

Korištenje neuronskih mreža za verifikaciju fotografija u procesu preuzimanja rizika u osiguranju

Mojsinović, Dubravko

Professional thesis / Završni specijalistički

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Electrical Engineering and Computing / Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:168:367014>

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

Download date / Datum preuzimanja: **2024-08-28**



Repository / Repozitorij:

[FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repository](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Dubravko Mojsinović

**KORIŠTENJE NEURONSKIH MREŽA
ZA VERIFIKACIJU FOTOGRAFIJA
U PROCESU PREUZIMANJA RIZIKA
U OSIGURANJU
SPECIJALISTIČKI RAD**

Zagreb, 2023.

UNIVERSITY OF ZAGREB
FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING
SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Dubravko Mojsinović

USING NEURAL NETWORKS
FOR PHOTOGRAPH VERIFICATION
IN INSURANCE UNDERWRITING PROCESS
**KORIŠTENJE NEURONSKIH MREŽA
ZA VERIFIKACIJU FOTOGRAFIJA
U PROCESU PREUZIMANJA RIZIKA
U OSIGURANJU**

SPECIALIST THESIS
SPECIJALISTIČKI RAD

Zagreb, 2023.

Specijalistički rad izrađen je na Sveučilištu u Zagrebu Fakultetu elektrotehnike i računarstva u sklopu poslijediplomskog specijalističkog studija Proizvodi, digitalne inovacije i tehnologije u osiguranju – INSURTECH

Mentor: izv. prof. dr. sc. Tomislav Petković

Specijalistički rad ima: 70 stranica

Specijalistički rad br.: _____

Povjerenstvo za ocjenu u sastavu:

1. prof. dr. sc. Marko Subašić – predsjednik
2. izv. prof. dr. sc. Tomislav Petković – mentor
3. doc. dr. sc. Azra Tafro, Sveučilište u Zagrebu Fakultet šumarstva i drvne tehnologije – članica

Povjerenstvo za obranu u sastavu:

1. prof. dr. sc. Marko Subašić – predsjednik
2. izv. prof. dr. sc. Tomislav Petković – mentor
3. doc. dr. sc. Azra Tafro, Sveučilište u Zagrebu Fakultet šumarstva i drvne tehnologije – članica

Datum obrane: 28. ožujka 2023.

SAŽETAK

U automobilskom autokasko osiguranju fotografiranje osobnih vozila omogućava dobivanje informacija prilikom prihvata u osiguranje i nakon štete. U području računalnog vida za detekciju vozila i izdvajanje značajki koriste se neuronske mreže. U radu se uzima prethodno naučeni model neuronske mreže koji je prilagođen. Prikazuje se metodologija za određivanje granice crvene boje u HSV modelu. Korišten program je Jupiterska bilježnica na platformi COLAB u koju se upisuju naredbe u Pythonu. Analizirano je 135 fotografija. Velik broj fotografija ne kadrira najbolje vozilo koje je predmet osiguranja. Udio površine detektiranog osobnog vozila na fotografiji od 39% pokazuje se kao udio kojemu treba težiti. Orijentacijski 100.000-200.000 piksela bi mogla biti donja granica kod akvizicije fotografije za osobno vozilo neovisno o pozadini koju zadovoljava većina fotografija. Program je na 15 fotografija, koje ne sadrže osobno vozilo, prepoznao da se ne radi o osobnom vozilu. U jednom slučaju program ne detektira osobno vozilo. Osobna vozila s udjelom crvenih piksela $\leq 3,6\%$ nisu crvena. Kod $< 3\%$ vozila rezultat je nejasan pa se takve fotografije trebaju ručno pregledati. Vozila s udjelom crvenih piksela $> 13,1\%$ su crvena. Rezultati dobiveni na fotografijama umanjanim za faktor 2 ne zaostaju za rezultatima na originalnim fotografijama s tim da program radi brže.

Ključne riječi: automobilsko kasko osiguranje, neuronska mreža, detekcija osobnog vozila na fotografiji, prepoznavanje crvenih vozila

ABSTRACT

In car casco insurance, taking photos of personal vehicles allows you to obtain information for underwriting and claim processing. In the field of computer vision, neural networks are used for vehicle detection and feature extraction. A pre-trained neural network model that has been adapted is used in the specialist thesis. The methodology for determining the red color limit in the HSV model is presented. Programming is done on a Jupyter notebook in COLAB environment with Python commands. 135 photos were analyzed. A large number of pictures do not focus the best on the vehicle that is the subject of insurance. The share of the surface of the detected passenger vehicle in the image of 39% proves to be a solid share to strive for. A rough 100.000-200,000 pixels might be the limit of adequate vehicle resolution that most photos meet. The program recognized correctly 15 photos with no personal vehicle. In one case, the program does not detect a personal vehicle. Cars with a proportion of red pixels $\leq 3.6\%$ are not red. In $< 3\%$ of vehicles, the result is unclear, so such photos should be reviewed manually. Vehicles with a red pixels share $> 13.1\%$ are red. The results obtained on the photos reduced by a factor of 2 do not lag behind the results on the original photos, with the fact that the program works faster.

Keywords: car casco (motor own damage) insurance, neural network, detection of personal vehicle in a photo, red colored car recognition

SADRŽAJ

Uvod.....	1
1. Pregled područja računalnog vida.....	3
2. Pregled procesa automobilske osiguranja.....	7
2.1. Unapređenje procesa.....	8
3. Primjenjena metoda.....	9
4. Detekcija osobnog vozila.....	11
5. Predobrada i kontrola fotografija.....	13
5.1. Uzimanje u obzir orijentacije fotografije.....	13
5.2. Detekcija osobnog vozila na fotografijama koje ne sadrže osobno vozilo.....	14
5.3. Prepoznavanje fotografija na kojima osobno vozilo nije dobro kadrirano.....	14
5.4. Prepoznavanje fotografija sa slabom rezolucijom.....	16
6. Prepoznavanje boje osobnog vozila.....	19
6.1. Sustavi boja.....	19
6.2. Izbor crvene boje za prepoznavanje.....	20
6.3. Kalibracija HSV modela radi prepoznavanja crvene boje.....	21
6.4. Histogram boja na detektiranom osobnom vozilu.....	27
7. Rezultati.....	29
7.1. Detekcija osobnog vozila na fotografijama na kojima se nalazi osobno vozilo.....	30
7.2. Detekcija osobnog vozila na fotografijama koje ne sadrže osobno vozilo.....	30
7.3. Prepoznavanje fotografija na kojima osobno vozilo nije dobro kadrirano.....	33
7.4. Fotografije sa slabom rezolucijom.....	38
7.5. Određivanje praga za prepoznavanje crvene boje.....	42
8. Analiza utjecaja smanjivanja rezolucije na rezultate.....	47
8.1. Detekcija osobnog vozila na fotografijama na kojima se nalazi osobno vozilo.....	48
8.2. Detekcija osobnog vozila na fotografijama koje ne sadrže osobno vozilo.....	50
8.3. Prepoznavanje fotografija na kojima osobno vozilo nije dobro kadrirano.....	50
8.4. Fotografije sa slabom rezolucijom.....	59
8.5. Određivanje praga za prepoznavanje crvene boje.....	60
9. Zaključak.....	61
10. Popis literature.....	63
11. Životopis.....	67
12. Biography.....	69

UVOD

„...Ipak, podloga svake definicije osiguranja je da je to zajednica osoba izložena istoj vrsti rizika, u kojoj se plaćanjem premije svih članova prikupljaju sredstva potrebna da bi se članu koji ima štetu ta šteta i naknadila...“ [1]


Jedan od problema s kojim se susreću osiguravajuća društva jest što se u okviru raznih procesa prikupljaju fotografije predmeta osiguranja, npr. osobnih vozila, ali se u dovoljnoj mjeri ne koriste mogućnosti modernih tehnologija za njihovu automatsku obradu i analizu. U tipičnom poslovnom procesu automobilskog kasko osiguranja fotografije vozila se pohranjuju u informacijski sustav osiguratelja nakon čega zaposlenici pregledavaju fotografije tijekom procesa preuzimanja rizika (*underwriting-UW*). Pritom je potrebno verificirati fotografije odnosno provjeriti poštuju li one zadane standarde, a osim toga se iz fotografija mogu izdvojiti značajke važne za procjenu rizika. Navedena verifikacija i izdvajanje značajki može se ostvariti korištenjem modernih tehnologija. Tipičan primjer je izdvajanje boje ili marke vozila pomoću koje se automatski može provjeriti sadrže li sve fotografije vozilo iste boje ili marke. Osim toga poznavanje boje ili drugih značajki svih vozila iz portfelja omogućava provođenje statističke analize radi boljeg razumijevanja preuzetog rizika.

Postoje razni detektori koji mogu prepoznati vozilo. Oni su dosta grubi i ne mogu prepoznati finije razlike kao npr. tip vozila, boju itd. za što je bolje koristiti metode koje barataju s fotografijama vozila. U području računalnog vida danas se za rješenje detekcije osobnog vozila i izdvajanje značajki koriste neuronske mreže. Osim korištenja neuronskih mreža jednom kada je vozilo detektirano, lokalizirano i segmentirano na fotografijama se za izdvajanje raznih značajki mogu koristiti standardne metode obrade i analize slika.

Cilj rada je istražiti literaturu i postojeće dobre prakse u osiguranju radi utvrđivanja kako se verificiraju fotografije te koje se sve značajke izdvajaju, koje se dodatno mogu izdvajati te kako se koriste u poslovnim procesima. U radu je odabrana kombinacija verifikacije kojom se detektira vozilo i značajke tj. prepoznavanja boje. Implementiran je i evaluiran program za provjeru značajke tj. crvene boje vozila. Pregledani su primarno internetski izvori, ali i stručni i znanstveni. Za odabranu značajku tj. crvenu boju definiran je kriterij kvalitete (točnost i pouzdanost) tj. granica odlučivanja. Na postojećim primjerima fotografija prikazano je kako program radi te je provedena kvalitativna i kvantitativna analiza.

U ovom radu se prikazuju i rezultati nakon smanjenja broja piksela usporedbom rezultata s onima na originalnim fotografijama.


Shema u nastavku prikazuje zamišljen proces obrade fotografija.



Slika 0.1 Odabrani proces obrade fotografija

1. PREGLED PODRUČJA RAČUNALNOG VIDA


U okviru umjetne inteligencije (*artificial intelligence*-AI) prepoznatljivo mjesto zauzima računalni vid u okviru kojeg se može pronaći prepoznavanje slika. [2]



Slika 1.1 Područja umjetne inteligencije [2]

Može se uočiti da je računalni vid područje umjetne inteligencije koje će doživjeti širu prihvaćenost u idućih nekoliko godina. Ono pak što računalni vid razlikuje od većine ostalih područja umjetne inteligencije je što je prošao područje prevelikih očekivanja [3] tj. jasno je što se može isporučiti.

Hype Cycle for Artificial Intelligence, 2021



gartner.com

Source: Gartner
© 2021 Gartner, Inc. and/or its affiliates. All rights reserved. Gartner and Hype Cycle are registered trademarks of Gartner, Inc. and its affiliates in the U.S. 1482644

Gartner

Slika 1.2 Područja umjetne inteligencije s očekivanjima, zrelosti i vremenskim okvirima razvoja [3]

Prepoznavanje predmeta s fotografija te izdvajanje značajki prepoznatog predmeta je dio područja računalnog vida i obrade slike, a u širem smislu se radi o oslikavanju koje uključuje snimanje, obradu i analizu slike. [4] Područje rada prema tome najvećim dijelom pripada u analizu slike s ciljanom primjenom u osiguranju. Postupci obrade slike i računalnog vida se danas redovito koriste u osiguranju, a vezano uz osobna vozila naglasak je na prepoznavanju oštećenja za što postoje određeni patenti te znanstvene publikacije. [5], [6], [7], [8]

Srodan problem verifikacije fotografije koji se standardno koristi jest verifikacija identiteta osobe te provjera zadovoljava li fotografija na službenom dokumentu propisane standarde. [9] Izdvajanje značajki (*data extraction, feature extraction*) je vrlo popularno. Uobičajeno se to čini u okviru *Optical character recognition* (OCR). [10] Međutim iz fotografija se mogu izdvajati i netekstualne značajke kao npr. boja, tekstura i oblik. Kod takvih postupaka problem je velika dimenzionalnost. Tako npr. mala fotografija od 100 x 100 piksela s 3 kanala RGB ima 30.000 brojeanih vrijednosti. A radi se o samo jednoj fotografiji. Postoje različite metode kojima se rješava problem dimenzionalnosti. [11]

Jedan od izazova kod sustava za praćenje cestovnog prometa koji se oslanjaju na računalni vid [12] je klasifikacija različitih tipova vozila koja su slične veličine i oblika.


U području računalnog vida danas se za rješenje detekcije osobnog vozila i izdvajanje značajki koriste neuronske mreže i prijenosno učenje. [13] Uobičajeno se počinje od prikladnog prednaučenog modela (npr. mreža VGG-16 za detekciju objekata naučena na ImageNet-u [14]) koji se kroz prijenosno učenje prilagodi specifičnom problemu npr. provjeri je li na fotografiji osobno vozilo. Osim korištenja neuronskih mreža jednom kada je vozilo detektirano, lokalizirano i segmentirano na fotografijama, za izdvajanje raznih značajki se mogu koristiti standardne metode obrade i analize slika čime se smanjuje kompleksnost cijelog postupka, npr. za izdvajanje značajki boje vozila se može koristiti statistička analiza vrijednosti piksela. Time se dobija interpretabilnost koja je kod neuronskih mreža vrlo ograničena.

Opisana kombinacija neuronskih mreža i standardnih metoda obrade i analize slike prema tome ima veliki potencijal za unaprjeđenje procesa preuzimanja rizika.

Umjetna neuronska mreža je skup umjetnih neurona koji su međusobno povezani. Mreža može imati jedan ili više ulaza i izlaza, između kojih se nalazi jedan ili više tzv. skrivenih slojeva (tzv. višeslojne mreže). Pojedinačni neuroni su, kao i slojevi, međusobno spojeni vezama kroz koje idu signali. Neuroni se aktiviraju ako je zadovoljen uvjet postavljen tzv. aktivacijskom funkcijom. [15]

Za prvi umjetni neuron su zaslužni Warren McCulloch i Walter Pitts 1943. [16]


Riječ je o primjeni bioloških sustava kao inspiracije pri oblikovanju boljih tehnika umjetne inteligencije i strojnog učenja. [17] U nastavku je prikaz neuronske mreže s ulaznim, skrivenim i izlaznim slojem. [18]



Slika 1.3 Umjetna višeslojna neuronska mreža [18]

Na prethodnoj slici prikazana je umjetna višeslojna neuronska mreža koja je potpuno povezana što znači da su svi neuroni iz prethodnog sloja povezani sa svim neuronima iz sljedećeg sloja. Duboka neuronska mreža [19] ima velik broj skrivenih slojeva. Na prethodnoj slici prikazana je mreža s dva skrivena sloja. Duboku neuronsku mrežu možemo zamisliti kao mrežu koja ima više desetaka takvih slojeva.

Konvolucijska duboka neuronska mreža [20] specifično koristi operaciju konvolucije [21]. Također, veze između neurona su reducirane (ne radi se o potpuno povezanoj mreži). Grafički se prikazuje na sljedeći način uz napomenu da je ovdje prikazana mreža sa samo 3 sloja (dakle nije duboka).



Slika 1.4 Konvolucijska neuronska mreža s 3 sloja [20]

2017. Google je izašao s *MobileNets*, klasom modela računalnog vida temeljenim na TensorFlow. TensorFlow je *open source* platforma za strojno učenje [22]. *MobileNets* su i danas jedna od najnaprednijih arhitektura računalnog vida. [23] MobileNetV1 je prva verzija iz proljeća 2017. MobileNetV2 je druga verzija MobileNet arhitekture iz 2018. Ona dalje unapređuje mogućnosti klasifikacije i detekcije objekata. 2021. uveden je MobileNetV3 koji koristi AutoML za pronalaženje najbolje arhitekture neuronske mreže za dani problem.

Postoje dvije vrste duboke neuronske mreže: *Base network* i *Detection network*. MobileNet pripada *Base networku*. [24] „Base network“ omogućuje *high level* klasifikaciju i detekciju objekata. Moguće je zadnji sloj (*Layer*) zamijeniti s detekcijskom mrežom npr. SSD-om (*Single shot detector*) koja služi za detekciju i istovremeno stvara *bounding boxes* i klasifikaciju. [25]

Sustav boja (model boja) je višedimenzionalna vizualizacija. Neki od poznatih modela su: RGB (red green blue), CMYK (cyan magenta yellow key), HSV (hue saturation value), HSL (hue saturation lightness). Više o toj problematici može se naći u poglavlju o prepoznavanju boje.

2. PREGLED PROCESA AUTOMOBILSKOG OSIGURANJA


Djelatnost osiguranja uobičajeno se uključuje u financijsku industriju iako je po mnogočemu vrlo različita od bankarstva ili upravljanja fondovima.

„...Ipak, podloga svake definicije osiguranja je da je to zajednica osoba izložena istoj vrsti rizika, u kojoj se plaćanjem premije svih članova prikupljaju sredstva potrebna da bi se članu koji ima štetu ta šteta i naknadila...“ [1]

Osiguranje se dijeli na osiguranje imovine i osiguranje osoba. Osiguranje imovine se dijeli na: osiguranje stvari od rizika požara i nekih drugih opasnosti, osiguranje motornih vozila, osiguranje transportnih rizika itd. Osiguranje motornih vozila dijeli se na osiguranje samog vozila (kasko ili autokasko osiguranje) i osiguranje odgovornosti prema trećim osobama za štetu uzrokovanu uporabom tih vozila. [1]

Osiguranje odgovornosti je obvezno osiguranje, dok je autokasko dobrovoljno osiguranje. Klijent svakako mora sklopiti obvezno osiguranje, dok se dobrovoljno osiguranje sklapa za novija vozila barem u *retail* segmentu. U okviru osiguranja motornih vozila autokasko osiguranje motornih vozila pokriva klijentu štetu radi oštećenja, uništenja ili nestanka osiguranog vozila.

Klijentima je osiguranje samo jedan, i često manji segment vezan uz osobno vozilo.



Slika 2.1 Procesi osiguranja tijekom životnog vijeka osobnog vozila

Autokaskom se osigurava vozilo kao predmet osiguranja i u tom slučaju poželjno je fotografiranje vozila prilikom preuzimanja u osiguranje.

U industriji osiguranja fotografiranje predmeta osiguranja je dosta uobičajeno. Fotografiranje omogućava dobivanje informacija prilikom prihvata u osiguranje, ali i nakon štete.

Moguće je fotografirati sva vozila koja se osiguravaju tj. prilikom prihvata u osiguranje. Moguće je fotografirati i samo ona vozila koja prvi put ulaze u portfelj. Mogu se fotografirati i

sva novoosigurana vozila. Moguće je fotografirati i vozila koja mogu imati veće štete kao i oštećena vozila koje se osiguravaju. Osiguratelj sam odlučuje koja vozila će fotografirati ovisno o svojim ciljevima. Ako npr. osiguratelj odluči osiguravati samo nova vozila iz salona tada je možda fotografiranje suvišno. S druge strane ako osiguratelj ima problema s dovoljnošću premije zbog puno šteta, tada treba pojačati kontrole prilikom prihvata u osiguranje, a fotografiranje tome doprinosi.

Fotografiranje nakon štete omogućuje utvrđivanje opsega novih oštećenja. Pritom naravno valja biti oprezan jer sva oštećenja nisu uvijek vidljiva.

2.1. Unapređenje procesa

Osiguravajuće društvo prikuplja sve veću količinu različitih podataka i različitih izvora kako bi unaprijedilo svoje poslovne procese i povećalo vrijednost. Osiguratelji kasne u digitalizaciji u odnosu na druge sektore. [26]

U poslovnom svijetu su se uvriježile određene automatske kontrole podataka, međutim one su još uvijek usmjerene na numeričke i tekstualne tipove podataka, ali ne i na druge vrste zapisa kao npr. slike. U poslovno odlučivanje uključujući i preuzimanje rizika važno je uključiti raznolike izvore podataka, pa tako i slike.

Jedan od elemenata koji mogu pomoći u zaključivanju o stanju i vrijednosti vozila je i prepoznavanje podataka sa fotografija.

U tom smislu mogući su razni postupci na fotografijama, a među kojima su i:


- prepoznavanje podataka na fotografiji (npr. registarska oznaka, broj šasije, kilometraža)
- prepoznavanje značajki na fotografiji (npr. boja, položaj vozila, oštećenje na vozilu)
- usporedba istog vozila na više fotografija snimljenih kroz vrijeme

Svrha ovih postupaka također može biti različita:

- Provjera jesu li fotografije ispravno arhivirane u informacijskom sustavu društva (npr. da se nisu ispremijesale fotografije različitih vozila)
- Provjera je li sadržaj fotografija odgovarajući (npr. nalazi li se na fotografiji predmet osiguranja)
- Provjera postoje li pogreške u podacima (npr. fotografija ukazuje na jedan broj šasije, dok je na Prometnoj dozvoli drugi broj šasije)
- Provjera hipoteze jesu li vozači vozila određenih boja skloniji riziku npr. vozači crvenih vozila
- Automatizirana obrada u kojoj se npr. na temelju fotografija vozila automatski obračunava premija

3. PRIMJENJENA METODA

Sljedeća slika pokazuje kako se u proces ugovaranja autokasko osiguranja u okviru osiguravajućeg društva uključuje tehnologija prikazana u radu.



Slika 3.1 Proces prepoznavanja vozila i crvene boje u kontekstu internih procesa osiguravajućeg društva

Program uzima podatke koji su prikupljeni fotografiranjem tijekom ugovaranja autokasko i spremljeni u repozitorij (DMS).

Program nakon inicijalizacije provjerava orijentaciju fotografije i ako uoči nedosljednosti rotira fotografiju kako bi fotografija bila spremna za detekciju. Naime, neke fotografije su snimljene držeći fotoaparatar/smartphone naopako i tome slično. Inače u uzorku je malo takvih fotografija, međutim program to može automatski riješiti (cca 10 komada).

Nakon toga se provodi detekcija vozila. Ukoliko osobno vozilo nije detektirano, ide se na ručnu obradu i po potrebi na unapređenje programa.

U idućem koraku se provjerava kvaliteta fotografije koristeći udjel površine detektiranog vozila i minimalne dimenzije piksela. Fotografije koje ne zadovoljavaju idu na ručni pregled te se po potrebi unapređuje program.

Na kraju se prepoznaje crvena boja na pravokutnom području interesa (*region of interest-ROI*) na izrezanoj (*crop*) fotografiji detektiranog osobnog vozila. Ovo osigurava eliminaciju većeg dijela površine tj. pozadine.

4. DETEKCIJA OSOBNOG VOZILA

Prednaučeni program može prepoznati osobna vozila i autobuse uz još neke druge objekte.

Ovo znači da je na više primjera mreža istrenirana da prepoznaje različite vrste objekata.

Pod osobnim vozilima u smislu ovog rada najbliže je kategorija M1 tj. motorna vozila za prijevoz putnika koja osim sjedišta vozača imaju još najviše 8 sjedišta. [27] Kategorija M OSOBNI AUTOMOBILI I AUTOBUSI Motorna vozila za prijevoz osoba s najmanje 4 kotača unutar koje se nalazi M1. [28]

Program prepoznaje osobno vozilo jer je uzet prednaučen model koji ih raspoznaje. Ispitan je rad programa na neispravnim ulaznim podacima tj. na fotografijama koje ne sadrže osobno vozilo, a program je prepoznao da se ne radi o osobnom vozilu.

Jedna pretpostavka je da ukoliko se na fotografiji nalazi vozilo, da je jedno vozilo dominantno. Dakle fotografija u centru ima jedno vozilo odnosno kadrira jedno vozilo. Ovo je važno stoga što je detekcijski algoritam implementiran na način da prepoznaje jedan objekt. Ovo je prihvatljiva pretpostavka jer je fokus na analizi fotografija osobnih vozila.

Algoritam radi i kada na fotografiji nema vozila. Iduća pretpostavka je da je vozilo na fotografiji pravo vozilo a ne igračka. Naime algoritam ne bi razlikovao igračku od pravog vozila. Međutim pokazalo se da program prepoznaje igračke.

Osvjetljenje i blic mogu također dosta zakomplicirati stvari. Zbog toga treba pretpostaviti da će fotograf koristiti blic kada nedostaje svjetla.

Ako je na fotografiji vozilo važno je da je ono cijelo a ne dio vozila te da je fotografirano bočno. Neke od ovih pretpostavki zapravo većina njih su prirodne i nekako se podrazumijevaju. Naime vidjeli smo da je i čovjeku teško razlikovati u nekim slučajevima narančastu od crvene boje pa se tada možemo pitati što je razumno očekivati od programa.

Fotografije se učitavaju u program i transformiraju u NumPy radi praktične obrade. NumPy (*Numerical Python*) je *open source* Python biblioteka. Biblioteka NumPy sadrži višedimenzionalna polja i matrice strukture podataka. [29]

```
import numpy as np
```

Prolazak kroz sve fotografije rješava se for petljom [30]

```
Import glob
```

```
!unzip /content/drive/MyDrive/ColabNotebooks/Carpictures/Slike.zip
```

```
Path = "/content/Slike/*.*"
```

```
for file in glob.glob(path):
```

Svojstva programa su:

- Korišten program je Jupiterska bilježnica na platformi COLAB u koju se upisuju naredbe u Pythonu.
- Koristi se model „SSD MobileNet v2 320x320“. [31] To je prethodno naučeni model neuronske mreže koji detektira objekte na učitanoj fotografiji.
- Može obraditi više fotografija.
- Detektira jedno osobno vozilo na fotografiji. Točnije unutar korištene funkcije `viz_utils.visualize_boxes_and_labels_on_image_array` parametar `max_boxes_to_draw` postavljen je na vrijednost 1
- Računa udio površine detektiranog osobnog vozila.
- Transformira fotografije u HSV prostor boja.
- Računa udio crvenih piksela na dijelu fotografije na kojem je detektirano osobno vozilo.
- Ispravno orijentira fotografiju ukoliko je prilikom fotografiranja fotoaparata bio nepravilno zarotiran.
- Prikazuje podatke o širini i visini fotografije u pikselima.
- Prikazuje rezultat obrade svih fotografija u tablici.
- Može provoditi cijeli postupak na umanjenim fotografijama.

5. PREDOBRAĐA I KONTROLA FOTOGRAFIJA

Konceptualno, predobrada i kontrola fotografija prethode detekciji i zato im se pristupa cjelovito u okviru ovog poglavlja. Međutim valja napomenuti da određene kontrole ovise o samoj detekciji osobnog vozila te su stoga inkorporirane u proces detekcije.

Predobrada u okviru računalnog vida uključuje različite postupke. U okviru ovog rada uzima se u obzir potencijalna neispravna orijentacija fotografije. Osim takve situacije, postoje i neke druge kao npr. provjera i korekcija fokusa ili oštine te osvjetljenosti prema ambijentalnom svjetlu. Na modernim fotoaparatom to je sastavni dio fotografiranja.

Kontrole kao takve imaju veliku važnost. Osim što osiguravaju kvalitetu fotografija na kojima se provodi obrada u kontekstu ovog rada, one mogu unaprijediti kasniju možebitnu obradu šteta kao i preventivno djelovati na smanjenje prijevara u osiguranju.

5.1. Uzimanje u obzir orijentacije fotografije

Program prepoznaje pogrešno orijentirane fotografije te korigira njihovu orijentaciju.

Neispravna orijentacija pametnog telefona prilikom fotografiranja vozila predstavlja problem originalnom programskom kodu.

Primjeri originalnih ulaznih fotografija	Fotografije kako ih interpretira program bez implementacije koda za korekciju orijentacije
	
	

Slika 5.1 Primjeri fotografija s pogrešnom orijentacijom, Izvor: Arhiva osiguravatelja

Prepoznavanje osobnog vozila kod neispravne orijentacije fotografija napravljeno je na sljedeći način. [32]

```
Import image_to_numpy
```

```
image_npo_orig = image_to_numpy.load_image_file(file)
```

5.2. Detekcija osobnog vozila na fotografijama koje ne sadrže osobno vozilo

Ukoliko program ne detektira osobno vozilo, fotografija se naprosto klasificira kao fotografija na kojoj nema osobnog vozila i procesno promatrano se šalje na ručni pregled jer se pretpostavlja da svaka fotografija mora prikazivati osobno vozilo.

Ovdje se može naglasiti da je procesno promatrano prirodno da se takva kontrola implementira već kod fotografiranja vozila i time se oteža, a idealno onemogućiti punjenje repozitorija (*Document management system-DMS*) fotografijama koje uopće ne prikazuju predmet osiguranja ili su nekvalitetne.

5.3. Prepoznavanje fotografija na kojima osobno vozilo nije dobro kadrirano

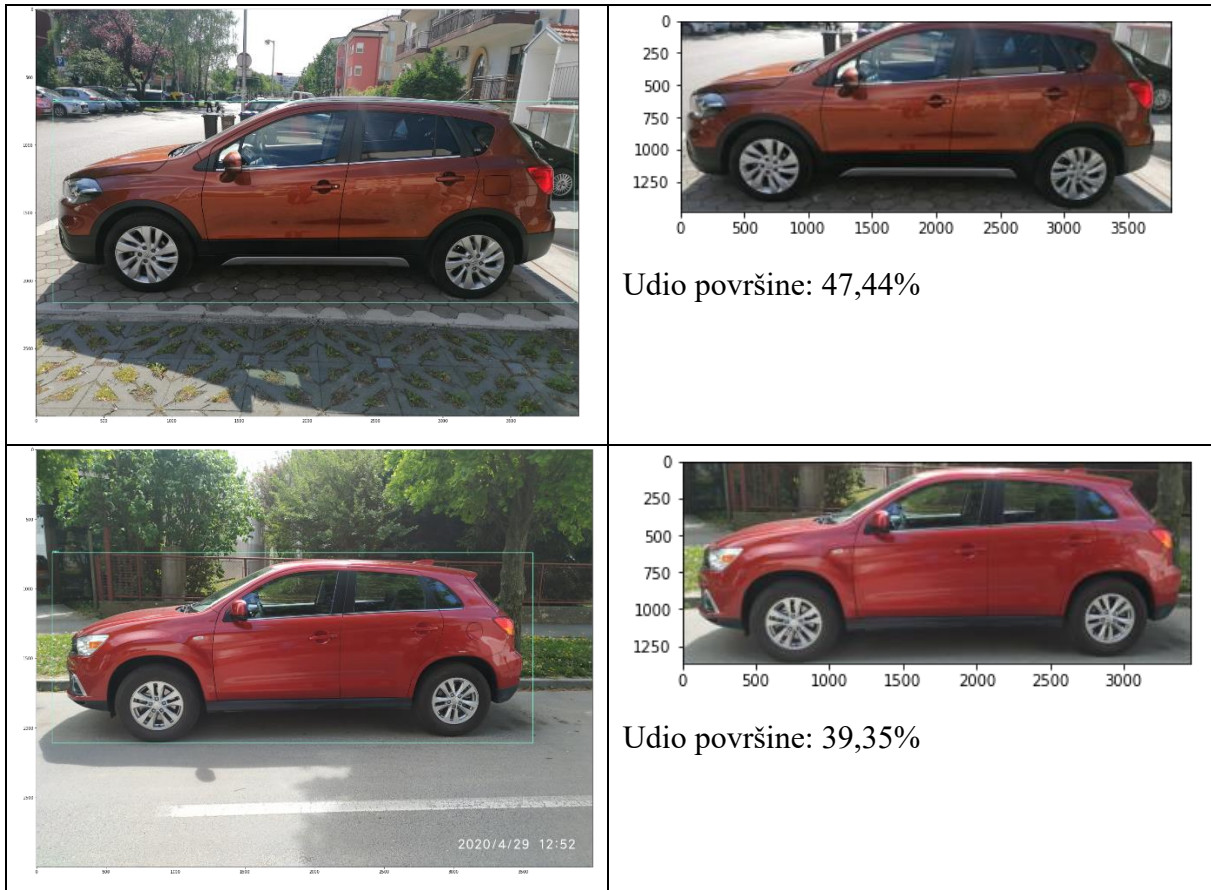
Postoje određeni minimalni standardi za fotografiranje vozila. Jedan od njih je da fotografija kadrira vozilo koje je predmet osiguranja. U tu svrhu izračunava se udio površine detektiranog objekta u odnosu na površinu cijele fotografije.

Pokazuje se da ovaj pristup daje još jedan pozitivan efekt, a to je da se, u slučaju postojanja više od jednog osobnog vozila na fotografiji, osigura detekcija upravo onog vozila koje je predmet osiguranja, a ne nekog drugog vozila koje se također nalazi na fotografiji.

Pritom valja paziti da se iz automatske obrade ne isključe fotografije koje, iako nisu dobro kadrirale vozilo, ipak imaju solidnu kvalitetu kako se ne bi tjeralo klijente na nepotrebno ponavljanje fotografiranja.

Program računa udio površine pravokutnika detektiranog vozila u odnosu na ukupnu površinu fotografije. Na taj način se osigurava da je željeno vozilo u centru fotografije. Naime, može se dogoditi da je na fotografiji nekoliko vozila i da program detektira vozilo u rubu fotografije umjesto željenog vozila.

U nastavku se prikazuju dva primjera dobro kadriranih fotografija.



Slika 5.2 Primjeri dobro kadriranih fotografija, Izvor: Arhiva osiguravatelja

Iz prethodnog se može zaključiti da je udio površine detektiranog osobnog vozila u fotografiji od 39% solidan udio i da njemu treba težiti, a po mogućnosti ga i premašiti.

Logički gledano moguće je da su na fotografiji dva ravnopravna osobna vozila od kojih svako zauzima cca. 40% površine. U tom slučaju rezolucija može biti dobra, ali nije jasno koje je vozilo u centru fotografije. Za ovaj slučaj mogao bi se uvesti indikator koji bi označavao više prepoznatih vozila na fotografiji. Ovo bi naravno povećavalo manualni rad, ali bi indiciralo mogući problem.


U nastavku se daje izvadak iz programskog koda kojim se računa udio površine dijela fotografije koji prikazuje osobnog vozilo u odnosu na površinu cijele fotografije.

```
(ff, im_height, im_width, gg)=image_np.shape[:4]
ymin=result['detection_boxes'][0][0][0]*im_height
xmin=result['detection_boxes'][0][0][1]*im_width
ymax=result['detection_boxes'][0][0][2]*im_height
xmax=result['detection_boxes'][0][0][3]*im_width
udiocrop=((int(ymax)-int(ymin))*(int(xmax)-int(xmin)))/(im_height*im_width)
```

5.4. Prepoznavanje fotografija sa slabom rezolucijom

Dodatni problem je i pitanje rezolucije fotografije. Naime fotografije vozila koje se koriste kod preuzimanja rizika trebaju imati dobru rezoluciju.

Rezolucija se može mjeriti na više načina među kojima je i ukupan broj piksela koji se dobiva kao umnožak širine i visine fotografije u pikselima. [33] Ako fotografija ima visoku rezoluciju, čak i ako vozilo nije dobro kadrirano, ne mora značiti da je fotografija neodgovarajuća. Vrijedi i obrnuto, ako je vozilo dobro kadrirano, a fotografija ima nisku rezoluciju, to može značiti da je fotografija neodgovarajuća. Slijedi primjer koji zorno pokazuje problematiku.



Slika 5.3 Efekt različite rezolucije na kvalitetu fotografije-originalna, Izvor: Arhiva osiguravatelja


UMANJENA FOTOGRAFIJA FAKTOROM 2



UMANJENA FOTOGRAFIJA FAKTOROM 3



UMANJENA FOTOGRAFIJA FAKTOROM 4



Slika 5.4 Efekt različite rezolucije na kvalitetu fotografije-umanjene, Izvor: Arhiva osiguravatelja

Originalna fotografija ima zadovoljavajuću rezoluciju. Međutim zbog lošeg kadriranja, kada se vozilo zumira radi pregleda, određeni dijelovi vozila nisu oštro vidljivi. Kod dvostrukog smanjenja rezolucije, vidljivost određenih dijelova je i dalje zadovoljavajuća, dok daljnje umanjenje onemogućuje jasan uvid okom u vanjsko stanje vozila.

Inače manja dimenzija detektiranog vozila je visina i to oko 200 piksela što je doista nisko.

Evo jedne ilustracije odnosa udjela površine i rezolucije. Neka je fotografija $\check{S} \times V = 1.095$ piksela \times 1.095 piksela. Površina (ukupan broj piksela) je dakle cca. 1.200.000 piksela. Ako vozilo zauzima 10% površine to je npr. cca. $600 \times 200 = 120.000$ piksela.

U tom smislu orijentacijski 120.000 piksela bi mogla biti granica zadovoljavajuće rezolucije osobnog vozila na fotografiji neovisno o pozadini.

6. PREPOZNAVANJE BOJE OSOBNOG VOZILA

Boja je vidljivi rezultat spektra svjetlosti koji je ili prenesen kroz prozirni medij ili je reflektiran od neke površine. [34]

„...Boja je proizvod svjetla i vida. Da bi fenomen boje bio moguć, potrebna su tri elementa: izvor svjetlosne energije, predmet na koji pada ta energija (što u krajnjem slučaju može biti i zrak) te čovjek (ili životinja) koji posjeduje složeni biološki i kulturalni aparat koji se sastoji od oka i mozga...“ [35]

Podatak o boji vozila nije dostupan u informacijskom sustavu osiguratelja, ali fotografije jesu jer se prikupljaju u okviru prodajnih procesa i procesa preuzimanja rizika. Zbog toga je moguće klasificirati vozila prema boji na osnovi njihovih fotografija.

Boja se ne traži na cijeloj fotografiji već samo na detektiranom objektu. Ovo osigurava da se boja u pozadini ne prepozna kao boja vozila.

Prednost korištenog pristupa je i što se izbjegava treniranje neuronske mreže za prepoznavanje boje koje bi zahtijevalo veliki broj prethodno klasificiranih fotografija po bojama. Naravno postoje i izazovi o kojima će biti riječi.

6.1. Sustavi boja

Kroz povijest umjetnici i znanstvenici koristili su razne modele za spektar boja kako bi apstraktni koncept pretvorili u nešto razumljivo. Sustav boja (model boja) je višedimenzionalna vizualizacija. Neki od poznatih modela su: RGB (*red green blue*), CMYK (*cyan magenta yellow key*), HSV (*hue saturation value*), HSL (*hue saturation lightness*)...

RGB i CMYK vezani su uz uređaje za reprodukciju, dok su HSV i HSL perceptualni prostori i kao takvi intuitivni za korištenje.

U radu je odabran HSV model [34] i [36]:

- *Hue* (nijansa boje) je prevladavajuća valna dužina
- *Saturation* (zasićenost boje ili čistoća) je mjera koliko je *hue* dominantan u boji. Vrijednost 0 znači sivu boju.
- *Value* (svjetlina ili intenzitet svjetla) količina svjetlosti koja se reflektira. Vrijednost 0 znači crnu boju.

Prednost HSV modela je što je jednostavan za razumijevanje [37] te je prikladan u kompjuterskoj grafici. [38]

Važno je razumjeti da nije dovoljno poznavati nijansu boje da bi se dobio rezultat, već je potrebna kombinacija nijanse, zasićenosti i svjetline. [39]

Kako bi se fotografija prikazala u HSV sustavu potreban je sljedeći programski kod [40]:

```
img_hsv = cv2.cvtColor(img1, cv2.COLOR_RGB2HSV)
```

6.2. Izbor crvene boje za prepoznavanje

„...Ono što doživljavamo, naš mozak prevodi kao koncept predmeta, mirisa, zvuka i, naravno, boja, što nam olakšava razumijevanje svijeta oko nas. Svemir pulsira energijom koju nazivamo elektromagnetskim valovima. Prosječno ljudsko oko može detektirati samo uski spektar tih vibracija, odnosno samo valne duljine između 380 i 760 nm. Taj raspon poznat nam je kao vidljiva svjetlost...“ [35]

„...Isaac Newton prvi je pokazao da se bijela svjetlost sastoji od svih boja spektra...“ [35]

Kao primjer za prepoznavanje, uzeta je crvena boja koja ima valnu duljinu od oko 700 nm. [35]

„...crvena, kao boja rata i krvi...“, [35]

„... Crvena je boja emocija bijesa i srama... crvena potiče agresiju i nasilje... „, [35]

Postoje određena razmišljanja da su vozači crvenih vozila opasniji na cesti, a u informacijskom sustavu se čuvaju fotografije vozila, ali ne i informacija o boji vozila pa bi se na ovaj način mogla provjeriti i takva hipoteza.

Ovo je jedan razlog zašto ima smisla prepoznavanje crvene boje na fotografiji. Naime, povezivanje crvene boje s konkretnim vozilom omogućuje testiranje korelacije između šteta na vozilu kao i razne predikcije.

Naravno, kada se prepozna crvena boja, slično se može napraviti i s drugim bojama.

Također u okviru procesa preuzimanja rizika prikuplja se više fotografija istog vozila kao i kod obrade šteta. Na ovaj način je provjerljiva prisutnost iste boje na različitim fotografijama istog vozila. Moguća je i usporedba s bojom koju je deklarirao proizvođač.

Automatizirano prepoznavanje boja olakšava ovakve analize.

Crvena boja se vidi kao crvena jer bijela svjetlost pada na vozilo, dijelom se apsorbira, a dijelom reflektira [41]. Ono što se reflektira je crveno i zato se u našem oku vidi kao crvena ili na fotografiji koja je rezultat fotografiranja.

Moguće je i da se crvena svjetlost reflektira s objekta koji nije crven i tada bi boja objekta mogla izgledati crvenkasto iako sam objekt nije crven. [42] Moguć je i obrnut problem, a to je da crven objekt ne izgleda crveno. Osim toga moguće je da je nejasno koja je boja objekta. Evo nekih primjera.



Crvenkasti odsjaj na bijelom vozilu



Vjerojatno smeđe vozilo



Vjerojatno crveno vozilo



Možda crveno ili narančasto vozilo


Slika 6.1 Primjeri otežanog prepoznavanja boje vozila

6.3. Kalibracija HSV modela radi prepoznavanja crvene boje

U nastavku se ilustrira primjer korištenja jednog *colour pickera* kako bi se odredile granice crvene u HSV modelu. [43]


Raspon nijanse je $[0..360]$, dok je u Python *library* raspon $[0..180]$ te stoga $H=20$ na *colour pickeru* znači $H=10$ u Pythonu. Potrebno je podijeliti iznos s 2. Rasponi za zasićenosti i svjetline su u rasponu $[0..255]$.

Promjena vrijednosti nijanse boje (H) prikazuje se na sljedećoj slici.




Slika 6.2 Efekt promjene nijanse (H) [43]

Važno je uočiti da crvena boja ima kako niske, tako i visoke vrijednosti nijanse boje H jer je H kut. U blizini kuta od 0 stupnjeva su i kutevi u blizini 360 stupnjeva. Slijedi rezultat variranja zasićenosti (S) i svjetline (V) u donjoj zoni nijanse (H)



Slika 6.3 Variranje zasićenosti S i svjetline V u donjoj zoni nijanse H [43]

U nastavku je variranje zasićenosti S i svjetline V u gornjoj zoni nijanse H .




Slika 6.4 Variranje zasićenosti S i svjetline V u gornjoj zoni nijanse H [43]

Može se uočiti da neke kombinacije baš i ne izgledaju crveno s tim da se različiti pojedinci međusobno ne bi mogli složiti jer tu ima i dosta subjektivnosti, ali i određenih tehničkih zakonitosti u pogledu prikaza na različitim uređajima kao i ispisu.

U nastavku se prikazuje i drugi pristup za provjeru prethodnih granica. [44]

HSV color map:



From the above HSV color map, to find a color, usually just look up for the range of h and s , and set v in range (20, 255).

Slika 6.5 HSV mapa boja s metodom za definiranje granica boja [44]

Slijedi tablica s rekapitulacijom pragova odnosno granica odlučivanja (*threshold*) koje će se uključiti u programski kod kako bi se prepoznali crveni pikseli u HSV prostoru boja na fotografiji. Tablica je rezultat spoja prethodno prikazana dva pristupa određivanju boja.

Tablica 6.1 Rekapitulacija pragova za prepoznavanje crvene boje pri čemu se razlikuju rezultati dva prikazana pristupa za definiciju granica

Pragovi	H	S	V
1- crvena po prvom i drugom pristupu	$0/2=0$	255	255
2- crvena po prvom i drugom pristupu	$20/2=10$	255	255
3- crvena po prvom i drugom pristupu	$326/2=163$	255	255
4- crvena po prvom i drugom pristupu	$360/2=180$	255	255
5- crvena po prvom i drugom pristupu	$0/2=0$	170	255
6- crvena po drugom pristupu	$0/2=0$	255	20
7- crvena po drugom pristupu	$20/2=10$	170	255
8- crvena po drugom pristupu	$20/2=10$	255	20
9- crvena po prvom i drugom pristupu	$360/2=180$	170	255
10- crvena po drugom pristupu	$360/2=180$	255	20
11- crvena po prvom i drugom pristupu	$326/2=163$	170	255
12- crvena po drugom pristupu	$326/2=163$	255	20

U sljedećoj tablici prikazuju se rasponi dobiveni na temelju pragova kako se primjenjuju u programu.

Tablica 6.2 Rasponi vrijednosti za program

Originalni naziv	<i>Hue-H</i>	<i>Saturation-S</i>	<i>Value-V</i>
Hrvatski naziv	Nijansa boje	Zasićenost boje	Svjetlina
Kumulativno primijenjeni rasponi	$0 \leq h \leq 10$	$170 \leq s \leq 255$	$20 \leq v \leq 255$
	$163 \leq h \leq 180$		

Prethodna tablica je implementirana u programski kod na način da se računa udio crvenih piksela na fotografiji s tim da se uzima područje interesa (*region of interest* ili ROI) detektiranog objekta, a ne originalna fotografija što značajno smanjuje utjecaj boje pozadine. Što se tiče koda, on radi na sljedeći način. Prvo uzima prethodno izrezanu (*crop*) fotografiju detektiranog vozila, dakle sa što manje pozadine. Nakon toga ju pretvara u HSV prostor boja. Prolazi kroz sve piksele i provjerava koji su crveni. Na kraju računa udio crvenih piksela u ukupnom broju pixela.

```
img1 = cropped_img
```

```
img_hsv = cv2.cvtColor(img1, cv2.COLOR_RGB2HSV)
```

```
(width, height, pix) =img_hsv.shape[:3]
```

```
# Initialize Variable
```

```
red_count=0
```

```
count = 0
```

```
# Iterate through each pixel
```

```
for x in range(0, width):
```

```
    for y in range(0, height):
```

```
        h, s, v = img_hsv[x, y]
```

```
        count += 1
```

```
        if((170<=s and s<=255) and (20<=v and v<=255) and ((0<=h and h<=10 or (163<=h and h<=180))):
```


```
            red_count += 1
```

```
print("udio crvenih pixela")
```


```
print (red_count/count)
```

6.4. Histogram boja na detektiranom osobnom vozilu

Granice crvene boje izabrane prethodnom pristupom može se još optimizirati. To se može učiniti koristeći histograme. U nastavku se pokazuje nekoliko primjera.



Slika 6.6 Histograme komponenti H,S i V za odabrane fotografije zajedno s rezultatom programa- 1. dio



Slika 6.7 Histogrami komponenti H,S i V za odabrane fotografije zajedno s rezultatom programa- 2. dio

Kod crvenog vozila su dosta visoke H vrijednosti oko 0 i/ili oko 180. Zanimljivo je da i bijelo vozilo ima H visoke H vrijednosti oko 0, međutim S vrijednosti su mu dosta niže u odnosu na crvena vozila pa je program zbog toga prepoznao relativno nizak udio crvenih piksela.

7. REZULTATI

Korišten program je Jupiterska bilježnica na platformi COLAB u koju se upisuju naredbe u Pythonu. Podaci, u ovom slučaju fotografije, mogu se učitati kao komprimirana .zip datoteka ili se mogu koristiti podaci s npr. *Google drive*.

Fotografije su prethodno klasificirane na način da naziv datoteke ima sljedeću strukturu: S-x-y-ostatak. jpg. Pritom:

- S je fiksno slovo na prvom mjestu naziva
- $x=\{0,1\}$, 1 za osobno vozilo, 0 inače
- $y=\{0,1\}$, 1 crvene boje, 0 inače
- ostatak je jedinstveni identifikator fotografije

Ova klasifikacija je opažajna i ne služi treniranju mreže, već služi za provjeru točnosti rada programa na detekciji osobnog vozila i prepoznavanju crvene boje.

Program čita naziv datoteke i pridružuje x i y rezultatu programa formirajući tablicu izlaznih rezultata koja je pogodna za deskriptivnu statističku analizu.


Analizirano je 135 fotografija. 120 fotografija uzeto je slučajnim odabirom iz repozitorija fotografija (DMS) osiguratelja s tim da se vodilo računa da bude i crvenih i vozila koja nisu crvena na fotografijama. Budući da je na svim fotografijama bilo osobno vozilo, 15 fotografija koje ne sadrže osobna vozila, su odabrane namjerno radi temeljitog ispitivanja kako bi se provjerila sposobnost programa za detekciju osobnog vozila. Uzete su fotografije bočnih strana vozila kako se ne bi baratalo s podacima o registraciji radi zaštite osobnih podataka.

Tablica 7.1 Opis skupa za testiranje

Stavka	Broj fotografija	Pojašnjenje
Slučajni uzorak s tim da bude zastupljeno i crvenih kao i osobnih vozila koja nisu crvena	120	iz DMS osiguratelja
Namjerno uključeno u uzorak	15	fotografirao autor
Uzorak	135	-

7.1. Detekcija osobnog vozila na fotografijama na kojima se nalazi osobno vozilo

U jednom slučaju program ne detektira osobno vozilo, već prepoznaje osobno vozilo kao kamion.


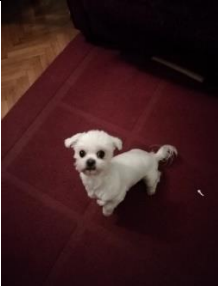







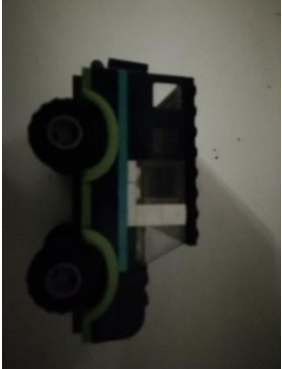







Slika 7.1 Osobno vozilo pogrešno detektirano kao kamion

Zaključuje se da je program jedno osobno vozilo prepoznao kao *truck* tj. kao kamion što je evidentna pogreška.

7.2. Detekcija osobnog vozila na fotografijama koje ne sadrže osobno vozilo

Program je na svih 15 fotografija koje ne sadrže osobno vozilo prepoznao da se ne radi o osobnom vozilu. Na ovaj način se pokazuje da određene slučajne ili namjerne pogreške program može identificirati. U nastavku se prikazuju podmetnute fotografije.

		
Loptica	Pas	Nacrtano vozilo
		
Nacrtano vozilo	Nacrtano vozilo	Nacrtano vozilo
		
Nacrtano vozilo	Auto-igračka	Auto-igračka
		
Auto-igračka-od kocaka	Nacrtana dva vozila	Nacrtano vozilo
		
Nacrtana dva vozila	Nacrtano vozilo	Namještaj

Slika 7.2 Fotografije koje ne sadrže osobna vozila

Prethodne fotografije sažete su u sljedećoj tablici.

Tablica 7.2 Opis uzorka


Stavka	Broj fotografija	Pojašnjenje
Razni predmeti	3	Ispravna detekcija
Nacrtana vozila	9	Ispravna detekcija
Autići-igračke	3	Ispravna detekcija
Uzorak	15	-

Može se zaključiti da je program uspješno prepoznao da razni predmeti, nacrtana vozila i igračke nisu osobna vozila.

Valja napomenuti da bi u slučaju konkretne implementacije trebalo još isprobati ponašanje programa kod fotografija koje su nastale fotografiranjem fotografija osobnog vozila, potpuno jednobojnih fotografija, fotografija na kojima je snijeg i fotografija koje kadriraju dijelove vozila npr. kotač.

7.3. Prepoznavanje fotografija na kojima osobno vozilo nije dobro kadrirano

Sljedeći graf je rezultat obrade uzorkovanih fotografija osobnih vozila.




Slika 7.3 Udio površine detektiranog osobnog vozila

Može se primijetiti da velik broj fotografija ne kadrira baš najbolje vozilo koje je predmet osiguranja. Tako je na čak 64 od 119 uzorkovanih fotografija udio površine detektiranog vozila manji od 30%, a tek je na 25 od 119 fotografija taj udio veći od 50% što navodi na zaključak da ima još dosta prostora za podizanje kvalitete fotografiranja edukacijom osoba koje fotografiraju i/ili boljim ulaznim kontrolama kod fotografiranja.

U nastavku se prikazuje kako je program detektirao osobno vozilo kod fotografija u grupi s najmanjim udjelima detektiranog vozila na fotografiji.

Prije svega pojašnjava se parametar *min_score_thresh* koji se može shvatiti kao granica pouzdanosti [45], a koji se definira u intervalu [0..1]. Zadržana je preporučena vrijednost parametra 0,5. [46]

Program, točnije korištena funkcija `viz_utils.visualize_boxes_and_labels_on_image_array`, će detektirati (prikazati pravokutni *bounding box*) samo one objekte kod kojih je pouzdanost detekcije veća ili jednaka `min_score_thresh`.





Udio: 0,22%. Sa `min_score_thresh=62%` prepoznaje osobno vozilo s desne strane u pozadini.



Udio: 0,54%. Sa `min_score_thresh=72%` prepoznaje osobno vozilo s lijeve strane u pozadini.

Slika 7.4 Fotografije s najmanjim udjelom površine detektiranog osobnog vozila-1. dio



Udio: 2,86%. Sa min_score_thresh=82% prepoznaje osobno vozilo s desne strane u pozadini.





Udio: 5,90%. Sa 79% prepoznaje osobno vozilo s lijeve strane u pozadini.



Udio: 6,33%. Sa min_score_thresh=67% prepoznaje željeno osobno vozilo.

Slika 7.5 Fotografije s najmanjim udjelom površine detektiranog osobnog vozila-2. dio



Udio: 8,71%. Sa min_score_thresh=73% prepoznaje željeno osobno vozilo.



Udio: 8,84%. Sa min_score_thresh=71% prepoznaje željeno osobno vozilo.

Slika 7.6 Fotografije s najmanjim udjelom površine detektiranog osobnog vozila-3. dio

Iz prethodne slike može se uočiti da je program detektirao pogrešno osobno vozilo na fotografiji u 4 od 7 slučajeva.

Može se zaključiti da kod malih udjela površine, uspješnost detekcije ovisi o tome nalazi li se na fotografiji još neko vozilo. Što je udio površine manji zapravo je vjerojatnost da je u pozadini obuhvaćeno još neko vozilo veća. Stavljanjem osobnog vozila koje je predmet osiguranja u centar fotografije, ovaj problem gubi na važnosti. Ono što se preporuča je da se kod manjih udjela površine fotografije ručno pregledaju. Svakako bi trebalo težiti korištenju aplikacije za fotografiranje koja bi prilikom fotografiranja upozorila na potrebu uzimanja fotografija koje zadovoljavaju standarde osiguratelja u ovom slučaju navodeći korisnika da predmet osiguranja stavi u središte fotografije.


Tablica 7.3 Rekapitulacija točnosti detekcije osobnog vozila kod fotografija na kojima je udio površine detektiranog osobnog vozila malen.

Stavka	Broj fotografija	Pojašnjenje
Udio površine detektiranog vozila <6%	4	Pogrešna detekcija osobnog vozila
Udio površine detektiranog vozila >6%	3	Ispravna detekcija osobnog vozila
Uzorak	7	-

Program bi se mogao unaprijediti na način da prepozna ukoliko se na fotografiji nalazi više vozila. Ovo bi naravno i povećalo broj fotografija koje bi trebalo manualno pogledati.

Dakle, kada u centru fotografije nije sam predmet osiguranja uočavaju se barem dva problema: nezadovoljavajuća rezolucija fotografije kao i veća mogućnost da kadar obuhvaća i druga vozila. Dakle, u takvim slučajevima tj. kada fotografija ne zadovoljava minimalni standard, predlaže se ručni uvid u takve fotografije prilikom preuzimanja vozila u osiguranje. Puno bolje rješenje bilo bi korištenje aplikacije kod fotografiranja koja bi prilikom fotografiranja upozorila na potrebu uzimanja fotografija koje zadovoljavaju standarde osiguratelja.

Osim gore opisane situacije u kojoj je vozilo u kadru, ali je na fotografiji prisutna složena pozadina, moguća je i obrnuta situacija.




Slika 7.7 Primjer fotografije na kojoj je vozilo izvan kadra

U ovom konkretnom slučaju program ispravno detektira osobno vozilo, ali se pojavljuje problem jer predmet osiguranja na fotografiji izlazi izvan kadra.

Problem se rješava usporedbom dimenzija originalne fotografije i fotografije detektiranog objekta. Ukoliko je širina ili visina približno jednaka, moguće je kroz aplikaciju za fotografiranje upozoriti korisnika da je potrebno da fotografija zadovoljava minimalne standarde. Alternativno fotografiju se može poslati na ručni pregled koji će vjerojatno rezultirati zahtjevom za dopunskim fotografiranjem.

7.4. Fotografije sa slabom rezolucijom

U nastavku se prikazuju podaci od udjelima površine na koju su nadodani podaci o broju piksela koji prikazuju detektirano vozilo.



Slika 7.8 Udio površine detektiranog osobnog vozila i rezolucija fotografije


Može se uočiti da u prosjeku postoji porast broja piksela koji opisuju osobno vozilo s porastom udjela površine. Međutim dosta je veliko rasipanje u broju piksela za određeni udio. Ipak pokazuje se da ih je s manje od 120.000 piksela 7 primjera od kojih je u grupi s najmanjim udjelom 5 primjera.

Za očekivati je da će kvaliteta fotoaparata rasti tj. novije kamere imaju bolju rezoluciju pa će ovaj problem protekom vremena gubiti na važnosti.

U nastavku je izdvojeno nekoliko karakterističnih fotografija s grafa koje se prikazuju u nastavku.

	 <p>321.121 piksela 8,7% udio površine detektiranog objekta Primjer fotografije u kojoj je udio površine vozila malen, međutim vozilo je opisano sa zadovoljavajućim brojem piksela.</p>
	 <p>119.830 piksela 10,1% udio površine detektiranog objekta Primjer fotografije u kojoj je udio površine vozila malen i broj piksela kojima se prikazuje vozilo je nizak. Osim toga snimljena strana vozila je u sjeni tj. snimano je prema izvoru svjetlosti.</p>
	 <p>70.692 piksela 23,0% udio površine detektiranog objekta Primjer fotografije u kojoj je udio površine nešto bolji, ali je broj piksela kojima se prikazuje vozilo nizak.</p>

Slika 7.9 Odabrane fotografije s karakterističnim brojem piksela-1. dio



Slika 7.10 Odabrane fotografije s karakterističnim brojem piksela-2. dio


Može se zaključiti da većina fotografija ima zadovoljavajuću rezoluciju. Kod viših udjela površine samo je u jednom slučaju uočena slaba rezolucija, dok je u grupi s najmanjim udjelom površine samo u jednom slučaju broj piksela zadovoljavajući.

Ono što se može primijetiti na prethodnoj slici su i dva primjera kod kojih je snimljena strana vozila u sjeni tj. snimano je prema izvoru svjetlosti tj. prema Suncu. Bolje je fotografirati ujutro ili u sumrak kada postoji dovoljno svjetla, a sjene nisu tako oštre.

7.5. Određivanje praga za prepoznavanje crvene boje

Preostalih 112 fotografija (od 135 primjera, na 15 primjera nema vozila, na 1 primjeru prepoznat je kamion, a 7 primjera su u grupi s najmanjim udjelom površine detektiranog vozila) je ručno klasificirano prema tome sadrže li crveno vozilo ili ne. Te fotografije čine skup podataka za testiranje programa za prepoznavanje crvenih osobnih vozila.

Program odabire pravokutno područje interesa na fotografiji te računa udio crvenih piksela u ukupnom broju piksela u pravokutniku. Rezultat je prikazan na sljedećoj slici.



Slika 7.11 Distribucija udjela crvenih piksela na fotografijama crvenih i osobnih vozila koja nisu crvena

Iz prethodne slike može se uočiti da fotografije s udjelom crvenih piksela do 3,6% prikazuju osobna vozila koja nisu crvena. Nakon toga ima nekoliko fotografija koje su crvene ili koje nisu crvene s pomiješanim udjelima. U nastavku se analizira tih 6 fotografija.

Crveno ručno klasificirana vozila u grupi najmanjeg udjela crvenih piksela



1. Udio crvenih piksela: 5,4%

Ručno klasificirana vozila koja nisu crvena u grupi najvećeg udjela crvenih piksela



2. Udio crvenih piksela: 8,8%



3. Udio crvenih piksela: 6,0%



4. Udio crvenih piksela: 16,5%



5. Udio crvenih piksela: 13,1%



6. Udio crvenih piksela: 25%

Slika 7.12 Crvena osobna vozila i vozila koja nisu crvena

Ne postoji odabir koji garantira sigurnu klasifikaciju vozila. Tako bi dva vozila iz prethodne tablice pod brojevima 4 i 6 na fotografijama s udjelima crvenih piksela 16,5% i 25% netko mogao smatrati crvenim, a netko ne. Uzimajući to u obzir, može se zaključiti da su vozila na fotografijama s više od 8,8% crvenih piksela crvena. Vozila pak s udjelom između 3,6% i 8,8% bi trebalo ručno klasificirati jer unutar tog raspona se nalazi 1 crveno i jedno vozilo koje nije crveno.

Slijedi tablica koja sistematizira prethodno pojašnjenje.

Tablica 7.4 Rekapitulacija točnosti prepoznavanja crvene boje osobnih vozila sa fotografija iz prethodne dvije slike

Udio crvenih piksela	Broj fotografija	Pojašnjenje
<3,6%	75	Ispravno prepoznavanje: vozilo nije crveno
[3,6%-5,4%>	0	Potreban ručni pregled ili proširenje uzorka ili ako je granica na 5,4% smatra se da vozilo nije crveno
5,4%, 6,0%	2 (rb. 1 i 3)	Ispravno prepoznavanje crvenog vozila ako je granica na 5,4%
8,8%	1 (rb. 2)	Neispravno prepoznavanje ako je granica na 5,4% ili za ručni pregled
16,5%, 25%	2 (rb. 4 i 6)	Neki promatrači bi mogli smatrati da su vozila crvena, a neki da nisu
>=13,1% osim prethodna 2 vozila	32 (uklj.i rb. 5)	Ispravno prepoznavanje: crveno vozilo
Uzorak	112	-

Dakle, jedna mogućnost je da se sporni raspon udjela crvenih piksela 3,6% - 13,1% pošalje na ručni pregled (<3% fotografija). Ovo bi prema uzorku bilo i najkorektnije i u tom slučaju se može tvrditi u kojim slučajevima program radi pouzdano, a u kojima ne. Ovo ima smisla i stoga što se iz grafikona može vidjeti relativno mali broj opažanja u tom rasponu pa bi svakako ovo bilo korektnije.

Druga mogućnost je da se granica crvenosti postavi na udio 5,4%. U tom slučaju 1 osobno vozilo je pogrešno grupirano u uzorku tj. vozilo s udjelom 8,8%.

Bilo bi poželjno da se uzorak proširi kako bi se razjasnilo ponašanje programa i u intervalu u kojem nije bilo opažanja iz uzorka.

Kako bi se lakše donijela odluka o granici, prikazuju se *confusion* matrice. [47]

Tablica 7.5 Confusion matrix za granicu 3,6% udjela crvenih piksela

Granica: 3,6%		STVARNE VRIJEDNOSTI	
		CRVENO	NIJE CRVENO
PROGNOZIRANE VRIJEDNOSTI	CRVENO	32+2+2=36	1
	NIJE CRVENO	0	75

Tablica 7.6 Confusion matrix za granicu 5,4% udjela crvenih piksela

Granica: 5,4%		STVARNE VRIJEDNOSTI	
		CRVENO	NIJE CRVENO
PROGNOZIRANE VRIJEDNOSTI	CRVENO	32+2+2=36	1
	NIJE CRVENO	0	75

Prethodne dvije granice bez greške prepoznaju crvena vozila, međutim u 1 slučaju vozio koje nije crveno pogrešno proglašavaju crvenim. Iz podataka nije moguće razaznati koja je granica bolja jer nedostaje primjera u rasponu [3,6%-5,4%>.

Tablica 7.7 Confusion matrix za granicu 8,8% udjela crvenih piksela

Granica: 8,8%		STVARNE VRIJEDNOSTI	
		CRVENO	NIJE CRVENO
PROGNOZIRANE VRIJEDNOSTI	CRVENO	32+2=34	1
	NIJE CRVENO	2	75

Ova granica je daje lošiji rezultat od ostalih jer griješi u 3 slučaja pa se odbacuje

Tablica 7.8 Confusion matrix za granicu 13,1% udjela crvenih piksela

Granica: 13,1%		STVARNE VRIJEDNOSTI	
		CRVENO	NIJE CRVENO
PROGNOZIRANE VRIJEDNOSTI	CRVENO	32+2=34	0
	NIJE CRVENO	2	75+1=76

Ova granica bez greške prepoznaje vozila koja nisu crvena, međutim u 2 slučaja crvena vozila pogrešno proglašava vozilima koja nisu crvena.

Može se zaključiti da je bolje uzeti granicu od 13,1% jer ona daje jaku garanciju da nema uljeza među crvenim vozilima jer je potrebno prepoznati crvenu boju. Granice od 3,6% ili 5,4% uključuju u grupu crvenih vozila i vozilo koje nije crvene boje pa je u tom smislu sigurnije ići na nešto višu granicu kako bi se dobila veća sigurnost da su vozila prepoznata kao crvena doista crvena. Ovo odgovara i na dilemu da li granicu spustiti na 8,9% tj. malo iznad primjera pod rb. 2. Dakle, bolje je uzeti višu vrijednost, a za fotografije u rasponu koji je nepouzdan moguće ih je slati na ručnu provjeru.

8. ANALIZA UTJECAJA SMANJIVANJA REZOLUCIJE NA REZULTATE

Uspoređeni su rezultati programa izvedenog na originalnim fotografijama te na fotografijama umanjenim za faktor 2.

Umanjenje se provelo sljedećim programskim kodom:

```
image_npo = image_npo_orig[:, :2, ::2]
```

Valja napomenuti da navedena intervencija ne izrezuje dio fotografije, već naprosto decimira piksele koji čine fotografiju. Postoje i drugi pristupi smanjenju fotografije. [48] Svakako bi se prije stvarne aplikacije trebala provesti i filtracija radi uklanjanja Moire efekta. [49]

Program se izvršava na Google *hosted runtime*. U vrijeme izvršavanja se ne računa vrijeme potrebno za pripremu okoline te vrijeme za *upload* fotografija na sam *Google Drive*. Tijekom rada višestruko su unaprijeđene performanse na način da se jednim pozivom funkcije provela i klasifikacija vozila i izračun udjela površine detektiranog objekta i izračun udjela crvenih piksela i prepoznavanje veličine fotografije. Inicijalno je svaki element značio poseban poziv funkcije.

Osim gore opisane optimizacije, također se eksperimentiralo i sa smanjenjem veličine ulaznih fotografija za faktor 2. Ovakvo smanjenje značajno smanjuje vrijeme izvođenja programa, ali je potrebno provjeriti kakav je utjecaj smanjenja veličine fotografija na rezultate.

Mjerenje vremena provedeno je sljedećim programskim kodom:

```
Import time
```

```
t1=time.perf_counter()
```

```
kod čije vrijeme izvršavanja mjerimo
```

```
t2=time.perf_counter()
```

```
print('time taken to run:',t2-t1)
```

Rezultat je prikazan u sljedećoj tablici.

Tablica 8.1 Rekapitulacija mjerenja izvođenja programa na originalnim i umanjenim fotografijama

Vrijeme u sekundama za obradu 135 fotografija Redni broj mjerenja	Originalna veličina fotografija	Fotografije umanjene faktorom 2: <i>image_npo =image_npo_orig[::2, ::2]</i>
1	1.065	301
2	1.083	304
3	1.064	311
4	1.068	308
5	1.081	310
Najlošije vrijeme	1.083 sekundi = 18 minuta	311 sekundi = 5 minuta
Najlošije vrijeme po jednoj fotografiji	8,02 sekundi / fotografiji	2,30 sekundi / fotografiji
Prosječno vrijeme po jednoj fotografiji	7,94 sekundi / fotografiji	2,27 sekundi / fotografiji

Očekuje se četverostruko ubrzanje jer je svaka fotografija smanjena 2 puta po svakoj dimenziji što rezultira s 4 puta manje piksela. Iz prethodne tablice je vidljivo da je empirijski rezultat, iako nešto slabiji od teoretskog, na njegovom tragu. U svakom slučaju može se zaključiti da smanjenje fotografija značajno utječe na smanjenje vremena izvođenja programa pri čemu jedinično vrijeme obrade jedne fotografije nije visoko što znači da bi se određene kontrole mogle implementirati i na *frontendu* tj. na aplikativnom sučelju prema klijentu koji je korisnik fotoaparata kojim se akviziraju fotografije.

8.1. Detekcija osobnog vozila na fotografijama na kojima se nalazi osobno vozilo

Na prvi pogled iznenađujuće, međutim program u svim slučajevima prepoznaje da se radi o osobnim vozilima. Dakle postiže se bolji rezultat, nego u slučaju korištenja originalnih fotografija. Naime, kod korištenja originalnih fotografija jedno vozilo nije bilo prepoznato kao osobno vozilo, već kao kamion odnosno kamionet (*truck*).



Fotografija originalne veličine detektira kamion



Fotografija umanjena faktorom 2 detektira osobno vozilo


Slika 8.1 Detektirano osobno vozilo na umanjenoj fotografiji za razliku od originalne

8.2. Detekcija osobnog vozila na fotografijama koje ne sadrže osobno vozilo

Program je na svih 15 fotografija prepoznao da se ne radi o osobnom vozilu.

8.3. Prepoznavanje fotografija na kojima osobno vozilo nije dobro kadrirano


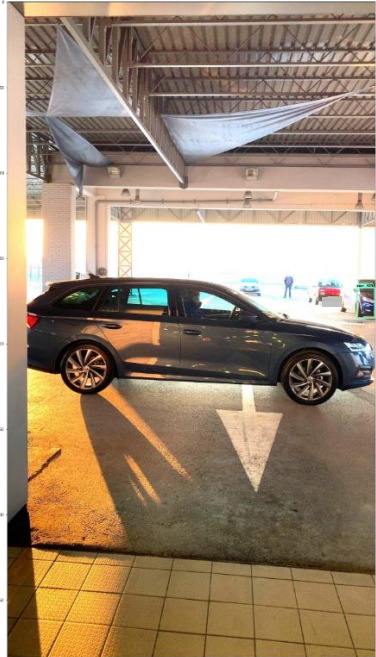
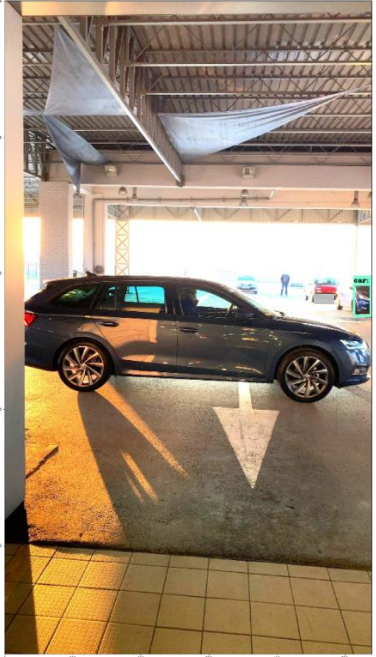
U ovom slučaju je je jedna fotografija više, nego kod analize s neumanjenim fotografijama jer je vozilo koje nije bilo detektirano u ovom slučaju detektirano.



Slika 8.2 Usporedni udio površine detektiranog osobnog vozila na originalnim i umanjenim fotografijama

Nema razlika u udjelima površine što je i očekivano. Dakle nema prepreke vezano uz udio površine u slučaju korištenja umanjenih fotografija koje se bitno brže obrađuju.

U nastavku se promatraju fotografije u grupi s najmanjim udjelom površine detektiranog objekta. Kao baza usporedbe koriste se originalne fotografije.

<p>1. ORIGINALNA VELIČINA</p>	
	
<p>Udio: 0,22%. Sa min_score_thresh=62% odabire osobno vozilo s desne strane u pozadini.</p>	
<p>UMANJENA FOTOGRAFIJA</p> <p>Udio: 0,23%. Sa min_score_thresh>50% odabire osobno vozilo s desne strane u pozadini.</p> <p>ZAKLJUČAK: BEZ PROMJENE</p>	

Slika 8.3 Usporedni prikaz originalnih i umanjenih fotografija osobnih vozila u grupi najmanjeg udjela površine-1. dio

2. ORIGINALNA VELIČINA



Udio: 48,31%. Sa min_score_thresh=75% prepoznaje željeno osobno vozilo. Napomena: Navedena fotografija u originalnoj veličini nije u grupi s najmanjim udjelima površine.

UMANJENA FOTOGRAFIJA


Udio: 0,24%. Sa min_score_thresh=76% odabire osobno vozilo iznad u pozadini.

ZAKLJUČAK: UMANJENJE
POGORŠAVA REZULTAT



Slika 8.4 Usporedni prikaz originalnih i umanjenih fotografija osobnih vozila u grupi najmanjeg udjela površine-2. dio

3. ORIGINALNA VELIČINA




Udio: 0,54%. Sa `min_score_thresh=72%` odabire osobno vozilo s lijeve strane u pozadini.

UMANJENA FOTOGRAFIJA



Udio: 13,01%. Sa `min_score_thresh=74%` prepoznaje željeno osobno vozilo.

ZAKLJUČAK: UMANJENJE
POBOLJŠAVA REZULTAT



Slika 8.5 Usporedni prikaz originalnih i umanjenih fotografija osobnih vozila u grupi najmanjeg udjela površine-3. dio

4. ORIGINALNA VELIČINA




Udio: 2,86%. Sa min_score_thresh=82% odabire osobno vozilo s desne strane u pozadini.

UMANJENA FOTOGRAFIJA

Udio: 2,93%. Sa min_score_thresh=81% odabire osobno vozilo s desne strane u pozadini.

ZAKLJUČAK: BEZ PROMJENE



Slika 8.6 Usporedni prikaz originalnih i umanjenih fotografija osobnih vozila u grupi najmanjeg udjela površine-4. dio

5. ORIGINALNA VELIČINA



Udio: 5,90%. Sa $\text{min_score_thresh}=79\%$ odabire osobno vozilo s lijeve strane u pozadini.

UMANJENA FOTOGRAFIJA

Udio: 6,00%. Sa $\text{min_score_thresh}=78\%$ odabire osobno vozilo s lijeve strane u pozadini.

ZAKLJUČAK: BEZ PROMJENE



Slika 8.7 Usporedni prikaz originalnih i umanjenih fotografija osobnih vozila u grupi najmanjeg udjela površine-5. dio

6. ORIGINALNA VELIČINA



Udio: 6,33%. Sa min_score_thresh=67% prepoznaje željeno osobno vozilo.

UMANJENA FOTOGRAFIJA


Udio: 6,87%. Sa min_score_thresh=67% prepoznaje željeno osobno vozilo.

ZAKLJUČAK: BEZ PROMJENE



Slika 8.8 Usporedni prikaz originalnih i umanjenih fotografija osobnih vozila u grupi najmanjeg udjela površine-6. dio

7. ORIGINALNA VELIČINA




Udio: 8,71%. Sa min_score_thresh=73% prepoznaje željeno osobno vozilo.

UMANJENA FOTOGRAFIJA

Udio: 8,92%. Sa min_score_thresh=74% prepoznaje željeno osobno vozilo.

ZAKLJUČAK: BEZ PROMJENE



Slika 8.9 Usporedni prikaz originalnih i umanjenih fotografija osobnih vozila u grupi najmanjeg udjela površine-7. dio

8. ORIGINALNA VELIČINA	
	
Udio: 8,84%. Sa min_score_thresh=71% prepoznaje željeno osobno vozilo.	
<p>UMANJENA FOTOGRAFIJA</p> <p>Udio: 8,70%. Sa min_score_thresh=66% prepoznaje željeno osobno vozilo.</p> <p>ZAKLJUČAK: BEZ PROMJENE</p>	
	

Slika 8.10 Usporedni prikaz originalnih i umanjenih fotografija osobnih vozila u grupi najmanjeg udjela površine-8. dio

U nastavku se prikazuje rekapitulacija prethodnih rezultata.

Redni broj fotografije iz prethodnih slika	Originalna veličina fotografije	Umanjena fotografija
1.	Pogrešna detekcija	
2.	Ispravna detekcija	Pogrešna detekcija
3.	Pogrešna detekcija	Ispravna detekcija
4.	Pogrešna detekcija	
5.	Pogrešna detekcija	
6.	Ispravna detekcija	
7.	Ispravna detekcija	
8.	Ispravna detekcija	
Uzorak	8	Od toga 7 primjera <10% udjela površine

Tablica 8.2 Usporedba rezultata korištenja originalnih i umanjenih fotografija u slučajevima kada je udio površine detektiranog osobnog vozila nizak

Može se zaključiti da umanjenje fotografije ne kviri rezultate u slučajevima kada detektirano vozilo zauzima malu površinu fotografije. Može se zaključiti da je u svakom slučaju dobro takve fotografije poslati na ručnu obradu kako ne bi došlo do pogrešaka slično kao i kod originalnih fotografija.


Smanjenje veličine fotografije faktorom 2 zapravo smanjuje broj piksela kojima se opisuje vozilo 4 puta. Dakle, kada je broj piksela na originalnoj fotografiji nizak, a uz to vozilo zauzima malen udio površine, tada bi se moglo dogoditi da je vozilo opisano s premalim brojem piksela, međutim na primjerima se ovaj problem nije pokazao. Uz to ne treba zaboraviti da su i fotoaparati sve bolji.

8.4. Fotografije sa slabom rezolucijom

Rezolucija fotografija je duplo slabija jer je transformacijom broj piksela smanjen 4 puta.

Ovo međutim nije problem jer se fotografije u originalnoj veličini pohranjuju u DMS, a smanjenje rezolucije služi za brži rad programa za detekciju i prepoznavanje boje.

Zanimljiv je slučaj vozila koje nije detektirano na originalnoj fotografiji, a na umanjenoj jest.

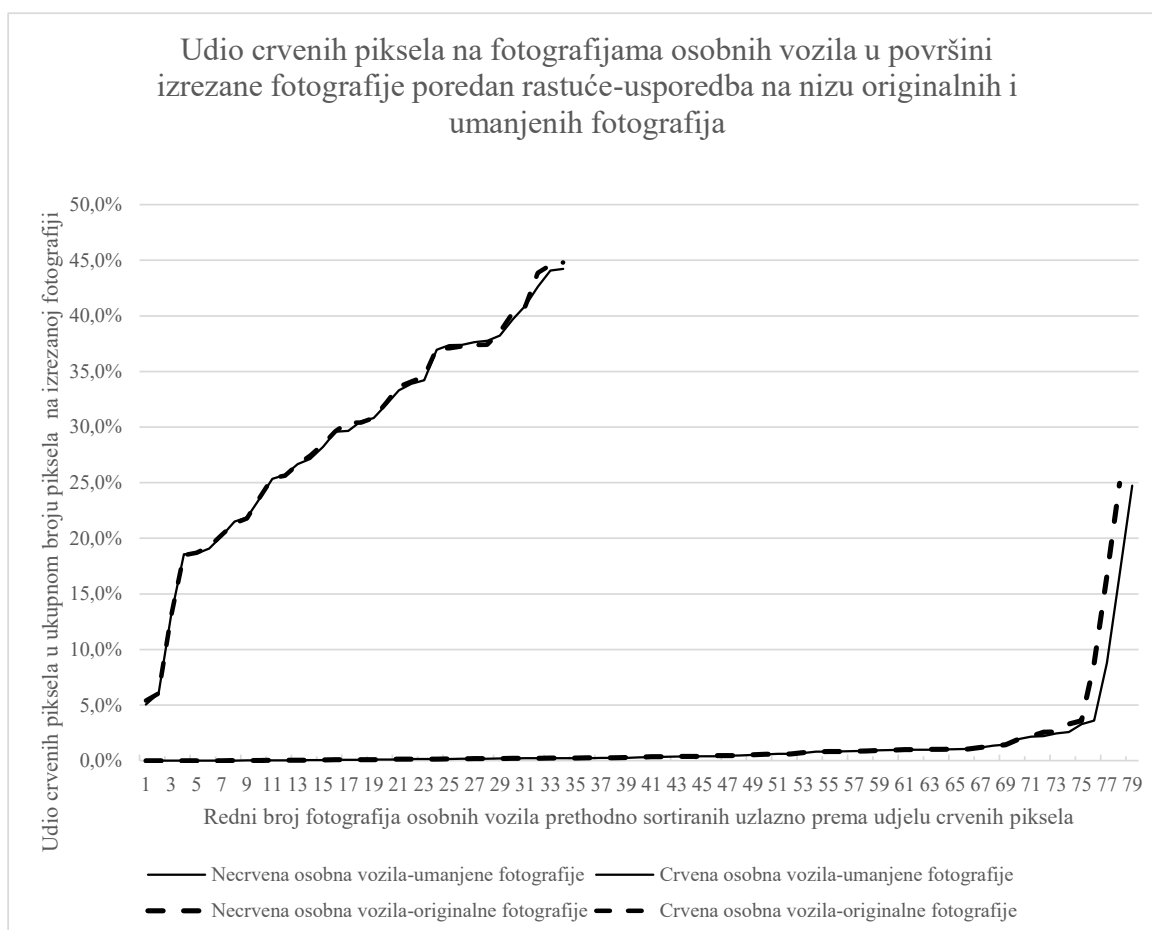


Slika 8.11 Dodatno prepoznato osobno vozilo na fotografiji s 5.060 piksela

8.5. Određivanje praga za prepoznavanje crvene boje

Na grafikonu su uspoređene distribucije na originalnim i umanjenim fotografijama. Može se uočiti da nema razlika.

Zaključuje se da prednost ima korištenje umanjenih fotografija zbog efikasnosti tj. vremenski kraćeg izvođenja programa.



Slika 8.12 Udio crvenih piksela kod originalnih i umanjenih fotografija

9. ZAKLJUČAK

U industriji osiguranja fotografiranje predmeta osiguranja, konkretnije osobnih vozila kod autokasko osiguranja, je dosta uobičajeno i omogućava dobivanje informacija prilikom prijema u osiguranje, ali i nakon štete. Osim teksta, s fotografija se mogu izdvajati i netekstualne značajke kao npr. boja, tekstura i oblik.

U radu je prikazana metoda za detekciju osobnog vozila i prepoznavanje njegove boje. Za detekciju osobnog vozila koristi se unaprijed trenirana neuronska mreža, a za prepoznavanja boje HSV prostor boja.

Svojstva programa su:

- Korišten program je Jupiterska bilježnica na platformi COLAB u koju se upisuju naredbe u Pythonu.
- Koristi se model „SSD MobileNet v2 320x320“. To je prethodno naučeni model neuronske mreže koji detektira objekte na učitanj fotografiji.
- Može obraditi više fotografija.
- Detektira jedno osobno vozilo na fotografiji.
- Računa udio površine detektiranog osobnog vozila.
- Transformira fotografije u HSV prostor boja.
- Računa udio crvenih piksela na dijelu fotografije na kojem je detektirano osobno vozilo.
- Ispravno orijentira fotografiju ukoliko je prilikom fotografiranja fotoaparata bio nepravilno zarotiran.
- Prikazuje podatke o širini i visini fotografije u pikselima.
- Prikazuje rezultat obrade svih fotografija u tablici.
- Može provoditi cijeli postupak na umanjnim fotografijama.

Analizirano je 135 fotografija iz prakse.

Vezano uz kadriranje fotografija kod akvizicije tj. fotografiranja:

- Velik broj fotografija ne kadrira baš najbolje vozilo koje je predmet osiguranja što navodi na zaključak da ima još dosta prostora za podizanje kvalitete fotografiranja edukacijom osoba koje fotografiraju kao i boljim ulaznim kontrolama kod fotografiranja.
- Udio površine detektiranog osobnog vozila na fotografiji od 39% zadovoljavajući je udio i njemu treba težiti, a po mogućnosti ga i premašiti.

Vezano uz rezoluciju fotografija kod akvizicije:

- Orijentacijski 100.000-200.000 piksela bi mogao biti njihov minimalno potreban broj neovisno o pozadini.

- Može se zaključiti da većina fotografija ima zadovoljavajuću rezoluciju. Osim toga za očekivati je da će kvaliteta fotoaparata rasti pa se tu ne očekuju izazovi.

Vezano uz detekciju osobnog vozila:

- Program je na svih 15 fotografija koje ne sadrže osobno vozilo prepoznao da se ne radi o osobnom vozilu.
- U jednom slučaju program ne detektira osobno vozilo, već prepoznaje osobno vozilo kao kamion.

Vezano uz izdvajanje boje:

- Prikazuje se metodologija koja kombinira tri pristupa (*colour picker*, graf i histograme) kako bi se odredile granice crvene boje u HSV modelu.
- Osobna vozila s udjelom crvenih piksela $<3,6\%$ nisu crvena. Kod $<3\%$ vozila rezultat je nejasan ($3,6\% - 13,1\%$) pa se takve fotografije trebaju ručno pregledati.
- Odabran je prag s udjelom crvenih piksela $13,1\%$ iznad kojeg se smatra da je vozilo crveno.
- Za stvarnu primjenu preporuča se korištenje složenije metode odabira praga.

Vezano uz efikasnost:

- Rezultati dobiveni na fotografijama umanjenim za faktor 2 (pikseli su prorijeđeni) ne zaostaju za rezultatima na originalnim fotografijama s tim da se značajno smanjuje vrijeme izvođenja programa.
- Prednost ima korištenje umanjenih fotografija.

Daljnji smjerovi istraživanja bi mogli biti:

- Prikupljanje i obrada fotografija radi dobivanja zaključka o bojama u intervalu za koji nije bilo empirijskih podataka u korištenom uzorku.
- Prepoznavanje različitih boja.
- Statistička analiza na temelju uparivanja s ostalim podacima o konkretnom vozilu kako bi se napravila regresija, npr. provjerila korelacija boje vozila sa štetama.
- Program može poslužiti za unapređenje kontrola na ulaznoj strani već kod fotografiranja vozila tj. prije spremanja u repozitorij kao i uključenja u sam proces preuzimanja rizika (npr. kod loših fotografija traži se dodatno fotografiranje ili usporedba raznih fotografija istog vozila).
- Prepoznavanje fotografija koje režu dijelove vozila tj. ne obuhvaćaju cjelovito vozilo.
- Prepoznavanje fotografija na kojima je više vozila.

10. POPIS LITERATURE

- [1] Ćurković, M., "Obvezna osiguranja u prometu", Zagreb: Inženjerski biro d.d., 2007.
- [2] Abdelmordy, F. et al., "Climate-smart agriculture using intelligent techniques, blockchain and Internet of Things": Concepts, challenges, and opportunities. Transactions on Emerging Telecommunications Technologies, 2022
- [3] Goasduff, L., "The 4 Trends That Prevail on the Gartner Hype Cycle for AI, 2021", Dostupno na: <https://www.gartner.com/en/articles/the-4-trends-that-prevail-on-the-gartner-hype-cycle-for-ai-2021>. [Posjećeno 28 11 2022].
- [4] Szeliski, R., "Computer Vision: Algorithms and Applications", Springer, 2022.
- [5] "US-10552913-B1 - Enhanced claims damage estimation using aggregate display," Dostupno na: <https://portal.unifiedpatents.com/patents/patent/US-10552913-B1>. [Posjećeno 11 3 2023].
- [6] "US-20200125885-A1 - Vehicle Insurance Image Processing Method, Apparatus, Server, and System", Dostupno na: <https://portal.unifiedpatents.com/patents/patent/US-20200125885-A1>. [Posjećeno 11 3 2023].
- [7] "US-9524450-B2 - Digital Image Processing Using Convolutional Neural Networks", Dostupno na: <https://portal.unifiedpatents.com/patents/patent/US-9524450-B2>. [Posjećeno 11 3 2023].
- [8] Shang, K., "Applying Image Recognition to Insurance", Dostupno na: <https://www.soa.org/498dba/globalassets/assets/files/resources/research-report/2018/applying-image-recognition.pdf>. [Posjećeno 11 3 2023].
- [9] Sean Chua, M., "In-Depth Analysis of Identification Documents Through Vision AI", Dostupno na: <https://towardsai.net/p/artificial-intelligence/in-depth-analysis-of-identification-documents-through-vision-ai>. [Posjećeno 11 3 2023].
- [10] "What Is OCR and How to Extract Data from Images?", Dostupno na: <https://techacute.com/how-to-extract-data-from-images/>. [Posjećeno 17 12 2022].
- [11] Cavin, A., "Systematic Way to Extract Features From Image Dana", Dostupno na: <https://towardsdatascience.com/feature-engineering-for-machine-learning-with-picture-data-d7ff8554920>. [Posjećeno 17 12 2022].
- [12] Kiran, S., "Vehicle Detection and Classification: A Review", Dostupno na: https://www.researchgate.net/publication/343482198_Vehicle_Detection_and_Classification_A_Review. [Posjećeno 28 11 2022].
- [13] Haykin, S., "Neural Networks and Learning Machines", New York: Pearson Prentice Hall, 2009.
- [14] "Everything you need to know about VGG16" Dostupno na: <https://medium.com/@mygreatlearning/everything-you-need-to-know-about-vgg16-7315defb5918>. [Posjećeno 10 01 2023].
- [15] "Umjetna neuronska mreža" Dostupno na: https://hr.wikipedia.org/wiki/Umjetna_neuronska_mre%C5%BEa. [Posjećeno 5 12 2022].
- [16] "Artificial neuron" Dostupno na: https://en.wikipedia.org/wiki/Artificial_neuron. [Posjećeno 12 3 2023].
- [17] "Osnove neuronskih mreža" Dostupno na: <https://course.elementsofai.com/hr/5/1>. [Posjećeno 5 12 2022].

- [18] Melcher, K., "A Friendly Introduction to [Deep] Neural Networks" Dostupno na: <https://www.knime.com/blog/a-friendly-introduction-to-deep-neural-networks>. [Posjećeno 5 12 2022].
- [19] "CHAPTER 5 Why are deep neural networks hard to train?" Dostupno na: <http://neuralnetworksanddeeplearning.com/chap5.html>. [Posjećeno 5 12 2022].
- [20] "CHAPTER 6 Deep learning" Dostupno na: <http://neuralnetworksanddeeplearning.com/chap6.html>. [Posjećeno 5 12 2022].
- [21] Shafkat, I., "Intuitively Understanding Convolutions for Deep Learning", Dostupno na: <https://towardsdatascience.com/intuitively-understanding-convolutions-for-deep-learning-1f6f42faee1>. [Posjećeno 10 01 2023].
- [22] Dostupno na: <https://www.tensorflow.org/>. [Posjećeno 7 12 2022].
- [23] Rodriguez, J., "The Evolution of Google's MobileNet Architectures to Improve Computer Vision Models" Dostupno na: <https://medium.com/dataseries/the-evolution-of-googles-mobilenet-architectures-to-improve-computer-vision-models-ffb483ffcc0a>. [Posjećeno 17 12 2022].
- [24] "Difference between SSD and Mobilenet" Dostupno na: <https://stackoverflow.com/questions/50585597/difference-between-ssd-and-mobilenet>. [Posjećeno 17 12 2022].
- [25] "Convolutional neural network" Dostupno na: https://en.wikipedia.org/wiki/Convolutional_neural_network. [Posjećeno 17 12 2022].
- [26] "Can Large Insurers Ever Innovate Like Their Insurtech Rivals?" Dostupno na: https://www.insurtechinsights.com/general-insurance-market-set-for-explosive-growth-allianz-axa-general-see-a-big-move/?utm_medium=email&utm_campaign=Newsletter%2015%20July%202022%20All&utm_content=Newsletter%2015%20July%202022%20All+CID_489e9082ae3d. [Posjećeno 28 11 2022].
- [27] "Kategorije" Dostupno na: <https://www.hak.hr/vozila/homologacija/kategorije/>. [Posjećeno 17 12 2022].
- [28] "Pravilnik o tehničkim uvjetima vozila u prometu na cestama" Dostupno na: <https://www.cvh.hr/gradani/propisi-i-upute/pravilnici/zakon-o-sigurnosti-prometa-na-cestama/pravilnik-o-tehnickim-uvjetima-vozila-u-prometu-na-cestama/>. [Posjećeno 17 12 2022].
- [29] "NumPy: the absolute basics for beginners", Dostupno na: https://numpy.org/devdocs/user/absolute_beginners.html. [Posjećeno 24 11 2022].
- [30] "Google Colab: How to loop through images in a folder?" Dostupno na: <https://stackoverflow.com/questions/51857468/google-colab-how-to-loop-through-images-in-a-folder>. [Posjećeno 24 11 2022].
- [31] Dostupno na: https://colab.research.google.com/github/tensorflow/hub/blob/master/examples/colab/tf_2_object_detection.ipynb. [Posjećeno 18 01 2023].
- [32] "image_to_numpy", Dostupno na: https://github.com/ageitgey/image_to_numpy. [Posjećeno 26 12 2022].
- [33] "Understanding DPI and Pixel Dimensions", Dostupno na: <https://www.iprintfromhome.com/mso/understandingdpi.pdf>. [Posjećeno 25 11 2022].

- [34] "HUE, VALUE, SATURATION", Dostupno na: <https://learn.leighcotnoir.com/artspeak/elements-color/hue-value-saturation/>. [Posjećeno 22 11 2022].
- [35] "Moć boja Kako su boje osvojile svijet", Zagreb: Etnografski muzej, ožujak-rujan 2009.
- [36] "The HSV Color Model in Graphic Design", Dostupno na: <https://www.lifewire.com/what-is-hsv-in-design-1078068>. [Posjećeno 2 1 2023].
- [37] Briggs, D., "The Dimensions of Colour" Dostupno na: <http://www.huevaluechroma.com/093.php>. [Posjećeno 22 11 2022].
- [38] "Color models and color spaces", Dostupno na: <https://programmingdesignsystems.com/color/color-models-and-color-spaces/index.html>. [Posjećeno 22 11 2022].
- [39] "Distinguish red color from white is HSV or similar color space", Dostupno na: <https://stackoverflow.com/questions/17931424/distinguish-red-color-from-white-is-hsv-or-similar-color-space>. [Posjećeno 24 11 2022].
- [40] "Finding red color in image using Python & OpenCV", Dostupno na: <https://stackoverflow.com/questions/30331944/finding-red-color-in-image-using-python-opencv>. [Posjećeno 22 11 2022].
- [41] "Colors of objects", Dostupno na: <https://www.pa.uky.edu/~sciworks/light/preview/color4aa.htm>. [Posjećeno 24 11 2022].
- [42] Dostupno na: <https://www.le.ac.uk/se/centres/sci/selfstudy/lht5.htm>. [Posjećeno 24 11 2022].
- [43] Dostupno na: <http://color.lukas-stratmann.com/color-systems/hsv.html>. [Posjećeno 25 11 2022].
- [44] "Computer Vision", Dostupno na: <https://cvexplained.wordpress.com/2020/04/28/color-detection-hsv/>. [Posjećeno 22 11 2022].
- [45] José, I., "Custom object detection for non-data scientists — Tensorflow", Dostupno na: <https://towardsdatascience.com/custom-object-detection-for-non-data-scientists-70325fef2dbb>. [Posjećeno 11 3 2023].
- [46] "In TensorFlow is min_score_thresh related to IoU?", Dostupno na: <https://stackoverflow.com/questions/67182946/in-tensorflow-is-min-score-thresh-related-to-iou>. [Posjećeno 11 3 2023].
- [47] Narkhede, S., "Understanding Confusion Matrix" Dostupno na: <https://towardsdatascience.com/understanding-confusion-matrix-a9ad42dcfd62>. [Posjećeno 10 3 2023].
- [48] "Alternative to scipy.misc.imresize() in Python" Dostupno na: <https://www.geeksforgeeks.org/alternative-to-scipy-misc-imresize-in-python/>. [Posjećeno 10 3 2023].
- [49] "Moiré pattern", Dostupno na: https://en.wikipedia.org/wiki/Moir%C3%A9_pattern. [Posjećeno 10 3 2023].
- [50] Dostupno na: <https://www.iprintfromhome.com/mso/understandingdpi.pdf>.
- [51] Dostupno na: https://en.wikipedia.org/wiki/HSL_and_HSV. [Posjećeno 25 11 2022].
- [52] Dostupno na: https://www.researchgate.net/figure/Artificial-intelligence-branches_fig3_362994009. [Posjećeno 28 11 2022].

[53] Dostupno na: <https://www.machinedesign.com/mechanical-motion-systems/article/21835963/what-are-the-differences-between-vehicledetection-technologies>. [Posjećeno 5 12 2022].

11. ŽIVOTOPIS

Rođen 14. svibnja 1976. u Sisku. Maturirao na XV. gimnaziji u Zagrebu (IB-International Baccalaureate program). 1994. upisao Ekonomski fakultet u Zagrebu.

Dobio Pohvalnicu odlukom Dekana Ekonomskog fakulteta za izvrstan uspjeh i postignute rezultate u školskoj godini 1996/97. kao jedan od najboljih studenata na Fakultetu.

Diplomirao na smjeru Organizacija i management 1998. te iste godine upisao i poslijediplomski znanstveni studij Operacijska istraživanja. Magistrirao 2004. godine. Na drugom smjeru, smjeru Financije, diplomirao 2005. godine. 2020. postigao ACCA.

Od 1995. do 1998. Demonstrator na Katedri za statistiku Ekonomskog fakulteta Sveučilišta u Zagrebu.

U Privrednoj banci Zagreb d.d. radio od 1998. do 2005. U okviru redovnih poslova radio na dokumentiranju i analizi poslovnih procesa te na poslovima planiranja i managerskog izvješćivanja. Među većim projektima u kojima je sudjelovao su: Projekt privatizacije Privredne banke Zagreb d.d, Projekt informatizacije poslovanja s pravnim osobama, Projekt vođenja računa za pravne osobe i Projekt informatizacije Riznice. Sudjelovao je i na nekoliko due dilligence projekata u Hrvatskoj, Bosni i Hercegovini i Srbiji. Od 2004. do 2006. honorarno je predavao kolegij Bankarstvo na Poslovnoj školi Start u Zagrebu. Od 2005. do 2011. radio je u Consule d.o.o. poduzeću koje se bavi zastupanjem modnih marki te veleprodajom i maloprodajom robe. Radio je na poslovima implementacije te kasnije održavanja i razvoja SAP informatičkog sustava tvrtke. Sudjelovao je i u raznim projektima tvrtke kao npr. na razvoju lojalnog programa. Vodio je i resor financija i računovodstva tvrtke. 2011. godine pokrenuo je tvrtku Adva računovodstvo d.o.o. koja se bavila pružanjem računovodstvenih usluga. Poduzeće je likvidirao 2014. godine. Od 2013. godine radi u osiguravajućem društvu Croatia osiguranje d.d. 2018.-2019. paralelno radi i u CROATIA osiguranje mirovinskom društvu kao interni revizor. U Croatia osiguranje d.d. radio je na poslovima interne revizije, produktnog managera i preuzimanja rizika. Trenutno radi na poslovima reosiguranja. Sudjelovao je i na raznim projektima društva.

Objavljeni radovi:

Mojsinović, Dubravko: Program lojalnosti u poduzeću-Studij slučaja, prema radionici održanoj 18.11.2008. na Zagrebačkoj školi ekonomije i managementa (ZŠEM) u Zagrebu, uvršteno u knjigu Maje Martinović: Marketing u Hrvatskoj 55 poslovnih slučajeva, MATE d.o.o., Zagreb, 2012.

Mojsinović, Dubravko: Selecting appropriate criterion for finding value adding wholesale customers, prezentacija na 13. Konferenciji za operacijska istraživanja, Split, 2010.

Mojsinović, Dubravko: How to implement key performance indicators in a company, Proceedings of the 10th International Symposium on Operational research SOR '09, Nova Gorica, Slovenia, September 23-25, 2009, Lidija Zadnik Stirn, Janez Žerovnik, Samo Drobne, Anka Lisec, str. 219.-226.

Mojsinović, Dubravko: Evaluating Loyalty Program in a Retail Company using Markov Analysis, prezentacija na Konferenciji za operacijska istraživanja, Pula, 2008.

Mojsinović, Dubravko: Best training proposal selection by combining personal beliefs with economic criteria, Proceedings of the 9th International Symposium on Operational research SOR '07, Nova Gorica, Slovenia, September 26-28, 2007, Lidija Zadnik Stirn, Samo Drobne, str. 241.-246.

Mojsinović, Dubravko: Comparison of Croatian banks interest rates on deposits using cluster analysis, Proceedings of the 11th International Conference on Operational Research KOI '06, Pula, Croatia, September 27-29, 2006., Croatian Operational research Society, Zagreb, Valter Boljunčić, Luka Neralić, Kristina Šorić, str. 141.-148.

Mojsinović, Dubravko: Five Croatian banks foreign currency position analysis using value at risk, Proceedings of the 8th International Symposium on Operational research SOR '05, Nova Gorica, Slovenia, September 28-30, 2005, Lidija Zadnik Stirn, Samo Drobne, str. 297.-302.

Mojsinović, Dubravko: Analiza otvorene devizne pozicije pet hrvatskih banaka VaR i ETL pokazateljima, Diplomski rad, 2005.

Mojsinović, Dubravko: Optimalni broj poslužitelja kao podrška help desku banke, prezentacija na Konferenciji za operacijska istraživanja, Trogir, 2004.

Mojsinović, Dubravko: O analizi iskorištenosti kapaciteta, 2nd Workshop on Operational Research for Young Researchers, Croatian Operational Research Society, Faculty of Economics, Zagreb, 2004.

Mojsinović, Dubravko: Odabir optimalnog broja poslužitelja u bankama primjenom teorije repova, Magistarski rad, 2004.

Mojsinović, Dubravko: Unapređenje procesa u bankama, Workshop on Operational Research for Young Researchers, Croatian Operational Research Society, Faculty of Economics, Zagreb, 2001.

Mojsinović, Dubravko: Projektiranje Državne riznice, Diplomski rad, 1998.

12. BIOGRAPHY

He was born on May 14, 1976 in Sisak. He graduated from XV. gymnasium in Zagreb (IB-International Baccalaureate program). In 1994, entered the Faculty of Economics in Zagreb.

Obtained Certificate from the Dean of Faculty of Economics for excellence during school year 1996/97 as one of the best students at the Faculty.

He graduated in the field of Organization and Management in 1998, and in the same year enrolled in the post-graduate scientific study of Operational Research. He received his master's degree in 2004. In 2005, he graduated from another course, Finance. In 2020. he achieved ACCA.

From 1995. until 1998. Demonstrator at Department of Statistics, Faculty of Economics, University of Zagreb.

In Privredna banka Zagreb d.d. he worked from 1998. to 2005. As part of his regular duties, he worked on documenting and analyzing business processes and on planning and managerial reporting. Among the larger projects in which he participated are: Privredna banka Zagreb d.d. Privatization Project, Introduction of IT support in commercial banking, Domestic payments for Legal Entities and Treasury IT introduction Project. He also participated in several due diligence projects in Croatia, Bosnia and Herzegovina and Serbia. From 2004 to 2006, he taught the Banking course part-time at the Start Business School in Zagreb. From 2005 to 2011, he worked at Consule d.o.o. a company that deals with fashion brands and the wholesale and retail of goods. He worked on implementation and later maintenance and development of the company's SAP IT system. He also participated in various company projects, such as the development of the loyalty program. He also managed the finance and accounting department of the company. In 2011, he started the company Adva accountancy d.o.o. which was engaged in providing accounting services. He liquidated the company in 2014. Since 2013, he has been working at the insurance company Croatia osiguranje d.d. 2018-2019 in parallel, he works in CROATIA osiguranje pension company as an internal auditor. In Croatia osiguranje d.d. he worked as an internal auditor, product manager and underwriter. He is currently working in reinsurance. He also participated in various company projects.

Published works:

Mojsinović, Dubravko: Program lojalnosti u poduzeću-Studij slučaja, prema radionici održanoj 18.11.2008. na Zagrebačkoj školi ekonomije i managementa (ZŠEM) u Zagrebu, uvršteno u knjigu Maje Martinović: Marketing u Hrvatskoj 55 poslovnih slučajeva, MATE d.o.o., Zagreb, 2012.

Mojsinović, Dubravko: Selecting appropriate criterion for finding value adding wholesale customers, prezentacija na 13. Konferenciji za operacijska istraživanja, Split, 2010.

Mojsinović, Dubravko: How to implement key performance indicators in a company, Proceedings of the 10th International Symposium on Operational research SOR '09, Nova Gorica, Slovenia, September 23-25, 2009, Lidija Zadnik Stirn, Janez Žerovnik, Samo Drobne, Anka Lisec, str. 219.-226.

Mojsinović, Dubravko: Evaluating Loyalty Program in a Retail Company using Markov Analysis, prezentacija na Konferenciji za operacijska istraživanja, Pula, 2008.

Mojsinović, Dubravko: Best training proposal selection by combining personal beliefs with economic criteria, Proceedings of the 9th International Symposium on Operational research SOR '07, Nova Gorica, Slovenia, September 26-28, 2007, Lidija Zadnik Stirn, Samo Drobne, str. 241.-246.

Mojsinović, Dubravko: Comparison of Croatian banks interest rates on deposits using cluster analysis, Proceedings of the 11th International Conference on Operational Research KOI '06, Pula, Croatia, September 27-29, 2006., Croatian Operational research Society, Zagreb, Valter Boljunčić, Luka Neralić, Kristina Šorić, str. 141.-148.

Mojsinović, Dubravko: Five Croatian banks foreign currency position analysis using value at risk, Proceedings of the 8th International Symposium on Operational research SOR '05, Nova Gorica, Slovenia, September 28-30, 2005, Lidija Zadnik Stirn, Samo Drobne, str. 297.-302.

Mojsinović, Dubravko: Analiza otvorene devizne pozicije pet hrvatskih banaka VaR i ETL pokazateljima, Diplomski rad, 2005.

Mojsinović, Dubravko: Optimalni broj poslužitelja kao podrška help desku banke, prezentacija na Konferenciji za operacijska istraživanja, Trogir, 2004.

Mojsinović, Dubravko: O analizi iskorištenosti kapaciteta, 2nd Workshop on Operational Research for Young Researchers, Croatian Operational Research Society, Faculty of Economics, Zagreb, 2004.

Mojsinović, Dubravko: Odabir optimalnog broja poslužitelja u bankama primjenom teorije repova, Magistarski rad, 2004.

Mojsinović, Dubravko: Unapređenje procesa u bankama, Workshop on Operational Research for Young Researchers, Croatian Operational Research Society, Faculty of Economics, Zagreb, 2001.

Mojsinović, Dubravko: Projektiranje Državne riznice, Diplomski rad, 1998.