



## PRIMENA METRIČKOG UČENJA U POLJOPRIVREDI APPLICATION OF METRIC LEARNING IN AGRICULTURE

Tomislav Tumbas, *Fakultet tehničkih nauka, Novi Sad*

### Oblast – ELEKTRONIKA ENERGETIKA I TELEKOMUNIKACIJE

**Kratak sadržaj** – *U ovom radu prikazujemo primenu metričkog učenja i mogućnost lakog skaliranja na nove klase bez potrebe za ponovnim obučavanjem u oblasti poljoprivrede, na klasifikaciji vrste cveća, vrste lista biljaka i bolesti lista biljaka.*

**Ključne reči:** Metričko učenje, mašinsko učenje

**Abstract** – *In this paper, we show the application of metric learning and ability to easily scale to new classes without the need for retraining in the field of agriculture, on the classification of flower types, plant leaf types and plant leaf diseases.*

**Keywords:** metric learning, machine learning

### 1. UVOD

Mašinsko učenje se uspešno primenjuje u različitim oblastima industrije. Prvi primeri mašinskog učenja bili su u obradi tabelarnih podataka u ekonomiji i bankarstvu. Napredovanjem grafičkih kartica ispunio se preduslov da se i računarska vizija primenom dubokog mašinskog učenja uspešno primeni na razne probleme u industriji.

Danas se duboko mašinko učenje u računarskoj viziji uspešno primenjuje u mnogim granama industrije, od izrade automobila i autonomne vožnje do detekcije loše izrađenih komponenti u mašinskoj industriji.

Jedan od oblasti koja zaostaje za ostatkom industrije je poljoprivreda. U skladu sa time, tema ovog rada je primena metričkog dubokog učenja na problem klasifikovanja vrste cveća, klasifikovanje vrste lista biljaka i bolesti biljaka.

### 2. NADGLEDANO UČENJE

Nagledano učenje je pod grana mašinskog učenja gde su na jednom delu podataka poznati ulazi i izlazi datog problema. Ulazni i izlazni podaci se obično predstavljaju vektorski kao  $x$  i  $y$ . Potrebno je ustanoviti relaciju između ulaza i izlaza. Nakon što ustanovimo ovu relaciju ona se koristi za predviđanja izlaza  $y$  za ulazne podatke  $x$  za koji nam nije unapred poznat izlaz  $y$ .

#### 2.2 Metričko učenje

Jedan od najneverovatnijih aspekata ljudskog vizuelnog sistema jeste sposobnost prepoznavanja sličnih objekata i

#### NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio prof. dr Rastislav Struharik.

scena. Ne trebaju nam stotine fotografija istog lica da bismo mogli da ga razlikujemo od hiljada drugih lica koja smo videli. Da li je moguće dizajnirati duboku neuronsku mrežu sa sličnom sposobnošću da kaže koji su objekti vizuelno slični, a koji nisu? To je u suštini ono što duboko metričko učenje pokušava da reši, da kaže na osnovu neke metrike šta je slično a šta nije.

Metričko učenje pojavljuje se 2002 godine u radu Ksinga (eng. Ksing) [4].

Metričko učenje na daljinu (ili jednostavno, metričko učenje) ima za cilj automatsko konstruisanje metrike rastojanja (odnosno sličnosti) specifične za dati zadatak iz (slabo) nadziranih podataka, uz pomoć mašinskog učenja. Naučena metrika se tada može koristiti za obavljanje različitih zadataka (npr. K-NN klasifikacija, grupisanje, ekstrakcija informacija).

Metrički problemi učenja dele se u dve glavne kategorije u zavisnosti od vrste nadzora nad podacima korišćenim za obuku:

1. Nadgledano učenje: algoritam ima pristup skupu tačaka podataka, od kojih svaka pripada određenoj klasi (oznaci), kao u standardnom problemu klasifikacije. Uopšteno govoreći, cilj u ovakvoj postavci je naučiti metriku udaljenosti koja tačke sa istom oznakom približava zajedno, dok razdvaja tačke sa različitim oznakama.

2. Slabo nadgledano učenje: algoritam ima pristup skupu tačaka podataka sa nadzorom samo na nivou parova (tipično parovi, trojke ili četvorke tačaka podataka). Klasičan primer takvog slabijeg nadzora je skup pozitivnih i negativnih parova: u ovom slučaju cilj je naučiti metriku udaljenosti koja stavlja pozitivne parove blizu jedne, a negativne parove daleko.

Na osnovu gore navedenih (slabo) nadziranih podataka, problem metričkog učenja je generalno formulisan kao problem optimizacije gde se traže parametri funkcije udaljenosti koji optimizuju neku ciljnu funkciju mereći slaganje sa podacima u obuci.

Velika prednost metričkog učenja u odnosu na klasifikaciju se nalazi u tome što metričko učenje ima mogućnost da radi na klasama koje nisu viđene u procesu obučavanja duboke neuronske mreže.. Metričko učenje može da razlikuje  $N$  klasa koje su viđene u toku obučavanja i dodatnih  $M$  klasa koje nisu viđene u procesu obučavanja.

### 3. OBUČAVANJE MODELA

Tok obučavanja modela obuhvata pripremu i podelu podataka, definisanje funkcije greške (funkcije cilja), definisanje modela i konačno obučavanje modela. Model

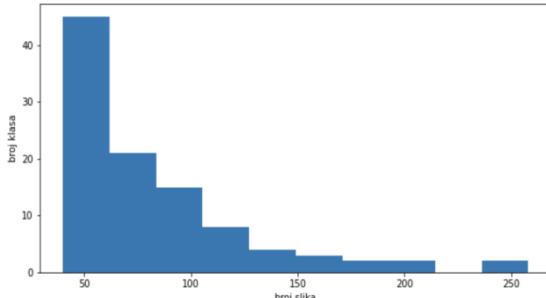
se obučava minimalizacijom greške između predviđanja modela i stvarnih vrednosti ciljne promenjive.

### 3.1. Podaci

#### 3.1.1 Flower skup podataka

Flower skup podataka sadrži slike različitih tipova cveća.

Broj slika po klasi se kreće od 40 do 258 sa srednjom vrednošću od 88,284 i standardnom devijacijom od 44,059.



Slika 1. Histogram slika po klasi

Podatke delimo u dve grupe, vrste cveća koje će biti viđene tokom treninga i vrste cveća koje neće biti viđene tokom treninga.

	Procent a klasi	Srednja vrednost broja slika po klasi	Standardna devijacija broja slika po klasi	Minimalna vrednost broja slika po klasi	Maksimalna vrednost broja slika po klasi
Viđena grupa	78.43	79.63	40.47	40	251
Neviđena grupa	21.56	82.63	55.09	40	258

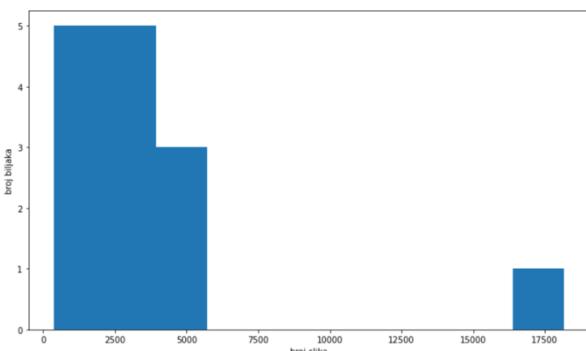
Tabela 1. podela Flower skupa podataka

Viđena grupa se deli po klasi na trening i validaciju u odnosu 80% i 20%.

#### 3.1.2 PlantVillage skup podataka

PlantVillage skup podataka sadrži slike listova biljaka i od svake vrste biljaka par pod klase koje predstavljaju bolest lista biljke.

Srednja vrednost broja slika po klasi je 3878,92 sa standardnom devijacijom od 4195,47.



Slika 2. Histogram slika po klasi

Podaci su podeljeni u viđenu i neviđenu grupu. U neviđenoj grupi nalaze se tri biljke sa svim svojim podgrupama.

	Broj biljaka	Broj podgrupa	Broj slika
Viđena grupa	3	8	8049
Neviđena grupa	11	30	46256

Tabela 2. podela PlantVillage skupa podataka

### 3.2. Funkcija cilja

Mnogi nedavni pristupi metričkom učenju zasnovani su parovima uzoraka. Njihove funkcije cilja mogu se izraziti preko kosinuse sličnosti u prostoru embeddinga. Ovu grupu metoda nazivano dubokim metričkim učenjem zasnovanim na parovima. Tu ubrajamo: kontrasne funkcije cilja, funkcija cilja tripleta, funkciju cilja četvorke, funkciju cilja N parova, funkcije cilja binomske devijacije, funkcije cilja ugla, funkcije cilja hijerarhijske trojke itd.

U svim ovim pristupima, trening uzorci se slažu u parove, trojke, četvorke ili n-torce rezultujući postojanjem polinomijalno rastućeg broja n-torki za obučavanje od kojih su mnoge redundantne ili korelisane te manje informativne za obučavanje duboke neuronske mreže. Ovo dovodi do ključnog pitanja za metode zasnovane na parovima, gde obuka sa slučajnim uzorkovanjem može biti preplavljenia redundantnim parovima, što dovodi do spore konvergencije i degeneracije modela sa lošijim performansama.

Jedna od pokušaja da se ovaj problem spore konvergencije reši jeste funkcija cilja više sličnosti (eng. Multisimilarity loss) (Wang, Han, Huang, Dong, Scot 2020 [3]) koji odabira teške uzorke u procesu obučavanja.

#### 3.2.1 Biranje parova

Za jedan primer biramo pozitivan i negativan par. Primer za koji biramo pozitivan i negativan par nazivamo sidro.

Pozitivni parovi:

$$S_{ij}^- > \min_{y_k = y_i} S_{ik} - \epsilon \quad (4)$$

Samo oni negativni parovi treba da budu uključeni u obuku čija je sličnost sa sidrom veća od minimalne sličnosti pozitiva (pozitiva koja leži najdalje u embedding prostoru) treba da budu uključeni u obuku, a ostali se odbacuju.

Negativni parovi:

$$S_{ij}^+ < \min_{y_k \neq y_i} S_{ik} + \epsilon \quad (5)$$

Samo oni pozitivi parovi čija je sličnost sa sidrom manja od maksimalne sličnosti negativa (negativ leži najbliže sidru) treba da budu uključeni u obuku, dok se ostali odbacuju.

### 3.2.2 Funkcija cilja više sličnosti

$$L_{ms} = \frac{1}{m} \sum_{i=1}^m \left\{ \frac{1}{\alpha} \log \left[ 1 + \sum_{k \in P_i} e^{-\alpha(s_{ik} - \lambda)} \right] + \frac{1}{\beta} \log \left[ 1 + \sum_{k \in N_i} e^{-\beta(s_{ik} - \lambda)} \right] \right\} \quad (6)$$

Gde su:

$P_i$  - pozitivni parovi

$N_i$  - negativni parovi

$s_{ik}$  – kosinusna distanca između parova

$\lambda$  – margina sličnosti

$\alpha, \beta$  – hiperparametri

### 3.3 Ciklični koeficijent obučavanja

Ciklični koeficijent obučavanja je tehnika podešavanja koeficijenta obučavanja tokom treninga obavljena u radu Smita (eng. Smith) 2017 godine [2]. Pre samog obučavanja neuronske mreže radi se pronalazak maksimalnog i minimalnog koeficijenta obučavanja.

Motivacija i ideja cikličnog rasporeda koeficijenta obučavanja je da povećanje koeficijenta obučavanja može kratkotrajno doneti negativne efekte ali dugotrajno pozitivne.

Kratkoročni negativan efekat prestavlja napuštanje lokalnog minimuma što zahteva pogoršavanje kvaliteta mreže.

Nakon kratkoročnog pogoršanja mreža može da nastavi ka globalnom minimumu što predstavlja dugotrajno poboljšanje.

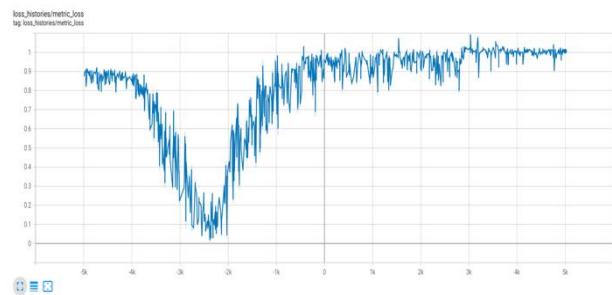
#### 3.3.1. Pronalazak minimalnog i maksimalnog koeficijenta obučavanja

Koeficijent učenja se prvo postavi na veoma malu vrednost (na primer 1e-10). Pokrene se obučavanje mreže, nakon svake iteracije slika koeficijent obučavanja se eksponencijalno povećava.

Za dati niz koeficijent obučavanja posmatramo izlaz funkcije cilja. Vrednost izlaza funkcije cilja će na početku da stagnira. U ovom trenutku koeficijent obučavanja još nije dovoljno porastao da bi neuronska mreža krenula da se obučava.

U nekom trenutku vrednost izlaza funkcije cilja kreće da opada. Koeficijent obučavanja je porastao dovoljno i proces obučavanja neuronske mreže je započeo. Neuronska mreža se obučava i vrednost izlaza funkcije cilja nastavlja da opada do trenutka kada kreće eksponencijalno da raste. Koeficijent obučavanja je previše porastao.

Koeficijent obučavanja u trenutku kada vrednost izlaza funkcije cilja kreće da opada predstavlja minimalni koeficijent obučavanja. Koeficijent obučavanja u trenutku kada vrednost izlaza funkcije cilja kreće da raste predstavlja maksimalni koeficijent obučavanja.



Slika 3. Vrednost izlaza funkcije cilja tokom određivanja maksimuma i minimuma koeficijenta obučavanja

#### 3.3.2. Ciklični raspored koeficijenta obučavanja

Logika cikličnog rasporeda koeficijenta obučavanja je sledeća:

$$\text{ciklus} = \text{math.floor}(1 + \text{brojač-epohe} / (2 * \text{veličina-ciklusa})) \quad (1)$$

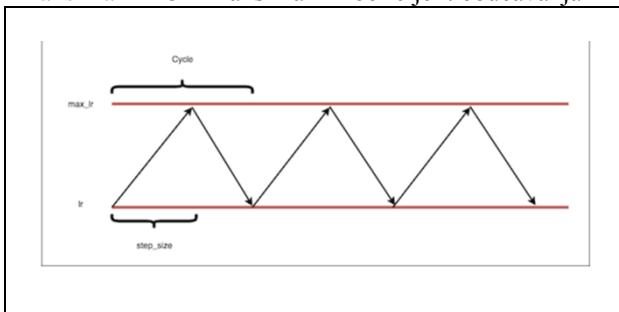
$$x = \text{math.abs}(\text{brojač-epohe} / \text{veličina-ciklusa} - 2 * \text{ciklus} + 1) \quad (2)$$

$$\text{koeficijent-obučavanja} = \text{minimalniKO} + (\text{maksimalniKO} - \text{minimalniKO}) * \text{math.max}(0, (1-x)) \quad (3)$$

Gde su:

minimalniKO – minimalni koeficijent obučavanja

maksimalniKO – maksimalni koeficijent obučavanja



Slika 4. Izgleda cikličnog koeficijenta obučavanja

### 3.4. Model

Za model neuronske mreže korišten je ResNet50 (eng. Residual Neural Networks) razvijenog od strane Majkrosoft istraživačkog departmana 2015 godine [1].

ResNet modeli uvode residualne skip konekcije koje sprečavaju efekat nestajućeg gradijenta (eng. Vanishing gradient) i omogućuju lakše učenje identifikacionih funkcija.

## 4. REZULTATI

### 4.1 Flower skup podataka

	Preciznost pri 1	Srednja prosečna preciznost
Viđeni primeri – trening	0.9957	0.9810
Viđeni primeri – validacija	0.9613	0.9162
Neviđeni primeri	0.9521	0.9048

Tabela 3. Rezultati na Flower skupu podataka

Prikazani rezultati su komparabilni sa najboljim klasifikacionim pristupima. Razlika između viđenog validacionog dela i neviđenog dela je veoma mala što nam govori da je ovaj model sposoban da radi na klasam koje nije video u treningu, što je jedna od glavnih prednosti metričkog učenja u odnosu na klasifikacione pristupe.

### 4.2 PlantVilage skup podataka

	Preciznost pri 1	Srednja prosečna preciznost
Viđeni primeri – trening	0.9998	0.9997
Viđeni primeri – validacija	0.9963	0.9950
Neviđeni primeri	0.9847	0.9431

Tabela 4. Rezultati na PlantVilage skupu podataka

Kao i kod prethodnog skupa podataka, rezultati su komparabilni sa najboljim klasifikacionim pristupima.

Nešto veća razlika je između validacije viđenog dela i neviđenog dela. Iz ovoga vidimo da ovaj model ne generalizuje dobro kao Flowers model. Ovo je moguće da se dešava iz više razloga:

1. Ceo skup podataka nema dovoljno primera da se napravi dovoljno dobra generalizacija
2. Nije urađena dobra podela na viđeni i neviđeni deo.
3. Regularizacija nije dovoljna ili je mreža prevelika i ipak dolazi do blagog pre-prilagođavanja na viđeni deo skupa podataka

Svakako, rezultati i dalje pokazuju da je model u stanju da radi i na klasama koje nije video u treningu.

## 5. ZAKLJUČAK

U mnogim realnim primenama veštačke inteligencije, broj klasa koje model treba da razlikuje i klasifikuje skoro

nikada se neće videti u procesu obučavanja. U slučaju poljoprivrede, vrste biljaka, bolesti biljaka, jako često će se pojavljivati nova klasa zbog koje bi se klasifikacioni model morao ponovo obučavati.

Ponovno obučavanje sa novom klasom zahteva skupljanje novih podataka, anotiranje i ponovno obučavanje modela. Anotiranje podataka je veoma dug i zahtevan proces. Anotacije nikada nisu u potpunosti tačne što znači da je potreno primenjivati neke metode automatskih detekcija grešaka i ručno ispravljati greške. Ovo je veoma skup proces koji zahteva puno resursa i vremena. U mnogim slučajevim ovo nije ni moguće uraditi jer ne postoji dovoljno podataka niti resursa za anotiranje.

Bez dodatnog prikupljanja podataka, anotiranja i celog skupog procesa, metričko učenje može da uspešno prepozna nove klase. Novi podaci se automatski klasteruju pomoću postojećih algoritama za klasterovanje. Na primeru bolesti biljaka, klasterovanjem bi se mogli odrediti klasteri zasebnih biljaka i unutar njih manji klasteri bolesti tih biljaka.

Dobijeni rezultati na oba skupa podataka pokazuju da se ovaj pristup može koristiti kako na klasama koje su viđene u procesu obučavanja tako i na podacima koji pripadaju klasama koje nisu viđene u treningu.

## 6. LITERATURA

- [1] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun: Deep Residual Learning for Image Recognition, Microsoft Research, arXiv:1512.03385, 2015.
- [2] Leslie N. Smith: Cyclical Learning Rates for Training Neural Networks, U.S. Naval Research Laboratory, arXiv: 1506.01186, 2017.
- [3] Xun Wang, Xintong Han, Weilin Huang\*, Dengke Dong, Matthew R. Scott: Multi-Similarity Loss with General Pair Weighting for Deep Metric Learning, Malong Technologies, Shenzhen, China, arXiv: 1904.06627, 2022
- [4] Eric P. Xing, Andrew Y. Ng, Michael I. Jordan, and Stuart J. Russell: Distance Metric Learning with Application to Clustering with Side-Information, Advances in Neural Information Processing Systems (NIPS) 15, pages 505–512, 2002.

## Kratka biografija:



**Tomislav Tumbas** rođen u Subotici 1992 god. Master rad na Fakultetu tehničkih nauka iz oblasti Elektrotehnike i računarstva – Embedded sistema i algoritama odbranio je 2022.god.

kontakt: tumbas.tomislav@gmail.com