrhu određivanja vremenskih prilika i klasifikaciju na osnovu istih. Preuslov za realizaciju aplikacije je instalacija dodatnih *Add-On* paketa: *Image Processing Toolbox*, *Statistics and Machine Learning Toolbox* i *Deep Learning Toolbox*.

GUI koji čini aplikaciju se sastoji iz dva fajla: *.fig* i *.m* fajla. U *.fig* fajlu je definicija korisničkog interfejsa aplikacije, a u *.m* fajlu je kod koji se izvršava u pozadini. Nakon što se definišu svi elementi u samom korisničkom interfejsu aplikacije, njihovo ponašanje se programira u pozadinskom kodu.

Otvaranjem *.fig* fajla u GUIDE-u se dobija forma koja će predstavljati krajnji izgled aplikacije. Na nju se postavljaju elementi koji su potrebni za rad aplikacije. Čuvanjem ovih promena u GUIDE-u se automatski kreira *.m* fajl, koji ima isti naziv kao i *.fig* fajl. Dakle, sada su kreirana oba fajla potrebna za rad aplikacije: *Klasifikacija_vremena.fig* i *Klasifikacija_vremena.m* fajlovi. Sada je potrebno isprogramirati rad aplikacije u *.m* fajlu.

Nakon što je ponašanje svih elemenata definisano, aplikacija je spremna za rad. Pokretanjem aplikacije dobija se početna forma, prikazana na slici 4. Na početnoj formi se nalaze dva dugmeta na levoj strani forme, "Izaberite sliku" i "Proceni vreme", prostor gde će izabrana slika biti učitana na desnoj strani forme i prostor gde se ispisuje rezultat u donjem delu forme.



Slika 4. Početna forma aplikacije

Pritiskom na dugme "Izaberite sliku" otvara se *Windows explorer* prozor gde se nalaze četiri kategorije vremenskih prilika. Otvaranjem ovih podfodera može se izabrati bilo koja slika u njima koja se učitava u prostor na glavnoj formi aplikacije.

Nakon što je slika izabrana, pritiskom na dugme "Proceni vreme" dobija se rezultat rada koda ispis u donjem delu forme aplikacije. Ispis je formatiran na način da se

menja jedino reč koja pokazuje kakvo je vreme (kišovito, oblačno, snežno ili sunčano). Na slici 5 je prikazano na primeru sunčane slike ispis rezultata.



Slika 5. Rezultat klasifikacije slike

6. ZAKLJUČAK

Proučavanjem i sagledavanjem različitih karakteristika mašinskog učenja i dubokog učenja stekao sam dublje razumevanje značaja koje će oni imati u budućim informacionim sistemima. Takođe sam uvideo da je veštacka inteligencija nova mlada naučna oblast koja ima potencijala da utiče na skoro sve aspekte modernog sveta.

Preporuka je za sve inženjere i naučnike da se uključe u izazove i upoznaju sa veštackom inteligencijom jer su mogućnosti zaista velike.

7. LITERATURA

- [1] Inductive Programming as Approach to Comprehensible Machine Learning, <http://ceur-ws.org/Vol-2194/schmid.pdf>
- [2] Morgan Kaufmann, "Readings in Machine Learning", California, 1990.
- [3] Novaković, J. (2013). Rešavanje klasifikacionih problema mašinskog učenja. Fakultet tehničkih nauka u Čačku.
- [4] Čugurović, M. (2021). UVOD U MAŠINSKO UČENJE KORIŠĆENJEM PROGRAMSKOG PAKETA ORANGE.
- [5] O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458.
- [6] Xin, Y., Kong, L., Liu, Z., Chen, Y., Li, Y., Zhu, H., ... & Wang, C. (2018). Machine learning and deep learning methods for cybersecurity. Ieee access, 6, 35365-35381.

Kratka biografija:



Srđan Gajić rođen je u Novom Sadu 1992. god. Osnovne studije na Fakultetu tehničkih nauka iz oblasti Industrijsko inženjerstvo – Informaciono-upravljački i komunikacioni sistemi završio je 2017. godine. Master studije Inženjerstvo informacionih sistema završio je 2022. godine.