



OBUČAVANJE DUBOKIH NEURONSKIH MREŽA VOĐENO PROSTOROM ZNANJA KNOWLEDGE SPACE DRIVEN TRAINING OF DEEP NEURAL NETWORKS

Andrej Hložan, Milan Segedinac, *Fakultet tehničkih nauka, Novi Sad*

Oblast – ELEKTROTEHNIKA I RAČUNARSTVO

Kratak sadržaj – *U ovom radu opisan je klasifikacioni problem u oblasti dubokog učenja, kako se taj problem rešava danas i predstavljena je jedna ideja kako bi se rešavanje ovakvog problema moglo unaprediti. Opisan je jedan od najpopularnijih algoritama za optimizaciju veštačkih neuronskih mreža – Stohastički gradijentni pad. Opisana je i implementirana ideja kako bi se ovaj optimizacioni algoritam mogao unaprediti pomoću tehnika iz oblasti Teorije prostora znanja i učenja po Kurikulumu (planu i programu) na osnovu generisanog prostora znanja.*

Ključne reči: Teorija prostora znanja, Učenje po Kurikulumu, Mašinsko učenje, Duboko učenje, Veštačke neuronske mreže

Abstract – This paper describes the classification problem in Deep learning, how it is solved today, and gives an idea how to improve the solution to this kind of problem. One of the most popular algorithms for the optimization of Artificial neural networks, Stochastic gradient descent, is described. An idea was described and implemented so that this optimization algorithm could be improved using the Knowledge Space Theory and the Curriculum learning based on the defined knowledge space.

Keywords: Knowledge space theory, Curriculum learning, Deep learning, Machine learning, Artificial neural networks

1. UVOD

Zbog velikog porasta količine podataka u različitim tipovima informacionih sistema, podataka na internetu i podataka proisteklih naučnim istraživanjima, u poslednjih nekoliko godina došlo je do potrebe i razvoja nauke o podacima (*Data science*). Cilj ove nauke jeste proučavanje velike količine podataka kako bi se izvukle značajne činjenice iz raznih oblasti života i poslovanja.

Ljudi koji se bave ovom naukom se sve više oslanjaju modelima mašinskog učenja iz razloga što je njihov glavni fokus na učenju nad velikim skupovima podataka. Ovi modeli, među kojima su najzastupljeniji modeli na arhitekturama veštačkih neuronskih mreža, danas su vrlo napredni i daju odlične rezultate.

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Milan Segedinac, red. prof.

U ovom radu se opisuje jedna grana mašinskog učenja, vrlo popularna u nauci o podacima, a to je rešavanje klasifikacionih problema. Opisana je i implementirana jedna ideja koja može da doprinese porastu kvaliteta obučavanja veštačke neuronske mreže a samim tim i boljim rezultatima klasifikacije. Osnovna ideja rada jeste implementiranje modela na takav način da simulira način na koji se ljudi usavršavaju u nekoj oblasti, a to je da uče lekcije u redosledu od lakših ka težim. Kako bi se ovo moglo izvesti, neophodno je klase označenih podataka svrstati u određene kategorije po težinama savladavanja. Za implementaciju razvrstavanja, ovaj rad se oslanja na tehnike iz oblasti Teorije prostora znanja.

2. PREGLED RELEVANTNE LITERATURE

Ovaj rad se oslanja na istraživanja sprovedena u naučnom radu [4] gde su autori izvršili poređenje obučavanja modela iste arhitekture sa i bez učenja po kurikulumu. Dve vrste modela su razmatrani: modeli koji rešavaju problem klasifikacije i jezički modeli (procesiranje prirodnog jezika). Dobijeni rezultati pokazuju da učenje po kurikulumu mogu pozitivno da utiču kako na performanse modela tako i na brzinu konvergencije prilikom treniranja. Fascinantni rezultati datog naučnog rada daju inspiraciju za dalje unapređenje optimizacije modela mašinskog učenja.

Kako bismo definisali šta je to dobar plan i program, tj. koje oblasti predstavljaju lake a koje teške za savladavanje, rad se velikim delom oslanja na teoreme i postulate iz Teorije prostora znanja [1]. Tehnike iz ove oblasti su implementirane u KST biblioteci [5] koja se koristi kako bi se generisao prostor znanja konkretnog klasifikacionog problema gde se dobijeni prostor znanja kasnije koristi za obučavanje modela.

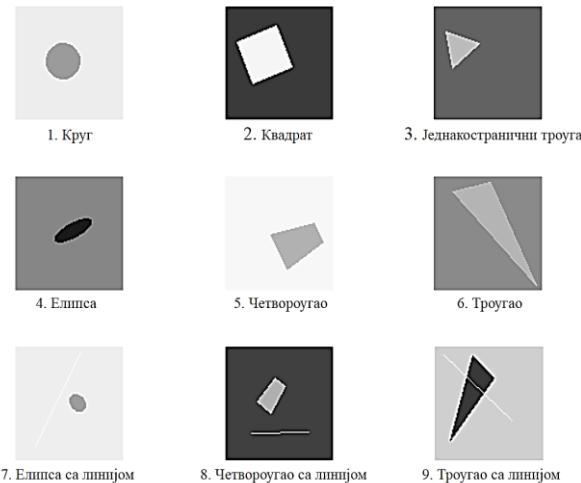
3. ARHITEKTURA SISTEMA

3.1 Skup podataka

Zadatak od interesa u ovom radu jeste klasifikacija geometrijskih oblika u 3 osnovne klase: krug, trougao i četvorougao. Skup podataka koji se koristi se sastoji od programski generisanih crno-belih slika dimenzija 96x96 piksela. Slike predstavljaju geometrijske oblike različitih vrsta. U osnovi su to krug, trougao i četvorougao ali pored toga sadrži i specijalne slučajevе navedenih klasa (slika 1). Stepeni varijabilnosti koji su prisutni u generisanim slikama su:

- Veličina objekta
- Pozicija objekta
- Orientacija objekta
- Boja objekta i boja pozadine

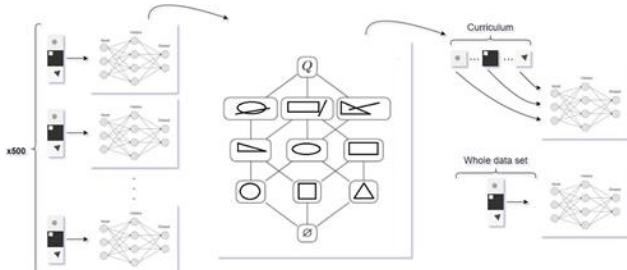
Pored toga, postoje dodatna geometrijska ograničenja prilikom generisanja slika. Ona su prisutna kako bi se osiguralo da bilo koji oblik objekta ceo staje unutar slike i da postoji makar minimalni kontrast i razlika u veličini između pozadine i objekta.



Slika 1: Klase podataka

Podaci su intuitivno podeljeni po težinama. U prvom redu su predstavljeni osnovni oblici: krug, pravilan četvorougao i pravilan trougao. Predpostavka jeste da će ove primere model najlakše moći da savlada. Nakon toga slede nešto teži primeri, tj. zakriviljeni oblici (elipsa, zakriviljeni trougao i zakriviljeni četvorougao). Poslednji i najteži primeri predstavljaju zakriviljene oblike koje sadrže liniju koja predstavlja šum gde je ideja da ovaj šum zasmeta modelu prilikom obučavanja.

3.2 Arhitektura sistema



Slika 2: Arhitektura sistema

Sistem koji rad opisuje se sastoje iz 3 celine:

1) Obučavanje 500 veštačkih neuronskih mreža nad skupom podataka raspoređenih u 9 klasa opisanih u prethodnom delu. Ove mreže su definisane različitim arhitekturama i obučavaju se nasumičnim brojem epoha. Ideja ovih modela jeste simulacija učenika gde su oni u realnosti svi različitih sposobnosti i troše različite vremenske periode za spremanje ispita.

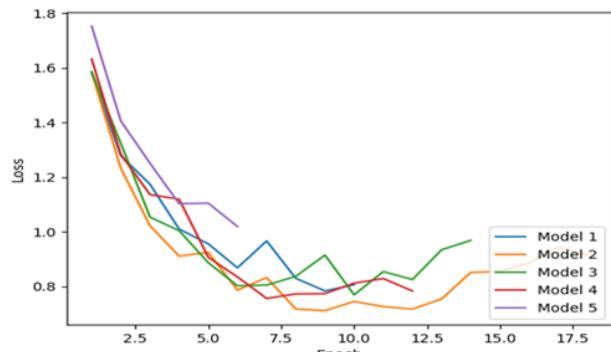
2) Generisanje prostora znanja pomoću obučenih modela (učenika) iz prvog koraka. Svakom modelu se prikazuje po 10 primera svake klase koje do tada model nije video. Ukoliko model pogodi više od 50% prikazanih primera date klase, smatramo da je ona dobro naučila datu klasu. Pomoću ovakvih odgovora generišemo usmereni graf gde čvorove predstavljaju klase geometrijskih oblika a putanje predstavljaju smernicu od lakše klase za učenje ka težoj. Cilj ovako generisanog prostora znanja jeste da nam ukaže redosled klasa po težini savladavanja.

3) Upoređivanje 2 kopije modela iste arhitekture koji je obučavan na 2 načina. Prvo se skup podataka podeli na skup za obučavanje (80%) i skup za validaciju (20%). Prvi model se obučava nad celim skupom za obučavanje sve dok ne dostigne lokalni optimum funkcije greške gde se obučavanje zaustavlja. Drugi model se obučava po planu i programu, tj. redosledom klasa koje definiše prethodno generisani prostor znanja. Oba modela se u toku obučavanja validiraju pomoću validacionog skupa što će nam dati informacije o kvalitetu obučavanja.

4. REZULTATI

4.1 Rezultati obučavanja učenika

Modeli koji predstavljaju učenike se treniraju nad celim skupom podataka gde se za samo treniranje koristi 80% a za validaciju 20% podataka. Na slici 3 je prikazano opadanje funkcije greške 5 nasumično izabranih modela nad validacionim skupom. Primećujemo da različite arhitekture modela utiču na brzinu savladavanja datih klasa. Takođe, samo treniranje je prekidano na nasumičnim mestima kako bismo dobili što veću raznovrsnost učenika. Arhitekture modela i broj iteracija su konfigurisane na takav način da krajnja tačnost modela prelazi 0.55 kako bi modeli bili iskoristivi.



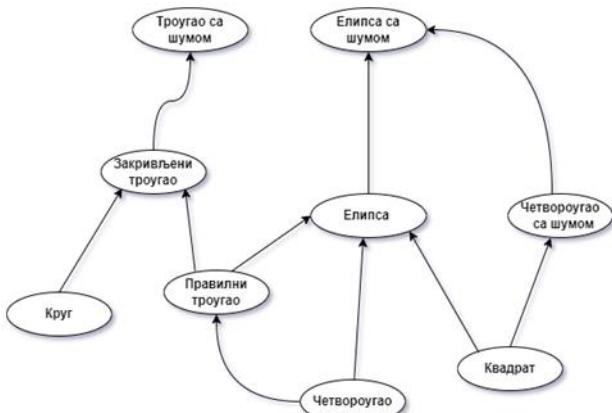
Slika 3: Funkcija greške modela učenika

4.2 Generisani prostor znanja

Obučeni modeli (učenici) dobijaju test od po 10 primera svake klase sa kojima se do tada nisu susreli. Modeli vrše predikcije klasa i pomoću njihovih odgovora se kreira matrica koja daje informacije o tome koji model je savladao koju klasu, a koju klasu nije uspeo da nauči. Ova matrica se dalje predaje KST biblioteci koja generiše usmereni graf gde čvorove predstavljaju klase, a ivice usmerenja od polazne ka rezultujućoj klasi. Ivice pokazuju koju je klasu prethodno potrebno savladati kako bi se mogla savladati sledeća.

Generisani prostor znanja je prikazan na slici 4. Prvo što se uočava iz datih rezultata jeste da početna intuitivna predpostavka o odnosu klasa nije daleko od dobijenih rezultata. Na primer, moglo se predvideti da savladavanju kvadrata i kruga neće prethoditi savladavanje neke druge klase. Takođe, tačna predpostavka je bila da su klase sa šumovima najteže za učenje. S druge strane, ono što se nije predviđeno jeste da je elipsa poprilično teška za savladavanje i da joj prethodi neka od klasa: četvorougao, pravilni trougao ili kvadrat. Zanimljiva posledica takođe jeste da pravilnom trougu prethodi četvorougao. Na osnovu grafa, date klase su podeljene u 3 kategorije:

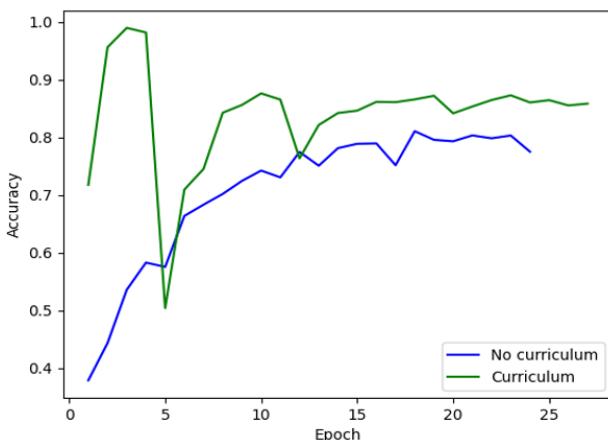
- **Laka:** kvadrat, četvorougao i krug
- **Srednja:** pravilni trougao, elipsa i zakriviljeni trougao
- **Teška:** trougao sa šumom, elipsa sa šumom i četvorougao sa šumom



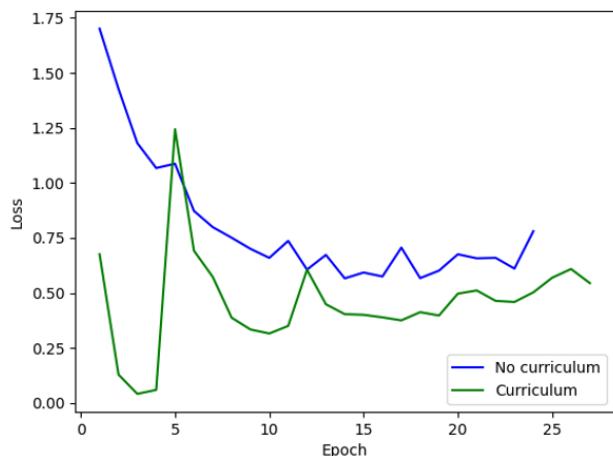
Slika 4: Generisani prostor znanja

4.3 Rezultat učenja modela vodenog prostorom znanja

Na slici 5 je prikazan grafik koji oslikava progres učenja modela na 2 različita načina. Prilikom standardnog obučavanja modela nad celim trening skupom (*No curriculum*) preciznost raste eksponencijalno do određene tačke, tj. epohe 18 gde dostiže svoju maksimalnu preciznost od 0.8107. U datom primeru je modelu dodeljeno strpljenje od 5 epoha u slučaju da preciznost ponovo počne da raste. S druge strane uočavamo drugačije rezultate kada je model obučavan po dobijenom prostoru znanja (*Curriculum*). U prvoj fazi obučavanja u kojoj model uči najlakše primere (kvadrat, četvorougao i krug), preciznost dostiže čak 0.9895 nakon samo 3 iteracija. Pošto u 4. iteraciji preciznost kreće da opada, odmah nastupa sledeća faza gde se skupu dodaju klase srednje težine (pravilni trougao, elipsa i zakriviljeni trougao). Preciznost ove faze je na samom početku 0.5 i samo nakon 6 iteracija dostiže vrednost od 0.8761. Nakon toga se skup proširuje sa najtežim primera (trougao sa šumom, elipsa sa šumom i četvorougao sa šumom). Preciznost u poslednjoj fazi kreće od 0.7636 i nakon 8 epoha dostiže maksimum od 0.8719.



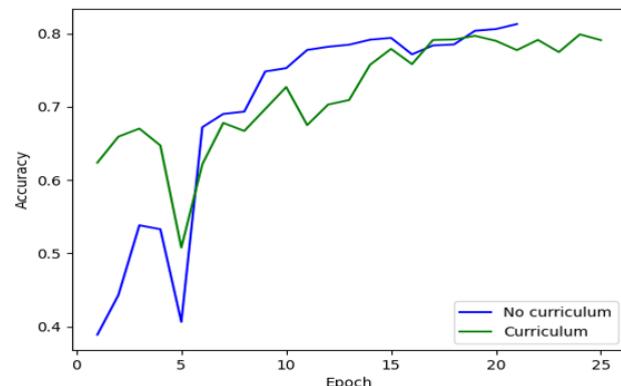
Slika 5: Preciznost finalnog modela



Slika 6: Funkcija greške finalnog modela

4.4 Obrnuti prostor znanja

Kako bismo utvrdili da je razvrstavanje klasa po kategorijama ispravno izvršeno, posmatrano je obučavanje modela iste arhitekture na 2 načina. Prvi način predstavlja klasično obučavanje nad celim trening skupom dok drugi način jeste obučavanje po obrnutom prostoru znanja od generisanog.



Slika 7: Preciznost modela (obrnuti KST)

Na slici 7 je prikazana tačnost obrnutog obučavanja (zelena boja) u odnosu na obučavanje nad celim skupom podataka odjednom (plava boja). Uočavamo da u prvoj fazi, gde model uči samo 3 klase, preciznost kreće da opada već nakon 3. iteracije a pritom je ona dostigla vrednost od 0.6702. U drugoj fazi obučavanja model dostiže preciznost od 0.7269, dok je u poslednjoj fazi maksimalna preciznost 0.7968. Ovo pokazuje da ovakav redosled klasa nije doprineo poboljšanju obučavanja u odnosu na klasičan način obučavanja te da je generisani prostor znanja dao bolje rezultate.

Analizom postignutih rezultata se može zaključiti nekoliko bitnih stavki. Prilikom rešavanja klasifikacionog problema, obučavanje veštačke neuronske mreže vođene prostorom znanja može doprineti poboljšanju preciznosti modela i smanjenju funkcije greške. Čak i nekoliko procenata boljih rezultata može biti od velikog značaja jer se klasifikacioni problem može sresti u raznim sferama života: medicina, procesiranje prirodnog jezika, detekcija prevare, računarska vizija, predviđanje prirodnih nezgoda itd. Drugi zaključak jeste da redosled klasa koje se predstavljaju modelu igra vrlo bitnu ulogu prilikom

obučavanja. Rezultati pokazuju da redosled klasa koji je generisan pomoću tehnika iz Teorije prostora znanja daje znacajno bolje rezultate u odnosu na nasumično odabran redosled klasa. Generisanje prostora znanja pomoći testiranja obučenih veštačkih neuronskih mreža predstavlja samo jedan od načina kako bi se prostor znanja mogao kreirati.

5. ZAKLJUČAK

U ovom radu je opisan klasifikacioni problem u mašinskom učenju i data je jedna ideja kako bi se optimizacija rešavanja ovog problema mogla unaprediti. Osnovna ideja jeste korišćenje tehnika iz oblasti Teorije prostora znanja i učenja po Kurikulumu (planu i programu) prilikom obučavanja veštačke neuronske mreže. Detaljno su opisane definicije iz Teorije prostora znanja koje nam pomažu pri razvrstavanju klasa podataka u kategorije po težinama za učenje. Opisano je kako izgleda duboko učenje danas, koje tehnike se koriste i dat je jedan od najpopularnijih algoritama za optimizaciju parametara veštačke neuronske mreže. Opisan je jedan od načina za usavršavanje učenika u dатој области под називом Учење по Kurikulumu. Ideja rada jeste da se iskoristi prostor znanja kao nešto što definiše redosled oblasti po težini i učenje po plan i programu kako bi simulirali način na koji ljudi stvarno uče, a to je usavršavanje oblasti od lakših ka težim.

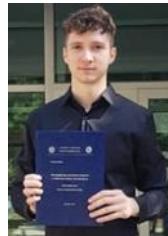
Prostor znanja u ovom radu je dobijen pomoću odgovora na test od strane simuliranih učenika. Učenici su implementirani pomoću neuronskih mreža koje se obučavaju nad datim generisanim skupom podataka koje u osnovi predstavljaju slike geometrijskih oblika. Nakon generisanog prostora znanja, finalni model se obučava datim prostorom znanja i rezultati su upoređeni sa rezultatima modela iste arhitekture koji se obučavao nad celim skupom podataka odjednom. Na osnovu dobijenih rezultata, možemo zaključiti da prostor znanja i učenje po Kurikulumu mogu doprineti poboljšanju rešavanja klasifikacionih problema. U ovom radu se pokazalo da ova vrsta obučavanja daje za oko 6% bolju tačnost i za oko 0.19 manju grešku. Pored toga, pokazalo se da je dobijeni prostor znanja ispravan jer su obučavanja istog modela ali drugaćijim redosledom klasa dali gore rezultate.

Sledeći korak u unapređenju sistema i potencijalno pronađenje globalnog optimuma optimizacione funkcije jeste korišćenje neuroevolutivnih algoritama. Ovi algoritmi predstavljaju kombinaciju algoritama mašinskog učenja i evolutivnih algoritama s ciljem da se generiše veštačka neuronska mreža sa optimalnom arhitekturom za specifičan problem. Veštačke neuronske mreže se koriste kao model učenja, dok se evolutivni algoritmi koriste kao optimizacione funkcije. Ideja bi bila da se generiše prostor znanja za određeni klasifikacioni problem i nakon toga iskoristi dobijena optimalna arhitektura mreže koja rešava takav problem, obučava po planu i programu generisan pomoću tehnika Teorije prostora znanja. Ovakva arhitektura bi potencijalno mogla da doprinese još boljim rezultatima iz razloga što se ne bi optimizovali samo parametri neuronske mreže, već i sama arhitektura mreže (broj slojeva mreže, broj čvorova u slojevima mreže, konekcije između čvorova).

6. LITERATURA

- [1] Jean-Claude Falmagne, Jean-Paul Doignon: “*Learning Spaces*”, 2011.
- [2] Christina Stahl, Cord Hockemeyer: “*Knowledge Space Theory*”, 2022.
- [3] Yoshua Bengio, Ian Goodfellow, Aaron Courville: “*Deep learning*”, 2015.
- [4] Yoshua Bengio, Jerome Louradour, Ronan Collobert, Jason Weston: “*Curriculum learning*”, 2009.
- [5] Milan Segedinac:
<https://github.com/milansegedinac/kst>, 2023.

Kratka biografija:



Andrej Hložan rođen je u Novom Sadu 1998. god. Master rad na Fakultetu tehničkih nauka iz oblasti Elektrotehnike i računarstva – Elektronsko poslovanje održan je 2023.god.
kontakt: hlozanandrei@gmail.com