

# Klasifikacija slika primjenom nadziranog strojnog učenja

---

**Roginić, Karla**

**Master's thesis / Diplomski rad**

**2024**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Zagreb, Faculty of Humanities and Social Sciences / Sveučilište u Zagrebu, Filozofski fakultet**

*Permanent link / Trajna poveznica:* <https://urn.nsk.hr/urn:nbn:hr:131:076804>

*Rights / Prava:* [In copyright/Zaštićeno autorskim pravom.](#)

*Download date / Datum preuzimanja:* **2025-02-22**



Sveučilište u Zagrebu  
Filozofski fakultet  
University of Zagreb  
Faculty of Humanities  
and Social Sciences

*Repository / Repozitorij:*

[ODRAZ - open repository of the University of Zagreb](#)  
[Faculty of Humanities and Social Sciences](#)



SVEUČILIŠTE U ZAGREBU  
FILOZOFSKI FAKULTET  
ODSJEK ZA INFORMACIJSKE I KOMUNIKACIJSKE ZNANOSTI  
Ak. god. 2023./2024.

Karla Roginić

## **Klasifikacija slika primjenom nadziranog strojnog učenja**

Diplomski rad

Mentor: prof. dr. sc. Sanja Seljan

Zagreb, rujan 2024.

## Izjava o akademskoj čestitosti

Izjavljujem i svojim potpisom potvrđujem da je ovaj rad rezultat mog vlastitog rada koji se temelji na istraživanjima te objavljenoj i citiranoj literaturi. Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava. Također izjavljujem da nijedan dio rada nije korišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

---

Karla Roginić

# Sadržaj

1. Uvod .....	1
2. Strojno učenje .....	3
2.1. Proces strojnog učenja.....	5
2.2. Vrste strojnog učenja.....	6
2.3. Modna industrija i strojno učenje .....	9
3. Nadzirano strojno učenje.....	12
3.1. Regresija.....	13
3.2. Klasifikacija .....	13
3.3. Algoritmi nadziranog strojnog učenja.....	14
3.3.1. Stablo odlučivanja .....	14
3.3.2. Slučajna šuma .....	16
3.3.3. Naivni Bayesov algoritam.....	17
3.3.4. Linearna regresija .....	18
3.3.5. Logistička regresija .....	19
3.3.6. Stroj s potpornim vektorima.....	20
3.3.7. K-najbliži susjed.....	21
4. Metrike evaluacije .....	22
5. Računalni vid.....	30
5.1. Klasifikacija slika .....	31
5.2. Duboko učenje.....	32
6. YOLOv8 .....	35
7. Istraživanje .....	36
7.1. Metodologija .....	37
7.2. Podatkovni skup .....	38
7.3. Alati .....	41

7.4. Struktura podataka.....	41
7.5. Izrada modela klasifikatora slika.....	42
7.6. Rezultati modela na testnom skupu podataka .....	50
7.6.1. Rezultati modela klasifikatora slika treniranog na 50 epoha .....	50
7.6.2. Rezultati modela klasifikatora slika treniranog na 100 epoha .....	54
8. Diskusija .....	59
9. Zaključak .....	66
Literatura .....	69
Popis slika .....	75
Popis tablica .....	77
Sažetak .....	78
Summary .....	79

# 1. Uvod

Prisutnost tehnologije u svakom aspektu života postala je gotovo neizostavna. Tehnološki napredak transformira način na koji živimo i utječe na naše razumijevanje i interpretaciju svijeta oko nas. Posebno se očituje napredak u području strojnog učenja koje je zahvatilo sve slojeve znanosti.

Učenje su „relativno trajne promjene u ponašanju koje nastaju kao posljedica iskustva pojedinaca“ također „posljedica procesa učenja je pamćenje“. „Kad se govori o učenju kod ljudi, obično se misli na proces stjecanja znanja, verbalnoga ili psihomotornoga“ („Učenje“, bez dat.). Također prema tome glavna zadaća strojnog učenja je omogućiti računalima da uče i izvršavaju određene zadatke bez eksplicitnog programiranja, a to se postiže uvježbavanjem algoritama na velikim količinama podataka dostupnih za zadatak koji se želi izvršiti, prema Gündüz i sur. (2019). Mahesh (2020) „navodi da je strojno učenje znanstveno proučavanje algoritama i statističkih modela koje koriste računalni sustavi za izvršavanje određenih zadataka bez programiranja“ te ističe kako je glavna prednost korištenja strojnog učenja ta da kada algoritam nauči što treba naučiti, svoj posao može obavljati automatski. (Mahesh, 2020). Upravo zbog toga strojno učenje je prepoznato u brojnim industrijama i poljima te se je počelo sve češće i više upotrebljavati. Uporaba strojnog učenja može se pronaći u medicini, ugostiteljstvu, ekonomiji, modnim industrijama, automobilskim industrijama i slično.

U kontekstu modnih industrija, primjene strojnog učenja uključuju razvoj sofisticiranih sustava za prepoznavanje i preporuke stilova, analizu trendova, preferencije potrošača, poboljšanje korisničkog iskustva, otkrivanje proizvoda i slično („International Association of Business Analytics Certification [IABAC]“, 2023). Primjer kako strojno učenje može unaprijediti otkrivanje proizvoda u modnoj industriji je proširenje pretraživanja putem automatiziranog označavanja proizvoda. Ova metoda dodaje detaljne atribute poput boje, materijala i uzorka, čime korisnicima olakšava pretraživanje artikla koji odgovaraju njihovim željama i potrebama. Vizualno pretraživanje također koristi umjetnu inteligenciju za identificiranje proizvoda na slikama koje su korisnici postavili i zatim nudi slične artikle iz dostupne ponude. Također, primjer korištenja strojnog učenja na web trgovinama može se primijetiti na web trgovini Lane Crawford gdje se koristi strojno učenje za preporuku stilova. Kada korisnik odabire neki odjevni predmet, stranica ne prikazuje samo taj predmet, već sve vizualno slične artikle iz ponude, što

omogućuje kupcima pregled svih sličnih proizvoda koje trgovina nudi („Fashion machine learning applications and examples“, bez dat.).

Cilj ovoga rada bio je razviti model za klasifikaciju slika primjenom nadziranog strojnog učenja. Specifičan cilj jest razviti model treniran na 50 i 100 epoha za klasifikaciju slika koji može prepoznati i klasificirati raznovrsne haljine prema njihovom podrijetlu te na kraju provesti usporedbu rezultata modela prema epohama.

Rad je podijeljen na dvije osnovne cjeline: teorijsku i praktičnu. U teorijskom dijelu svako poglavlje definira i analizira ključne pojmove za razumijevanje strojnog učenja i klasifikacije slika. Prema tome, u drugom poglavlju definirano je strojno učenje, prikazan je proces i vrste strojnog učenja te se analizira primjena strojnog učenja u modnim industrijama. U trećem poglavlju fokusira se na nadzirano strojno učenje, zadatke učenja pod nadzorom i algoritme. Četvrto poglavlje posvećeno je metrikama evaluacije, uključujući prikaz formula za izračun metrika. U petom poglavlju razraduju se pojmovi računalni vid, klasifikacija slika i duboko učenje. Šesto poglavlje pruža detaljan pregled YOLOv8 modela, koji je korišten za razvoj modela u praktičnom dijelu rada.

U praktičnom dijelu rada prikazano je provedeno istraživanje. Detaljno se opisuje razvoj modela za klasifikaciju slika treniranog na 50 i 100 epoha. Izrada modela klasifikacije slika na različitom broju epoha obavljena je kako bi se na kraju mogli usporedili rezultati prema broju epoha koji se postavljaju prije samog treniranja. Model treniran na 50 epoha u izradi klasifikatora slika bio je postavljen na 50 epoha, a model treniran na 100 epoha je bio postavljen na 100 epoha. Za razvoj modela koristio se skup podataka koji je sadržavao slike kulturno raznolikih haljina iz 4 različite regije svijeta: Skandinavija, Mediteran, Ujedinjeni Arapski Emirati i središnja Europa. Slike haljina za Ujedinjene Arapske Emirate prikazivale su abayu, široku haljinu koja potječe iz arapskih zemalja, slike haljina Skandinavije prikazivale su bunad, tradicionalnu narodnu nošnju koja se nosi u Norveškoj, slike haljina Mediterana prikazivale su ljetne lepršave haljine i slike haljina središnje Europe prikazivale su dirndl, tradicionalnu nošnju koja je najčešće nošena u Njemačkoj i Austriji. Također u praktičnom dijelu rada prikazuje se proces treniranja i validacije modela, predikcija i testiranje te evaluacija i rezultati. Na kraju slijedi Diskusija, Zaključak, Popis literature, Popis slika i tablica te sažeci s ključnim riječima na hrvatskom i engleskom jeziku.

## 2. Strojno učenje

Prema Kubát, Bratko i Michalski (1996), područje strojnog učenja započelo je prije četiri desetljeća s ciljem razvoja računalnih metoda koje bi implementirale različite oblike učenja u određenim mehanizmima za generiranje znanja iz primjera ili podataka. Mohri, Rostamizadeh i Talwalkar (2018) navode da se strojno učenje može definirati kao računalna metoda koja koristi iskustva za poboljšanje performansi ili za točna predviđanja. Prema Alzubi, Nayyar i Kumar (2018), strojno učenje je multidisciplinarno polje s obiljem istraživanja koja ga podupiru. Iqbal i Yan (2015) navode da se strojno učenje može smatrati podpoljem umjetne inteligencije jer se ti algoritmi mogu smatrati građevnim blokovima koji omogućuju računalima da se ponašaju inteligenčno, umjesto da samo pohranjuju i dohvaćaju elemente podataka poput sustava baza podataka i drugih programa. Također ističu da je strojno učenje inspirirano akademskim disciplinama poput informatike, statistike, biologije i psihologije. Ističu da je osnovna svrha strojnog učenja omogućiti računalima da automatski identificiraju korisne prediktore na osnovu prethodnih iskustava. Raschka (2015) objašnjava pojam strojnog učenja kao proces i znanost o algoritmima koji pružaju informacije o podacima. Također navodi da strojno učenje pruža učinkovitiji način prikupljanja podataka za postupno poboljšanje izvedbe prediktivnih modela i donošenje odluka temeljenih na podacima, umjesto da se od ljudi zahtjeva ručno izvođenje pravila i izrada modela.

Alpaydin (2010) definira strojno učenje kao proces „programiranja računala za optimizaciju kriterija izvedbe pomoću primjera podataka ili prošlog iskustva.“ Model se sastoji od parametara, a proces učenja obuhvaća optimizaciju tih parametara putem računalnog programa koristeći podatke za obuku. Model može biti **prediktivan**, što omogućuje izradu budućih predviđanja, **opisni**, gdje pomaže u stjecanju znanja iz podataka, ili **kombinacija oba**. Strojno učenje primjenjuje statističku teoriju za kreiranje matematičkih modela, jer mu je osnovni cilj donošenje zaključaka na osnovu podataka. Računalna znanost ima dvostruku ulogu u ovom procesu. Prvo, obuka zahtijeva primjenu učinkovitih algoritama za optimizaciju i kapacitet za pohranu i obradu velikih količina podataka. Drugo, nakon što se model nauči, važno je da njegova reprezentacija i algoritamski postupak zaključivanja budu učinkoviti. Nadalje, u određenim primjenama, učinkovitost algoritama za učenje i zaključivanje, kao i njihova prostorna i vremenska složenost, mogu biti jednakо važni kao i prediktivna točnost (Alpaydin, 2010).

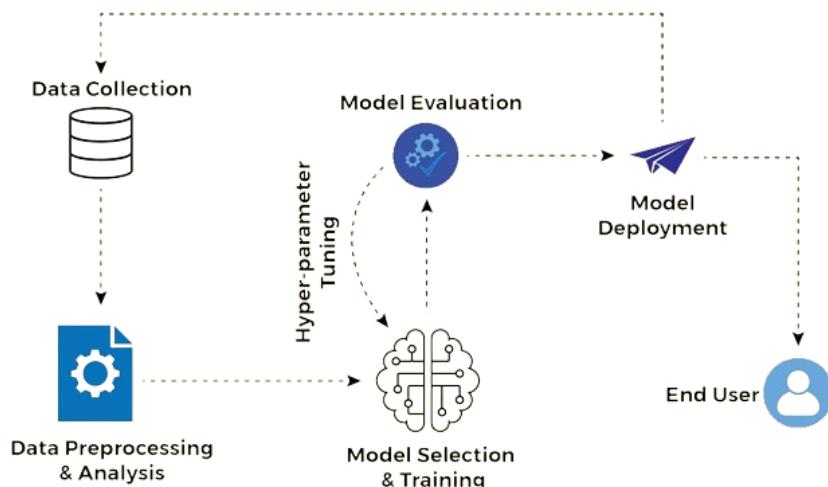
„Zadatak algoritama strojnog učenja je pronaći prirodne uzorke i poveznice u podacima te na temelju toga steći uvid i predviđati ishode. Algoritmi strojnog učenja primjenjuju se svakodnevno za donošenje bitnih odluka u medicinskoj dijagnostici, trgovanju i mešetarenju dionicama, predviđanju potrošnje energije itd.“ (Bolf, 2021). Strojno učenje postalo je ključno u mnogim sektorima zbog stalnog rasta velike količine podataka (eng. big data), a područja gdje se najčešće primjenjuje strojno učenje su:

- „Računalne financije - provjera kreditne sposobnosti kad se trebaju dodijeliti krediti ili analiza velikih količina podataka u bankarskoj industriji (Pejić i sur., 2019 ; Marrara i sur., 2019; Pejić Bach i sur., 2019) ;
- Predikcije u obrazovnom sustavu - predviđanje završetka studija i analitike podataka (Radišić u sur., 2023; Radišić i sur.,2024)
- Obrada slika i računalni vid - prepoznavanje lica (Al-Dujaili i sur., 2024), detekcija gibanja, detekcija raznih objekata, generiranje 3D modela (Reljić i sur., 2019), modna industrija (Govindaraju i Prasanna, 2024);
- Računalna biologija – u medicini u detekciji tumora, istraživanje lijekova i sekvenciranje DNA, debljini i itd. (Rajbhoj i sur., 2024; Seljan, 2024);
- Proizvodnja energije - prognoza opterećenja elektroenergetske mreže i kretanja cijena, nuklearna energija (Katalinić i sur., 2024);
- Industrijska proizvodnja - u prediktivnom održavanju, procjeni i nadziranju kvalitete proizvoda;
- Obrada prirodnog jezika - raspoznavanje govora, razumijevanje i generiranje prirodnog jezika, ekstrakcija informacija“ (Bolf, 2021), prepoznavanje govora i strojno prevođenje (Seljan i Dundjer, 2014; Zaghouani i sur., 2024), analitika podataka iz područja politike (Katalinić i sur. 2024), iz područja financija (Krstić i sur., 2019), različiti algoritmi primjene strojnog prevođenja primjenom konkordancija (Jaworski i sur., 2021), analize tekstova (Dunder i sur., 2020 , Seljan i sur., 2014).

## 2.1. Proces strojnog učenja

Strojno učenje podskup je umjetne inteligencije koji koristi skupove podataka kako bi iz njih dobio uvid i predviđao buduće vrijednosti (Lara, bez dat.). U nastavku je naveden niz koraka koji opisuje proces strojnog učenja (Slika 1):

1. **Prikupljanje podataka** - kako bi točnost predviđanja bila što veća potrebno je prikupljanje kvalitetnih podataka koji se mogu prikupljati iz različitih izvora, kao što su web stranice, društvene mreže i slično.
2. **Predobrada podataka** - nakon što su podatci sakupljeni potrebno je provesti njihovo obrađivanje kako bi se uklonile duple vrijednosti, uklonili podaci koji nisu potrebni i kako bi se standardizirali formati. U ovome koraku osigurava se kvaliteta skupa podataka i poboljšava točnost rješavanjem mogućih izvora pogrešaka.
3. **Obuka modela** - započinje nakon prikupljanja i obrade skupa podataka, koristeći algoritam koji je prilagođen za modeliranje tog skupa podataka. Prikupljeni skup podataka obično se dijeli na: skup za treniranje/obuku, skup za validaciju i skup za testiranje.
4. **Procjena modela** - kod procjene modela određuje se radi li model točno ili ne. Neki od mjernih podataka koji se koriste su točnost, preciznost, F1 mjera itd.
5. **Implementacija modela** - kod implementacije modela uključuje se integriranje uvježbanog modela u probleme iz stvarnog svijeta kako bi se oni riješili (Lara, bez dat.).

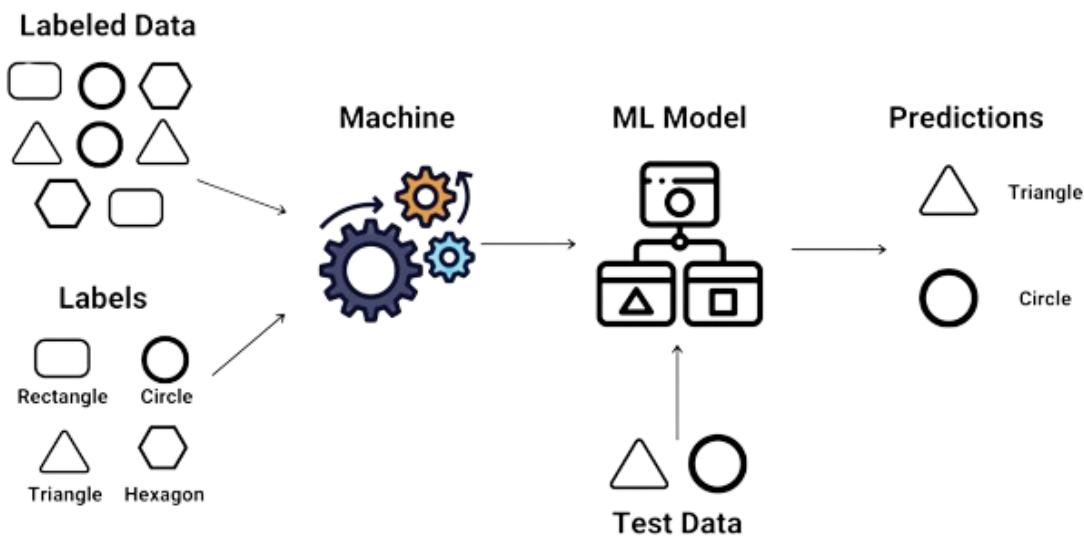


Slika 1. Proces strojnog učenja

## 2.2. Vrste strojnog učenja

Postoji mnogo načina za treniranje algoritama strojnog učenja, a sam odabir algoritama ovisi o željenom ishodu (Chao, 2011). Obično se dijele na četiri dijela:

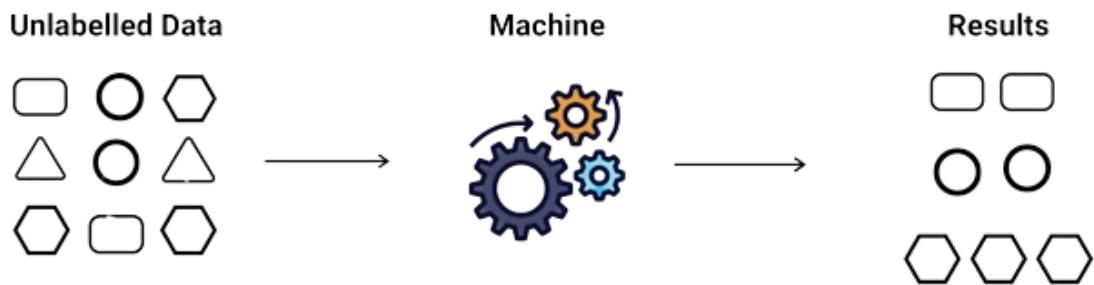
1. **Nadzirano strojno učenje** - "modeli se uvježbavaju, odnosno grade, primjenom skupa ulaznih i izlaznih podataka prikupljenih eksperimentom ili akvizicijom tako da mogu predviđati buduće izlaze na temelju dostupnih ulaza" (Bolf, 2021). Nadzirano učenje (Slika 2) poznato je i kao učenje putem primjera odnosno učenje na primjerima. (Oladipupo, 2010).



Slika 2. Nadzirano strojno učenje

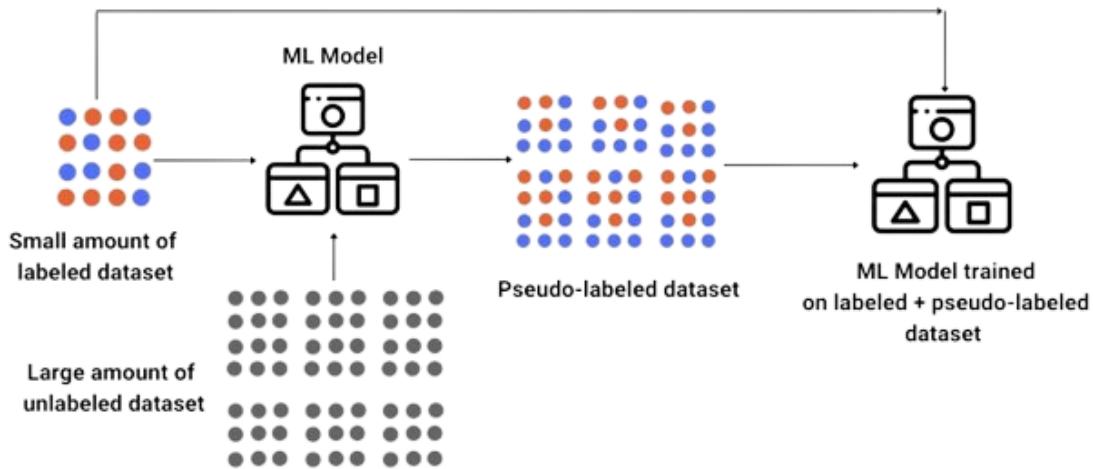
2. **Nenadzirano strojno učenje** - „zadatak nenadziranog učenja je pronaći skrivene uzorke i inherentne strukture u ulaznim podacima bez poznavanja izlaza“ (Bolf, 2021). Ovaj pristup je prikladan u situaciji kada kategorije podataka nisu poznate te u ovome pristupu podaci u obuci nisu označeni. Učenje bez nadzora smatra se pristupom učenju koji se temelji na statistici i stoga se odnosi na problem pronalaženja skrivene strukture u neoznačenim podacima (Slika 3). Cilj nenadziranog strojnog učenja je grupiranje, procjena gustoće, pronalaženje povezanosti među značajkama i smanjenje dimenzionalnosti (Alzubi i sur., 2018). Najčešća tehnika nenadziranog učenja je

grupiranje (eng. clustering), pri čemu se traže skriveni obrasci ili grupe (Seljan i sur., 2020). „Primjenu nalazi pri analizi sekvenca gena, analizi tržišta i prepoznavanju objekata,, (Bolf, 2021).



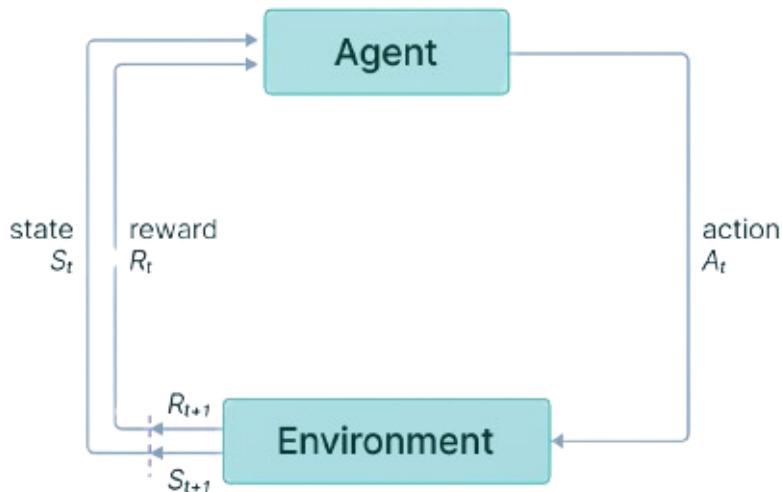
Slika 3. Nenadzirano strojno učenje

3. **Polu-nadzirano strojno učenje** - može se definirati kao kombinacija označenih i neoznačenih podataka za generiranje odgovarajućih funkcija ili klasifikatora (Slika 4), (Oladipupo, 2010). Omogućuje se iskorištavanje velikih količina neoznačenih podataka u kombinaciji s obično manjim skupovima označenih podatka. Polu-nadzirane metode učenja posebno su relevantne u situacijama kada je dobivanje dovoljne količine označenih podataka pretjerano teško ili skupo, dok je velike količine neoznačenih podataka relativno lako dobiti. U takvim situacijama, niti potpuno nadzirane niti nenadzirane metode učenja neće pružiti odgovarajuća rješenja. Cilj polu-nadziranog modela učenja je pružiti bolji ishod za predviđanje i iskoristiti neoznačene podatke za konstrukciju boljih postupaka učenja (Alzubi i sur., 2018).



Slika 4. Polu-nadzirano strojno učenje

**4. Učenje s pojačanjem** - odnosi se na načine poboljšanja učinka kroz iskustvo pokušaja i pogrešaka te se temelji na povratim informacijama (Slika 5). Učenje s pojačanjem se koristi za obuku AI modela u složenim sustavima kao što su autonomna vožnja, robotika i proizvodnja, jer pomaže u povećanju automatizacije i optimizaciji operativne učinkovitosti. (Alpaydin, 2010). Dakle učenje s pojačanjem se fokusira na donošenje odluka od strane autonomnih agenata. Autonomni agent je svaki sustav sposoban donositi odluke i djelovati u skladu sa svojim okruženjem, bez potrebe za neposrednim uputama od strane ljudi. U učenju s pojačanjem, autonomni agent stječe sposobnost izvršavanja zadataka metodom pokušaja i pogrešaka bez ikakvog vodstva od strane ljudi. Ova metoda se posebno bavi sekvencijalnim problemima donošenja odluka u neizvjesnim okruženjima. Učenje s pojačanjem uključuje interakciju između agenta, okoline i cilja. Primjer ovog procesa je Markovljev proces odlučivanja, gdje agent učenja s pojačanjem stječe znanje o problemu kroz interakciju s okolinom. Okolina pruža agentu informacije o trenutnom stanju, koje on koristi za odabir svojih akcija. Ako neka akcija dovede do nagradnog signala iz okoline, agent će biti motiviran da tu akciju ponovi u sličnim budućim situacijama. Ovaj proces se kontinuirano ponavlja za svako novo stanje. S vremenom, agent uči kroz nagrade i kazne koje akcije treba poduzeti u određenom okruženju kako bi postigao željeni cilj. (Sutton i Barto, 2014).



Slika 5. Učenje s pojačanjem

### 2.3. Modna industrija i strojno učenje

Moda je „način odijevanja svojstven određenom razdoblju, društvu, skupini. Pojam se primjenjuje i na frizuru, nakit, dekoraciju interijera, pravila ponašanja i načine zabavljanja pa i općenito na tendencije u kulturi i umjetnosti. U tom smislu, moda je jedan od najistančanijih pokazatelja ukusa epohe, koji je pak jedan od temelja estetskog i kritičkoga vrednovanja nekoga povijesnog razdoblja“ („Moda“, bez dat.).

U doba velikog i brzog digitalnog napretka i brzine razvijanja modnih trendova i potrebe za novitetima, modne industrije sve više prihvataju i uključuju tehnologije kako bi zadržale svoju konkurenčku prednost. Grana umjetne inteligencije, strojno učenje, sve češće se koristi u modnoj industriji bilo to za predviđanje trendova, upravljanje zalihamama, otkrivanje prijevara i segmentacije kupaca, optimizacija cijena i slično. U današnje vrijeme modne industrije se najviše bore s predviđanjem trendova pa i shodno tome problemom održivosti. Konstantna potražnja za novitetima dovodi do prekomjerne proizvodnje, a tradicionalne metode predviđanja temelje se na povijesnim podacima što rezultira težim zadovoljavanjem zahtjeva potrošača (Aptean, 2023). Upravo zbog toga strojno učenje i analiza podataka nude priliku za moguća rješenja problema u modnoj industriji.

Neki od načina na koje strojno učenje utječe na modnu industriju su : predviđanje trendova, personalizacija, upravljanje zalihami, održiva moda, poboljšani marketing i oglašavanje i kontrola kvalitete. Sposobnost predviđanja trendova pomoću strojnog učenja rezultira preciznijim razvojem proizvoda i boljim upravljanjem zalihami. Algoritmi analiziraju velike količine podataka kako bi prepoznali nove modnih trendove. Podaci mogu biti prikupljeni iz društvenih mreža, koje su danas postale najčešće mjesto za reklamiranje i prikazivanje mode, uz to mogu se i koristiti povijesni podaci, promatrati ponašanje potrošača i slično. Također personalizacijom omogućava se veće zadovoljstvo kupaca i potencijalno povećanje prodaje proizvoda. Analizira se prošla kupovna kupca, njegove preferencije i ponašanje te na temelju toga algoritmi predlažu prilagođene individualne preporuke. Kako bi se smanjili viškovi zaliha, ali isto tako i manjak, strojno učenje optimizira razine zaliha s točnim predviđanjem potražnje. Ovaj pristup ne samo da smanjuje količinu otpada i pozitivno utječe na okoliš, već također omogućuje značajne uštede. Pozitivan utjecaj na okoliš ima i održiva moda gdje strojno učenje pomaže kod optimizacije opskrbnog lanca i smanjene potrošnje energije. Nadalje, analizom podataka o klijentima algoritmi mogu prepoznati najbolja mjesta za oglašavanje i najbolje strategije što se kasnije očituje povratom ulaganja za modne industrije. Strojno učenje može se koristiti za identificiranje nedostataka i odstupanja u stvarnome vremenu što osigurava zadovoljavanje najviših standarda proizvoda („IABAC“, 2023).

Ovo su samo neki od primjera uključivanja strojnog učenja u modne industrije te se potencijal tehnologija i strojnog učenja može iskoristiti i na razne druge načine u modnoj industriji. U nastavku ovog poglavlja prikazat će se neka od dosadašnjih istraživanja na temu strojnog učenja i modne industrije.

Samia, Soraya i Malika (2022) provode istraživanje naziva *Fashion Image Classification using Machine Learning, Deep Learning and Transfer Learning Models*. Cilj njihovog istraživanja je korištenje dubokog i strojnog učenja za pravilnu identifikaciju i klasifikaciju slika odjeće. Klasifikacija slika odjevenih stilova korisna je kod e-trgovina, oglašavanja i još mnogo toga. U istraživanju koriste se algoritmi strojnog učenja (potporni vektor, K-najbliži susjed, stablo odlučivanja, slučajna šuma), algoritmi dubokog učenja (CNN - konvolucijska neuronska mreža, AlexNet, GoogleNet, LetNet, LetNet5) i prijenos učenja korištenjem prethodno obučenih modela (VGG16, MobileNet i RestNet50). Podaci su obučeni i testirani pomoću Tensorflow/Keras i Scikit-Learn biblioteka u Pythonu. Metrika koja je bila korištena za procjenu izvedbe strojnog i dubokog učenja je bila točnost i matrica konfuzije. Skup za treniranje sastojao se od 60.000 slika, a skup za testiranje od 10.000 slika. Korištene slike

upotrijebljene su iz *fashion-MNIST* skupa podataka. Svaka slika pripadala je jednoj od 10 klasa (majica/top, hlače, pulover, haljina, kaput, sandala, košulja, tenisica, torba i čizma) te je svakoj klasi pripadalo 6000 slika. Najbolji rezultat za strojno učenje u ovome istraživanju korištenjem umjetne neuronske mreže (eng. ANN – artificial neural networks) imao je 88,71 %, a za duboko učenje korištenjem GoogleNet arhitekture imao je 93,75% što je ukazivalo na to da broj epoha i dubina mreže ima učinak na postizanje boljih rezultata (Samia, Soraya i Malika, 2022).

Di (2020) provodi istraživanje naziva *A comparative research on clothing images classification based on neural network models*. U ovome radu koriste se četiri modela neuronske mreže, a to su: Fully Connected Neural Network (Potpuno povezana neuronska mreža), CNN (konvolucijska neuronska mreža), MobileNet i MobileNet2 te su se koristile za klasifikaciju slika odjevnih predmeta. Skup podataka koji je bio korišten (*fashion-MNIST*) sadržavao je deset kategorija (majica/top, hlače, pulover, haljina, kaput, sandala, košulja, tenisica, torba i čizma) slika u sivim tonovima. Skup za treniranje sastojao se od 60.000 slika, a skup za testiranje sastojao se od 10.000 slika. Rezultati prikazuju kako je MobileNet postigao veću razinu točnosti u odnosu na tradicionalne modele duboke neuronske mreže i konvolucijske neuronske mreže nakon stabilizacije treninga te je MobileNet učinkovitija metoda klasifikacije u odnosu na potpuno povezanu neuronsku mrežu i konvolucijske neuronske mreže s točnošću od 91 % gdje iako je vrijeme za obuku duže točnost je veća.

Rohrmanstorfer, Komarov i Mödritscher (2021) provode istraživanje naslova *Image Classification for the Automatic Feature Extraction in Human Worn Fashion Data*. Kako je nezaobilazan konstantan rast slikovnih podataka postaje nužno automatski obrađivati slikovne informacije. U istraživanju koristi se četiri različita pristupa za uspješno izdvajanje značajki. Skup podataka sastojao se od 2567 slika koje su bile podijeljene u 10 klasa (torba, kaput, haljina, kapa, pulover, košulja, cipele, odijelo, hlače, majica) te su klase unutar skupa podataka imale uravnotežen broj slika. Skup podataka sastojao se od slika ljudi koji su imali odjeću na sebi. Omjerom 80:20 bio je podijeljen skup za obuku i skup za testiranje. Rezultati ovog istraživanja ukazuju na to da su konvolucijske neuronske mreže dobar standard za klasifikaciju slika te da je TensorFlow dobar izbor biblioteke za njihovu izgradnju. Hlače, cipele i šešir su najbolje klasificirani u odnosu na ostale odjevne predmete, te je prikazano da je moguće postupno poboljšati točnost validacije stvorenog skupa s početnih 69 % na konačnih 84 %.

### **3. Nadzirano strojno učenje**

Kao što je već navedeno, nadzirano strojno učenje je tehnika strojnog učenja gdje se model obučava da nauči funkciju pomoću skupa podataka za obuku. Skup podataka za obuku sastoji se od parova ulaznih objekata zajedno s njihovim odgovarajućim izlazima. Izlaz funkcije može biti u obliku regresije odnosno kontinuirane vrijednost i klasifikacije gdje je moguće predvidjeti oznake klase ulaznog objekta. Cilj nadziranog učenja je razviti model koji može s visokom točnošću predvidjeti izlaznu vrijednost funkcije za nove ulazne podatke (Zhang, 2010).

U nadziranom strojnom učenju, proces učenja može se razdvojiti u dvije ključne faze: faza obuke odnosno treniranja i faza testiranja. Tijekom faze obuke, algoritam učenja koristi podatke obuke za stjecanje informacija o značajkama i konstruiranje modela učenja. U sljedećoj fazi, odnosno fazi testiranja, model učenja koristi izvršni mehanizam za generiranje predviđanja za testne podatke. Testni podaci su podaci na kojima model nije treniran, dakle to su još modelu neviđeni podaci. Označeni podaci koje proizvodi model učenja predstavljaju konačno predviđene ili klasificirane podatke. U problemima klasifikacije, nadzirano učenje je tehnika koja se najčešće koristi jer ima za cilj osposobiti stroj da nauči unaprijed određen sustav klasifikacije. Ovaj proces rezultira skupom podataka koji se sastoji od značajki i pripadajućih oznaka (Nasteski, 2017).

„Algoritam učenja koristi skup značajki kao ulazne podatke s točnim izlazima. Algoritam uči tako da uspoređuje svoje stvarne izlaze s točnim izlazima kako bi identificirao greške. Zatim prilagođava model na temelju tih pogrešaka“ (Nasteski, 2017). Nadzirano učenje najčešće se koristi za obuku neuronskih mreža i stabala odlučivanja. Neuronske mreže i stabla odlučivanja oslanjaju se na podatke koje pruža unaprijed definirana klasifikacija i koristi se za predviđanje vjerojatnih događaja na temelju prijašnjih podataka. Jedan od primjera nadziranog učenja može biti aplikacija za predviđanja vrste perunike na temelju mjera njenog cvijeta. Zadaci učenja pod nadzorom podijeljeni su u dvije kategorije: klasifikacija (diskretna oznaka) i regresija (kontinuirana oznaka) (Nasteski, 2017).

### **3.1. Regresija**

Regresija je „modeliranje (predviđanje) ciljne numeričke vrijednosti“ (Jović, 2019). Također Jović (2019) navodi i neke primjere regresije „predviđanje kretanja cijena dionica, predviđanje težine na temelju visine i predviđanje cijena kuće/stana na temelju različitih parametara“ (Jović, 2019). Kod regresije kao oblika nadziranog strojnog učenja algoritmi uče iz podataka kako bi predvidjeli kontinuirane vrijednosti. Primjeri kontinuiranih vrijednosti mogu biti temperatura, težina, cijena. Alpaydin (2010) navodi primjer regresije kao oblik nadziranog strojnog učenja na primjeru predviđanja cijene rabljenog automobila. Određeni unosi su atributi automobila i to mogu biti marka, godina, kilometraža, za koje je poznato da utječu na samu cijenu i vrijednost automobila. Izlaz je cijena automobila. Kada je izlaz numerička vrijednost odnosno broj tada se to naziva regresijskim problemom. Oznakom  $X$  označavaju se atributi automobila, odnosno to je ulaz, a oznakom  $Y$  cijena, odnosno izlaz. Pregledavanjem prijašnjih transakcija mogu se prikupiti podaci o obuci te program strojnog učenja prilagođava funkciju prema tim podacima kako bi mogao naučiti  $Y$  kao i funkciju  $X$  (Alpaydin, 2010).

### **3.2. Klasifikacija**

Klasifikacija je definirana kao „razvrstavanje primjerka u određenu klasu (dvije klase, više klase)“ (Jović, 2019). Također Jović (2019) navodi primjere klasifikacije za dvije klase: „analiza sentimenata (dvije ciljne klase – zadovoljan, nezadovoljan) i detekcija atrijske fibrilacije (dvije ciljne klase – da/ne)“ i više klase: „kategorizacija proizvoda i klasifikacija biljne vrste“ (Jović, 2019) i klasifikacija legitimne i neželjene pošte (Kovač i sur., 2022, Seljan i sur., 2023, Dundjer i sur., 2023).

Klasifikacija je oblik nadziranog strojnog učenja u kojem algoritmi koriste podatke i uče iz njih kako bi predvidjeli buduće ishode ili događaje. Alpaydin (2010) objašnjava primjenu klasifikacije na primjeru banke. Banka može koristiti podatke o klijentima, poput kreditne povijesti i ulaganja, kako bi predvidjela hoće li određeni klijent ispuniti svoje obveze. Klasifikacijski algoritmi koriste se za predviđanje diskretnih ishoda. Postoji **binarna klasifikacija** koja prima dvije moguće vrijednosti, na primjer da ili ne i **višeklasna klasifikacija** kada postoji više od dvije vjerojatnosti (Alpaydin, 2010).

### **3.3. Algoritmi nadziranog strojnog učenja**

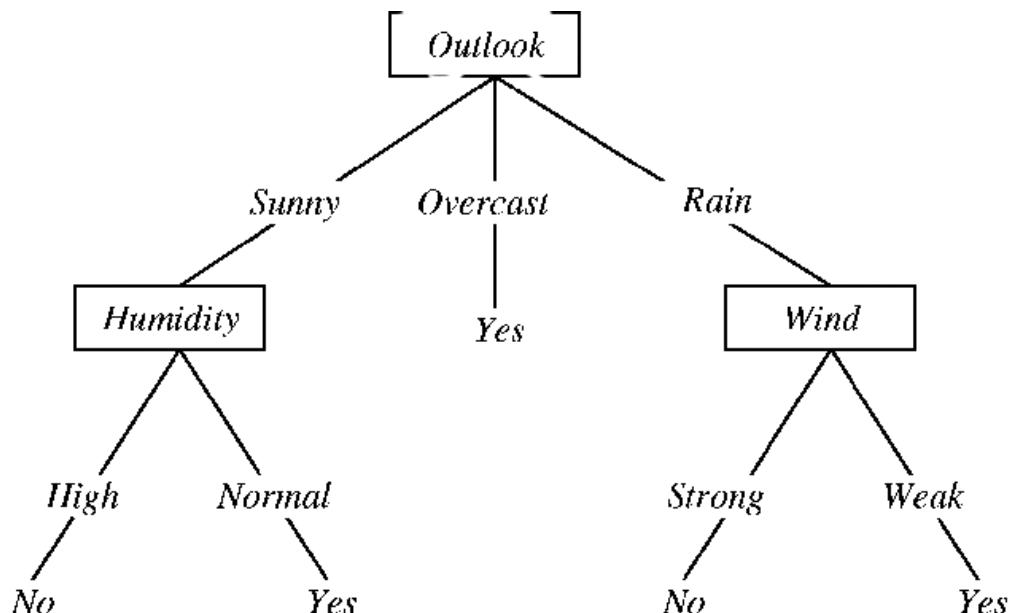
Nadzirano strojno učenje podrazumijeva različite algoritme, a neki od algoritama nadziranog strojnog učenja su: stablo odlučivanja (eng. Decision tree), naivni Bayesov algoritam (eng. Naive Bayes), linearna regresija (eng. Linear regression), logistička regresija (eng. Logistic regression) i stroj s potpornim vektorima (eng. Support vector machines) (Mahesh, 2020).

#### **3.3.1. Stablo odlučivanja**

Mahesh (2020) definira stablo odlučivanja (eng. Decision tree) kao „grafikon koji predstavlja izbore i njihove rezultate u obliku stabla. Čvorovi na grafu predstavljaju događaj ili izbor, a rubovi grafa predstavljaju pravila ili uvjete odlučivanja.“ (Mahesh, 2020).

Stablo odlučivanja (Slika 6) je klasifikator koji klasificira instance sortirajući ih prema vrijednostima njihovih značajki. Stablo odlučivanja sastoji se od čvorova koji tvore korijensko stablo i predstavlja značajku u instanci koju treba klasificirati. Korijensko stablo je prema tome distribuirano stablo s osnovnim čvorom bez ulaznih rubova. Kod stabla odlučivanja, grane predstavljaju vrijednost koju čvor može preuzeti, a instance se klasificiraju počevši od korijenskog čvora, gdje se sortiraju prema vrijednostima vlastitih značajki. Svi ostali čvorovi imaju jedan dolazni rub. Testni čvor je naziv za čvor koji ima odlazne rubove, a listovi su svi ostali čvorovi. „U stablu odlučivanja, svaki testni čvor dijeli prostor instanci na dva ili više podprostora, ovisno o određenim funkcijama ulaznih vrijednosti“ (Nasteski, 2017). U jednostavnijem slučaju, svaki test promatra jedan atribut, a prostor instanci se dijeli na temelju vrijednosti tog atributa. Za numeričke attribute, uvjet se temelji na određenom rasponu. Svaki list stabla povezan je s određenom klasom koja predstavlja najprikladniju ciljnu vrijednost, a može sadržavati i vektor vjerojatnosti koji prikazuje kolika je vjerojatnost da ciljni atribut ima određenu vrijednost. Instance se klasificiraju kretanjem od korijena stabla prema dolje, prolazeći kroz testove duž puta sve do lista. Kod uporabe stabla odlučivanja, svaki čvor je označen atributom koji testira, dok njegove grane predstavljaju pripadajuće vrijednosti atributa. Kod numeričkih atributa, stablo odlučivanja može se geometrijski interpretirati kao skup hiperravnina, pri čemu je svaka hiperravnina okomita na jednu od osi (Nasteski, 2017).

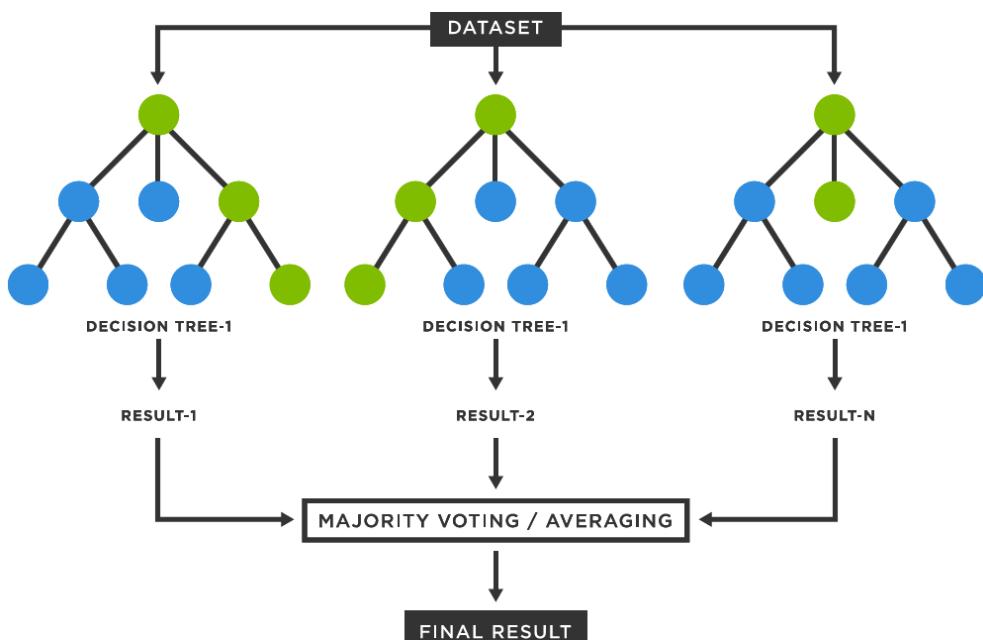
Primjena stabla odlučivanja najčešća je kod rudarenja podataka i u strojnog učenju kao modelu koji preslikava opažene podatke o stavci u zaključke o ciljnoj vrijednosti stavke. Ovakva stabla nazivaju se regresijska stabla ili klasifikacijska stabla. Klasifikatori stabala odlučivanja obično koriste metode naknadnog rezanja koje procjenjuju učinkovitost stabala odlučivanja dok se skraćuju pomoću skupa za provjeru valjanosti odnosno validacijskog skupa. Bilo koji čvor može se ukloniti i zamijeniti najčešćom klasom u skupu za obuku, koja se određuje prema učestalosti pojavljivanja (Akinsola i sur., 2017). Stablo odlučivanja funkcioniра na temelju sljedećeg principa. Algoritam kreće od vrha odnosno od korijenskog čvora koji predstavlja cijeli skup podataka, zatim algoritam traži najvažniju značajku koja najbolje dijeli podatke u različite skupine, ovaj dio se obavlja kao postavljanje pitanja na dijelu račvanja stabla. Na osnovu odgovora na pitanja, podaci se dijele u manje podskupove koji stvaraju nove grane. Svaka grana predstavlja jedan od mogućih putova kroz stablo. Ovaj postupak algoritam ponavlja, postavlja pitanja i dijeli podatke u svakoj grani dok ne dođe do konačnih lisnih čvorova koji predstavljaju predviđene ishode (Saini, 2024).



Slika 6. Jednostavan prikaz stabla odlučivanja

### 3.3.2. Slučajna šuma

Algoritam slučajne šume (eng. Random tree forest) je temeljen na algoritmu višestrukih stabla odlučivanja. Razlika između stabla odlučivanja i slučajne šume je u tome što stablo odlučivanja koristi jedno stablo, dok slučajna šuma koristi više stabala odlučivanja za donošenje prosudbi. Svako stablo u slučajnoj šumi gradi se koristeći nasumični podskup podataka, pri čemu se za svaku particiju mjeri nasumični podskup značajki. Ovaj pristup uvodi varijabilnost među pojedinačnim stablima, smanjujući rizik od prekomjernog opremanja i poboljšavajući ukupnu izvedbu predviđanja. Slučajna šuma (Slika 7) se temelji na rekurziji. Stvara se grupa stabala odlučivanja, a metoda pakiranja koristi se za njihovu obuku. Prednost je ta što je algoritam neosjetljiv na šum te se zbog toga može koristiti za neuravnotežene skupove podataka (Jayatilake i Ganegoda, 2021). Algoritam slučajne šume djeluje tako da se za izgradnju svakog stabla odlučivanja odabire slučajni podskup podatkovnih točaka i značajki. Za svaki uzorak se konstruira posebno stablo odlučivanja, koje zatim pruža svoj izlaz. Konačni rezultat određuje se glasovanjem većine ili prosjekom za klasifikaciju i regresiju (Sruthi, 2024).



Slika 7. Slučajna šuma

### 3.3.3. Naivni Bayesov algoritam

Naivni Bayesov (eng. Naive Bayes) algoritam se svodi na primjenu Bayesovog teorema. Bayesov teorem je matematička formula koja se koristi za izračunavanje vjerojatnosti, a uvjetna vjerojatnost je vjerojatnost da će se ishod dogoditi s obzirom na to da se drugi događaj već dogodio (Slika 8). Naivni Bayesov algoritam je nadzirana metoda strojnog učenja i statistička metoda za klasifikaciju, a predviđa da vjerojatnost za svaku klasu pripada određenoj klasi i da je klasa s najvećom vjerojatnošću klasa za koju se smatra da će se pojaviti najvjerojatnije. Glavna svrha Bayesove klasifikacije je mogućnost rješavanja problema predviđanja. Neke od prednosti koje pruža su praktični algoritmi učenja, mogućnost kombiniranja promatranih podataka, pruža i korisnu perspektivu za razumijevanje i procjenu algoritama učenja i izračunava eksplizitne vrijednosti za hipotezu i uklanja šum u ulaznim podacima (Nasteski, 2017). Prema Mahesh (2020), naivni Bayesov algoritam uglavnom se primjenjuje u industrijama za klasifikaciju teksta te se najčešće koristi za grupiranje, a sama svrha klasifikacije ovisi o uvjetnoj vjerojatnosti događanja.

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)}$$

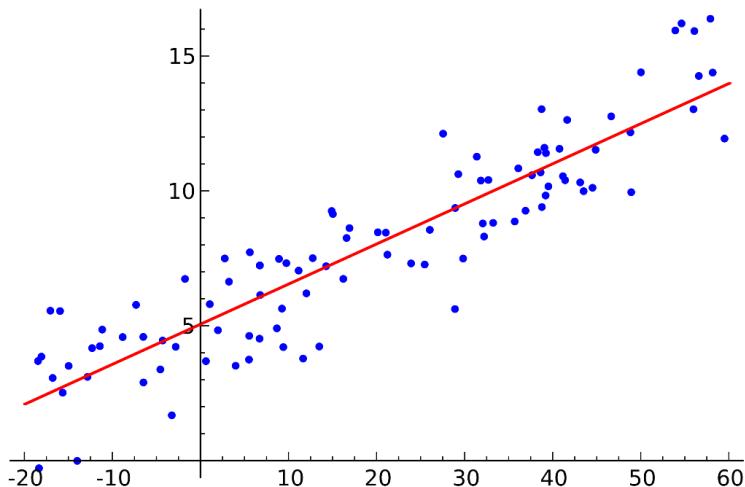
Likelihood                      Class Prior Probability  
↓                                  ↓  
Posterior Probability            Predictor Prior Probability

$$P(c | X) = P(x_1 | c) \times P(x_2 | c) \times \cdots \times P(x_n | c) \times P(c)$$

Slika 8. Matematička formula - Naive Bayes

### 3.3.4. Linearna regresija

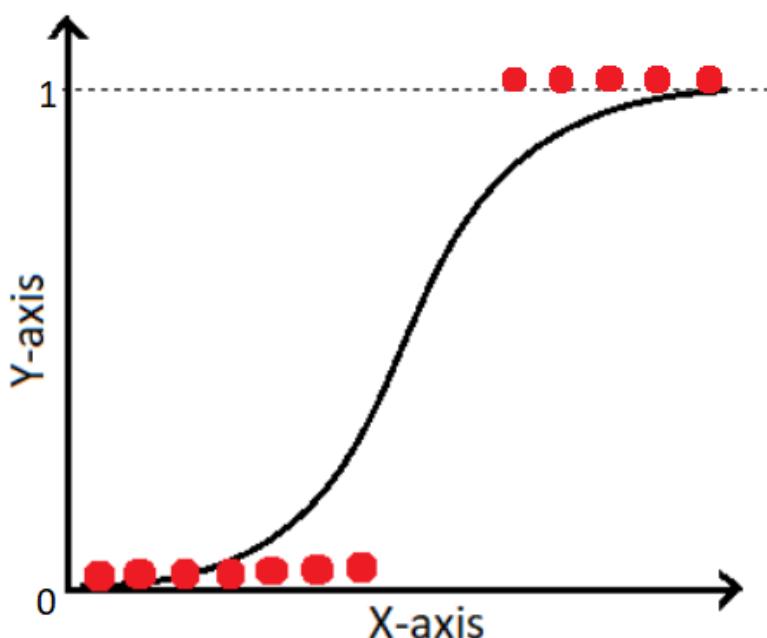
Linearna regresija (eng. Linear regression) može se opisati kao jedna od jednostavnijih oblika algoritama strojnog učenja. Linearna regresija koristi se za učenje predviđanja kontinuirane vrijednosti na temelju značajki u skupu podataka za obuku. Promjene vrijednosti nezavisne varijable imaju utjecaj na vrijednost zavisne varijable, koja predstavlja učinak. Linearna regresija pripada algoritmima nadziranog učenja gdje se tada obučava model na skupu označenih podataka koji se još nazivaju podaci za obuku ili treniranje, a zatim se koristi model za predviđanje oznaka na neoznačenim podacima (Nasteski, 2017). U nastavku (Slika 9) prikazana je slika linearne regresije. Crveni pravac izračunat je na temelju skupa podataka za obuku, gdje svaka točka ima poznatu oznaku, s ciljem što preciznijeg usklađivanja točaka minimiziranjem vrijednosti odgovarajuće funkcije gubitka (Nasteski, 2017).



Slika 9. Linearna regresija

### 3.3.5. Logistička regresija

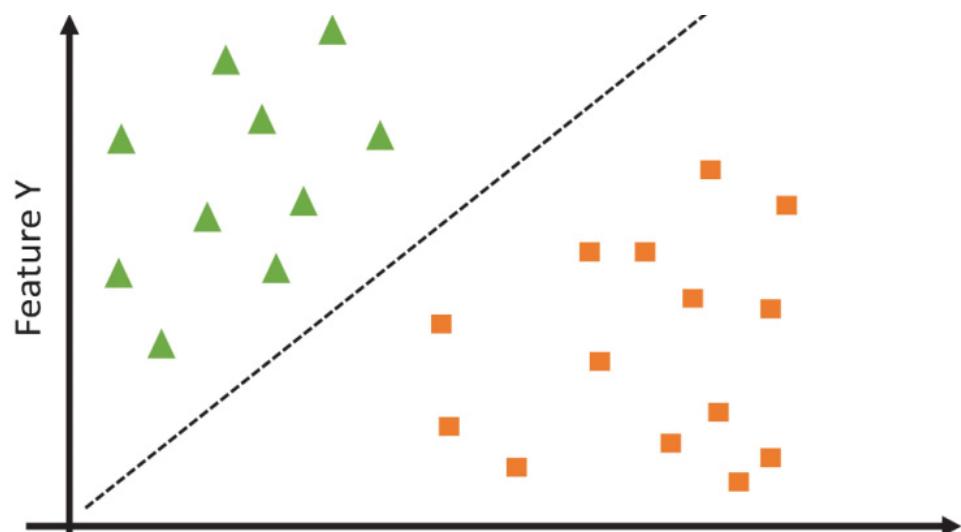
Logistička regresija (eng. Logistic regression) opisuje se kao linearne regresije s ciljnom varijablom koja se označava kao  $Y$  koja je diskretna, (Slika 10). Logistička regresija koristi *logit* funkciju te daje predviđanja o vjerojatnosti da će se dogoditi binaran događaj (Nasteski, 2017). „Ova vrsta regresije predviđa vjerojatnost pojavljivanja događaja prilagođavanjem podataka logističkoj funkciji. Kao i ostali oblici regresijske analize, tako i ova, logistička, koristi prediktorske varijable koje mogu biti numeričke ili kategoričke“ (Nasteski, 2017). Logistička regresija navodi gdje postoje granice između klase te navodi da vjerojatnosti klase ovise o udaljenosti od granice u specifičnom pristupu. Što je skup podataka veći tako se procjene pomiču prema ekstremima, koji su 0 i 1. Također, logistička regresija daje snažna i detaljna predviđanja, no predviđanja mogu biti pogrešna. Najčešće se logistička regresija koristi za primjenjenu statistiku i analizu diskretnih podataka (Akinsola, 2017).



Slika 10. Logistička regresija

### 3.3.6. Stroj s potpornim vektorima

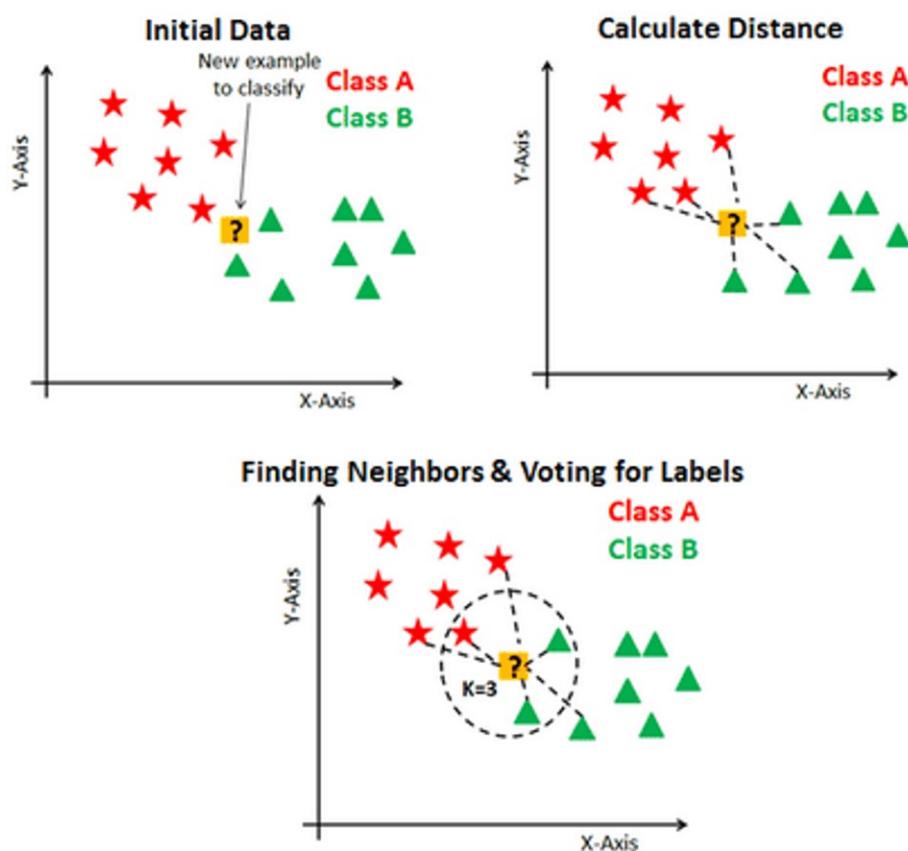
Stroj potpornih vektora (eng. Support vector machines) je model nadziranog strojnog učenja koji se najčešće koristi za probleme klasifikacije, konstruiranje hiperravnine gdje je udaljenosti između dvije klase podatkovnih točaka najveća (Slika 11). Hiperravnina naziva se još i granica odluke zbog toga što odvaja klase podatkovnih točaka s obje strane ravnine. Granica odluke na primjer može odvajati pse u odnosu na mačke. Pojam *margina* odnosi se na udaljenost između razdvajajuće hiperravnine i instanci na obje strane (Akinsola, 2017). „Pokazalo se da maksimiziranje margine, odnosno dobivanje najveće moguće udaljenosti između hiperravnine i instanci s obje strane, smanjuje gornju granicu očekivane pogreške generalizacije“ (Akinsola, 2017).



Slika 11. Stroj s potpornim vektorima

### 3.3.7. K-najbliži susjed

K-najbliži susjed (eng. K-nearest neighbour, KNN) je metoda nadziranog strojnog učenja koja procjenjuje blizinu jedne podatkovne točke prema drugoj podatkovnoj točki kako bi se odlučilo mogu li se dvije podatkovne točke grupirati (Slika 12). Sama blizina odnosno udaljenost između podatkovnih točaka predstavlja stupanj do kojeg su one međusobno usporedive (Jayatilake i Ganegoda, 2021). „Predviđanje za novu instancu postiže se pronalaženjem najsličnijih instanci, a zatim sažimanjem izlazne varijable prema sličniminstancama“ (Jayatilake i Ganegoda, 2021). Za već spomenuto izračunavanje udaljenosti koristi se euklidska udaljenost. Skup podataka za obuku predstavljen je kao skup vektora u višedimenzionalnom prostoru značajki, pri čemu svaki vektor ima pridruženu oznaku klase. Ova metoda nadziranog strojnog učenja najčešće se koristi kod prepoznavanja uzorka, rudarenju podataka, otkrivanju upada i slično (Jayatilake i Ganegoda, 2021).



Slika 12. K-najbliži susjed

## 4. Metrike evaluacije

Evaluacija se definira kao „procjena, čin ili proces utvrđivanja ili procjenjivanja vrijednosti neke stvari, izražene u novčanim jedinicama“ (Hrvatska enciklopedija, bez dat.). Prema tome metrike evaluacije omogućuju kvantificiranje izvedbe modela strojnog učenja. Uz dobru pripremu podataka i samu obuku modela strojnog učenja sastavni dio ovog procesa je i evaluacija. Evaluacija pruža informacije o izvedbi obučenog modela te daje do znanja gdje je model izvrstan, gdje je podbacio te također omogućuje podešavanje algoritama tako da se postignu što bolji krajnji rezultati. Ukoliko nema evaluacije ne može se utvrditi ostvarivanje ciljeva, implementacija i daljnji razvoj modela (Vujović, 2021).

U klasifikaciji je važan zadatak predviđanje ciljne varijable koja je u obliku diskretnih vrijednosti. Važnost evaluacije klasifikacijskih modela leži u **razumijevanju izvedbe modela**, gdje metrike pružaju mjere za razumijevanje izvedbe modela, **odabiru modela**, gdje se omogućava dobra procjena kod odabira najboljeg modela, **poboljšanju modela**, koje pomaže kod prepoznavanja područja u kojima model ima lošu izvedbu, a analizom ovih područja mogu se obaviti potrebna poboljšanja modela, **otkrivanju prekomjernog prilagođavanja**, gdje model daje dobre rezultate na podacima za treniranje odnosno obuku, ali loše na nevidljivim podacima. Može se poboljšati pravilnom procjenom pomoću skupa za provjeru valjanosti. Najčešće metrike evaluacije u modelima klasifikacije su: točnost, preciznost i odziv, F1 mjera, matrica konfuzije, AUC-ROC (Područje ispod krivulje i radna karakteristika prijemnika) i log gubitak (Erickson i Kitamura, 2021).

**Točnost (eng. accuracy )** mjeri točnost predviđanja klasifikatora odnosno točnost je omjer broja točnih predviđanja prema ukupnom broju predviđanja. (Vujović, 2021).

Formula (Slika 13) za točnost se izvodi zbrajanjem slučajeva u kojima model točno predviđa pozitivnu klasu (True positives, TP) i slučajeva u kojima model točno predviđa negativnu klasu (True negatives, TN) te dijeljenjem tih rezultata sa zbrojenim ukupnim TP (točno predviđena pozitivna klasa), TN (točno predviđena negativna klasa), FP (netočno predviđena pozitivna klasa) i FN (netočno predviđena negativna klasa). Prema ovome izračunu dobivamo točna predviđanja, no točnost sama po sebi ne daje cijelu sliku izvedbe modela te je potrebno koristiti i druge metrike kako bi se to ostvarilo (Vujović, 2021).

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

Slika 13. Formula za izračunavanje točnosti

Dakle točnost kao rezultat daje koliko je predviđanja model ostvario od ukupnih predviđanja te je točnost postavljena kao vrijednost između 0 (sva predviđanja su pogrešna) i 1 (točno predviđanje svih slučajeva). Primjerice ako je točnost nekog modela 0,76 to ukazuje na to da je taj model točan 76% vremena. Također nekad visok postotak točnosti ne mora ukazivati na to da je model dobar. Ukoliko je visok postotak, a skup s podacima neuravnotežen tada će se kao rezultat pojavljivati visok postotak a model neće biti koristan jer prepoznaje samo klasu koja je najzastupljenija (Vujović, 2021).

**Preciznost i odziv (eng. Precision and recall)** su metrike koje se koriste za evaluaciju klasifikacijskih modela. **Preciznost** je mjera koja opisuje koliko je od svih slučajeva koje je model klasificirao kao pozitivne stvarno bilo pozitivnih. Preciznost se javlja kao korisna metrika kada je veći problem kod lažno pozitivnih rezultata nego kod lažno negativnih odnosno visoka preciznost prikazuje nisku stopu lažno pozitivnih predviđanja. Dakle preciznost mjeri točnost ili kvalitetu modela. Ako model ima preciznost od 0,8 to ukazuje da je 80 % slučajeva bilo pozitivno i tako ih je i model predvidio („Evaluation Metrics in Machine Learning“, 2024).

Matematički se preciznost prikazuje na ovaj način (Slika 14):

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

Slika 14. Formula preciznosti

Formula za izračunavanje preciznosti izvodi se dijeljenjem točnih pozitivnih rezultata (True positive, TP) s brojem predviđenih pozitivnih rezultata gdje se u tome slučaju zbrajaju slučajevi

u kojima model točno predviđa pozitivnu klasu (True positive, TP) i slučajevi u kojima model netočno predviđa pozitivnu klasu (False positive, FP) (Dalianis, 2018).

Postoje još i **prosječna preciznost i srednja prosječna preciznost** (eng. **Average precision – AP, Mean average precision -mAP**). Prosječna preciznost izračunava područje ispod krivulje preciznosti i odziva gdje daje jednu vrijednost koja sažima preciznost i performanse odziva modela, dok srednja prosječna preciznost izračunava prosječnu AP vrijednost u više klasa objekata. Srednja prosječna preciznost je korisna kod otkrivanja objekata s više klasa kako bi se pružila sveobuhvatna procjena performansa modela. Niska srednja prosječna preciznost znači da bi model trebao poboljšanje („YOLO Performance Metrics“, bez dat.).

**Odziv** objašnjava koliko je model ispravno klasificirao slučajeve od svih stvarnih pozitivnih slučajeva. U ovome slučaju odziv je koristan kada je FN (lažno negativan) veći problem nego FP (lažno pozitivan). Dakle odziv omogućuje mjeru postupnosti ili količine modela; visoka razina odziva prikazuje nisku stopu lažno negativnih predviđanja. Ako model daje odziv od 0,8 to ukazuje na to da je model uočio 80 % pozitivnih slučajeva (Dalianis, 2018). Matematički se odziv prikazuje na ovaj način (Slika 15):

$$\text{Recall} = \frac{TP}{TP + FN}$$

Slika 15. Formula odziva

Formula za izračunavanje odziva izvodi se dijeljenjem točnih pozitivnih rezultata (True positive, TP) s brojem predviđenih pozitivnih rezultata gdje se u tome slučaju zbrajaju slučajevi u kojima model točno predviđa pozitivnu klasu (True positive, TP) i slučajevi u kojima model netočno predviđa negativnu klasu (False negative, FN) (Dalianis, 2018).

**F1 mjera** je metrika koja se najčešće koristi kod neuravnoteženih podataka. „Izražava se kao harmonijska sredina preciznosti i odziva“ (Dalianis, 2018). Rezultat F1 mjere će biti visok ako su i preciznost i odziv visoki. Dakle, F1-mjera kombinira preciznost i odziv te pruža ravnotežu između njih. Raspon F1 mjere seže od 0 (i preciznost i odziv su 0 ili je jedan od njih 0) do 1 (savršena preciznost i odziv) te ova metrika evaluacije govori koliko je klasifikator precizan i robustan. Ako su rezultati F1 mjere viši to znači da model ima manje lažno pozitivnih i manje

lažno negativnih rezultata, a ako su rezultati F1 mjere niži to znači da model ima ili previše lažno pozitivnih rezultata ili previše lažno negativnih rezultata (Dalianis, 2018). Matematički se F1 mjera prikazuje na ovaj način (Slika 16):

$$F1Score = \frac{2 * Precision * Recall}{Precision + Recall}$$

Slika 16. Formula F1 mjere

Formula za izračunavanje F1 mjere je harmonijska sredina preciznosti i odziv. Rezultat se dobiva izračunavanjem prosjeka preciznosti i odziva (Gubrani, 2024).

**Matrica konfuzije** je evaluacijska metrika za mjerjenje performansi modela u problemima klasifikacije strojnog učenja, gdje izlaz može pripadati dvjema ili više klase. Matrica konfuzije (Slika 17) je prikazana i definirana kao tablica koja se koristi za opisivanje izvedbe klasifikacije na testnom skupu podataka za koje su poznate prave vrijednosti. Matrica konfuzije je korisna za mjerjenje odziva, preciznosti, točnosti i AUC-ROC i predstavlja rezultate klasifikacije (Colliot, 2023).

		true	
		1	0
predicted	1	TP	FP
	0	FN	TN

Slika 17. Prikaz matrice konfuzije

**Kod binarne klasifikacije** gdje su dvije klase, matrica konfuzije dijeli ispitne uzorke u 4 kategorije na temelju njihove istinitosti i predviđenih oznaka: točno pozitivni (TP- predviđanje je bilo pozitivno i to je istina, označava se s 1), točno negativni(TN-predviđanje je bilo negativno i to je istina, označava se s 0), lažno pozitivni(FP- naziva se još i pogreška tipa 1,

gdje se predviđa pozitivno, a zapravo je lažno) i lažno negativni (FN- naziva se još i pogreška tipa 2, gdje se predviđa negativno i to je lažno) (Kumar, 2024).

Kod klasifikacije s više klasa, matrica konfuzije pruža rezultate toga koliko dobro model radi u više klase pružajući uvide u to gdje je došlo do problema i gdje model dobro funkcionira (Gubrani, 2024). **Višeklasna matrica konfuzije** također se sastoji od točno pozitivnih (TP), točno negativnih (TN), lažno pozitivnih (FP) i lažno negativnih (FN) predikcija za svaku klasu. Višeklasna matrica se može interpretirati na više načina: dijagonalno, preciznost, odziv i F1 rezultat za svaku klasu, makro i mikro-prosjeci, klasne neravnoteže i prilagodbe i tehnike vizualizacije („Multiclass Confusion Matrix - All That You Need to Know“, 2024).

Kod dijagonalne interpretacije rezultata promatraju se dijagonalni elementi matrice zbog toga što oni predstavljaju slučajeve gdje je model točno predvidio klasu. Preciznost, odziv, F1 mjera mogu se izračunati za svaku klasu posebno. Makro i mikro-prosjeci se koriste za prikaz ukupne izvedbe modela, gdje makro-prosjek izračunava mjerne podatke neovisno za svaku klasu i zatim ih izračunava prosjekom, a mikro-prosjek agregira doprinose svih klasa za izračun prosječne metrike. Klasne neravnoteže i prilagodbe gdje klase s manje instanci mogu neproporcionalno utjecati na izvedbu. Tehnike vizualizacije upućuju na korištenje vizualnih alata kako bi se poboljšala interpretabilnost matrice zabune („Multiclass Confusion Matrix - All That You Need to Know“, 2024).

Primjer izračunavanja matrice zabune za 3 klase može se prikazati na primjeru skupa podataka o perunici. Kada je matrica konfuzije ispisana (Slika 18) moguće je izračunati vrijednosti TP, TN, FN i FP za vrstu Setosa: TP = 5 (predviđene vrijednosti se podudaraju sa stvarnim vrijednostima), TN = 10 (izračunava se zbrajanjem svih vrijednosti koje ne pripadaju retku i stupcu za klasu koju promatramo), FP = 0 (zbroj svih vrijednosti u stupcu koji promatramo, osim TP), FN = 0 (zbroj svih vrijednosti u retku koji promatramo, osim za TP). Dalje se izračunavaju vrijednosti TP, TN, FP i FN za versicolor vrste: TP = 3, TN = 10, FP = 1, FN = 1. Na kraju se izračunava vrijednosti TP, TN, FP i FN za vrste virginica: TP = 5, TN = 8, FP = 1, FN = 1. Na ovaj način mogu se dobiti TP, TN, FP i FN vrijednosti za svaku od klase (Tablica 1) („Multiclass Confusion Matrix - All That You Need to Know“, 2024).

		Predicted Values			
		Setosa	Versicolor	Virginica	Row Total
Actual Values	Setosa	5	0	0	5
	Versicolor	0	3	1	4
	Virginica	0	1	5	6
	Column Total	5	4	6	15

Slika 18. Višeklasna matrica konfuzije

Tablica 1. Matrica konfuzije - TP, TN, FP i FN vrijednosti za svaku klasu

Klasa	TP	TN	FP	FN
Setosa	5	10	0	0
Versicolor	3	10	1	1
Virginica	5	8	1	0

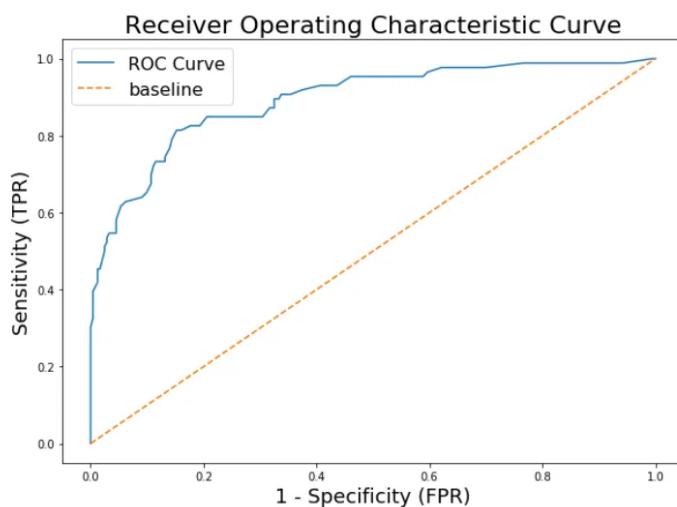
**AUC-ROC (eng. Area under the Receiver Operating Characteristic Curve - Područje ispod krivulje i radna karakteristika prijemnika)** najčešće se koriste za procjenu izvedbe modela u zadacima binarne klasifikacije. ROC krivulja je dijagram koji iscrtava pravu pozitivnu stopu odnosno opoziv (TPR, eng. True positive rate) naspram lažno pozitivne stope odnosno udio negativnih slučajeva koji su netočno klasificirani kao pozitivni (FPR, eng. False positive rate) pri različitim postavkama praga i odvaja signal od šuma (Kumar, 2024). Formule za izračunavanje ROC krivulje (Slika 19) :

$$TPR = \frac{TruePositives}{TruePositives + FalseNegatives}$$

$$FPR = \frac{FalsePositives}{FalsePositives + TrueNegatives}$$

Slika 19. Formule za izračun ROC krivulje

TPR mjeri udio točnih pozitivnih rezultata koju su ispravno prepoznati kao takvi. TPR se dobiva dijeljenjem točnih pozitivnih rezultata (True positive, TP) sa zbrojem slučajeva u kojima model točno predviđa pozitivnu klasu (True positive, TP) i slučajeva u kojima model netočno predviđa negativnu klasu (False negative, FN). FPR mjeri udio negativnih rezultata koji su pogrešno prepoznati kao pozitivni. TPR se dobiva dijeljenjem lažnih pozitivnih rezultata (False positive, FP) sa zbrojem slučajeva u kojima model netočno predviđa pozitivnu klasu (False positive, FP) i slučajeva u kojima model točno predviđa negativnu klasu (True negative, TN) (Kumar, 2024). AUC označava područje ispod ROC krivulje (Slika 20) i mjeri cijelo dvodimenzionalno područje ispod cijele ROC krivulje od (0,0) do (1,1). 1 označava savršen klasifikator, od 0,5 označava nasumičnu klasifikaciju, a manje od 0,5 ukazuje na loš model (Kumar, 2024).



Slika 20. Prikaz ROC krivulje

**Log gubitak (eng. Log loss)** odnosno logaritamski gubitak je važan kod problema binarne klasifikacije. Log gubitak uzima u obzir rezultate vjerojatnosti koje je proizveo klasifikator. Također, los gubitak je značajan zbog toga što pruža nijansiran pogled na performanse modela i koristan je kod pregleda pouzdanosti predviđanja. Dakle, ova metrika pruža mjeru pogreške za modele klasifikacije te je ključno da manja vrijednost ukazuje na bolju izvedbu modela. Na primjer, ako je rezultat 0, to znači da model ima savršen log gubitak (svaka predviđena vjerojatnost za stvarnu klasu je 1), gornje granice za veličine gubitka nema nego se u pravilu gleda na to što su lošija predviđanja modela to je veći log gubitak (Kumar, 2024).

Matematička formula za log gubitak (Slika 21) :

$$LogLoss = -\left(\frac{1}{n}\right) \sum y * \log(\hat{y}) + (1 - y) * \log(1 - \hat{y})$$

Slika 21. Formula za log gubitak

Log gubitak se izračunava koristeći predviđene vjerojatnosti koje generira klasifikator u odnosu na stvarne oznake.  $N$  označava ukupan broj uzoraka,  $y$  je stvarna oznaka klase,  $\hat{y}$  je predviđena vjerojatnost da uzorak pripada klasi 1 i  $\Sigma$  se odnosi na sve uzorke u skupu podataka (Kumar, 2024).

## 5. Računalni vid

Računalni vid je područje umjetne inteligencije koje koristi neuronske mreže i strojno učenje kako bi omogućilo računalima i sustavima da analiziraju i interpretiraju informacije iz digitalnih slika, videa i slično. Dok računalni vid funkcioniра slično ljudskom vidu, ljudi imaju prednost zbog dugogodišnjeg iskustva u prepoznavanju i razlikovanju objekata, procjenjivanju udaljenosti, praćenju kretanja i drugih zadataka. Računalni vid omogućuje računalima da preuzmu ove zadatke koristeći kamere, algoritme i podatke, umjesto ljudske mrežnice. („International Business Machines [IBM]“, bez dat.).

Računalni vid zahtijeva veliku količinu podataka. Kroz ponavljanu analizu tih podataka, sustav postupno uči prepoznavati razlike i na kraju identificirati slike. Na primjer, da bi se računalo sposobilo za prepoznavanje bicikala, potrebno je unijeti veliki broj slika bicikala i sličnih objekata kako bi naučilo razlikovati i prepoznati bicikle. Ovaj cilj može se postići korištenjem dvije ključne tehnologije: duboko učenje i konvolucijska neuronska mreža (CNN) („IBM“, bez dat.).

Primjeri zadataka računalnog vida uključuju **klasifikaciju slika** gdje sustav može vidjeti sliku i klasificirati je (mačka, naranča, lice osobe). Dakle, sposoban je precizno predvidjeti kojoj klasi pripada određena slika. Na primjer, klasifikacija slika može se primijeniti na društvenim mrežama za automatsko prepoznavanje i filtriranje nepoželjnih sadržaja koje korisnici postavljaju. Ova tehnika omogućava sustavima da prepozna slike koje krše pravila zajednice i automatski ih uklone ili označe („IBM“, bez dat.). Također zadaci računalnog vida uključuju **detekciju objekata**, gdje klasifikacija slike pomaže u identifikaciji određene klase slike, a zatim se otkriva i bilježi njihov izgled na slici ili video. Primjer detekcije objekata može biti otkrivanje oštećenja na pokretnoj traci ili prepoznavanje strojeva koji zahtijevaju održavanje. Nadalje, zadaci računalnog vida uključuju i **praćenje objekta** koje prati objekt nakon što je detektiran. Praćenje objekta se često se provodi na slikama snimljenima u nizu ili video zapisima u stvarnom vremenu. Primjer paćenja objekta može biti kod autonomnih vozila koja trebaju ne samo klasificirati i otkrivati objekte kao što su pješaci, drugi automobili i cestovna infrastruktura, već ih moraju pratiti u pokretu kako bi izbjegli sudare i poštivali prometne zakone („IBM“, bez dat.). Posljednji zadatak odnosi se na **dohvaćanje slika temeljeno na sadržaju**, pri čemu se „računalni vid koristi za pregledavanje, pretraživanje i dohvaćanje slika iz velikih baza podataka na temelju njihovog sadržaja, umjesto na osnovi metapodataka

povezanih s njima. Ovaj zadatak može uključivati automatsko označavanje slika koje zamjenjuje ručno označavanje. Primjer dohvaćanja slika temeljno na sadržaju može se koristiti u sustavima za upravljanje digitalnom imovinom, čime se povećava točnost pretraživanja i dohvaćanja“ („IBM“, bez dat.).

Prikupljanje velike količine podataka ključno je za uspjeh u mnogim tehnologijama temeljenim na strojnom učenju, no jednako je važno osigurati da ti podaci budu kvalitetni i raznoliki. Korištenje kvalitetnih podataka utječe na točnost i pouzdanost rezultata. Pristrani podaci mogu dovesti do pogrešaka koje mogu negativno utjecati na pojedince ili tvrtke. Primjerice, pristranost u tehnologijama prepoznavanja lica može rezultirati netočnim identifikacijama, dok pogrešna klasifikacija u financijskim modelima može uzrokovati nepravedno odbijanje zahtjeva za zajmove ili kredite. Kako bi se smanjio rizik od pristranosti i osigurala pravičnost u rezultatima, ključno je pažljivo planirati proces prikupljanja podataka. Jedna od metoda smanjenja pristranosti je slučajno uzorkovanje, gdje se nasumično odabire podskup podatkovnih točaka iz populacije, čime se povećava vjerojatnost dobivanja reprezentativnog uzorka. Uz slučajno uzorkovanje može se i upotrijebiti metoda stratificirano uzorkovanje, gdje se populacija dijeli u podskupine na temelju relevantnih karakteristika i zatim odabire uzorak iz svakog stratuma. Također korištenje raznolikih izvora podataka i primjena alata za otkrivanje pristranosti može dodatno pomoći u osiguravanju ravnoteže i preciznosti u rezultatima (Barney, Schmelzer, 2024).

## 5.1. Klasifikacija slika

Shuptrine (2024) definira klasifikaciju slika kao proces kategorizacije slika u različite klase na temelju njihovog sadržaja, što uključuje algoritme strojnog učenja, a najviše uključuje modele dubokog učenja poput konvolucijskih neuronskih mreža (CNN) koji identificiraju uzorce unutar slika i dodjeljuju ih najadekvatnijoj kategoriji. „Klasifikacija slika je široko rasprostranjeno istraživačko područje dubokog učenja, prepoznavanja uzoraka, interakcije čovjeka s računalom“ (Ramprasath i sur., 2022). U današnje vrijeme klasifikacija slika se koristi kako bi se smanjila razlika između ljudskog i računalnog vida, tako da strojevi prepoznaju slike, a cilj je identificirati jedinstvene značajke slike. Da bi se skup podataka mogao klasificirati u različite klase mora postojati dobro poznat odnos između podataka i klasa u koje su klasificirani (Bharadi i sur., 2017). Najpoznatiji primjer uporabe ove tehnologije je na Facebooku. Facebook

s 98% točnosti može identificirati lice na različitim slikama nakon samo nekoliko slika na kojima je to lice bilo označeno i tako ih svrstatи u Facebook album sa slikama (Abu i sur., 2019).

Prema članku *What is image classification? Basics you need to know* (2023), za klasifikaciju slika, ovisno o problemu s kojim se radi, postoje razne vrste metodologija. Najčešće su to:

**Binarna klasifikacija** se koristi logikom *ili-ili* za označavanje slika. Na primjer ta vrsta klasifikacije koristi se kada imamo kao zadatak kategorizirati svježe i trulo voće ili maligne i benigne tumore, dakle klasificiraju se nepoznate podatkovne točke u dvije kategorije.

**Višerazredna** odnosno *multiclass* klasifikacija bavi se kategorizacijom stavki u tri ili više klasa.

**Višeznačna** ili *multilabel* klasifikacija je vrsta klasifikacije gdje svaka slika pripada točno jednog klasi, ali se svakoj slici dodjeljuje više oznaka.

**Hijerarhijska** klasifikacija organizira klase u hijerarhijsku strukturu na temelju njihovih sličnosti. Klasa niže razine je specifičnija dok klasa više razine predstavlja šire kategorije („What is image classification? Basics you need to know“, 2023).

## 5.2. Duboko učenje

Prema Lv, Zhang i Wang (2022), duboko učenje (eng. Deep learning) realizira obuku skupova podataka velikih razmjera kroz višerazinski mrežni model i usvaja metodu izdvajanja značajki sloj po sloj kako bi se dobile značajke slike visoke razine. Također navode kako se mrežni model dubokog učenja koristi i za dobivanje dubokih značajki slike kroz više skrivenih slojeva. U procesu klasifikacije i prepoznavanja slika, način učenja značajki i njihove kombinacije uglavnom su određeni modelom dubokog učenja. Najčešće korišteni modeli dubokog učenja su ograničeni modeli Boltzmannova stroja i model konvolucijske neuronske mreže (Lv, Zhang i Wang, 2022). Njihova međusobna sličnost leži kod klasifikacije slika. Svi modeli prolaze kroz procese unošenja informacija o slikama, obrade podataka, ekstrakcije značajki, obuke modela te na kraju izlaza klasifikacije. Modeli dubokog učenja također su sposobni naučiti i opisati značajke slike. Metoda dubokog učenja primjenjuje se i u prepoznavanju prirodnog jezika te u klasifikaciji i detekciji slika. Nadalje, duboko učenje opisuje karakteristike specifičnih objekata kroz hijerarhijsku obradu prema velikoj količini informacija o rubnim značajkama te je

učinkovita metoda za obradu velikih podataka i dobivanje apstraktnih značajki korištenjem modela neuronske mreže (Lv, Zhang i Wang, 2022).

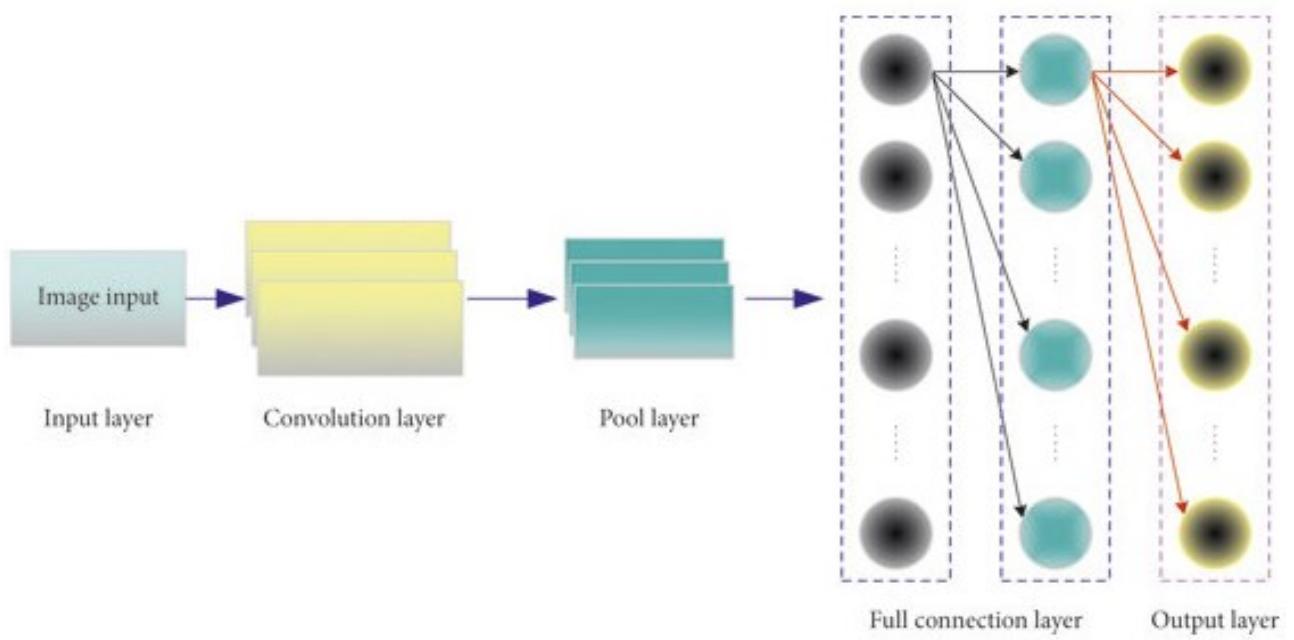
Funkcioniranje dubokog učenja radi na principu „umjetne neuronske mreže ili neuronske mreže dubokog učenja koja nastoji imitirati ljudski mozak kombinacijom unosa podataka, težine i pristranosti te zajedničkim radom omogućavaju točno prepoznavanje, klasifikaciju i opisivanje objekta“ („IBM“, 2024).

**Duboke neuronske mreže** mogu se opisati kao „više slojeva međusobno povezanih čvorova gdje se svaki od njih nadograđuje na prethodni sloj zbog poboljšanja predviđanja i kategorizacije“ („IBM“, 2024).

**Širenje naprijed** (eng. forward propagation) je naziv za napredovanje izračuna kroz mrežu, a vidljivi slojevi su ulazni i izlazni slojevi duboke neuronske mreže. Ulazni sloj se definira kao mjesto za unos podataka za obradu, a izlazni sloj je mjesto za vršenje konačnog predviđanja i klasifikacije („IBM“, 2024).

**Širenje unatrag** (eng. backpropagation) je proces u kojem se izračunavaju greške u predviđanjima i prilagođavaju težine i pristranosti funkcije, krećući se unatrag kroz slojeve kako bi se trenirao model. Povratno širenje odnosno širenje unatrag također koristi algoritme gradijentnog spuštanja. Zajedničkim snagama, širenje naprijed i širenje unatrag omogućuju neuronskoj mreži izvršavanje predviđanja i ispravljanje svih pogrešaka te algoritam s vremenom postaje sve bolji („IBM“, 2024).

**Konvolucijska neuronska mreža** (eng. Convolutional neural network - CNN) je mrežna struktura dubokog učenja koja se koristi kod obrade slika, prepoznavanje jezika, vremenskih serija podataka i klasifikacije slike te se sastoji od ulaznog sloja podataka i izlaznog sloja rezultata. Otkriva značajke unutar slike i otkriva i prepoznaje objekte. Konvolucijska neuronska mreža (Slika 22) sastoji se od tri sloja: konvolucijski sloj, skupni sloj i sloj pun veze. Konvolucijski sloj je zaslužen za ekstrakciju značajki, skupni sloj je zaslužen za mapiranje značajki i sloj pun veze sličan je općoj strukturi neuronske mreže te svi čvorovi nisu međusobno povezani, već su povezani s čvorovima prethodnog sloja. Kroz konvolucijski sloj izvršava se zadatak izračuna konvolucijske neuronske mreže, a jezgra u konvolucijskom sloju je srž modela konvolucijske neuronske mreže. Konvolucijski sloj primjenjuje konvoluciju na ulaznu sliku kako bi izdvojio karakteristične informacije slike (Lv, Zhang i Wang, 2022).



Slika 22. Prikaz konvolucijske neuronske mreže

## 6. YOLOv8

YOLOv8 je suvremen model dubokog učenja dizajniran za detekciju objekata u stvarnom vremenu u aplikacijama računalnog vida. Kao najnoviji model u seriji YOLO, YOLOv8 može se primjenjivati za detekciju objekata, klasifikaciju slika i segmentaciju instanci. Kod detekcije objekata, YOLOv8 precizno lokalizira otkrivene objekte dodjeljujući im označke klase i označavajući koordinate okvira. U segmentaciji slike alat pruža informacije na razini piksela za svaki objekt, omogućujući detaljniju analizu i razumijevanje sadržaja slike. Kod klasifikacije, YOLOv8 određuje primarnu kategoriju ili klasu kojoj slika pripada. Model YOLOv8 je razvila softverska tvrtka *Ultralytics*. Arhitektura YOLOv8 koristi metode računalnog vida i algoritme strojnog učenja za preciznu identifikaciju i lokalizaciju objekata na slikama i videozapisa s visokim stupnjem točnosti i brzine. Konvolucijske neuronske mreže (CNN) su se pokazale najučinkovitijima za postizanje točne detekcije objekata, stoga YOLOv8 koristi CNN za izvođenje detekcije objekata u stvarnom vremenu s visokom preciznošću („Under the hood: YOLOv8 architecture explained“, 2023).

Prije početka treniranja modela postavljaju se epohe (eng. Epoch). Epohe imaju ključnu ulogu u procesu obuke modela jer su izravno povezane s time koliko dobro model uči i generalizira nevidljive podatke. Broj epoha je hiperparametar koji odeđuje koliko će puta algoritam učenja prolaziti kroz cijeli skup podataka za obuku. Premalo epoha može rezultirati nedovoljno obučenim modelom (eng. Underfitting), dok previše epoha može rezultirati pretjeranim opremanjem (eng. Overfitting), što znači da model umjesto da uči temeljne obrasce, model počinje pamtitи podatke o obuci („What is Epoch in Machine Learning?“, 2023). Zadane postavke za treniranje YOLOv8 modela su 300 epoha, no mogu se smanjiti ili povećavati prema potrebama modela. Također, veličina slika je postavljena na 640 piksela što se također može mijenjati po potrebi. Kod veličine serije se preporuča najveća veličina koju hardver dopušta, a kod hiperparametara se preporuča trenirati model sa zadanim postavkama, a onda također po potrebi mijenjati (Jocher, 2023).

## 7. Istraživanje

Cilj ovog istraživanja je razviti model za klasifikaciju slika koji može prepoznati i klasificirati raznovrsne haljine prema njihovom kulturnom podrijetlu. Kroz evaluaciju rezultata modela pratit će se kako na rezultate utječe broj epoha koji je postavljen prije početka treniranja. Dakle, pratit će se rezultati dobiveni nakon završetka treniranja modela i provedet će se evaluacija rezultata dobivenih na testnim slikama s obzirom na broj epoha. Broj epoha koji se prati u izgradnji klasifikatora slika je 50 i 100.

Odabrane su 4 kategorije odnosno, 4 različite kulture i haljine karakteristične za njih. Shodno tome cilj je da model može prepoznati i označiti haljine prema njihovom podrijetlu. Kulturne skupine čije su tipične haljine odabrane za istraživanje su Ujedinjeni Arapski Emirati, Mediteranske zemlje, Skandinavske zemlje i središnja Europa. Kroz ovaj rad želi se doprinijeti boljem razumijevanju i kategorizaciji kulturno specifičnih odjevnih tradicija, istražujući primjenu strojnog učenja u kontekstu mode i kulturne baštine. Postizanje uspješnog modela omogućilo bi automatsko prepoznavanje i označavanje slika tradicionalnih haljina, što ima potencijalne primjene u industriji mode, obrazovanju te očuvanju i promociji kulturne raznolikosti.

Kod izgradnje modela, kreiran je klasifikator slika na vlastitom skupu podataka. Pri izradi modela provedeni su sljedeći koraci: treniranje i validacija, testiranje i predikcija na testnom skupu podataka i evaluacija rezultata. Treniranje modela se obavlja nad skupom podataka koji je podijeljen u 4 direktorija prema podrijetlu haljina te se na kraju treniranja dobivaju podešene težine modela i rezultati treniranja u kojima su prikazani parametri modela kroz epove. „Epoha se odnosi na jedan potpuni prolaz kroz cijeli skup podataka za obuku.“ („Europska akademija za certifikaciju informacijskih tehnologija“ [EITCA], bez dat.). Dakle, broj epoha (eng. Epoch) je hiperparametar koji je potrebno podesiti tijekom procesa treniranja modela. Hiperparametri (eng. Hyperparameter) su vanjske postavke koje se koriste za kontrolu procesa obuke modela strojnog učenja. Dakle hiperparametri se konfiguriraju prije početka treninga i ostaju konstantni tijekom cijelog procesa. Osim epoha, hiperparametri uključuju i brzinu učenja (eng. Learning rate), koja kontrolira veličinu koraka koje model poduzima prilikom optimizacije svojih parametara tijekom obuke, veličina serije (eng. Batch size), koja utječe na dinamiku treniranja i slično (Yadav, 2024). S druge strane, parametri (eng Parameter.) su svojstva podataka o treniranju koja se uče tijekom procesa treniranja, u slučaju dubokog učenja to su težina (eng.

Weight) i pristranost (eng. Bias), (Faisal, 2020). Broj epoha je bitno podesiti zbog toga što utječe na točnost predviđanja i povezan je s pojavom pretjeranog opremanja (eng. Overfitting) i nedovoljnog opremanja (eng. Underfitting). Pretjerano opremanje (eng. Overfitting) odnosi se na situaciju u kojoj je model previše usmjeren na podatke za treniranje, uključujući ne samo ključne obrasce već i šum. Zbog toga model postaje previše prilagođen specifičnostima podataka za treniranje, što dovodi do loše sposobnosti generalizacije na nove, nepoznate podatke, rezultirajući smanjenom točnošću predviđanja u stvarnim uvjetima. Nedovoljno opremanje (eng. Underfitting) nastaje kada je model prejednostavan za prepoznavanje osnovnih obrazaca u podacima, što rezultira visokom pristranošću i niskom točnošću predviđanja („EITCA“, bez dat.). Također, „povećanje broja epoha kod treniranja modela može pomoći u poboljšanju performansi modela. Kako se broj povećava, model bi trebao bolje učiti iz podataka za treniranje, a točnost predviđanja na skupovima podataka za treniranje i validaciju teži ka poboljšanju“ („EITCA“, bez dat.).

Nakon treniranja i validacije slijedi testiranje i predikcija koja se odvija na novom testnom skupu podataka kojeg sustav još nije vidio i za kraj, evaluacija dobivenih rezultata na testnom skupu podataka.

## 7.1. Metodologija

U ovom istraživanju, cilj je izraditi model strojnog učenja za klasifikaciju slika haljina na temelju njihovog kulturnog podrijetla. Proces izgradnje modela obuhvaća nekoliko faza, prikupljanje i pripremu podataka, treniranje modela na različitom broju epoha, predikciju i testiranje, evaluaciju performansi i analizu i usporedbu rezultata. Skup podataka sastojao se od slika haljina karakterističnih za četiri kulturne skupine: Ujedinjeni Arapski Emirati, Mediteranske zemlje, Skandinavske zemlje i središnja Europa. Slike su organizirane u 4 direktorija prema podrijetlu haljina što omogućuje jednostavnije treniranje modela. Izrada modela klasifikatora slika realizirana je korištenjem YOLOv8 modela dubokog učenja. YOLOv8 je napredan model dubokog učenja koji se koristi za otkrivanje objekata i klasifikaciju slika. Prikupljen skup podataka podijelio se je na skup za treniranje (320 slika), validaciju (80 slika) i testiranje (200 slika). Kod razvoja modela podesila se je veličina slika (800 piksela) i broj epoha, dok su svi ostali hiperparametri osim broja epoha ostali na svojim zadanim vrijednostima. Korištena su dva različita broja epoha (50 i 100) kako bi se ispitalo kako broj

epoha utječe na točnost klasifikacije i performanse modela. Tijekom treniranja model prolazi kroz više epoha, gdje se tijekom svake epohe parametri modela prilagođavaju na temelju povratnih informacija. Nakon svake epohe, prati se točnost modela na validacijskom skupu kako bi se ocijenilo učenje modela i njegove performanse na neviđenim podacima. Za predikciju i testiranje modela korištene su najbolje težine modela, odnosno *best.pt*. *Best.pt* sadrži težine modela nakon epohe s najboljim rezultatima unutar zadanog broja epoha. Model se je testirao na zasebnom skupu podataka koji nije korišten tijekom treniranja i validacije te taj testni skup omogućuje procjenu kako model generalizira na nove neviđene podatke. Performanse modela evaluirane su pomoću metrika: točnost, preciznost (makro), odziv (marko), matrica konfuzije i F1-mjera (makro). Makro mjere se koriste za višeklasne klasifikacije te daju jednaku težinu svim klasama. Posebna pažnja posvećena je utjecaju broja epoha na performanse modela, pri čemu su uspoređeni rezultati za treniranje na 50 i 100 epoha. Rezultati su analizirani kako bi se utvrdilo kako broj epoha utječe na sposobnost modela da pravilno klasificira haljine iz različitih skupina na testnom skupu podataka.

## 7.2. Podatkovni skup

Skup podataka je ručno izrađen preuzimanjem slika s dostupnih online trgovina za 4 odabrane kategorije. Kategoriju Ujedinjenih Arapskih Emirata najviše predstavljaju slike (Slika 23) abaye (neki od web dućana: Boksha, Hera Closet, EmiratiAbaya), slike haljina za kategoriju Mediterana predstavljaju slike (Slika 24) lepršavih ljetnih haljina (neki od web dućana: Beau & Ro, Petal & Pup, Hello Molly), središnju Europu predstavljaju slike (Slika 25) tipičnog njemačkog i austrijskog dirndlja (neki od web dućana: Krüger Dirndl, Dirndl.com, AlpenHertz) i Skandinaviju predstavljaju slike (Slika 26) tradicionalne nošnje bunad (neki od web dućana: Norske Bunader, Embla Bunader, Eva Lie Design). Ukupan broj preuzetih slika je 600. Svaka slika se sastoji od pozadine i osobe koja na sebi nosi haljinu. Sve slike prije nego što su podijeljene na skup za trening, validaciju i test su postavljene na jednaku veličinu (800x1200) tako da se osigura jednostavnija obrada podataka. Slike su imenovane riječju *Slika* i brojem koji je slijedio, npr. *Slika101*. Zatim su slike podijeljene na skup za treniranje gdje je ukupno bilo 320 slika, od kojih je bilo 80 slika haljina za svaku od 4 kategorije posebno. Dakle 80 slika koje su predstavljale haljine specifične za Mediteran, 80 slika koje su predstavljale haljine specifične za središnju Europu, 80 slika koje su predstavljale Ujedinjene Arapske Emirate i 80 slika koje

su predstavljale Skandinaviju. Zatim skup za validaciju gdje je ukupno bilo 80 slika, 20 slika za svaku od 4 kategorija posebno i skup za test koji se sastojao od ukupno 200 slika, 50 slika za svaku od 4 kategorija posebno.



Slika 23. Haljine Ujedinjenih Arapskih Emirata



Slika 24. Haljine Mediterana



Slika 25. Haljine središnje Europe



Slika 26. Haljine Skandinavskih zemalja

### 7.3. Alati

Istraživanje u ovome radu obuhvaća razvoj modela za klasifikaciju slika primjenom YOLOv8 modela korištenjem programskog jezika Python verzije 3.8. Programska jezika Python je izabran zbog svojih mogućnosti proširenja s raznim paketima i bibliotekama koje olakšavaju rad. Za treniranje modela korištena je inačica yolov8n.pt. Izrada modela je provedena korištenjem programskog jezika Python u razvojnog okruženju PyCharm. Prije samog početka izrade modela bilo je potrebno preuzeti Pythonove pakete kako bi korištenje YOLOv8 modela bilo moguće. U Python uvezene su različite biblioteke, Ultralytics (8.0.58), NumPy (1.24.2), Scikit-learn, Csv, i Pandas. Ultralytics je korišten za YOLOv8 model, Numpy biblioteka se koristila za numeričke operacije, Scikit-learn biblioteka se koristila za izračunavanje metrika, csv je služio za rad s podacima u csv formatu i Pandas je biblioteka koja se koristila za analizu podataka i rad s csv datotekama. Kodovi korišteni za treniranje YOLOv8 modela preuzeti su sa službene stranice Ultralytics YOLOv8.

### 7.4. Struktura podataka

Strukturiranje podataka raspoređeno je prema zahtjevima YOLOv8 algoritma koji se koristi za strojno učenje.

Slike za izgradnju modela klasifikatora slika spremljene su unutar glavnog direktorija pod nazivom *class\_dataset*. Unutar tog direktorija nalaze se dvije mape koje su nazvane *train* i *val*. Unutar *train* mape nalaze se 4 mape u kojima se nalaze slike za treniranje raspoređene u 4 različite kategorije prema kojima su klasificirane slike. Kategorije za klasificiranje slika odnose se na podrijetlo haljina. Prva mapa unutar *train* mape nazvana je *CentralEurope\_dresses* koja ima 80 slika haljina karakterističnih za središnju Europu, druga mapa nazvana je *Mediterranean\_dresses* koja ima 80 slika haljina karakterističnih za Mediteran, treća mapa nazvana je *Scandinavian\_dresses* koja ima 80 slika haljina karakterističnih za Skandinaviju i četvrta mapa nazvana je *UAE\_dresses* koja ima 80 slika haljina karakterističnih za Ujedinjene Arapske Emirate. Pored mape *train*, unutar direktorija *class\_dataset* nalazi se mapa *val*. Struktura mape *val* jednaka je kao i kod mape *train*. Nazivi mapa jednaki su kao i u mapi *train*, dakle *CentralEurope\_dresses* koja ima 20 slika haljina karakterističnih za središnju Europu, druga mapa nazvana je *Mediterranean\_dresses* koja ima 20 slika haljina karakterističnih za

Mederteran, treća mapa nazvana je *Scandinavian\_dresses* koja ima 20 slika haljina karakterističnih za Skandinaviju i četvrta je mapa nazvana *UAE\_dresses* koja ima 20 slika haljina karakterističnih za Ujedinjene Arapske Emirate. Mapa sa skupom za testiranje nalazi se izvan direktorija *class\_dataset* te se unutar te mape sve slike haljina nalaze zajedno bez odvajanja u posebne mape. Testni skup obuhvaća 200 slika, po 50 iz svake od četiri kategorije: Mediteran, Skandinavija, UAE i središnja Europa.

## 7.5. Izrada modela klasifikatora slika

U ovome dijelu rada opisat će se izrada modela klasifikatora slika treniranog na 50 i 100 epoha. Za isti model treniran na 50 epoha, kao i za isti model treniran na 100 epoha, bit će opisan proces treniranja i validacije, testiranja i predikcije i evaluacije rezultata na testnom skupu podataka.

### Treniranje i validacija

Prije početka treniranja modela klasifikatora slika, odabire se broj epoha i veličina slika. Broj epoha u izradi modela treniranog na 50 epoha bio je postavljen na 50, dok je u izradi modela treniranog na 100 epoha broj epoha bio postavljen na 100, a veličina slika je postavljena na 800 piksela.

Kao rezultat treniranja spremi se: csv datoteka s rezultatima treniranja modela kroz svaku epohu, mapa s najboljim i zadnjim rezultatom treniranja modela i args. yaml datoteka s opisom parametara modela.

Csv datoteka sastoji se od detaljnog opisa treniranog modela. Kod modela treniranog na 50 epoha u prvome stupcu nalaze se epohe. 50 epoha znači da je model prošao kroz cijeli skup podataka 50 puta. Kod modela treniranog na 100 epoha u prvome stupcu također se nalaze epohe, a 100 epoha znači da je model prošao kroz cijeli skup podataka 100 puta.

Za svaku epohu prikazani su rezultati:

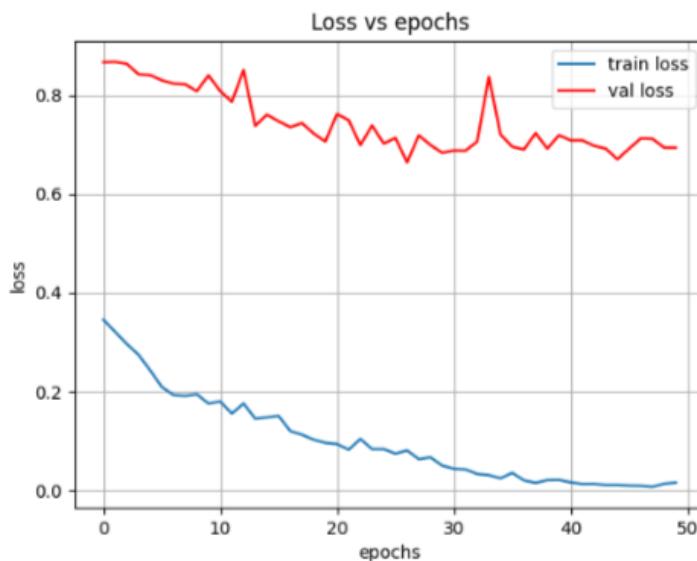
- train loss (gubitak na setu za treniranje),
- metrics accuracy top1 (točnost modela),
- metrics accuracy top 5 (točnost modela),
- val loss (gubitak na validacijskom setu) i
- lr/pg0, lr/pg1, lr/pg2 (stope učenja, eng. Learning rates).

**Train loss** označava gubitak na setu za treniranje odnosno prikazuje koliko dobro model trenira na podacima, niža vrijednost označava bolje treniranje. **Val loss** označava gubitak na validacijskom setu te se mjeri koliko dobro model generalizira neviđene podatke što znači da ako je niža vrijednost gubitka to je bolje generaliziranje („Training and validation loss in deep learning“, 2024). **Metrics accuracy top 1** označava točnost modela na trening setu gdje se u obzir uzima samo predikcija koja je najvjerojatnija te se ovom metrikom prikazuje koliko je puta model točno predvidio pravu klasu kao najvjerojatniju. Važno je da kroz proces treniranja točnost raste. **Metrics accuracy top 5** označava točnost modela na trening setu gdje se uzimaju u obzir 5 najvjerojatnijih predikcija. Model je uspješan ako je točan razred među prvih pet predikcija. Sljedeće su prikazane **stope učenja** koje određuju koliko se parametri modela ažuriraju u svakom koraku treninga (Riva, 2021).

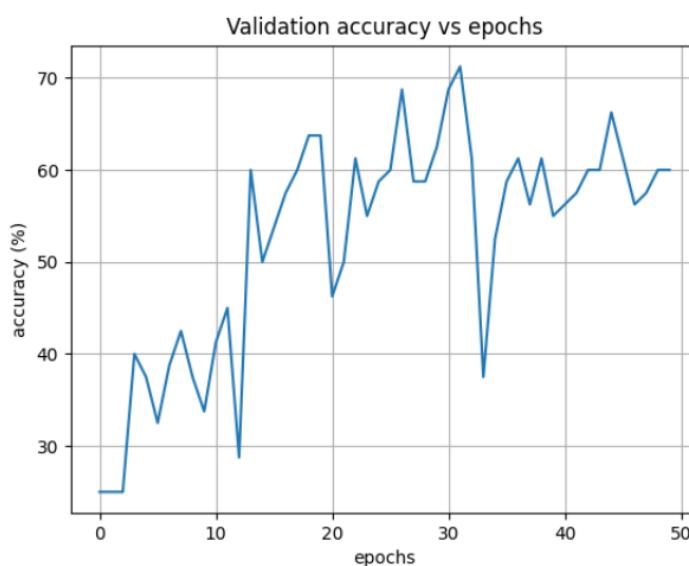
Fokus izvedbe modela je na promatranju modela kroz Train loss, Metrics accuracy i Val loss. Na slici 27, prikazan je graf koji prikazuju rezultate treniranja modela na 50 epoha prema gubitcima s obzirom na epohe. Prikazan je gubitak na setu za treniranje i gubitak na setu za validaciju. Plava linija prikazuje gubitke s obzirom na treniranje, a crvena linija prikazuje gubitke s obzirom na validaciju. Obje linije s obzirom na rast broja epoha padaju. Kod crvene linije očituje se nagli rast na 34. epohi, no nakon toga gubitci s obzirom na validaciju opet padaju. Ukupno gledano, obje linije s brojem epoha padaju, što ukazuje na napredak kod treniranja te je takav ishod poželjan. Na slici 28, prikazan je graf koji prikazuje rezultate treniranja modela na 50 epoha prema točnosti validacije s obzirom na epohe. Plava linija na grafu prikazuje porast točnosti kako raste broj epoha što je poželjan ishod kod treniranja modela.

Na slici 29, prikazan je graf koji prikazuje rezultate treniranja modela na 100 epoha prema gubitcima s obzirom na epohe. Prikazan je gubitak na setu za treniranje i gubitak na setu za validaciju. Plava linija prikazuje gubitke s obzirom na treniranje, a crvena linija prikazuje

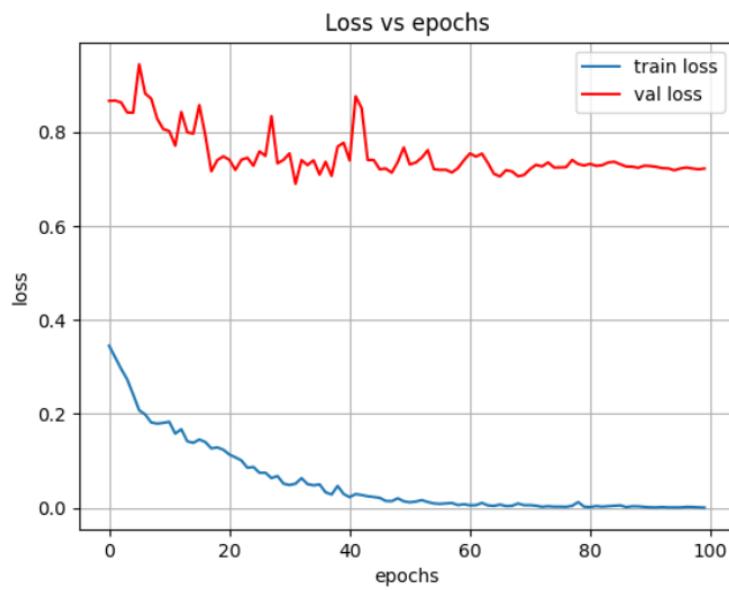
gubitke s obzirom na validaciju. Obje linije s obzirom na rast broja epoha padaju, no crvena linija prema kraju treniranja ne pada nego zadržava otprilike jednak gubitak. Pad plave linije ukazuje na napredak kod smanjenja gubitaka kod treniranja, no zadržavanje crvene linije na jednoj ravnini prema kraju treniranja označava da se validacijski gubitci nisu toliko smanjivali već su ostajali isti. Na slici 30, prikazan je graf koji prikazuje rezultate treniranja modela na 100 epoha prema točnosti validacije s obzirom na epohe. Plava linija na grafu raste s brojem epoha, no kod 40-e epohe ima nagli pad. Nakon naglog pada kod 40-e epohe, točnost opet raste kako raste i broj epoha.



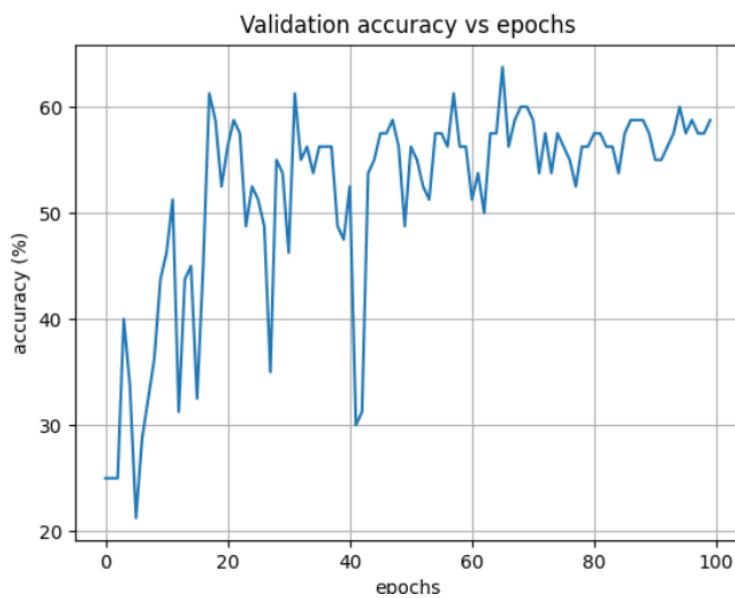
Slika 27. Rezultati treniranja modela na 50 epoha s obzirom na broj epoha i gubitke treniranja i validacije



Slika 28. Rezultati treniranja modela na 50 epoha - validacijska točnost s obzirom na broj epoha



Slika 29. Rezultati treniranja modela na 100 epoha s obzirom na broj epoha i gubitke treniranja i validacije



Slika 30. Rezultati treniranja modela na 100 epoha - validacijska točnost s obzirom na broj epoha

Mapa s najboljim i zadnjim rezultatom treniranja modela naziva se *weights* odnosno težine. U mapi *weights* nalaze se spremljeni modeli nakon treniranja. Unutar te mape nalaze se dvije mape: *last.pt* i *best.pt*. *Last.pt* i *best.pt* koriste se za označavanje dvije verzije modela koje su sačuvane tokom treniranja. *Last.pt* sadrži posljednju verziju modela koja je sačuvana nakon posljednje epohe, što znači da sadrži modele koji su trenirani do zadane točke zaustavljanja procesa treniranja. U slučaju modela treniranog na 50 epoha zadnja epoha je 50, dok je u slučaju modela treniranog na 100 epoha zadnja epoha 100. *Last.pt* se koristi kod nastavka treniranja i provjere napretka tijekom treniranja. *Best.pt* datoteka sadrži verziju modela koja ima najbolje performanse tijekom cijelog procesa treniranja. U izgradnji modela koristi se *Best.pt*. Model treniran na 50 epoha ima najvišu točnost na kraju 31. epohe od 71,25 % (Slika 31), a model treniran na 100 epoha ima najvišu točnost na kraju 65. epohe od 64 % (Slika 32). Prema ovim podacima može se vidjeti da model s manje epoha (50 epoha) daje bolje rezultate nakon treniranja u odnosu na model s više epoha (100 epoha).

22	20	0.09366	0.4625
23	21	0.08221	0.5
24	22	0.1041	0.6125
25	23	0.08335	0.55
26	24	0.08331	0.5875
27	25	0.07432	0.6
28	26	0.08073	0.6875
29	27	0.06314	0.5875
30	28	0.06682	0.5875
31	29	0.05001	0.625
32	30	0.04369	0.6875
33	31	0.04224	0.7125
34	32	0.03301	0.6125
35	33	0.03068	0.375
36	34	0.02438	0.525
37	35	0.03532	0.5875
38	36	0.02009	0.6125
39	37	0.01508	0.5625
40	38	0.02061	0.6125
41	39	0.02103	0.55
42	40	0.016	0.5625

Slika 31. Najviši postotak točnosti kod treniranja modela na 50 epoha

58	56	0.00962	0.5625
59	57	0.01058	0.6125
60	58	0.00612	0.5625
61	59	0.00788	0.5625
62	60	0.00566	0.5125
63	61	0.00598	0.5375
64	62	0.01062	0.5
65	63	0.00546	0.575
66	64	0.00435	0.575
67	65	0.00718	0.6375
68	66	0.00402	0.5625
69	67	0.00451	0.5875
70	68	0.00945	0.6
71	69	0.00588	0.6
72	70	0.00599	0.5875
73	71	0.00477	0.5375
74	72	0.00242	0.575
75	73	0.00371	0.5375
76	74	0.00271	0.575
77	75	0.00275	0.5625
78	76	0.0024	0.55

Slika 32. Najviši postotak točnosti kod treniranja modela na 100 epoha

### Testiranje i predikcija klase

Nakon što je provedeno treniranje modela izvršava se predikcija na testnom skupu podataka. Prije nego što je obavljena predikcija modela treniranog na 50 epoha i modela treniranog na 100 epoha, na većem broju slika (200 slika), obavila se je predikcija modela treniranog na 50 epoha i predikcija modela treniranog na 100 epoha na jednoj slici kako bi se dobio uvid rada modela. Predikcija je obavljena preko koda u alatu PyCharm gdje se je učitao trenirani model, best.pt i jedna slika iz testnog skupa.

Rezultat predikcije treniranog modela na 50 epoha: `{0:'CentralEurope_dresses' = 0.011933388188481331, 1:'Mediterranean_dresses' = 0.1601240634918213, 2:'Scandinavian_dresses' = 0.4044611155986786 i 3: 'UAE_dresses = 0.42348143458366394} = UAE_dresses.`

U rezultatu predikcije modela na 50 epoha prikazane su brojčane vjerojatnosti pripadanja slike *Slika1* svakoj od 4 klasi. Prema vjerojatnostima iz rezultata predikcije može se vidjeti da

najveću vjerojatnost ima klasa *UAE\_dress* s 42 %, što nije točno jer slika *Slika1* prikazuje haljinu karakterističnu za Skandinaviju (Slika 33).

Rezultat predikcije treniranog modela na 100 epoha:  $\{0: 'CentralEurope_dresses' = 3.9194648593365855e-07, 1: 'Mediterranean_dresses' = 5.829565807857762e-08, 2: 'Scandinavian_dresses' = 0.9999995231628418 i 3: 'UAE_dresses' = 1.132225563305056e-11\} = Scandinavian_dresses$ . U rezultatu predikcije modela treniranog na 100 epoha prikazane su također brojčane vjerojatnosti pripadanja slike *Slika1* svakoj od klase. Prema vjerojatnostima iz rezultata predikcije može se vidjeti da najveću vjerojatnost ima klasa *Scandinavian\_dress* s visokih 99 %, što je točno jer *Slika1* prikazuje haljinu karakterističnu za Skandinaviju.



Slika 33. Prikaz slike *Slika1*

Za testiranje i dobivanje predikcija za model treniran na 50 i 100 epoha na svih 200 testnih slika, prijašnji kod za predikciju jedne slike je dorađen kako bi se mogla obaviti predikcija na svih 200 slika i kako bi se rezultati predikcije spremili u csv datoteku (Slika 34), (Slika35) za lakšu provedbu evaluacije modela.

1	Images	Class	Probability
2	Slika1.jpg	3: 'UAE_dresses'	0.42348143458366394
3	Slika10.jpg	3: 'UAE_dresses'	0.9928539395332336
4	Slika100.jpg	1: 'Mediterranean_dresses'	0.43303045630455017
5	Slika101.jpg	0: 'CentralEurope_dresses'	0.9914353489875793
6	Slika102.jpg	1: 'Mediterranean_dresses'	0.9734448194503784
7	Slika103.jpg	1: 'Mediterranean_dresses'	0.8016247153282166
8	Slika104.jpg	1: 'Mediterranean_dresses'	0.7926389575004578
9	Slika105.jpg	1: 'Mediterranean_dresses'	0.9889146685600281
10	Slika106.jpg	1: 'Mediterranean_dresses'	0.9885757565498352
11	Slika107.jpg	1: 'Mediterranean_dresses'	0.9872971773147583
12	Slika108.jpg	1: 'Mediterranean_dresses'	0.7237625122070312
13	Slika109.jpg	1: 'Mediterranean_dresses'	0.9987145662307739
14	Slika11.jpg	3: 'UAE_dresses'	0.9763234257698059
15	Slika110.jpg	1: 'Mediterranean_dresses'	0.8683986067771912
16	Slika111.jpg	0: 'CentralEurope_dresses'	0.4739956855773926
17	Slika112.jpg	0: 'CentralEurope_dresses'	0.7677845358848572
18	Slika113.jpg	1: 'Mediterranean_dresses'	0.9959837198257446
19	Slika114.jpg	1: 'Mediterranean_dresses'	0.9432475566864014
20	Slika115.jpg	1: 'Mediterranean_dresses'	0.9804661870002747
21	Slika116.jpg	1: 'Mediterranean_dresses'	0.7107481956481934
22	Slika117.jpg	1: 'Mediterranean_dresses'	0.9783726334571838
23	Slika118.jpg	1: 'Mediterranean dresses'	0.5293083190917969

Slika 34. Prikaz rezultata testiranja modela treniranog na 50 epoha i njegovih predikcija klasa za svaku sliku

1	Images	Class	Probability
2	Slika1.jpg	2: 'Scandinavian_dresses'	0.9999995231628418
3	Slika10.jpg	3: 'UAE_dresses'	0.8726010322570801
4	Slika100.jpg	1: 'Mediterranean_dresses'	0.6630406975746155
5	Slika101.jpg	0: 'CentralEurope_dresses'	0.99625164270401
6	Slika102.jpg	1: 'Mediterranean_dresses'	0.5620638728141785
7	Slika103.jpg	1: 'Mediterranean_dresses'	0.8240929841995239
8	Slika104.jpg	0: 'CentralEurope_dresses'	0.8914936184883118
9	Slika105.jpg	1: 'Mediterranean_dresses'	0.9551201462745667
10	Slika106.jpg	1: 'Mediterranean_dresses'	0.9997649788856506
11	Slika107.jpg	1: 'Mediterranean_dresses'	0.9971311092376709
12	Slika108.jpg	0: 'CentralEurope_dresses'	0.9650905728340149
13	Slika109.jpg	1: 'Mediterranean_dresses'	0.9999113082885742
14	Slika11.jpg	3: 'UAE_dresses'	0.9954569339752197
15	Slika110.jpg	1: 'Mediterranean_dresses'	0.9997841715812683
16	Slika111.jpg	1: 'Mediterranean_dresses'	0.875974178314209
17	Slika112.jpg	0: 'CentralEurope_dresses'	0.8111200332641602
18	Slika113.jpg	1: 'Mediterranean_dresses'	0.9993347525596619
19	Slika114.jpg	0: 'CentralEurope_dresses'	0.8237344622612
20	Slika115.jpg	1: 'Mediterranean_dresses'	0.9854027032852173
21	Slika116.jpg	1: 'Mediterranean_dresses'	0.7883918881416321
22	Slika117.jpg	1: 'Mediterranean_dresses'	0.9969268441200256
23	Slika118.jpg	1: 'Mediterranean dresses'	0.939982533454895

Slika 35. Prikaz rezultata testiranja modela treniranog na 100 epoha i njegovih predikcija klasa za svaku sliku

## Evaluacija

Za model treniran na 50 epoha i model treniran na 100 epoha, nakon spremanja rezultata predikcija nad svih 200 testnih slika, provela se je evaluacija. Za evaluaciju je korišten csv dokument sa svim rezultatima predikcije modela i csv dokument s točnim oznakama za svaku od 200 testnih slika. Evaluacija je bila provedena u PyCharm razvojnom okruženju gdje su bile uvedene biblioteke Pandas i Scikit-learn. Pandas je služio za korištenje i analizu podataka u csv formatu, a Scikit-learn je korišten za izračunavanje metrika. Evaluacija modela provedena je kroz 5 metrika koje se koriste za višeklasne klasifikacije: točnost, F1-mjera (makro), preciznost (makro), odziv (makro) i matrica konfuzije. Makro mjere kod računanja F1-mjere, preciznosti i odziva se koriste za višeklasne klasifikacije i daju jednaku težinu svim klasama (Snajder, 2022).

## 7.6. Rezultati modela na testnom skupu podataka

Rezultati modela klasifikatora slika na testnom skupu podataka prikazat će se i obrazložiti zasebno. Prvo će se prikazati rezultati modela treniranog na 50 epoha, a zatim rezultati modela treniranog na 100 epoha. Rezultati modela klasifikatora slika usporedit će se na osnovi broja postavljenih epoha.

### 7.6.1. Rezultati modela klasifikatora slika treniranog na 50 epoha

Rezultati evaluacije modela treniranog na 50 epoha dobiveni su računanjem matrice konfuzije, preciznosti, odziva, F1 mjere i točnosti.

Prema rezultatima matrice konfuzije (Tablica 2), model najbolje prepoznaće i klasificira slike haljina koje pripadaju klasi *Mediterranean\_dresses* s 34 točna klasificiranja od ukupno 50 testnih slika koje prikazuju haljine karakteristične za Mediteran, također model u najviše slučajeva prepoznaće i klasificira slike haljina koje pripadaju klasi *UAE\_dresses* s 23 točna klasificiranja od ukupno 50 slika, no za slike ove kategorije također dodjeljuje i krive klase, primjerice *Scandinavian\_dresses* (14). Za slike koje pripadaju klasama *CentralEurope\_dresses* i *Scandinavian\_dresses*, model često predviđa veće vjerojatnosti za druge netočne klase. Slike koje prikazuju klasu *CentralEurope\_dresses*, model u 18 slučajeva pogrešno klasificira kao

*Mediterranean\_dresses*. Moguć razlog za ovaj ishod je to što jedino slike haljina karakterističnih za Mediteran sadrže slike kraćih haljina kao što su i haljine karakteristične za središnju Europu, dok su sve ostale haljine uglavnom dugačke u ostalim kategorijama. Slike koje prikazuju klasu *Scandinavian\_dresses*, u 23 slučajeva model pogrešno klasificira kao *UAE\_dresses*. Razlog ovakvog rezultata također može biti taj da jedinio ove dvije kategorije na svim slikama imaju uglavnom dugačke haljine. Ovakav rezultat matrice konfuzije jasno pokazuje da je model sklon pogreškama u prepoznavanju i klasifikaciji slika za klase *CentralEurope\_dresses* i *Scandinavian\_dresses*. Mogući uzroci ovih rezultata mogu biti i različitost između skupa za treniranje i skupa za testiranje posebno u pogledu osvjetljenja i pozadine slika. Skup podataka za treniranje kod haljina karakterističnih za središnju Europu sadrži slike koje su međusobno slične, također i skup podataka za treniranje za slike haljina karakterističnih za Skandinaviju sadrži slike koje su međusobno slične, dok se skupovi za testiranje ovih dviju kategorija razlikuju od skupova za treniranje ovih kategorija, što može otežati modelu prepoznavanje haljina iz tih klasa. Nasuprot tome, za slike haljina karakterističnih za Mediteran i Ujedinjene Arapske Emirate podaci u skupu za treniranje i testiranje su uglavnom ujednačeni u pogledu osvjetljenja i pozadine. Također, ovi skupovi podataka su trenirani na raznolikim slikama i testirani na raznolikim slikama, što omogućuje modelu da bolje nauči i prepozna različite karakteristike haljina. Osim toga, najbolji rezultati postignuti kod slika karakterističnih za Mediteran mogu biti rezultat toga što se slike tih haljina značajno razlikuju od svih ostalih slika haljina. Značajne razlike u značajkama haljina iz Mediterana omogućuju modelu lakše razlikovanje tih haljina od drugih, što dovodi do boljih performansi u prepoznavanju.

Tablica 2. Matrica konfuzije modela treniranog na 50 epoha

Točna/predviđena klasa	CentralEurope_dresses	Mediterranean_dresses	Scandinavian_dresses	UAE_dresses
CentralEurope_dresses	15	18	3	14
Mediterranean_dresses	6	34	5	5
Scandinavian_dresses	9	4	14	23
UAE_dresses	10	3	14	23

Prema prikazanoj matrici konfuzije na Tablici 2, izrađena je i Tablica 3 gdje je za svaku klasu prikazan broj točno pozitivnih (TP), točno negativnih (TN), lažno pozitivnih (FP) i lažno negativnih (FN) primjera (Tablica 3). Točno pozitivne (TP) vrijednosti su one vrijednosti koje se podudaraju sa stvarnim vrijednostima, točno negativne (TN) vrijednosti se izračunavaju zbrajanjem svih stupaca i redaka osim one klase za koju se računa vrijednost, lažno pozitivne (FP) vrijednosti se računaju zbrajanjem svih vrijednosti stupca za klasu za koju računamo vrijednost osim njene TP vrijednosti i lažno negativne (FN) vrijednosti se računaju zbrajanjem svih vrijednosti u retku za klasu za koju računamo vrijednost osim njene TP vrijednosti. Prema tome za klasu *CentralEurope\_dresses* dobivene su sljedeće vrijednosti: TP (točno pozitivni) je 15, FP (lažno pozitivni) je 25, FN (lažno negativni) je 35 i TN (točno negativni) je 125. Za klasu *Mediterranean\_dresses* dobivene su sljedeće vrijednosti: TP (točno pozitivni) je 34, FP (lažno pozitivni) je 25, FN (lažno negativni) je 16 i TN (točno negativni) je 125. Za klasu *Scandinavian\_dresses* dobivene su sljedeće vrijednosti: TP (točno pozitivni) je 14, FP (lažno pozitivni) je 22, FN (lažno negativni) je 36 i TN (točno negativni) je 128. Za klasu *UAE\_dresses* dobivene su sljedeće vrijednosti: TP (točno pozitivni) je 23, FP (lažno pozitivni) je 42, FN (lažno negativni) je 27 i TN (točno negativni) je 108.

Tablica 3. Vrijednosti TP, TN, FP, FN za svaku klasu modela treniranog na 50 epoha

	<b>TP (točno pozitivni)</b>	<b>FP (lažno pozitivni)</b>	<b>FN (lažno negativni)</b>	<b>TN (točno negativni)</b>
<b>CentralEurope_dresses (središnja Europa)</b>	15	25	35	125
<b>Mediterranean_dresses (Mediteran)</b>	34	25	16	125
<b>Scandinavian_dresses (Skandinavija)</b>	14	22	36	128
<b>UAE_dresses (UAE)</b>	23	42	27	108

Kod izračuna metrika, prvo su izračunate metrike preciznost, odziv i F1 mjera za svaku klasu posebno (Tablica 4). Metrike su izračunate korištenjem formula za izračun i Tablice 3 koja sadrži podatke o točno pozitivnim, lažno pozitivnim, lažno negativnim i točno negativnim vrijednostima za svaki klasu. Prema tome, za klasu *CentralEurope\_dresses* dobivena je preciznost od 38% (od svih primjera koje je model klasificirao za ovu klasu, 38% njih je zaista pripadalo ovoj klasi), odziv od 30% (model uspijeva prepoznati 30% stvarnih primjera ove klase) i F1 mjera od 33%, za klasu *Mediterranean\_dresses* dobivena je preciznost od 58% (od svih primjera koje je model klasificirao za ovu klasu, 58% njih je zaista pripadalo ovoj klasi), odziv od 68% (model uspijeva prepoznati 68% stvarnih primjera ove klase) i F1 mjera od 62%, za klasu *Scandinavian\_dresses* dobivena je preciznost od 39% (od svih primjera koje je model klasificirao za ovu klasu, 39% njih je zaista pripadalo ovoj klasi), odziv od 28% (model uspijeva prepoznati 28% stvarnih primjera ove klase) i F1 mjera od 33% i za klasu *UAE\_dresses* dobivena je preciznost od 35% (od svih primjera koje je model klasificirao za ovu klasu, 35% njih je zaista pripadalo ovoj klasi), odziv od 46% (model uspijeva prepoznati 46% stvarnih primjera ove klase) i F1 mjera od 40%.

Za uvid u performanse cijelog modela za sve klase zajedno također su izračunate metrike preciznost (makro), odziv (makro) i F1 mjera (makro) (Tablica 5). Za uvid u prosječne performanse cijelog modela na svim klasama koristi se makro uprosječivanje koje osigurava jednakost među klasama. Prema tome, preciznost (makro) cijelog modela iznosi 42% što znači da je model u 42% slučajeva bio točan kada je predviđao određenu klasu kao pozitivnu. Odziv (makro) cijelog modela iznosi 43% što znači da je model prepoznao 43% stvarnih pozitivnih primjera svake klase. F1 mjera (makro) cijelog modela iznosi 42% što znači da je model postigao 42% balansa između preciznosti i odziva za sve klase. Uz ove metrike izračunala se je i ukupna točnost cijelog modela koja iznosi 43% što znači da je model točno klasificirao 43% testnih slika.

Tablica 4. Rezultati metrika modela treniranog na 50 epoha za svaku klasu zasebno

	F1-mjera	Preciznost	Odziv
<b>CentralEurope_dresses (središnja Europa)</b>	33 %	38 %	30 %
<b>Mediterranean_dresses (Mediteran)</b>	62 %	58 %	68 %
<b>Scandinavian_dresses (Skandinavija)</b>	33 %	39 %	28 %
<b>UAE_dresses (UAE)</b>	40 %	35 %	46 %

Tablica 5. Ukupni rezultati metrika modela treniranog na 50 epoha

	Model treniran na 50 epoha
<b>Točnost</b>	43%
<b>F1-mjera (makro)</b>	42%
<b>Preciznost (makro)</b>	42%
<b>Odziv (makro)</b>	43%

### 7.6.2. Rezultati modela klasifikatora slika treniranog na 100 epoha

Rezultati evaluacije modela treniranog na 100 epoha dobiveni su računanjem matrice konfuzije, preciznosti, odziva, F1 mjere i točnosti.

Prema rezultatima matrice konfuzije (Tablica 6), model dobro prepoznaje i klasificira slike haljina koje pripadaju klasama *Mediterranean\_dresses* (31), *Scandinavian\_dresses* (23) i

*UAE\_dresses* (29). Također rezultati prikazuju da model najbolje klasificira slike haljina karakterističnih za Mediteran (31). Model ima najmanje točno klasificiranih slika za haljine koje predstavljaju klasu *CentealEurope\_dresses* (7) te model najčešće slike ove kategorije označava pogrešno kao *Mediterranean\_dresses* (22). Razlog za klasificiranje ove klase s pogrešnom klasom *Mediterranean\_dresses*, gdje su 22 slike krivo klasificirane ovom klasom može biti taj da haljine karakteristične za Mediteran jedine sadrže kraće haljine kao što to sadrži i skup slika za središnju Europu. Nadalje, mogući uzroci ovih rezultata mogu biti neusklađenost između skupa za treniranje i skupa za testiranje posebno u pogledu osvjetljenja i pozadine slika te skup podataka za treniranje kod haljina karakterističnih za središnju Europu sadrži slike koje su međusobno slične, dok se skup za testiranje razlikuje od skupa za treniranje, što može otežati modelu prepoznavanje haljina iz tih klasa. Nasuprot tome, za slike haljina karakterističnih za Mediteran podaci u skupu za treniranje i testiranje su uglavnom ujednačeni u pogledu osvjetljenja i pozadine. Također, ovaj skup podataka je treniran na raznolikim slikama i testiran na raznolikim slikama, što omogućuje modelu da bolje nauči i prepozna karakteristične značajke haljina. Osim toga, najbolji rezultati postignuti kod slika karakterističnih za Mediteran mogu biti rezultat toga što se slike tih haljina značajno razlikuju od svih ostalih haljina. Značajne razlike u značajkama haljina iz Mediterana omogućuju modelu lakše razlikovanje tih haljina od drugih, što dovodi do boljih performansi u prepoznavanju.

Tablica 6. Matrica konfuzije modela treniranog na 100 epoha

Točna/Predviđena klasa	CentralEurope_dresses	Mediterranean_dresses	Scandinavian_dresses	UAE dresses
CentralEurope_dresses	7	22	7	14
Mediterranean_dresses	8	31	4	7
Scandinavian_dresses	3	8	23	16
UAE dresses	8	2	11	29

Prema prikazanoj matrici konfuzije na Tablici 6, izrađena je i Tablica 7 gdje je za svaku klasu prikazan broj točno pozitivnih (TP), točno negativnih (TN), lažno pozitivnih (FP) i lažno negativnih (FN) primjera (Tablica 3). Prema tome za klasu *CentralEurope\_dresses* dobivene su sljedeće vrijednosti: TP (točno pozitivni) je 7, FP (lažno pozitivni) je 19, FN (lažno negativni) je 43 i TN (točno negativni) je 131. Za klasu *Mediterranean\_dresses* dobivene su sljedeće vrijednosti: TP (točno pozitivni) je 31, FP (lažno pozitivni) je 32, FN (lažno negativni) je 19 i TN (točno negativni) je 118. Za klasu *Scandinavian\_dresses* dobivene su sljedeće vrijednosti: TP (točno pozitivni) je 23, FP (lažno pozitivni) je 22, FN (lažno negativni) je 27 i TN (točno negativni) je 128. Za klasu *UAE\_dresses* dobivene su sljedeće vrijednosti: TP (točno pozitivni) je 29, FP (lažno pozitivni) je 37, FN (lažno negativni) je 21 i TN (točno negativni) je 113.

Tablica 7. Vrijednosti TP, TN, FP, FN za svaku klasu modela treniranog na 100 epoha

	TP (točno pozitivni)	FP (lažno pozitivni)	FN (lažno negativni)	TN (točno negativni)
<b>CentralEurope_dresses (središnja Europa)</b>	7	19	43	131
<b>Mediterranean_dresses (Mediteran)</b>	31	32	19	118
<b>Scandinavian_dresses (Skandinavija)</b>	23	22	27	128
<b>UAE_dresses (UAE)</b>	29	37	21	113

Kod izračuna metrika, prvo su izračunate metrike preciznost, odziv i F1 mjera za svaku klasu posebno (Tablica 8). Metrike su izračunate korištenjem formula za izračun i Tablice 7, koja sadrži podatke o točno pozitivnim, lažno pozitivnim, lažno negativnim i točno negativnim vrijednostima za svaki klasu. Prema tome, za klasu *CentralEurope\_dresses* dobivena je preciznost od 27% (od svih primjera koje je model klasificirao za ovu klasu, 27% njih je zaista

pripadalo ovoj klasi), odziv od 14% (model uspijeva prepoznati 14% stvarnih primjera ove klase) i F1 mjera od 18%, za klasu *Mediterranean\_dresses* dobivena je preciznost od 49% (od svih primjera koje je model klasificirao za ovu klasu, 49% njih je zaista pripadalo ovoj klasi), odziv od 62% (model uspijeva prepoznati 62% stvarnih primjera ove klase) i F1 mjera od 55%, za klasu *Scandinavian\_dresses* dobivena je preciznost od 51% (od svih primjera koje je model klasificirao za ovu klasu, 51% njih je zaista pripadalo ovoj klasi), odziv od 46% (model uspijeva prepoznati 46% stvarnih primjera ove klase) i F1 mjera od 48% i za klasu *UAE\_dresses* dobivena je preciznost od 44% (od svih primjera koje je model klasificirao za ovu klasu, 44% njih je zaista pripadalo ovoj klasi), odziv od 58% (model uspijeva prepoznati 58% stvarnih primjera ove klase) i F1 mjera od 50%.

Za uvid u performanse cijelog modela za sve klase zajedno također su izračunate metrike preciznost (makro), odziv (makro) i F1 mjera (makro) (Tablica 9). Za uvid u prosječne performanse cijelog modela na svim klasama koristi se makro uprosječivanje koje osigurava jednakost među klasama. Prema tome, preciznost (makro) cijelog modela iznosi 43% što znači da je model u 43% slučajeva bio točan kada je predviđao određenu klasu kao pozitivnu. Odziv (makro) cijelog modela iznosi 45% što znači da je model prepoznao 45% stvarnih pozitivnih primjera svake klase. F1 mjera (makro) cijelog modela iznosi 43% što znači da je model postigao 43% balansa između preciznosti i odziva za sve klase. Uz ove metrike izračunala se je i ukupna točnost cijelog modela koja iznosi 45% što znači da je model točno klasificirao 45% testnih slika.

Tablica 8. Rezultati metrika modela treniranog na 100 epoha za svaku klasu zasebno

	<b>F1-mjera</b>	<b>Preciznost</b>	<b>Odziv</b>
<b>CentralEurope_dresses (središnja Europa)</b>	18 %	27 %	14 %
<b>Mediterranean_dresses (Mediteran)</b>	55 %	49 %	62 %
<b>Scandinavian_dresses (Skandinavija)</b>	48 %	51 %	46 %
<b>UAE_dresses (UAE)</b>	50 %	44 %	58 %

Tablica 9. Ukupni rezultati metrika modela treniranog na 100 epoha

	<b>Model treniran na 100 epoha</b>
<b>Točnost</b>	45%
<b>F1-mjera (makro)</b>	43%
<b>Preciznost (makro)</b>	43%
<b>Odziv (makro)</b>	45%

## 8. Diskusija

Prema rezultatima modela klasifikacije slika treniranog na 50 i 100 epoha napravljena je usporedba rezultata prema broju postavljenih epoha.

### Usporedba modela klasifikacije slika prema broju postavljenih epoha (50 i 100)

Prema tablici 10, može se vidjeti da model treniran na 100 epoha daje ukupno neznatno bolje rezultate na testnim slikama u odnosu na rezultate modela treniranog na 50 epoha. Rezultati svih metrika kod modela treniranog na 100 epoha prikazuju poboljšanje od 2 % i 1 %. Rezultati kod točnosti modela ukazuju da je model treniran na 100 epoha bolji za 2 % od modela treniranog na 50 epoha te da je model treniran na 100 epoha ukupno ispravno klasificirao veći broj primjera. Kod F1 (makro) mjere poboljšanje je za 1 %. Preciznost je također poboljšana za 1 % što ukazuje da model uspijeva preciznije odrediti pripadnost slike haljina odgovarajućoj klasi. Odziv je povećan za 2 % što znači da je model bolje prepoznavao stvarne pozitivne primjere za svaku klasu. Ukupni rezultati modela treniranog na 100 epoha su bolji u odnosu na ukupne rezultate modela treniranog na 50 epoha, no kada se promatraju performanse modela treniranog na 100 epoha za svaku klasu posebno, uočava se pogoršanje modela u dvije klase s obzirom na model treniran na 50 epoha.

Tablica 10. Rezultati metrika modela treniranog i na 50 i na 100 epoha

	Model treniran na 50 epoha	Model treniran na 100 epoha
Točnost	43%	45%
F1-mjera (makro)	42%	43%
Preciznost (makro)	42%	43%
Odziv (makro)	43%	45%

Tablica 11, prikazuje rezultate metrika modela treniranog na 50 epoha i rezultate modela treniranog na 100 epoha za svaku klasu posebno. Usporedbom rezultata metrika modela treniranog na 100 epoha i rezultata metrika modela treniranog na 50 epoha mogu se uočiti pogoršanja kod modela treniranog na 100 epoha kod rezultata preciznosti, odziva i F1 mjere za

dvije klase, *CentralEurope\_dresses* i *Mediterranean\_dresses*. No model treniran na 100 epoha pokazuje i bolje rezultate u odnosu na model treniran na 50 epoha i to za klase *UAE\_dresses* i *Scandinavian\_dresses*.

Tablica 11. Rezultati metrika modela treniranog na 50 epoha i rezultati metrika treniranog modela na 100 epoha za svaku klasu posebno

	<b>F1-mjera</b>	<b>Preciznost</b>	<b>Odziv</b>
<b>CentralEurope_dresses (središnja Europa) model treniran na 50 epoha</b>	33%	38%	30%
<b>CentralEurope_dresses (središnja Europa) model treniran na 100 epoha</b>	18%	27%	14%
<b>Mediterranean_dresses (Mediteran) model treniran na 50 epoha</b>	62%	58%	68%
<b>Mediterranean_dresses (Mediteran) model treniran na 100 epoha</b>	55%	49%	62%
<b>Scandinavian_dresses (Skandinavija) model treniran na 50 epoha</b>	33%	39%	28%
<b>Scandinavian_dresses (Skandinavija) model treniran na 100 epoha</b>	48%	51%	46%
<b>UAE_dresses (UAE) model treniran na 50 epoha</b>	40%	35%	46%
<b>UAE_dresses (UAE) model treniran na 100 epoha</b>	50%	44%	58%

Prema tablici 12, gdje su prikazani rezultati matrice konfuzije modela treniranog na 50 epoha i modela treniranog na 100 epoha, može se uočiti da model treniran na 100 epoha pokazuje poboljšanja u točnosti klasificiranja slika haljina za klase *Scandinavian\_dresses* i *UAE\_dresses* dok se kod klase *CentralEurope\_dresses* i *Mediterranean\_dresses* mogu uočiti pogoršanja, odnosno bolji rezultati za model treniran na 50 epoha.

Tablica 12. Matrica konfuzije modela klasifikacije slika treniranog na 50 epoha i modela treniranog na 100 epoha

Točna/Predviđena klasa	<b>CentralEurope_dresses</b>	<b>Mediterranean_dresses</b>	<b>Scandinavian_dresses</b>	<b>UAE_dresses</b>
<b>CentralEurope_dresses (središnja Europa), model treniran na 50 epoha</b>	15	18	3	14
<b>CentralEurope_dresses (središnja Europa), model treniran na 100 epoha</b>	7	22	7	14
<b>Mediterranean_dresses (Mediteran), model treniran na 50 epoha</b>	6	34	5	5
<b>Mediterranean_dresses (Mediteran) model treniran na 100 epoha</b>	8	31	4	7
<b>Scandinavian_dresses (Skandinavija), model treniran na 50 epoha</b>	9	4	14	23
<b>Scandinavian_dresses (Skandinavija), model treniran na 100 epoha</b>	3	8	23	16
<b>UAE_dresses (UAE), model treniran na 50 epoha</b>	10	3	14	23
<b>UAE_dresses (UAE), model treniran na 100 epoha</b>	8	2	11	29

Prema rezultatima iz matrice konfuzije, kod slika haljina karakterističnih za središnju Europu (*CentralEurope\_dresses*), model treniran na 50 epoha daje bolje rezultate (15) u odnosu na rezultate (7) modela treniranog na 100 epoha te također model treniran na 100 epoha očituje i porast pogrešnog klasificiranja slika haljina karakterističnih za središnju Europu klasom *Mediterranean\_dresses*, što ukazuje na to da model nakon treniranja na 100 epoha ima više poteškoća u označavanju slika haljina karakterističnih za središnju Europu. Kod slika haljina karakterističnih za Mediteran (*Mediterranean\_dresses*), model treniran na 50 epoha daje bolje rezultate (34) u odnosu na rezultate (31) modela treniranog na 100 epoha te također model treniran na 100 epoha očituje i porast pogrešnog klasificiranja slika haljina karakterističnih za Mediteran klasama *CentralEurope\_dresses* i *UAE\_dresses* što također ukazuje na to da model nakon treniranja na 100 epoha ima više poteškoća u označavanju slika haljina karakterističnih za Mediteran.

Kod slika haljina karakterističnih za Skandinaviju (*Scandinavian\_dresses*) model treniran na 100 epoha daje bolje rezultate (23) u odnosu na rezultate (14) modela treniranog na 50 epoha. Kod slika haljina karakterističnih za Ujedinjene Arapske Emirate (*UAE\_dresses*) model treniran na 100 epoha daje bolje rezultate (29) u odnosu na rezultate (23) modela treniranog na 50 epoha.

Bolji rezultati modela treniranog na 100 epoha kod klasificiranja slika haljina karakterističnih za Ujedinjene Arapske Emirate i Skandinaviju upućuj na to da model nakon treniranja na 100 epoha bolje prepozna te slike haljina. Ovaj ishod može biti rezultat izraženijih i različitih karakteristika haljina Ujedinjenih Arapskih Emirata, koje model s više epoha uspješnije prepoznaće. Također za slike haljina karakterističnih za Skandinaviju i Ujedinjene Arapske Emirate, više epoha omogućava modelu da detaljnije nauči značajke tih haljina.

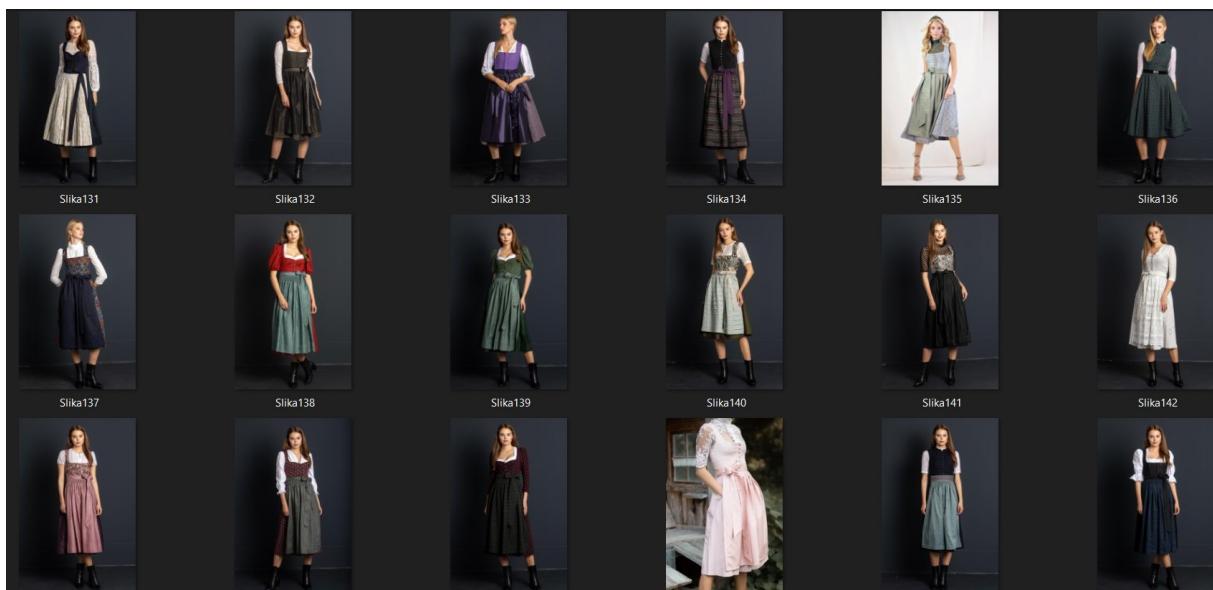
Lošiji rezultati modela treniranog na 100 epoha u usporedbi s modelom treniranim na 50 epoha mogu biti rezultat nedovoljno raznolikog skupa za treniranje, posebice kod slika haljina karakterističnih za središnju Europu, a kod slika haljina karakterističnih za Mediteran, dulje treniranje može dovesti do toga da model nauči previše specifične značajke te klase što onda rezultira slabijim rezultatima.

Promatrajući model treniran na 50 epoha i model treniran na 100 epoha, u oba slučaja model najlošije prepoznaće i klasificira slike haljina karakterističnih za središnju Europu (*CentralEurope\_dresses*). Potencijalan razlog za loše rezultate može biti taj što su slike haljina karakteristične za središnju Europu u skupu za treniranje (Slika 36) međusobno vrlo slične i prikazuju uglavnom slične oblike haljina dok se slike u skupu za testiranje (Slika 37) dosta

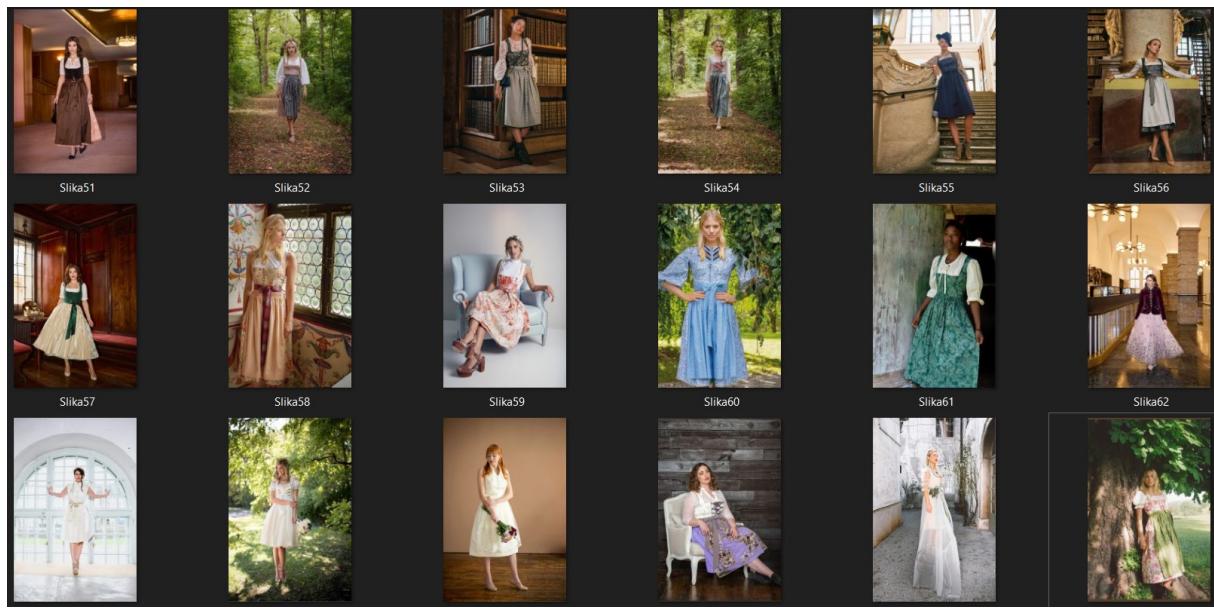
razlikuju od slika korištenih za treniranje. Također, postoji i razlika u pozadini i osvjetljenju između slika u skupu za treniranje i testiranje.

S druge strane, i kod modela treniranog na 50 epoha i treniranog na 100 epoha, najbolje su označene slike haljina karakterističnih za Mediteran. Iako model treniran na 100 epoha pokazuje pogoršanje kod prepoznavanja slika haljina karakterističnih za Mediteran i dalje ukupno najbolje prepoznaje slike haljine za tu regiju. Potencijalan razlog za najbolje prepoznavanje i klasificiranje slika karakterističnih za Mediteran je taj da je skup podataka za ovu kategoriju međusobno dosta različiti i kod treniranja (Slika 38) i kod testiranja (Slika 39) što potencijalno modelu omogućuje da bolje nauči i prepozna karakteristike tih haljina te također razlog zašto model najbolje klasificira slike ovih haljina može biti taj što se slike ovih haljina značajno razlikuju od slika haljina iz drugih klasa.

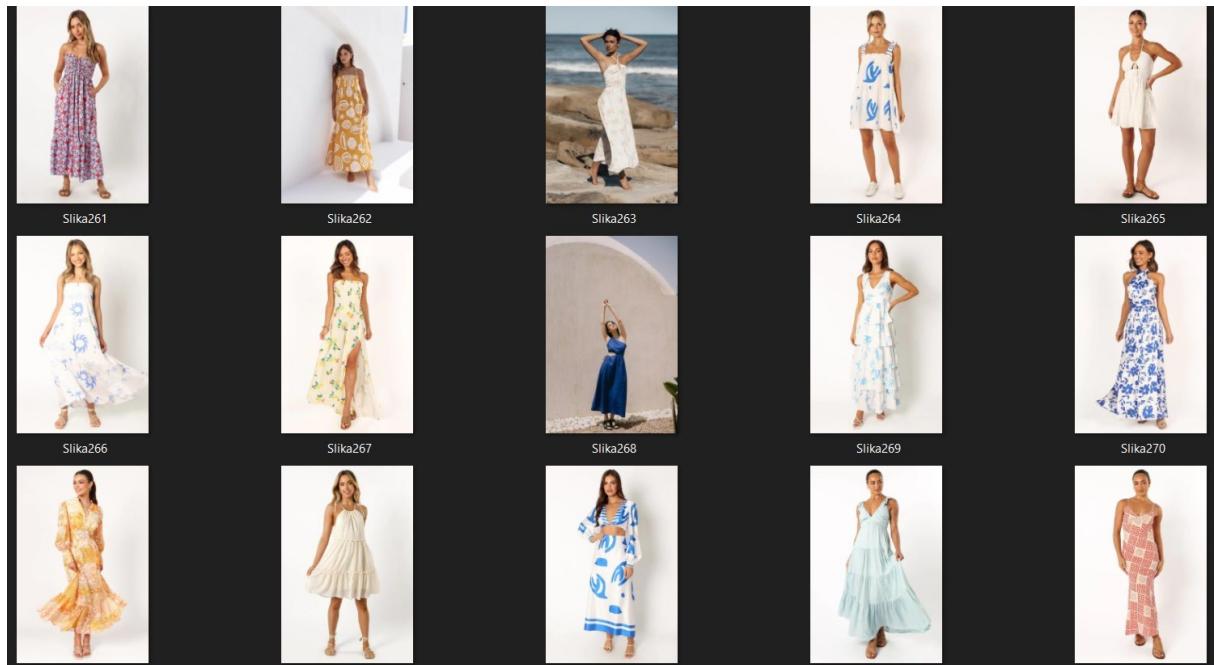
Prema rezultatima može se zaključiti da broj epoha ima utjecaj na rezultate modela te da bi se dobili bolji rezultati potrebno je podešavanje broja epoha tako da se očitaju poboljšanja modela u svim klasama. S obzirom na rezultate modela treniranog na 50 epoha i modela treniranog na 100 epoha, vidljivo je da modeli ne postižu visoke performanse te da bi se model unaprijedio potrebno je provesti dodatna treniranja, podešavanje broja epoha i ostalih hiperparametara modela, povećanje broja i raznolikosti skupa podataka. Dodavanjem većeg broja slika, kao i raznolikijih slika različitih haljina u različitim okruženjima, modelu se može omogućiti da bolje prepozna i nauči ključne značajke specifičnih vrsta haljina, što bi rezultiralo boljim performansama.



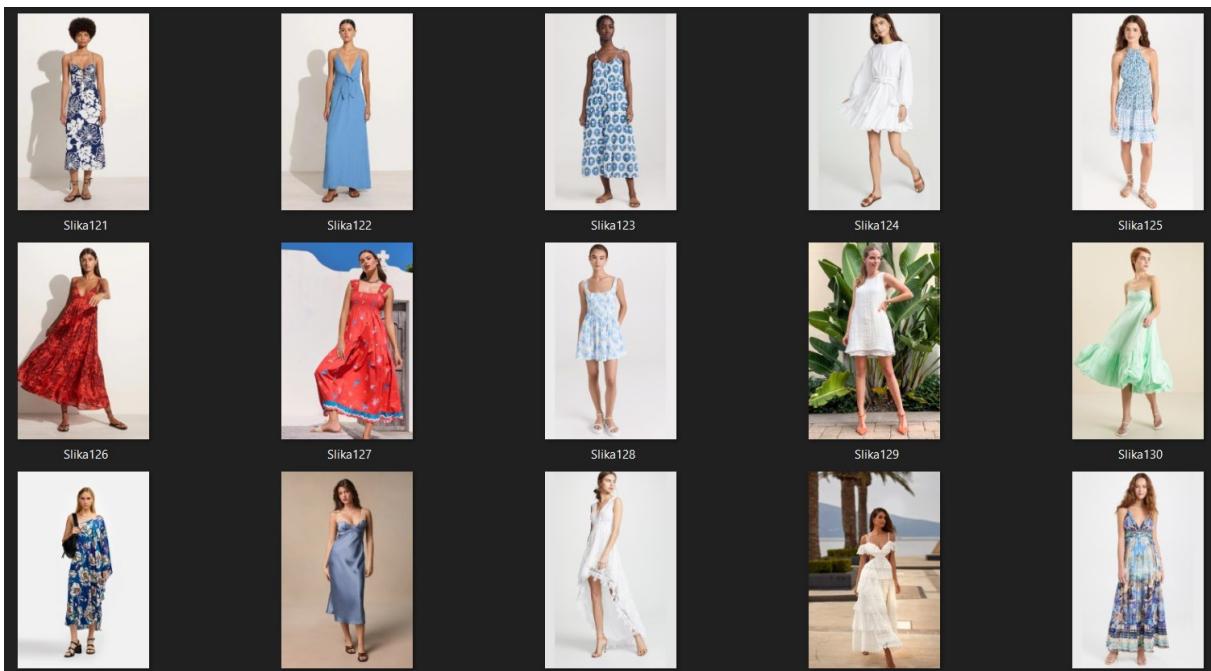
Slika 36. Skup podataka za treniranje koji prikazuje haljine karakteristične za središnju Europu (CentralEurope\_dress)



Slika 37. Skup podataka za testiranje koji prikazuje haljine karakteristične za središnju Europu (CentralEurope\_dress)



Slika 38. Skup podataka za treniranje koji prikazuje haljine karakteristične za Mediteran (Mediterranean\_dress)



Slika 39. Skup podataka za testiranje koji prikazuje haljine karakteristične za Mediteran (Mediterranean\_dress)

## **9. Zaključak**

Cilj ovog rada je razviti model za klasifikaciju slika koji može prepoznati i klasificirati raznovrsne haljine prema njihovom kulturnom podrijetlu. Ovim pristupom želi se doprinijeti boljem razumijevanju i kategorizaciji kulturno specifičnih odjevnih tradicija, s potencijalnim primjenama u modnoj industriji, obrazovanju i promicanju kulturne raznolikosti.

U teorijskom dijelu rada definirano je strojno učenje te se prikazuje proces i različite vrste strojnog učenja. Zatim se navode područja gdje se najčešće primjenjuje strojno učenje te se detaljnije definira i analizira upotreba strojnog učenja u modnoj industriji. Nadalje, fokus se stavlja na nadzirano strojno učenje, uključujući zadatke učenja pod nadzorom i ključne algoritme. Posebna pažnja posvećena je i metrikama evaluacije uz prikaz formula za njihov izračun koje se koriste u izračunavanju metrika u istraživačkome dijelu rada. Nadalje, razrađuju se pojmovi računalni vid, klasifikacija slika i duboko učenje i pruža se detaljan pregled YOLOv8 modela koji se koristi za razvoj modela u istraživačkom dijelu rada.

U praktičnom dijelu rada prikazano je provedeno istraživanje gdje se detaljno opisuje razvoj i evaluacija modela s različitim brojem epoha za klasifikaciju slika haljina. Prikazuje se skup podataka, proces treniranja modela i rezultati treniranog modela, testiranje i izvršavanje predikcija na testnom skupu podataka i na kraju evaluacija i rezultati modela na testnom skupu podataka.

Razvijen je model s različitim brojem epoha (50 i 100) za klasifikaciju slika haljina, pri čemu je za izradu modela korišten skup podataka koji sadrži slike kulturno raznolikih haljina. Ove kulturne skupine obuhvaćaju Ujedinjene Arapske Emirate, Mediteranske zemlje, Skandinavske zemlje i središnju Europu. Slike haljina prikupljene su iz javno dostupnih izvora na internetu, prvenstveno iz online trgovina. Prije početka treniranja modela, bilo je nužno pravilno strukturirati podatke. Slike su organizirane u direktorije, pri čemu je broj direktorija odgovarao broju kategorija prema kojima će model klasificirati slike. U ovom istraživanju, slike su podijeljene u četiri direktorija, svaki odražava jednu od četiri kategorije. Kategorije su definirane prema podrijetlu haljina, i to su: Mediterranean\_dresses, Scandinavian\_dresses, UAE\_dresses i CentralEurope\_dresses. Ova podjela omogućuje da model ispravno klasificira slike prema odgovarajućim kategorijama.

Skup podataka za treniranje sastojao se je od 320 slika (80 slika za svaku od 4 kulturne regije), skup podataka za validaciju uključivao je 80 slika (20 slika za svaku od 4 kulturne regije), a testni skup je obuhvaćao 200 slika (50 slika za svaku kulturnu regiju).

Izrada modela s različitim brojem epoha za klasifikaciju slika obavljena je kako bi se na kraju mogli usporedili rezultati prema broju epoha koji se postavljaju prije samog treniranja. Model treniran na 50 epoha u izradi klasifikatora slika bio je postavljen na 50 epoha, dok je model treniran na 100 epoha bio postavljen na 100 epoha. Veličina slika kod izrade modela klasifikacije slika postavljena je na 800 piksela.

Uzimajući u obzir rezultate metrika, model za klasifikaciju slika postiže slabe rezultate. Rezultati modela neovisno o broju epoha prikazuju da model najbolje klasificira slike haljina karakterističnih za Mediteran, a najlošije klasificira slike haljina karakterističnih za središnju Europu.

Analiza rezultata klasifikacije slika na testnom skupu podataka modela treniranog na 50 epoha i modela treniranog na 100 epoha pokazuje da model treniran na 100 epoha ostvaruje ukupno neznatno bolje rezultate u usporedbi s modelom treniranim na 50 epoha. Specifično, model treniran na 100 epoha pokazuje poboljšanje u ukupnom rezultatu metrika za evaluaciju modela. Metrike točnost, F1-mjera, preciznosti i odziv, očituju povećanje od 1-2%. Međutim, dok model treniran na 100 epoha pokazuje generalna poboljšanja i ukupno bolji rezultat, postoje značajni nedostaci u njegovoj izvedbi, posebno u klasifikaciji slika haljina karakterističnih za središnju Europu (*CentralEurope\_dresses*) i Mediteran (*Mediterranean\_dresses*). Dakle dobiveni rezultati prikazuju da veći broj epoha na kategorije slika središnje Europe i Mediterana utječe negativno i dobivaju se manji rezultati, a na kategorije slika UAE i Skandinavije utječe pozitivno i postižu se bolji rezultati gdje više epoha omogućava modelu da detaljnije nauči značajke tih haljina. Lošiji rezultati modela treniranog na 100 epoha u usporedbi s modelom treniranim na 50 epoha mogu biti rezultat nedovoljno raznolikog skupa za treniranje kod slika karakterističnih za središnju Europu dok dulje treniranje može dovesti do toga da model nauči previše specifične značajke za klasu *Mediterranean\_dresses* što također rezultira lošijim rezultatima. Na ovakav ukupni rezultat moguće je da je i utjecao skup podataka koji se koristio za treniranje i validaciju koji je bio relativno mali, s ukupno 320 slika za treniranje i 80 slika za validaciju. Ovako mali broj podataka može otežati modelu da nauči dovoljno relevantnih informacija, što može dovesti do loših rezultata. Također, različita podjela slika između trening i test skupova može utjecati na to da model postigne bolje rezultate na nekim klasama, dok druge klase mogu pokazivati lošije performanse. Prema tome, za postizanje optimalnih rezultata

potrebno je daljnje podešavanje broja epoha i drugih hiperparametara. Također, povećanje broja i raznolikosti skupa podataka, s ciljem boljeg odražavanja različitih uvjeta i karakteristika haljina, može značajno unaprijediti sposobnost modela da točno klasificira slike u sve kategorije.

## Literatura

1. Abu, M. A., Indra, N. H., Rahman, A. H. A, Sapiee, N. A., Ahmad I. (2019). *A study on Image Classification based on Deep Learning and Tensorflow*. 12. 563-569. Preuzeto 17.06.2024. s [https://www.researchgate.net/publication/332850035\\_A\\_study\\_on\\_Image\\_Classification\\_based\\_on\\_Deep\\_Learning\\_and\\_Tensorflow](https://www.researchgate.net/publication/332850035_A_study_on_Image_Classification_based_on_Deep_Learning_and_Tensorflow)
2. Kumar, S. (2024). *Metrics to Evaluate your Classification Model to take the Right Decisions*. Preuzeto 17.06.2024. s <https://www.analyticsvidhya.com/blog/2021/07/metrics-to-evaluate-your-classification-model-to-take-the-right-decisions/>
3. Akinsola, J.E.T., (2017). *Supervised Machine Learning Algorithms: Classification and Comparison*. International Journal of Computer Trends and Technology (IJCTT), 48, 128-138. Preuzeto 17.06.2024. s [https://www.researchgate.net/publication/318338750\\_Supervised\\_Machine\\_Learning\\_Algorithms\\_Classification\\_and\\_Comparison](https://www.researchgate.net/publication/318338750_Supervised_Machine_Learning_Algorithms_Classification_and_Comparison)
4. Al-Dujaili, M. J., Dhaam, H. Z., Al-Fatlawi, A. (2024). *An overview of face recognition methods*. Bio Web of conferences 97 (00024). Preuzeto 05.09.2024. s <http://doi.org/10.1051/bioconf/20249700024>
5. Alpaydin, E. (2010). *Introduction to machine learning (2nd ed.)*. The MIT Press. Preuzeto 11.06.2024. s: [https://kkpatel17.wordpress.com/wp-content/uploads/2015/04/alppaydin\\_machinelearning\\_2010.pdf](https://kkpatel17.wordpress.com/wp-content/uploads/2015/04/alppaydin_machinelearning_2010.pdf)
6. Alzubi, J. A., Nayyar, A. Kumar, A. (2018). *Machine Learning from Theory to Algorithms: An Overview*. Journal of Physics: Conference Series, 1142. Preuzeto 11.06.2024. s <https://iopscience.iop.org/article/10.1088/1742-6596/1142/1/012012>
7. Aptean (2023). *How Machine Learning Is Shaping the Retail Fashion Industry*. Preuzeto 17.06.2024. s <https://www.aptean.com/en-US/insights/blog/machine-learning-in-fashion-industry>
8. Barney, N., Schmelzer, R. (2024). *6 ways to reduce different types of bias in machine learning*. Preuzeto 05.09.2024. s <https://www.techtarget.com/searchenterpriseai/feature/6-ways-to-reduce-different-types-of-bias-in-machine-learning>
9. Bharadi, V., Mukadam, A. I., Panchbhai, M. N., Rode, N. N. (2017). *Image classification using deep learning*. International Journal of Engineering Research and Technology (IJERT) 6(11). Preuzeto 17.06.2024. s <https://www.ijert.org/image-classification-using-deep-learning>
10. Bolf, N. (2021). *Strojno učenje. Kemija u industriji*, 70(9-10), 591-593.
11. Chao, W. L. (2011). *Machine learning tutorial*. DISP Lab, Graduate Institute of Communication Engineering, National Taiwan University.
12. Colliot, O. (Ed.). (2023). *Machine learning for brain disorders*. Humana. Preuzeto 17.06.2024. s <https://library.oapen.org/handle/20.500.12657/75361>
13. Dalianis, H. (2018). *Evaluation Metrics and Evaluation*. In: *Clinical Text Mining*. Springer, Cham. Preuzeto 21.06.2024. s [https://doi.org/10.1007/978-3-319-78503-5\\_6](https://doi.org/10.1007/978-3-319-78503-5_6)
14. Di, W. (2020). *A comparative research on clothing images classification based on neural network models*. 2020 IEEE 2nd International Conference on Civil Aviation Safety and Information Technology. Preuzeto 17.06.2024. s <https://ieeexplore.ieee.org/document/9368530>

15. Dunder, I., Pavlovski, M., Seljan, S. (2020). *Computational Analysis of a Literary Work in the Context of Its Spatiality*. Trends and Innovations in Information Systems and Technologies. WorldCIST 2020. Advances in Intelligent Systems and Computing, Springer, 252-261. Preuzeto 05.09.2024. s [https://doi.org/10.1007/978-3-030-45688-7\\_26](https://doi.org/10.1007/978-3-030-45688-7_26)
16. Dunder, I., Seljan, S., Odak, M. (2023). *Data acquisition and Corpus Creation for phishing detection*. 2023 46th MIPRO ICT and Electronics Convention (MIPRO), 589–594. Preuzeto 17.06.2024. s <https://doi.org/10.23919/mipro57284.2023.10159904>
17. Erickson, B. J., Kitamura, F. (2021). *Magician's Corner: 9. Performance Metrics for Machine Learning Models*. Radiology. Artificial intelligence, 3(3), e200126. Preuzeto 20.06.2024. s <https://doi.org/10.1148/ryai.2021200126>
18. Europska akademija za certifikaciju informacijskih tehnologija [EITCA] (bez dat.). *Kakav je odnos između broja epoha u modelu strojnog učenja i točnosti predviđanja iz pokretanja modela?* Preuzeto 21.06.2024. s <https://hr.eitca.org/artificial-intelligence/eitc-ai-tff-tensorflow-fundamentals/overfitting-and-underfitting-problems/solving-models-overfitting-and-underfitting-problems-part-1/what-is-the-relationship-between-a-number-of-epochs-in-a-machine-learning-model-and-the-accuracy-of-prediction-from-running-the-model/>
19. *Evaluacija* (bez dat.). Hrvatska Enciklopedija. Preuzeto 17.06.2024. s <https://enciklopedija.hr/clanak/evaluacija>
20. *Evaluation Metrics in Machine Learning* (2024). Preuzeto 12.06.2024. s <https://www.geeksforgeeks.org/metrics-for-machine-learning-model/>
21. Faisal, R. (2020). *What Are Model Parameters In Deep Learning, and How To Calculate It*. Preuzeto 21.06.2024. s <https://medium.com/analytics-vidhya/what-are-model-parameters-in-deep-learning-and-how-to-calculate-it-de96476caab>
22. *Fashion machine learning applications and examples* (bez dat.). Preuzeto 05.09.2024. s <https://www.intelstyle.com/fashion-machine-learning-applications-and-examples/>
23. Govindaraju, S., Prasanna, R. T. (2024). *Fashion Finder : Ai-Powered Image Analysis and Online Shopping Integration App*. International Journal of Scientific Research in Computer Science, Engineering and Information Technology. 10. 395-402. 10.32628/CSEIT2410234.
24. Gubrani, S., (2024). *Evaluating Multi-Class Classification Model using Confusion Matrix in Python*. Preuzeto 12.06.2024. s <https://medium.com/@gubrani.sanya2/evaluating-multi-class-classification-model-using-confusion-matrix-in-python-4d9344084dfa>
25. Gündüz, D., De Kerret, P., Sidiropoulos, N., Gesbert, D., Murthy, C., Van Der Schaar, M. (2019). *Machine Learning in the Air*. Preuzeto 20.06.2024. s <https://www.imperial.ac.uk/media/imperial-college/research-centres-and-groups/ipc-lab/2019-Machine-learning-in-the-air.pdf>
26. *Image classification*. (bez dat.). Preuzeto 20.06.2024. s: <https://docs.ultralytics.com/tasks/classify/>
27. International Association of Business Analytics Certification [IABAC] (2023). *Machine Learning's Role in the Future of Fashion Industry*. Preuzeto 17.06.2024. s <https://iabac.medium.com/machine-learnings-role-in-the-future-of-fashion-industry-3614cb172c42>
28. International Business Machines [IBM] (2024). *What is deep learning?* Preuzeto 17.06.2024. s <https://www.ibm.com/topics/deep-learning>

29. International Business Machines [IBM] (bez dat.). *What is computer vision?* Preuzeto 17.06.2024. s <https://www.ibm.com/topics/computer-vision>
30. Iqbal, M., Yan, Z. (2015). *Supervised machine learning approaches: A survey.* International Journal of Soft Computing. Preuzeto 11.06.2024. s [https://www.researchgate.net/publication/301779181\\_SUPERVISED\\_MACHINE\\_LEARNING\\_APPROACHES\\_A\\_SURVEY](https://www.researchgate.net/publication/301779181_SUPERVISED_MACHINE_LEARNING_APPROACHES_A_SURVEY)
31. Jaworski, R., Dunder, I., Seljan, S. (2021). *Usability Analysis of the Concordia Tool Applying Novel Concordance Searching.* Information Technology and Systems. 1, 128-138. Preuzeto 05.09.2024. s <https://doi.org/10.1007/978-3-03>
32. Jayatilake, S. M., Ganegoda, G. U. (2021). *Involvement of Machine Learning Tools in Healthcare Decision Making.* *Journal of healthcare engineering.* (online) Dostupno na: <https://onlinelibrary.wiley.com/doi/10.1155/2021/6679512> (Pristupljeno 12.06.2024.)
33. Jocher, G., Q, B. (2023.) *Tips for best training results.* Preuzeto 20.06.2024. s [https://docs.ultralytics.com/yolov5/tutorials/tips\\_for\\_best\\_training\\_results/](https://docs.ultralytics.com/yolov5/tutorials/tips_for_best_training_results/)
34. Jović, A. (2019). *Uvod u strojno učenje.* Radionica DataCrunch 2019, EESTEC LC Zagreb, Sveučilište u Zagrebu Fakultet elektrotehnike i računarstva. Preuzeto 17.06.2024. s <https://www.bib.irb.hr:8443/1028790>
35. Katalinić, J., Dunder, I., Seljan, S. (2024). *Polarizing Topics on Twitter in the 2022 United States Elections.* Information 14 (11), 609. Preuzeto 05.09.2024. s <https://doi.org/10.3390/info14110609>
36. Katalinić, J., Dunder, I., Seljan, S. (2024). *Unraveling the Nuclear Debate: Twitter Insights through Clustering.* Electronics.
37. Kovač, A., Dunder, I., Seljan, S. (2022). *An overview of machine learning algorithms for detecting phishing attacks on Electronic Messaging Services.* 2022 45th Jubilee International Convention on Information, Communication and Electronic Technology (MIPRO). Preuzeto 05.09.2024. s <https://doi.org/10.23919/mipro55190.2022.9803517>
38. Krstić, Ž., Seljan, S., Zoroja, J. (2019). *Visualization of Big Data Text Analytics in Financial Industry: A Case Study of Topic Extraction for Italian Banks.* ENTRENOVA '19 - ENTerprise REsearch InNOVAtion 5 (1), 67-75.
39. Kubát, M., Bratko, I., Michalski, R.S. (1996). *A Review of Machine Learning Methods* *Machine Learning and Data Mining: Methods and Applications*, Edited 1.2 the Machine Learning Task. Preuzeto 11.06.2024. s <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=e2f9cf5e6c13fe4244b0359c852747c1393c30ca>
40. Lara, M. (bez dat.). *How does machine learning work?* Preuzeto 11.06.2024. s <https://www.sitecore.com/knowledge-center/digital-marketing-resources/how-does-machine-learning-work>
41. Lv, Q., Zhang, S. i Wang, Y. (2022). *Deep Learning Model of Image Classification Using Machine Learning, Advances in Multimedia.* Preuzeto 17.06.2024. s [https://www.researchgate.net/publication/362126836\\_Deep\\_Learning\\_Model\\_of\\_Image\\_Classification\\_Using\\_Machine\\_Learning](https://www.researchgate.net/publication/362126836_Deep_Learning_Model_of_Image_Classification_Using_Machine_Learning)
42. Mahesh, B. (2020). *Machine Learning Algorithms - A Review.* International Journal of Science and Research (IJSR) ResearchGate Impact Factor, 9(1), 381-386. Preuzeto 20.06.2024. s <https://doi.org/10.21275/ART20203995>
43. Marrara, S., Pejić Bach, M., Seljan, S., Topalovic, A. (2019). *FinTech as a Disruptive Technology for Financial Institutions*, 42-60.

44. *Moda* (bez dat.). Hrvatska Enciklopedija. Preuzeto 17.06.2024. s <https://www.enciklopedija.hr/clanak/moda>
45. Mohri, M., Rostamizadeh, A., Talwalkar, A. (2018). *Foundations of Machine Learning*. Cambridge, MA: MIT Press. Preuzeto 11.06.2024. s [https://www.hlevkin.com/hlevkin/45MachineDeepLearning/ML/Foundations\\_of\\_Machine\\_Learning.pdf](https://www.hlevkin.com/hlevkin/45MachineDeepLearning/ML/Foundations_of_Machine_Learning.pdf)
46. *Multiclass Confusion Matrix - All That You Need to Know* (2024). Preuzeto 17.06.2024. s <https://www.projectpro.io/recipes/explain-multiclass-confusion-matrix>
47. Nasteski, V. (2017). *An overview of the supervised machine learning methods*. Horizons, 4, 51-62. Preuzeto 17.06.2024. s [https://www.researchgate.net/publication/328146111\\_An\\_overview\\_of\\_the\\_supervised\\_machine\\_learning\\_methods](https://www.researchgate.net/publication/328146111_An_overview_of_the_supervised_machine_learning_methods)
48. Oladipupo, T. (2010). *Types of Machine Learning Algorithms*. Preuzeto 11.06.2024. s [https://www.researchgate.net/publication/221907660\\_Types\\_of\\_Machine\\_Learning\\_Algorithms](https://www.researchgate.net/publication/221907660_Types_of_Machine_Learning_Algorithms)
49. Pejić Bach, M., Krstić, Ž., Seljan, S. (2019). *Big data text mining in the financial sector*. In *Expert systems in finance*, 80-96.
50. Pejić Bach, M., Krstić, Ž., Seljan, S., Turulja, L. (2019). *Text Mining for Big Data Analysis in Financial Sector: A Literature Review*. Sustainability, 11 (5), 1-27. Preuzeto 05.09.2024. s <https://doi.org/10.3390/su11051277>
51. Radišić, B., Dunder, I., Seljan, S. (2023). *Data Analysis of the Motivation and Factors for a Shorter Duration of Study*. Central European Conference on Information and Intelligent Systems CECIIS, 179-187. Preuzeto 05.09.2024. s <https://repositorij.ftrr.hr/islandora/ob>
52. Radišić, B., Dunder, I., Seljan, S. (2024). *Predictive Factors for Completion or Dropping Out of Professional Studies*. Central European Conference on Information and Intelligent Systems CECIIS.
53. Rajbhoj, S. M., Shivale, S., Mulik, V. P., Shirke, S., Yadav, A. P. (2024). *Obesity Guard: Machine Learning for Early Detection and Preventioning*. International Research Journal on Advanced Engineering Hub (IRJAEH). 2. 2041-2051. 10.47392/IRJAEH.2024.0279.
54. Ramprasath, M., Hariharan, S., Prasath, R. (2022). *Image Classification using Convolutional Neural Networks*. Preuzeto 17.06.2024. s [https://www.researchgate.net/publication/357974255\\_Image\\_Classification\\_using\\_Convolutional\\_Neural\\_Networks](https://www.researchgate.net/publication/357974255_Image_Classification_using_Convolutional_Neural_Networks)
55. Raschka, S. (2015). *Python Machine Learning*. Packt Publishing Ltd., Birmingham. Preuzeto 11.06.2024. s <http://radio.eng.niigata-u.ac.jp/wp/wp-content/uploads/2020/06/python-machine-learning-2nd.pdf>
56. Reljić, I., Dunder, I., Seljan, S. (2019). *Photogrammetric 3D Scanning of Physical Objects: Tools and Workflow*. TEM Journal DOI: 10.18421/TEM82-09 8 (2), 383-388.
57. Riva, M. (2021). Top-N accuracy metrics. Preuzeto 20.06.2024. s <https://www.baeldung.com/cs/top-n-accuracy-metrics>
58. Rohrmanstorfer, S., Komarov, M., Mödritscher, F. (2021). *Image Classification for the Automatic Feature Extraction in Human Worn Fashion Data*. Mathematics. 9(6), 624. Preuzeto 20.06.2024. s <https://www.mdpi.com/2227-7390/9/6/624>

59. Saini, A. (2024). *What is Decision Tree? [A Step-by-Step Guide]*. Preuzeto 12.06.2024. s <https://www.analyticsvidhya.com/blog/2021/08/decision-tree-algorithm/>
60. Samia, B., Soraya, Z. i Malika, M. (2022). *Fashion Images Classification using Machine Learning, Deep Learning and Transfer Learning Models*. Preuzeto 17.06.2024. s <https://ieeexplore.ieee.org/document/9786364>
61. Seljan S., Miloloža, I., Pejić Bach, M. (2020). *e-Government in European Countries: Gender and Ageing Digital Divide*. Interdisciplinary Management Research XVI, 1563-1584.
62. Seljan, S. (2024). *Zdravlje studenata u digitalnom okruženju: tehnologija u borbi protiv debljine*. Preuzeto 05.09.2024. s [ZDRAVLJE STUDENATA U DIGITALNOM OKRUŽENJU: TEHNOLOGIJA U BORBI PROTIV DEBLJINE | Nefro \(healthmed.hr\)](#)
63. Seljan, S., Baretić, M., Kučiš, M. (2014). *Information retrieval and terminology extraction in online resources for patients with diabetes*. Collegium antropologicum 38 (2), 705-710.
64. Seljan, S., Dundar, I. (2014). *Combined Automatic Speech Recognition and Machine Translation in Business Correspondence Domain for English-Croatian*. Journal of Computer, Information, Systems and Control Engineering 8 (11), 1069.
65. Seljan, S., Tolj, N., Dundar, I. (2023). *Information extraction from security-related datasets*. 2023 46th MIPRO ICT and Electronics Convention (MIPRO). Preuzeto 17.06.2024. s <https://doi.org/10.23919/mipro57284.2023.10159920>
66. Shuptrine, C. (2024). *What Is Image Classification? The Definitive 2024 Guide*. Preuzeto 25.06.2024. s <https://www.nyckel.com/blog/image-classification/>
67. Snajder, J. (2022). *Vrednovanje modela Strojno učenje 1*, UNIZG FER, ak. god. 2022./2023. Predavanje, verzija 1.3. Preuzeto 20.06.2024. s [https://www.fer.unizg.hr/predmet/struce1/materijali%23!p\\_rep\\_142310!\\_210848](https://www.fer.unizg.hr/predmet/struce1/materijali%23!p_rep_142310!_210848)
68. Sruthi, E.R. (2024). *Understand Random Forest Algorithm With Examples*. Preuzeto 12.06.2024. s <https://www.analyticsvidhya.com/blog/2021/06/understanding-random-forest/>
69. Sutton, R. S., Barto, A. G. (2014). *Reinforcement Learning: An Introduction*. The MIT Press, 53-57. Preuzeto 17.06.2024. s <https://web.stanford.edu/class/psych209/Readings/SuttonBartoIPRLBook2ndEd.pdf>
70. *Training and validation los sin deep learning* (2024.) Preuzeto 20.06.2024. s <https://www.baeldung.com/cs/training-validation-loss-deep-learning>
71. *Učenje* (bez dat.). Hrvatska Enciklopedija. Preuzeto 20.06.2024. s <https://www.enciklopedija.hr/clanak/ucenje>
72. *Under the hood: YOLOv8 architecture explained* (2023). Preuzeto 20.06.2024. s <https://keylabs.ai/blog/under-the-hood-yolov8-architecture-explained/>
73. Vujović, Ž. Đ. (2021). *Classification model evaluation metrics*. International Journal of Advanced Computer Science and Applications (IJACSA), 12(6). Preuzeto 20.06.2024. s [https://www.researchgate.net/publication/352902406\\_Classification\\_Model\\_Evaluation\\_Metrics](https://www.researchgate.net/publication/352902406_Classification_Model_Evaluation_Metrics)
74. *What is Epoch in Machine Learning?* (2023). Preuzeto 20.06.2024. s <https://www.simplilearn.com/tutorials/machine-learning-tutorial/what-is-epoch-in-machine-learning>

75. *What is image classification? Basics you need to know* (2023). Preuzeto 17.06.2024. s <https://www.superannotate.com/blog/image-classification-basics>
76. Yadav, P. (2024) *Image Classification Hyperparameter Tuning: A Comprehensive Guide*. Preuzeto 21.06.2024. s <https://medium.com/@prashantyadav03082000/image-classification-hyperparameter-tuning-a-comprehensive-guide-000c945c2531>
77. *YOLO Performance Metrics*. (bez dat.). Preuzeto 12.06.2024. s <https://docs.ultralytics.com/guides/yolo-performance-metrics/#case-3>
78. Zaghouani, W., Seljan, S., Dunder, I., Yahiaoui, R., Al-Adwan, A. (2024). *Creating a Multilingual Dataset in Arabic and Croatian from Sports Videos through a Data Processing Pipeline Combining ASR and MT*.
79. Zhang, Y. (Ed.). (2010). *New Advances in Machine Learning*. InTech.

## **Popis slika**

Slika 1. Proces strojnog učenja .....	5
Slika 2. Nadzirano strojno učenje.....	6
Slika 3. Nenadzirano strojno učenje.....	7
Slika 4. Polu-nadzirano strojno učenje.....	8
Slika 5. Učenje s pojačanjem .....	9
Slika 6. Jednostavan prikaz stabla odlučivanja .....	15
Slika 7. Slučajna šuma .....	16
Slika 8. Matematička formula - Naive Bayes.....	17
Slika 9. Linearna regresija.....	18
Slika 10. Logistička regresija .....	19
Slika 11. Stroj s potpornim vektorima .....	20
Slika 12. K-najbliži susjed .....	21
Slika 13. Formula za izračunavanje točnosti.....	23
Slika 14. Formula preciznosti.....	23
Slika 15. Formula odziva .....	24
Slika 16. Formula F1 mjere.....	25
Slika 17. Prikaz matrice konfuzije .....	25
Slika 18. Višeklasna matrica konfuzije .....	27
Slika 19. Formule za izračun ROC krivulje .....	28
Slika 20. Prikaz ROC krivulje.....	28
Slika 21. Formula za log gubitak .....	29
Slika 22. Prikaz konvolucijske neuronske mreže.....	34
Slika 23. Haljine Ujedinjenih Arapskih Emirata.....	39
Slika 24. Haljine Mediterana.....	39
Slika 25. Haljine središnje Europe .....	40
Slika 26. Haljine Skandinavskih zemalja .....	40
Slika 27. Rezultati treniranja modela na 50 epoha s obzirom na broj epoha i gubitke treniranja i validacije .....	44
Slika 28. Rezultati treniranja modela na 50 epoha - validacijska točnost s obzirom na broj epoha .....	44

Slika 29. Rezultati treniranja modela na 100 epoha s obzirom na broj epoha i gubitke treniranja i validacije .....	45
Slika 30. Rezultati treniranja modela na 100 epoha - validacijska točnost s obzirom na broj epoha .....	45
Slika 31. Najviši postotak točnosti kod treniranja modela na 50 epoha.....	46
Slika 32. Najviši postotak točnosti kod treniranja modela na 100 epoha.....	47
Slika 33. Prikaz slike Slika1.....	48
Slika 34. Prikaz rezultata testiranja modela treniranog na 50 epoha i njegovih predikcija klase za svaku sliku .....	49
Slika 35. Prikaz rezultata testiranja modela treniranog na 100 epoha i njegovih predikcija klase za svaku sliku .....	49
Slika 36. Skup podataka za treniranje koji prikazuje haljine karakteristične za središnju Europu (CentralEurope_dress).....	63
Slika 37. Skup podataka za testiranje koji prikazuje haljine karakteristične za središnju Europu (CentralEurope_dress).....	64
Slika 38. Skup podataka za treniranje koji prikazuje haljine karakteristične za Mediteran (Mediterranean_dress).....	64
Slika 39. Skup podataka za testiranje koji prikazuje haljine karakteristične za Mediteran (Mediterranean_dress).....	65

## **Popis tablica**

Tablica 1. Matrica konfuzije - TP, TN, FP i FN vrijednosti za svaku klasu.....	27
Tablica 2. Matrica konfuzije modela treniranog na 50 epoha.....	51
Tablica 3. Vrijednosti TP, TN,FP,FN za svaku klasu modela treniranog na 50 epoha .....	52
Tablica 4. Rezultati metrika modela treniranog na 50 epoha za svaku klasu zasebno.....	54
Tablica 5. Ukupni rezultati metrika modela treniranog na 50 epoha .....	54
Tablica 6. Matrica konfuzije modela treniranog na 100 epoha.....	55
Tablica 7. Vrijednosti TP, TN,FP,FN za svaku klasu modela treniranog na 100 epoha .....	56
Tablica 8. Rezultati metrika modela treniranog na 100 epoha za svaku klasu zasebno.....	57
Tablica 9. Ukupni rezultati metrika modela treniranog na 100 epoha .....	58
Tablica 10. Rezultati metrika modela treniranog i na 50 i na 100 epoha.....	59
Tablica 11. Rezultati metrika modela treniranog na 50 epoha i rezultati metrika treniranog modela na 100 epoha za svaku klasu posebno .....	60
Tablica 12. Matrica konfuzije modela klasifikacije slika treniranog na 50 epoha i modela treniranog na 100 epoha .....	61

# Klasifikacija slika primjenom nadziranog strojnog učenja

## Sažetak

Prisutnost tehnologije u svakom aspektu života postala je gotovo neizostavna. Tehnološki napredak transformira način na koji živimo i utječe na naše razumijevanje i interpretaciju svijeta oko nas. Posebno se očituje napredak u području strojnog učenja koje je zahvatilo sve slojeve znanosti i većinu industrija, posebno modnu industriju. Stoga primjena nadziranog strojnog učenja u klasifikaciji slika s naglaskom na kulturno specifične haljine iz različitih regija svijeta postaje važna. Ovim pristupom želi se doprinijeti boljem razumijevanju i kategorizaciji kulturno specifičnih odjevnih tradicija, s potencijalnim primjenama u modnoj industriji, obrazovanju i promicanju kulturne raznolikosti.

Cilj ovog rada bio je razviti model za klasifikaciju slika koji može prepoznati i klasificirati raznovrsne haljine prema njihovom podrijetlu. Razvijen je model za klasifikaciju slika koristeći skup podataka koji sadrži slike kulturno raznolikih haljina iz Skandinavije, Mediterana, Ujedinjenih Arapskih Emirata i središnje Europe. Model je treniran na različitom broju epoha (50 i 100) kako bi se usporedili rezultati i performanse modela s obzirom na broj epoha. Analiza performansi modela u odnosu na broj epoha, pokazuje da model treniran na većem broju epoha (100) postiže neznatna poboljšanja u odnosu na model treniran na manjem broju epoha (50). Veći broj epoha (100) poboljšava performanse u klasifikaciji slika haljina karakterističnih za Ujedinjene Arapske Emirate i Skandinaviju, dok negativno utječe na klasifikaciju slika haljina karakterističnih za središnju Europu i Mediteran. I model treniran na 50 epoha i model treniran na 100 epoha ima poteškoća u klasificiranju slika haljina karakterističnih za središnju Europu, dok najbolje rezultate postiže u klasifikaciji slika haljina karakterističnih za Mediteran. Za postizanje optimalnih rezultata potrebno je daljnje podešavanje broja epoha i drugih hiperparametara. Također, povećanje broja i raznolikosti skupa podataka, s ciljem boljeg odražavanja različitih uvjeta i karakteristika haljina, može značajno unaprijediti sposobnost modela da točno klasificira slike u sve kategorije.

**Ključne riječi:** strojno učenje, nadzirano strojno učenje, klasifikacija slika, detekcija objekata, modna industrija, epohe

# **Image classification using supervised machine learning**

## **Summary**

The presence of technology in every aspect of life has become almost inevitable. Technological progress is transforming the way we live and influencing our understanding and interpretation of the world around us. The progress in the field of machine learning, which has affected all layers of science and most industries, especially the fashion industry, is particularly evident. Therefore, the application of supervised machine learning in image classification with a focus on culturally specific dresses from different regions of the world becomes important. This approach aims to contribute to a better understanding and categorization of culturally specific clothing traditions, with potential applications in the fashion industry, education and the promotion of cultural diversity.

The aim of this paper was to develop a model for image classification that can recognize and classify various dresses according to their origin. An image classification model was developed, using a dataset containing images of culturally diverse dresses from Scandinavia, the Mediterranean, the United Arab Emirates, and Central Europe. The model was trained on different numbers of epochs (50 and 100) to compare the results and performance of the model with respect to the number of epochs. The analysis of the performance of the model in relation to the number of epochs shows that the model trained on a larger number of epochs (100) achieves slight improvements compared to the model trained on a smaller number of epochs (50). A larger number of epochs (100) improves the performance in the classification of dress images characteristic of the United Arab Emirates and Scandinavia, while negatively affecting the classification of dress images characteristic of Central Europe and the Mediterranean. Both the model trained on 50 epochs and the model trained on 100 epochs have difficulties in classifying images of dresses characteristic of Central Europe, while they achieve the best results in classification of images of dresses characteristic of the Mediterranean. To achieve optimal results, further adjustment of the number of epochs and other hyperparameters is necessary. Also, increasing the number and diversity of the dataset, with the aim of better reflecting the different conditions and characteristics of the dresses, can significantly improve the model's ability to accurately classify images into all categories.

**Keywords:** machine learning, supervised machine learning, image classification, object detection, fashion industry, epochs