

Usporedba postupka klasifikacije tekstilija primjenom *Weka* i *Orange Data Mining* programskih paketa

Selma Imamagić¹, Tomislav Rolich¹, Željko Penava¹

¹Sveučilište u Zagrebu Tekstilno-tehnološki fakultet, Prilaz baruna Filipovića 28a, 10000 Zagreb

Sažetak: Rad se temelji na usporedbi postupka klasifikacije digitalnih slika tekstilnih plošnih proizvoda u programskim paketima *Weka* i *Orange Data Mining*. Za navedenu svrhu su provedena dva pokusa. U prvom pokusu su relevantne značajke izdvojene metodom filtracije (CLF, EHF, FCTHF, GF i SCHF filteri) dok su u drugom pokusu za te svrhe korištene konvolucijske neuronske mreže (Google Inception v3, SqueezeNet). U oba pokusa su primijenjeni isti klasifikatori (Tree, SVM, Random Forest, Naive Bayes, Logistic Regression i Neural Network). Rezultati provedenih pokusa praćeni su kroz postotak ispravno klasificiranih digitalnih slika. Veći postotak ispravno klasificiranih digitalnih prikaza postignut je u drugom pokusu za sve klasifikacijske modele što ukazuje na superiornost metode dubokog učenja prilikom izdvajanja relevantnih značajki. Najbolji rezultat klasifikacije (95,52 %) postignut je kombinacijom Inception v3 mreže i Neural Network klasifikatora.

Ključne riječi: klasifikacija, *Weka*, *Orange Data Mining*, filtracija, konvolucijske neuronske mreže

1. Uvod

Strojno učenje je grana umjetne inteligencije usmjerena na razvoj algoritama sposobnih za “učenje” obrazaca ponašanja određene skupine podataka. Cilj spomenutog “učenja” jest izgradnja modela kojim će se na temelju naučenih obrazaca ponašanja moći donositi predviđanja i zaključci o novom, algoritmu nepoznatom skupu podataka.

Jedno od područja primjene strojnog učenja jest klasifikacija podataka. Cilj je izgraditi prediktivni model, tzv. klasifikator kojim se predviđaju diskretne vrijednosti, tj. pripadnost podatka određenoj klasi [1, 2]. Budući da svaki podatak ima unaprijed poznatu klasu kojoj pripada, problem klasifikacije spada u nadzirano učenje (engl. *Supervised Learning*). S tim u vezi, ulazni podaci prilikom izgradnje klasifikatora

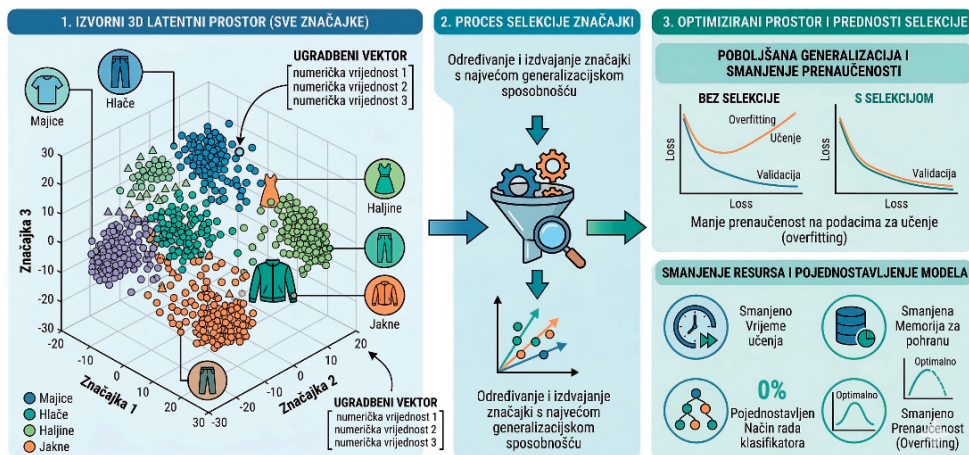
podijeljeni su u dva skupa podataka. Prvi skup namijenjen je “učanju algoritma” (engl. *learning step*) na skupu podataka za učenje (engl. *training set*) gdje se algoritam “uči” pridruživanju primjera podataka pripadajućim klasama [3-5]. Pritom se gradi predikcijski model – klasifikator [3, 5]. Drugi skup naziva se ispitnim skupom (engl. *test set*) i koristi se isključivo za provjeru točnosti izgrađenog klasifikatora, ne i za njegovo učenje [3-5]. Na temelju rezultata ispitnog skupa vrednuje se generalizacijska sposobnost modela, primarno kroz parametar točnosti klasifikacije (engl. *accuracy*), ali i kroz preciznost (engl. *precision*), odaziv (engl. *recall*) i F1-vrijednost. Cilj ovog rada je usporediti učinkovitost dviju metoda izdvajanja značajki – filtracije i konvolucijskih neuronskih mreža – u postupku klasifikacije digitalnih slika tekstilnih plošnih proizvoda primjenom programskih paketa Weka i Orange Data Mining.

2. Odabir relevantnih značajki primjera podataka

U prostoru primjera podataka svaki podatak predstavljen je ugradbenim vektorom (engl. *embedding*) u latentnom prostoru, Slika 1 [1]. Broj dimenzija latentnog prostora odgovara broju značajki primjera podatka (engl. *features*) koje ga karakteriziraju. Pritom svaka točka ugradbenog vektora odgovara numeričkoj vrijednosti određene značajke [1]. Cilj je prije postupka klasifikacije odrediti i izdvojiti one značajke primjera kojima će se postići što veća generalizacijska sposobnost klasifikatora. Dodatno, postupkom selekcije značajki smanjuje se: prenaučenosť klasifikatora na podacima za učenje (engl. *overfitting*), vrijeme učenja algoritma, potrebna memorija za pohranu podataka te pojednostavljuje način rada klasifikatora [6].

Slika 1 prikazuje primjer vizualizacije latentnog prostora. Iako se prikazani primjer temelji na zvučnim podacima, on jasno ilustrira princip rada strojnog učenja prema kojem se podaci sličnih značajki u latentnom prostoru nalaze u međusobnoj blizini, što je temelj za klasifikaciju digitalnih slika tekstilnih plošnih proizvoda analiziranih u ovom radu.


POBOLJŠANJE GENERALIZACIJE KLASIFIKATORA ODJEĆE SELEKCIJOM ZNAČAJKI IZ 3D LATENTNOG PROSTORA



Slika 1: Vizualizacija latentnog prostora podataka [7]

2.1. Filtri

Selektiranje značajki primjera uporabom filtera temelji se na rangiranju značajki s obzirom na njihov utjecaj na uspješnost klasifikacije. Rangiranje se odvija primjenom različitih statističkih metoda, primjerice mjera raspršenosti (varijanca, standardna devijacija, raspon), Hi-kvadrat testa, korelacijske analize ili ANOVA metode [8]. Značajke koje se procjene da sadrže važnije informacije prema statističkoj metodi za dani klasifikacijski problem bit će izdvojene kao korisne, dok će one s najmanjom biti eliminirane i neće se koristiti kod izgradnje latentnog prostora. Postupak odabira značajki filtriranjem primjenjuje se u fazi predobrade podataka, prije izgradnje klasifikatora [9]. Neovisnost o postupku izgradnje klasifikatora i oslanjanje isključivo na svojstva značajki smanjuje vjerojatnost prenaučenoosti klasifikatora na podacima za učenje te čini ovu metodu brzim i efikasnim načinom uklanjanja nepotrebnih značajki primjera, posebice pogodnu za velike skupine primjera podataka.



GF

[10.420364,0.039542,10.423867,0.039555,10.423867,0.039555,10.420364,0.039542,10.423867,0.039555,10.423867,0.039555,10.768928,0.040865,10.772548,0.040878,10.772548,0.040878,10.768928,0.040865,10.772548,0.040878,10.772548,0.040878,10.758971,0.040827,10.762587,0.04084,10.762587,0.04084,10.758971,0.040827,10.762587,0.04084,10.762587,0.04084,10.730758,0.04072,10.734365,0.040733,10.734365,0.040733,10.730758,0.04072,10.734365,0.040733,10.734365,0.040733,10.650555,0.040415,10.654135,0.040429,10.654135,0.040429,10.650555,0.040415,10.654135,0.040429,10.654135,0.040429,knitwear]

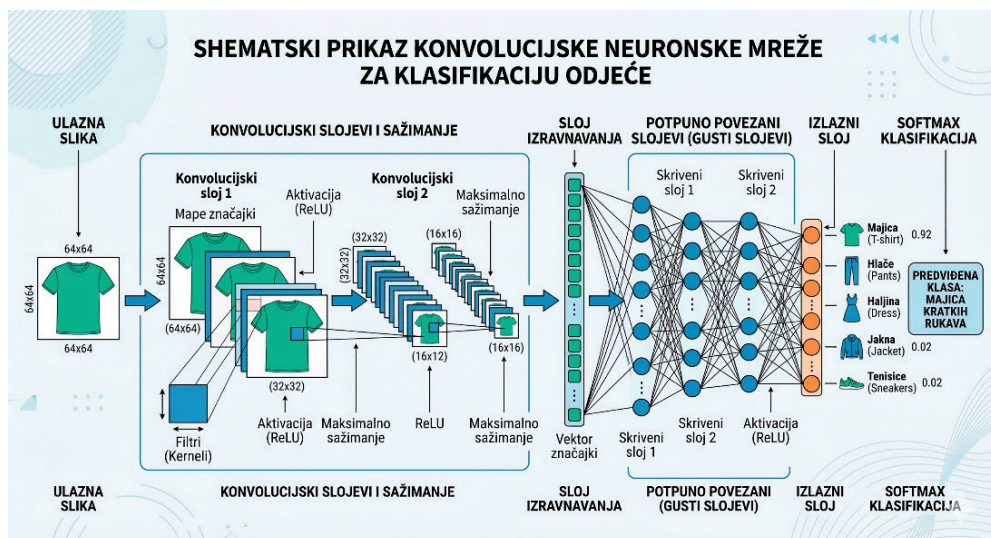
Slika 2: Prikaz pletiva nakon selektiranja značajki *GaborFilter*-om [4]

Ograničenje ove metode jest zanemarivanje međusobne ovisnosti i interakcije značajki, što može rezultirati zadržavanjem redundantnih informacija koje ne doprinose diskriminativnoj moći modela.

2.2. Konvolucijske neuronske mreže

Neuronske mreže pripadaju algoritmima strojnog učenja inspiriranim kompleksnom strukturom ljudskog mozga [10, 11]. Sastoje se od više uzastopnih slojeva međusobno povezanih čvorova ili neurona koji provode nelinearne transformacije podataka velikih dimenzionalnosti. Svaki sloj izvodi jednostavnu matematičku operaciju na svom ulazu i prosljeđuje rezultat sljedećem sloju [10]. Jedan od modela neuronskih mreža su konvolucijske neuronske mreže (engl. *Convolutional Neural Network*, CNN) namijenjene klasifikaciji podataka i računalnom vidu [12].

Konvolucijske neuronske mreže sastoje se od konvolucijskog sloja, sloja sažimanja i izlaznog sloja, Slika 3.



Slika 3: Način rada konvolucijske neuronske mreže na primjeru klasifikacije odjeće [7]

Konvolucijski sloj (engl. *convolutional layer*) obrađuje ulazne podatke i izdvaja značajke istih. Sastoji se od niza filtera (nazvanih jezgrom) kojima se postupkom konvolucije, tj. unakrsnom korelacijom djeluje na ulazne podatke te stvaraju mape značajki ključne za danju obradu. Konvolucijom ostaju sačuvani prostorni odnosi između piksela slike, a veličina mapa značajki odgovara veličini korištenih jezgri [10].

Sloj sažimanja (engl. *pooling layer*) smanjuje prostornu veličinu mapa značajki na ulazu u jednu značajku na izlazu iz sloja [13]. Sažimanje se odvija primjenom statističkih pokazatelja, primjerice odabirom maksimalne ili prosječne vrijednosti značajke. Navedenim se smanjuje potrebna memorija za pohranu te sprječava prenaučenosť modela na podatke za učenje [13].


Izlazni sloj (engl. *fully connected layer*) služi kao posljednji sloj sažimanja u neuronskoj mreži. On preuzima izdvojene značajke primjera i prosljeđuje ih klasifikatoru [11].

3. Materijali i metodologija

3.1. Materijali

Istraživanje je provedeno na skupu digitalnih slika tekstilnih plošnih proizvoda dobivenih skeniranjem stvarnih uzoraka iz tekstilne industrije. Skeniranje tekstilnih uzoraka provedeno je pomoću plošnog skenera Canon CanoScan LiDE 400 pri razlučivosti od 300 dpi. Svi tekstilni uzorci skenirani su u kontroliranim uvjetima, čime je osigurana standardizacija ulaznih podataka.

Skup podataka obuhvatio je ukupno 5173 skenirana uzoraka, koji su podijeljeni u pet osnovnih klasa prema vrsti tekstilne strukture: čipke, netkani tekstil, pletivo, tepisi i tkanine, Slika 4.



Slika 4: Primjeri skeniranih pet klasa tekstilnih plošnih proizvoda: a. čipka, b. netkani tekstil, c. pletivo, d. tepih, e. tkanina

U skupu podataka korištenom u istraživanju analizirano je 421 uzorak čipki, 2207 uzoraka netkanog tekstila, 524 uzorka pletiva, 644 uzorka tepiha te 1377 uzoraka tkanina, Tablica 1.

S obzirom da je uzet neravnomjeran broj slika tekstilnih plošnih proizvoda po klasama, u analizu rezultata bit će uvedene metričke vrijednosti preciznosti, odaziva i F1-vrijednosti. Time će se spriječiti moguća pojava pristranosti klasifikatora.

Tablica 1: Tekstilni plošni proizvodi korišteni u istraživanju, njihov opis i broj slika primjera [14]

Tekstilni plošni proizvod	Opis	Broj slika
čipka	Čipke predstavljaju rupičaste tekstilne plošne proizvode namijenjene ukrašavanju odjeće, posteljnog i stolnog rublja te za unutrašnje uređenje prostora stanovanja.	421
netkani tekstil	Netkani tekstil predstavlja posebnu skupinu tekstilnih plošnih proizvoda koji se mogu izrađivati različitim proizvodnim tehnikama, najčešće sjedinjavanjem tekstilnih vlakana u funkcionalnu plošnu tvorevinu. Karakterizira ih relativno velika nejednolikost strukture iz koje proizlazi nejednolikost raznih svojstava, naročito debljine, površinske mase i čvrstoće.	2207
pletivo	Pletiva su tekstilni plošni proizvodi načinjeni od očica nastalih od jedne ili više niti, odnosno više sustava niti, prema pravilima određene vrste prepleta. Strukturu pletiva čine uzdužni nizovi i poprečni redovi očica, čime se formira karakteristična elastična plošna tvorevina.	524
tepih	Tepisi, odnosno podni prostirači, predstavljaju tekstilne plošne proizvode namijenjene oblaganju podova. Pojavljuju se kao metražna roba ili komadni proizvodi. Njihova se struktura u pravilu sastoji od vlasaste površine (flora) po kojem se hoda tijekom upotrebe te podloge koja osigurava mehaničku stabilnost, dimenzijsku postojanost i potrebnu čvrstoću proizvoda.	644
tkanina	Tkanine su tekstilni plošni proizvodi dobiveni postupkom tkanja, pri čemu se odlikuju plošnim oblikom s izraženim dimenzijama duljine i širine, dok je debljina u odnosu na njih znatno manja. Struktura tkanina sastoji se od dvaju sustava niti – osnove i potke – koje se međusobno isprepliću pod pravim kutom prema unaprijed definiranim pravilima tkanja. Ovakav način povezivanja niti ostvaruje se procesom tkanja na tkalačkom stanu te rezultira pravilnom i ponavljajućom strukturom površine.	1377
Σ:		5173

3.2. Metodologija

Rad se temelji na usporedbi uspješnosti klasifikacije slika tekstilnih plošnih proizvoda nakon izdvajanja relevantnih značajki metodom filtracije i primjenom konvolucijskih neuronskih mreža. Provedena su dva različita pokusa u dva koraka: izdvajanje relevantnih značajki te klasifikacija digitalnih slika, Tablica 2.

Tablica 2: Provedba pokusa

	Prvi pokus	Drugi pokus
programski paket	Weka	Orange Data Mining
broj ulaznih podataka (slika)	5173	5173
broj klasa	5	5
postupak izdvajanja značajki	filtracija (CLF, EHF, FCTHF, GF, SCHF)	konvolucijske neuronske mreže (Google Inception v3, SqueezeNet)
prediktivni model	klasifikator (Tree, SVM, Random Forest, Naive Bayes, Logistic Regression, Neural Network)	klasifikator (Tree, SVM, Random Forest, Naive Bayes, Logistic Regression, Neural Network)

3.2.1. Izdvajanje značajki

Izdvajanje značajki metodom filtracije

U programskom paketu *Weka* odabrano je 5 različitih filtara za izdvajanje relevantnih značajki slika kojima se želi postići čim uspješnija klasifikacija. Pritom se broj izdvojenih značajki skeniranih prikaza razlikuje s obzirom na korišteni filtar. Odabrani su sljedeći filtri:

1. ***ColorLayoutFilter (CLF)***: izdvaja značajke prostorne raspodjele boja na slici
2. ***EdgeHistogramFilter (EHF)***: izdvaja značajke položaja rubova, linija i diskontinuiteta slike
3. ***FuzzyColorAndTextureHistogramFilter (FCTHF)***: izdvaja značajke boje i teksture slike
4. ***GaborFilter (GF)***: specijaliziran za analizu i izdvajanje teksturnih značajki slike
5. ***SimpleColorHistogramFilter (SCHF)***: izdvaja značajke učestalosti pojavljivanja određene boje na slici [4, 15-17].
6. ***Izdvajanje značajki primjenom konvolucijskih neuronskih mreža***

U programskom paketu *Orange Data Mining* odabrane su 2 konvolucijske neuronske mreže za odabir relevantnih značajki ulaznog skupa digitalnih slika. Radi se o *Google Inception v3* i *SqueezeNet* konvolucijskim neuronskim mrežama.

Google Inception v3 evaluira slike na lokalnom ili udaljenom serveru [18]. Treniran je na skupu podataka *ImageNet* te generira vektor od 2048 značajki. Struktura konvolucijske mreže ima četiri komponente: tri konvolucijska sloja (1x1, 3x3, 5x5) i sloj

sažimanja (3x3) [19]. Izdvajanjem značajki preko više konvolucijskih slojeva različitih veličina te njihovim spajanjem u mapu značajki u sloju sažimanja teži se postizanju boljeg prikaza slike [19]. Također, razdvajanjem višestrukog konvolucijskog sloja u više manjih slojeva različitih veličina smanjuje se potreban broj parametara te se omogućuje istovremeno izdvajanje više relevantnih prostornih značajki [19].

SqueezeNet je jednostavna neuronska mreža također trenirana na skupu podataka ImageNet, ali za razliku od neuronske mreže *GoogleInception v3*, generira vektor od 1000 značajki. Temelj ove mreže čini tzv. "Fire modul", odnosno jedan konvolucijski sloj filtara dimenzija 1x1 te drugi konvolucijski sloj koji kombinira filtre dimenzija 1x1 i 3x3 [20]. *SqueezeNet* nastaje slaganjem opisanih osnovnih "Fire-modula" [20]. Sama neuronska mreža je pogodna za primjenu u ograničenim računalnim resursima ili pak u slučajevima gdje je naglasak na brzini obrade velikih skupova podataka.


3.2.2. Postupak klasifikacije

Za potrebe klasifikacije digitalnih slika odabrano je 6 klasifikatora dostupnih u oba korištena programska paketa.

Klasifikator *Tree* koristi metodu stabla odlučivanja prilikom klasifikacije podataka. Klasifikator na svakom čvoru odluke stabla dijeli skup primjera sukladno informacijskoj dobiti (engl. *information gain*). Prvo se odabire značajka s najvećom informacijskom dobicom na temelju koje će se izvesti podjela primjera u određenom čvoru odluke [4]. Informacijska dobit značajke ukazuje na "dobit" ukoliko se izvede podjela primjera po toj značajki u određenom čvoru stabla odlučivanja [4, 18]. Glavne prednosti ovog klasifikatora su njegova jednostavnost i lakoća razumijevanja. Ipak, ovaj klasifikator uzima u obzir sve značajke primjera što dovodi do nestabilnosti stabla odlučivanja, ali i prenaučivosti modela na podatke za treniranje.

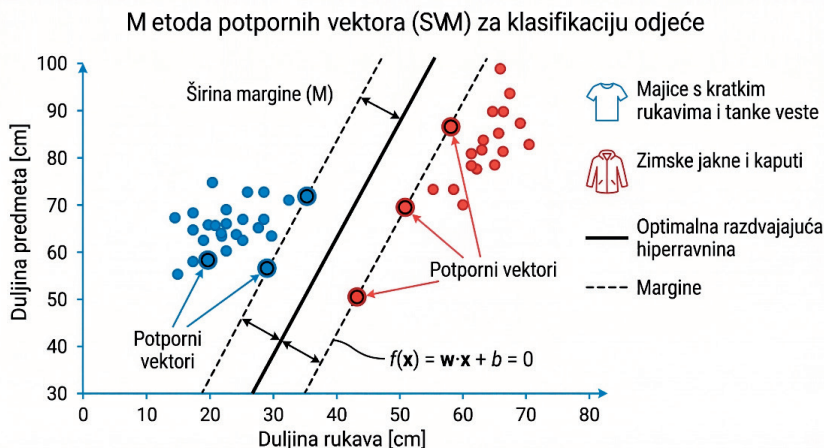
Klasifikator *Random Forest* (Slika 5) temelji se na predviđanjima više stabala odlučivanja kako bi se spriječila korelacija između značajki ulaznih podataka [21]. Na početku slučajnim odabirom uzimaju se podskupovi podataka iz skupa podataka za učenje te se svako stablo trenira na drugom podskupu [18, 21]. Dodatno, ne uzimaju se u obzir sve značajke ulaznog skupa podataka koje će se koristiti za podjelu primjera u određenom čvoru odluke, nego su iste nasumično odabrane [18, 21]. Time se sprječava prenaučivost modela na podatke za treniranje, ali i povećava generalizacijska sposobnost klasifikatora [21]. Glavni nedostatak jest velik broj stabala odlučivanja koji zahtijevaju duže vrijeme učenja klasifikacijskog modela i sporije dobivanje rezultata nakon postupka učenja [21].

Shematski prikaz klasifikatora Slučajna šuma (Random Forest Classifier)



Slika 5: Random Forest klasifikator [7]

Metoda potpornih vektora (*SVM*), Slika 6, nalazi hiper-ravninu, tj. plohu koja ima najveću marginu, odnosno udaljenost između primjera različitih klasa [18]. Kritične točke, odnosno primjeri podataka najbliži toj plohi nazivaju se potpornim vektorima. Cilj metode potpornih vektora jest maksimizirati marginu s obzirom da je pretpostavka da generalizacijska sposobnost klasifikatora raste s porastom vrijednosti margine [22]. SVM klasifikatori prema Srivastava i Bhambhu [23] daju bolje rezultate klasifikacije u odnosu na druge metode nadziranog učenja, ali su jako osjetljivi na definiranje parametara klasifikacije. Često korisnici moraju provoditi više unakrsnih provjera (engl. *cross-validation*) što zahtjeva veće vrijeme odabira i postavki modela.




Slika 6: Metoda potpornih vektora (SVM) na primjeru klasifikacije odjeće [7]

Logistička regresija je statistička metoda korištena u klasifikaciji binarnog rješenja, primjerice “da” ili “ne” razreda [24]. S tim u vezi, **Logistic Regression** klasifikator upotrebnom logističke funkcije, poznate još i kao sigmoidna funkcija, stvara odnos između zavisne (klasa) i jedne ili više nezavisnih varijabli i daje rješenje u vidu vjerojatnosti pripadanja primjera određenoj klasi (vrijednost između 0 i 1) [24]. Način rada klasifikatora je lako razumljiv i jednostavan, učinkovit po pitanju vremena rada i memorije, što ga čini pogodnim za rad s većim skupovima podataka i broja značajki [24]. Glavni nedostatak primjene ove metode jest ograničenost na binarne rezultate, osjetljivost na stršće vrijednosti (engl. *outliers*), osjetljivost na prenaučenos modela na podatke za učenje posebice ako je broj značajki primjera veći od broja samih primjera [25]. Iako je *Logistic Regression* primarno binarni klasifikator, u ovom istraživanju se koristi njegova multinomijalna varijanta prilagođena za klasifikaciju u pet različitih klasa tekstilnih plošnih proizvoda.

Naive Bayes je brz i jednostavan probabilistički klasifikator koji se temelji na Bayesovom teoremu uz pretpostavku o jednakosti utjecaja značajki primjera na pridruživanje oznake klase primjeru te njihovoj međusobnoj neovisnosti [4, 18]. U praktičnoj primjeni ovakve “naivne” pretpostavke često nisu slučaj što dovodi do smanjenja točnosti klasifikacije.

Neural Network je višeslojna neuronska mreža (engl. *Multi-layer perceptron, MLP*) kod koje se učenje odvija pomoću algoritma s povratnom propagacijom pogreške (engl. *back-propagation*) [18], Slika 7. Povratna propagacija pogreške obuhvaća širenje kroz mrežu od ulaznog do izlaznog sloja, određivanje pogreške i njenu propagaciju unazad do ulaznog sloja čime se ista ugrađuje u “formulu” za učenje [26]. MLP mreže imaju jedan ulazni, jedan izlazni i jedan ili više skrivenih slojeva neurona.



Slika 7: MLP mreža s jednim ulaznim, jednim skrivenim i jednim izlaznim slojem

Glavna prednost uporabe neuronskih mreža u odnosu na druge konvencionalne metode klasificiranja jest njihova vođenost podacima tako da se lako mogu prilagoditi bilo kojem ulaznom skupu primjera [25]. Nadalje, radi se o nelinearnim modelima što im daje fleksibilnost u kompleksnim odnosima podataka [25]. Iako daju odlične prediktivne rezultate na velikim skupovima ulaznih podataka, nedovoljan broj podataka može dovesti do prenaučivosti na podacima za učenje [26]. Za svoj rad zahtijevaju značajne računalne resurse. Često se smatraju “crnim kutijama” s obzirom da zbog postojanja skrivenih neurona, daju slab uvid u način donošenja odluka klasifikacije [26].

4. Rezultati s raspravom

U radu je klasifikacija provedena u dva pokusa. U prvom pokusu provedeno je tri-deset mjerenja, a u drugom dvanaest. Rezultati svakog pokusa praćeni su postotkom ispravno klasificiranih primjera, odnosno preko generalizacijske sposobnosti klasifikatora. Rezultati su prikazani tablično (Tablice 3 i 4).

Tablica 3: Rezultati prvog eksperimenta u programskom paketu Weka

Filtar	Broj značajki	<i>Tree</i>	SVM	<i>Random Forest</i>	<i>Naive Bayes</i>	<i>Logistic Regression</i>	<i>Neural Network</i>
CLF	33	79,43	82,93	82,00	54,09	46,32	69,46
EHF	80	58,09	75,45	69,69	45,68	60,35	66,85
FCTHF	192	87,92	84,59	91,13	57,76	82,47	66,89
GF	60	68,43	44,52	69,63	42,80	55,92	59,64
SCHF	64	87,61	71,89	91,69	38,57	68,03	82,49

Najbolji i najlošiji rezultat klasifikacije digitalnih slika postignut je primjenom *SCHF*-filtra. Činjenica da ovaj filtar s *Random Forest* klasifikatorom postiže 91,69 % ispravno klasificiranih primjera sugerira da su boje unutar klasa u ovom specifičnom skupu podataka vrlo diskriminativne, tj. da se učestalost pojavljivanja određenih boja na skeniranim prikazima jasno razlikuje po klasama (npr. možda su tepisi specifičnih boja u odnosu na čipku). Primjena *Random Forest* klasifikatora su se u ovom eksperimentu u prosjeku i postigli najbolji rezultati klasifikacije (raspon između 69,63 % i 91,69 %). Navedeno se može pripisati načinu rada ovog klasifikatora koji kombinira rad višestrukih, nekoreliranih stabala odlučivanja, koji su trenirani na nasumično odabranim skupovima podataka za učenje. Prilikom podjele čvorova u stablu, klasifikator ne uzima u obzir sve značajke već samo nasumični podskup značajki. Time smanjuje korelaciju između stabala i sprječava da jedno dominantno obilježje prevlada, povećavajući raznolikost modela [27].

Kombinacija *SCH*-filtra s *Naive Bayes* klasifikatorom daje najlošiji rezultat klasifikacije od 38,57 %. Ovako nizak postotak ispravno klasificiranih primjera može se povezati s njegovim “naivnim” pretpostavkama o jednakosti utjecaja značajki primjera na pridruživanje oznake klase primjeru te njihovoj međusobnoj neovisnosti. Utjecaj ovih “naivnih” pretpostavki moguće je vidjeti i u kombinaciji s ostalim filtrima gdje je postotak ispravno klasificiranih primjera dostignuo najviše 57,76 % (u kombinaciji s filtrom *FCTHF*).

Tablica 4: Rezultati drugog eksperimenta u programskom paketu Orange Data Mining

CNN	Broj značajki	<i>Tree</i>	SVM	<i>Random Forest</i>	<i>Naive Bayes</i>	<i>Logistic Regression</i>	<i>Neural Network</i>
Google Inception v3	2048	85,42	93,21	92,44	86,29	95,42	95,52
SqueezeNet	1000	86,35	84,88	91,84	73,36	91,46	94,63

U drugom pokusu najslabiji rezultat klasifikacije od 73,36 % postignut je izdvajanjem značajki *SqueezeNet* konvolucijskom neuronskom mrežom u kombinaciji s *Naive Bayes* klasifikatorom. U odnosu na *Google Inception v3*, ova CNN mreža izdvaja vektor s manjim brojem značajki što dovodi do pada preciznosti klasifikacije, posebice u kombinaciji s klasifikatorom koji se temelji na pretpostavkama koje su često “naivne” na praktičnim primjerima. Najbolji rezultat (95,52 %) dobiven je izdvajanjem značajki *Google Inception v3* i primjenom *Neural Network* klasifikatora što ukazuje na dominantnost primjene neuronskih mreža u postupku klasifikacije.

Nadalje, uspoređujući Tablice 3 i 4, može se uočiti kako je primjena konvolucijskih neuronskih mreža prilikom izdvajanja relevantnih značajki dovela do puno većeg postotka ispravno klasificiranih primjera u odnosu na izdvajanje metodom filtracije čak i za jednostavne klasifikatore kao što je *Logistic Regression*. Dok filtri u programskom paketu *Weka* izdvajaju značajke na temelju fiksno definiranih matematičkih formula (npr. histogrami boja ili rubova), konvolucijske neuronske mreže u programskom paketu *Orange Data Mining* automatski uče hijerarhijske prikaze podataka, što rezultira znatno većom diskriminativnom moći modela.

S tehničkog aspekta, tijekom provedbe pokusa uočena je korelacija između preciznosti i računalne zahtjevnosti. Naime, *Google Inception v3* je dao najveću točnost klasifikacije, ali s druge strane zahtijevao je i više vremena za izdvajanje 2048 značajki. *SqueezeNet* se s te strane pokazao kao optimalno rješenje za brzu obradu uz neznatan pad ispravnosti klasifikacije. Nasuprot tome, metoda filtracije u programskom paketu *Weka* pokazala se računalno manje zahtjevnom, ali uz značajno slabiju generalizacijsku moć klasifikatora.

S obzirom da ukupna točnost klasifikacije može biti varljiva kod skupova podataka s neravnomjernim brojem uzoraka po klasama, provedena je dodatna evaluacija oba pokusa primjenom metrike preciznosti, odaziva i F1-vrijednosti. U Tablici 5 prikazane su samo metričke vrijednosti najbolje postignutih rezultata iz oba pokusa.

Tablica 5: Sažeti prikaz ponderiranih metrika za najbolje modele po metodama izdvajanja značajki

Metoda izdvajanja značajki	Klasifikator	Točnost klasifikacije [%]	Preciznost	Odaziv	F1-mjera	F1-mjera (čipka)
SCHF	<i>Random Forest</i>	91,69	0,916	0,917	0,916	0,994
Google Inception v3	<i>Neural Network</i>	95,52	0,955	0,955	0,955	0,996
<i>SqueezeNet</i>	<i>Neural Network</i>	94,63	0,945	0,946	0,946	0,989

Za najuspješniji model (*Google Inception v3 + Neural Network*) F1-mjera iznosi 0,955. Posebno je značajno kako za najmalobrojniju klasu “čipka” postignut rezultat F1-mjere od 0,996 što potvrđuje da metoda dubokog učenja iznimno precizno identificira specifične tekstilne strukture čak i uz manji broj uzoraka.

5. Zaključak

U ovom istraživanju provedena je usporedba klasifikacije tekstilnih plošnih proizvoda primjenom *Weka* i *Orange Data Mining* programskih paketa. Klasifikacija je provedena na skupu od 5173 digitalnih slika tekstilnih materijala podijeljenih u pet klasa: čipke (421), netkani tekstil (2207), pletiva (524), tepisi (644) i tkanine (1377). Analizirana je učinkovitost spomenuta dva programska paketa korištenjem različitih metoda izdvajanja relevantnih značajki. U programu *Weka* korišteni su vizualni filtri (CLF, EHF, FCTHF, GF, SCHF) dok su u programu *Orange Data Mining* korištene konvolucijske neuronske mreže (*Google Inception v3*, *SqueezeNet*). Rezultati nedvojbeno pokazuju superiornost metoda dubokog učenja, pri čemu kombinacija *Inception v3* konvolucijske neuronske mreže i *Neural Network* klasifikatora postiže najvišu točnost od 95,52%. Konvolucijska neuronska mreža *SqueezeNet* je tek neznatno slabija od *Google Inception v3*, ali i dalje superiorna u odnosu na filtracijske metode u programu *Weka* čime se još jednom potvrđuje dominacija pristupa dubokog učenja u izdvajanju relevantnih značajki ulaznog skupa primjera.

Zahvala

Objava rada proizašla je iz provedbe institucionalnog istraživačkog projekta "Održivi razvoj odjeće dodane vrijednosti: Digitalno prototipiranje, primjena umjetne inteligencije i biomaterijala", AI3D-BioWear, šifra projekta: TTF-IIP-02, koji financira Europska unija – NextGenerationEU.

Objava rada proizašla je iz provedbe institucionalnog istraživačkog projekta "Transformacija i recikliranje otpadnog asortimana u sekundarni hit", TRASH, šifra projekta: TTF-IIP-03, koji financira Europska unija – NextGenerationEU.

Objava rada proizašla je iz provedbe institucionalnog istraživačkog projekta "Istraživanje i razvoj održivih, funkcionalnih tekstilnih komponenti za kompozite nove generacije", FUNK-TEX, šifra projekta: TTF-IIP-06, koji financira Europska unija – NextGenerationEU.

6. Literatura

- [1] Bergmann, D.: What is machine learning?, *Dostupan na* <https://www.ibm.com/think/topics/machine-learning>, *Pristupljeno*: 2026-02-01
- [2] Nasteski, V.: An overview of the supervised machine learning methods, *Horizons*, **4** (2015) 51-62, <https://doi.org/10.20544/HORIZONS.B.04.1.17.P05>
- [3] Han J.; Kamber M., Pei, J.: *Data Mining: concepts and techniques 3rd edition*, Morgan Kaufmann Publishers, 978-0-12-381479-1, USA (2012)
- [4] Imamagić, S.; Rolich, T., Penava, Ž.: Primjena algoritama strojnog učenja u svrhu klasifikacije tekstilnih plošnih proizvoda u programskom paketu *Weka, Koža & Obuća*, **73** (2024) 3, 8-13, <https://doi.org/10.34187/ko.73.3.2>
- [5] Nichols, J. A.; Herbert Cjan, H. S., Baker, M. A. B.: Machine learning: applications of artificial intelligence to imaging and diagnosis, *Biophysical Reviews*, **11** (2018) 1, 111-118, <https://doi.org/10.1007/s12551-018-0449-9>
- [6] Seetharaman, P.; Wichern, G., Venkataramani, S., Le Roux, J.: Class-conditional Embeddings for Music Source Separation, *Proceedings of ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 301-306, 978-1-4799-8131-1, Brighton, UK, May 2019, IEEE (2019)
- [7] Slike generirane pomoću modela Gemini 3 Flash Image (Nano Banana 2), Google Gemini 3.1 Pro, <https://gemini.google.com>, *Pristupljeno* 2026-03-12
- [8] <https://medium.com/@abhaysingh71711/filter-method-in-feature-selection-a-key-to-smarter-machine-learning-2e343e837fc7>, *Pristupljeno*: 2026-02-18
- [9] Sánchez-Marroño, N.; Alonso-Betanzos, A., Tombilla-Sanromán, M.: Filter Methods for Feature Selection – A Comparative Study, *Intelligent Data Engineering and Automated Learning - IDEAL 2007*, Yin, H.; Tino, P.; Corchado, E.; Byrne, W.; Yao, X. (Eds.), 178-187, 3540772251, Birmingham, UK, December 2007, Springer (2007)

- [10] Stojanović, A.; Kovačević, Ž., Ivošević, D.: Ansambl metode strojnog učenja, *Polytechnic & Design*, **11** (2023) 4, 245-252, <https://doi.org/10.19279/TVZ.PD.2023-11-4-04>
- [11] Mjahad, A.; Polo-Aguado, A., Llorens-Serrano, L., Rosado-Muñoz, A.: Optimizing Image Feature Extraction with Convolutional Neural Networks for Chicken Meat Detection Applications, *Applied Sciences*, **15** (2025) 2, 1-28, <https://doi.org/10.3390/app15020733>
- [12] <https://www.ibm.com/think/topics/convolutional-neural-networks>, *Pristupljeno*: 2026-02-18
- [13] Raj, R.; Kos, A.: An Extensive Study of Convolutional Neural Networks: Applications in Computer Vision for Improved Robotics Perceptions, *Sensors*, **5** (2025) 4, 1-19, <https://doi.org/10.3390/s25041033>
- [14] Čunko, R.; Pezelj, E.: Tekstilni materijali, *Zrinski d.d.*, 953-155-061-1, Čakovec (2002)
- [15] University of Waikato: Weka 3.8.6 programski paket
- [16] Abidin, D.: The Effect of Derived Features on Art Genre Classification with Machine Learning, *Sakarya University Journal of Science*, **25** (2021) 6, 1275-1286
- [17] Musleh, D.; Alotaibi, M., Alhaidari, F., Rahman, A., Mohammad, R. M.: Intrusion Detection System Using Feature Extraction with Machine Learning Algorithms in IoT, *Journal of Sensor and Actuator Networks*, **12** (2023) 29, 1-19
- [18] <https://orangedatamining.com/>, *Pristupljeno*: 2026-02-26
- [19] Zeng, Y.; Zhu, X.: Skin Cancer Detection Based on Hybrid Model by Means of Inception V3 and ResNet 50, *Proceedings of the 2022 3rd International Conference on Artificial Intelligence and Education*, Fox, B.; Zhao, C.; Anthony, M. T. (Eds.), 275-282, 978-94-6463-040-4, Chengdu, China, June 2022, Atlantis Press Zeger Karssen (2023)
- [20] Hao, M.; Sun, Q., Xuan, C., Zhang, X. Zhao, M.: SqueezeNet: An Improved Lightweight Neural Network for Sheep Facial Recognition, *Applied Sciences*, **14** (2024) 4, 1-13, <https://doi.org/10.3390/app14041399>
- [21] Salman, A. H.; Kalakech, A., Steiti, A.: Random Forest Algorithm Overview, *Babylonian Journal of Machine Learning*, **2024** (2024), 69-79, <https://doi.org/10.58496/BJML/2024/007>
- [22] Srivastava, D.; Bhambhu, L.: Data classification using support vector machine, *Journal of Theoretical and Applied Information Technology*, **12** (2010) 1, 1-7
- [23] Labhade-Kumar, N.: Study of Supervised Logistic Regression Algorithm, *Alochana Journal*, **13** (2024) 11, 227-230
- [24] <https://eris.foi.hr/11neuronske/nn-predavanje5.html>, *Pristupljeno*: 2026-03-05
- [25] Zhang, G. P.: Neural Networks for Classification: A Survey, *IEEE Transactions on Systems Man and Cybernetics Part C (Applications and Reviews)*, **30** (2000) 4, 451-462, <https://doi.org/10.1109/5326.897072>
- [26] https://www.researchgate.net/post/What_are_some_criticisms_of_Neural_Networks2, *Pristupljeno*: 2026-03-01
- [27] Baladram: Random Forest, Explained: A Visual Guide with Code Examples, <https://towardsdatascience.com/random-forest-explained-a-visual-guide-with-code-examples-9f736a6e1b3c/>, *Pristupljeno*: 2026-03-03