

# Klasifikacija histoloških snimaka crijeva

---

Hrabar, Fran

Master's thesis / Diplomski rad

2024

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://um.nsk.hr/um:nbn:hr:168:679913>

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

Download date / Datum preuzimanja: **2025-03-14**



Repository / Repozitorij:

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



SVEUČILIŠTE U ZAGREBU  
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 305

# KLASIFIKACIJA HISTOLOŠKIH SNIMAKA CRIJEVA

Fran Hrabar

Zagreb, veljača 2024.

SVEUČILIŠTE U ZAGREBU  
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 305

# KLASIFIKACIJA HISTOLOŠKIH SNIMAKA CRIJEVA

Fran Hrabar

Zagreb, veljača 2024.

## **DIPLOMSKI ZADATAK br. 305**

Pristupnik: **Fran Hrabar (0036514281)**

Studij: Računarstvo

Profil: Računarska znanost

Mentor: prof. dr. sc. Marko Subašić

Zadatak: **Klasifikacija histoloških snimaka crijeva**

Opis zadatka:

Ispitati metode za klasifikaciju slika, uz poseban naglasak na klasifikaciju biomedicinskih slika te klasifikaciju slika velike rezolucije. Prikupiti odgovarajuću bazu histoloških snimaka crijeva visoke rezolucije s poznatom dijagnozom. Implementirati metodu za klasifikaciju histoloških snimaka crijeva u cjelini, kao i klasifikaciju manjih isječaka iz snimke. Implementirati i metodu za uzimanje isječaka s osiguranjem maksimalne dozvoljene zastupljenosti pozadine. Ispitati točnost na prikupljenoj bazi slika te posebnu pažnju obratiti na pouzdanost procjene klase. Za implementaciju koristiti programski jezik Python. Za detaljnije informacije obratiti se mentoru.

Rok za predaju rada: 9. veljače 2024.



# Sadržaj

<b>1. Uvod</b>	<b>3</b>
<b>2. Skup podataka</b>	<b>4</b>
2.1. NDPI format	4
2.2. Neuravnoteženost podataka	5
2.3. Podjela podataka	5
<b>3. Model</b>	<b>8</b>
3.1. Konvolucijske mreže	9
3.2. Ekstraktor značajki	10
3.3. EfficientNet	11
3.4. Parametri modela	12
<b>4. Predobrada</b>	<b>14</b>
4.1. Smanjivanje veličine (engl. <i>downscaling</i> )	14
4.2. Segmentacija	14
4.2.1. Multi - Otsu dovođenje praga	14
4.2.2. Obrada temeljena na zakrpama (engl. <i>patch-based processing</i> )	16
4.2.3. Cjevovod (engl. <i>pipeline</i> ) izgradnje novog skupa podataka	16
4.2.4. Siva slika (engl. <i>grayscale image</i> )	16
4.2.5. Zasićenje (engl. <i>saturation</i> ) u HSV modelu boja (engl. <i>Hue Saturation Value</i> )	18
4.2.6. Nijansa (engl. <i>hue</i> ) u HSV modelu boja (engl. <i>Hue Saturation Value</i> )	22
<b>5. Treniranje</b>	<b>26</b>
5.1. Funkcija gubitka	26

5.2. Augmentacija podataka . . . . .	26
5.3. Optimizator . . . . .	27
5.4. Težine klasa . . . . .	28
5.5. Hiperparametri . . . . .	28
<b>6. Rezultati . . . . .</b>	<b>29</b>
6.1. Većinsko glasovanje . . . . .	30
6.2. Odabir . . . . .	32
<b>7. Zaključak . . . . .</b>	<b>37</b>
<b>Literatura . . . . .</b>	<b>38</b>
<b>Sažetak . . . . .</b>	<b>40</b>
<b>Abstract . . . . .</b>	<b>41</b>

# 1. Uvod

Crohnova bolest (CD) i ulcerozni kolitis (UC) su kronične upalne bolesti crijeva koje karakterizira upala u probavnom sustavu. Ulcerozni kolitis primarno utječe na sluznicu debelog crijeva te je upala kontinuiranog uzorka. Crohnova bolest je transmuralna, što znači da može zahvatiti cijelu debljinu crijevne stijenke, te su često upaljeni dijelovi izmiješani s nezahvaćenim područjima crijeva. Liječnici donose odluku dijagnoze bolesti na temelju biopsije (histološke snimke) i kliničkih, laboratorijskih, radiografskih i endoskopskih promatranja [1].

Cilj rada je stvaranje sustava za dijagnozu bolesti crijeva na temelju histoloških snimki crijeva. Metode strojnog učenja su se pokazale uspješnima u području medicine, a zbog kompleksnosti zadatka i strukture podataka gdje su podaci slike s objektima koji su podložni translaciji, rotaciji i sličnim transformacijama - duboke neuronske mreže su dobar izbor za rješavanje zadatka.



## 2. Skup podataka

Skup podataka (engl.*dataset*) se sastoji od histoloških snimaka crijeva u .ndpi formatu i pripadnih metapodataka u .xlsx formatu. Metapodaci su:

- Pacijent
- Datum uzorkovanja
- PHD broj
- Stakalce broj
- Dijagnoza

Metapodaci koji su se koristili u sklopu ovog projekta su:


- Pacijent
- Dijagnoza

Ulaz u neuronsku mrežu su histološke snimke crijeva ili neka obrada tih snimaka, slika 2.1. Ciljna varijabla je Dijagnoza koja ima klase CD (Crohnova bolest, (engl.*Crohn's Disease*)) i UC (Ulcerozni kolitis, (engl.*Ulcerative colitis*)).

Originalni skup podataka se sastoji od 36 stakalaca (engl.*slides*). Anonimiziran prikaz broja stakalaca i dijagnoze po pacijentu se vidi u tablici 2.1.

### 2.1. NDPI format

NDPI (NanoZoomer Digital Pathology Image) je jedna od varijanti Hamamatsu formata. Hamamatsu format je višedatotečni (engl.*multi-file*) JPEG/NGR s pridruženim metapo-



**Slika 2.1.** Histološka slika crijeva

dacima (engl.*metadata*) i formatima indeksne datoteket (engl.*index file format*), te datotekama sličnim TIFF formatu s pridruženim metapodacima [2].

## 2.2. Neuravnoteženost podataka

Problematičnost ovog skupa podataka je u tome što je više histoloških snimaka stakalca presjeka crijeva klase CD nego klase UC, štoviše broj pacijenata koji su dijagnosticirani s Crohnovom bolešću je također veći nego onih dijagnosticirani s ulceroznim kolitisom - što će se pokazati značajnim u kasnijim poglavljima, tablica 2.2.

## 2.3. Podjela podataka

Zbog postojanja više slika stakalca po pacijentu nije ispravno ni mudro nasumično podijeliti stakalca u skup za treniranje i validaciju. Korisnija metoda podjele je *podjela po pacijentu* (engl.*patient-wise split*)[3]. Podjela po pacijentu svrstava sve slike pojedinog pacijenta u samo jedan od skupova podataka, skup za treniranje ili skup za testiranje. Ova metoda podjele eliminira curenje podataka (engl.*data leakage*) i potiče generalizacijsku vještinu modela na neviđenim pacijentima.

U ovom radu podjela pacijenata je po broju stakalaca po pacijentu. Pacijenti koji imaju više od jednog pripadnog stakalca su svrstani u skup za treniranje, a oni pacijenti koji imaju jedno pripadno stakalce su svrstani u skup za testiranje. To rezultira podjelom u tablici 2.3.

Pacijent	Dijagnoza	Broj snimaka
Pacijent 1	CD	3
Pacijent 2	CD	4
Pacijent 3	CD	1
Pacijent 4	CD	2
Pacijent 5	CD	1
Pacijent 6	CD	3
Pacijent 7	CD	2
Pacijent 8	CD	2
Pacijent 9	CD	1
Pacijent 10	CD	3
Pacijent 11	CD	1
Pacijent 12	CD	1
Pacijent 13	CD	1
Pacijent 14	UC	1
Pacijent 15	UC	3
Pacijent 16	UC	4
Pacijent 17	UC	1
Pacijent 18	UC	2

Tablica 2.1. Anonimiziran prikaz broja stakalaca i dijagnoze po pacijentu

Dijagnoza	Broj stakalaca	Udio stakalaca (%)	Broj pacijenata	Udio pacijenata (%)
CD	25	69,44	13	72,22
UC	11	30,55	5	27,77

Tablica 2.2. Anonimiziran prikaz broja stakalaca i dijagnoze po pacijentu

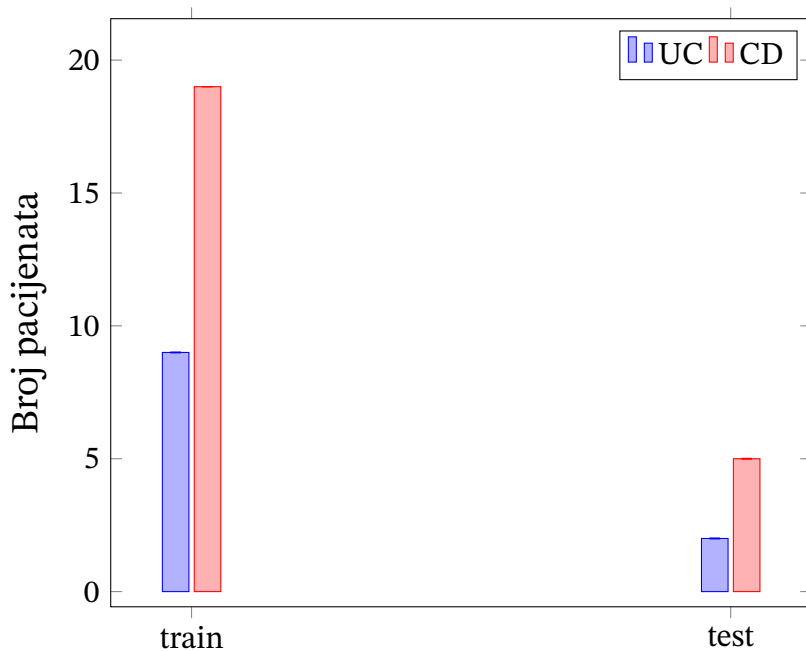
Ravnoteža skupa podataka za treniranje i skupa podataka za testiranje je prikazana u tablici 2.4. I skup za treniranje i skup za testiranje su neuravnoteženi, čak i s različitim distribucijama po klasama – ta informacija će biti relevantna pri treniranju i evaluaciji modela.

Pacijent	Dijagnoza	Broj snimaka	Skup podataka
Pacijent 1	CD	3	train
Pacijent 2	CD	4	train
Pacijent 4	CD	2	train
Pacijent 6	CD	3	train
Pacijent 7	CD	2	train
Pacijent 8	CD	2	train
Pacijent 10	CD	3	train
Pacijent 15	UC	3	train
Pacijent 16	UC	4	train
Pacijent 18	UC	2	train
Pacijent 3	CD	1	test
Pacijent 5	CD	1	test
Pacijent 9	CD	1	test
Pacijent 11	CD	1	test
Pacijent 12	CD	1	test
Pacijent 13	CD	1	test
Pacijent 14	UC	1	test
Pacijent 17	UC	1	test

Tablica 2.3. Podjela pacijenata u skup za treniranje i skup za testiranje

Skup podataka	Broj stakalaca	Udio stakalaca (%)	Broj pacijenata	Udio pacijenata (%)
train	28	77.78	10	55.56
test	8	22.22	8	44.44

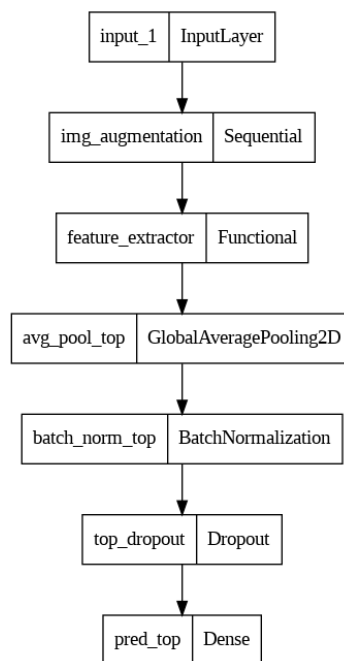
Tablica 2.4. Raspodjela stakalaca i pacijenata u skupu za treniranje i skupu za testiranje



Slika 2.2. Raspodjela pacijenata po dijagnozi i skupu podataka

### 3. Model

Model koji se koristi za ulaz prima slike oblika  $N \times 3 \times 600 \times 600$ , gdje je  $N$  veličina mini-grupe, dok je izlaz klasifikacija (dijagnoza) bolesti crijeva u Crohnovu bolest ili ulcerozni kolitis. Model se sastoji od predtreniranog EfficientNet B7 u ulozi ekstraktora značajki (engl. *feature extractor*) i dodatnog završnog bloka koji slijedi arhitekturu EfficientNet bloka, slika 3.1.



**Slika 3.1.** Arhitektura modela.

Blok se sastoji od:

- sloja globalnog sažimanja srednjom vrijednošću (engl. *global mean pooling layer*)
- sloja normalizacije nad grupom (engl. *batch normalization layer*)
- sloja isključivanja čvorova grafa (engl. *dropout layer*)

- potpuno povezanog unaprijednog sloja (engl. *fully connected feedforward layer*)

Kako bi se od EfficientNet predtreniranog modela dobio ekstraktor značajki moraju se skinuti EfficientNet blokovi s vrha modela, time se otkrivaju posredne značajke koje se mogu koristiti za klasifikaciju. Što se više blokova skida to su značajke primitivnije i općenitije, a što se manje blokova skida to su značajke kompleksnije i specijaliziranije skupu podataka na kojemu je ekstraktor treniran. U sklopu ovoga rada razmotrit će se utjecaj broja skinutih blokova i odabranih metrika.

Dio ovog poglavlja je preuzet iz prethodnog autorovog djela [4].

### 3.1. Konvolucijske mreže

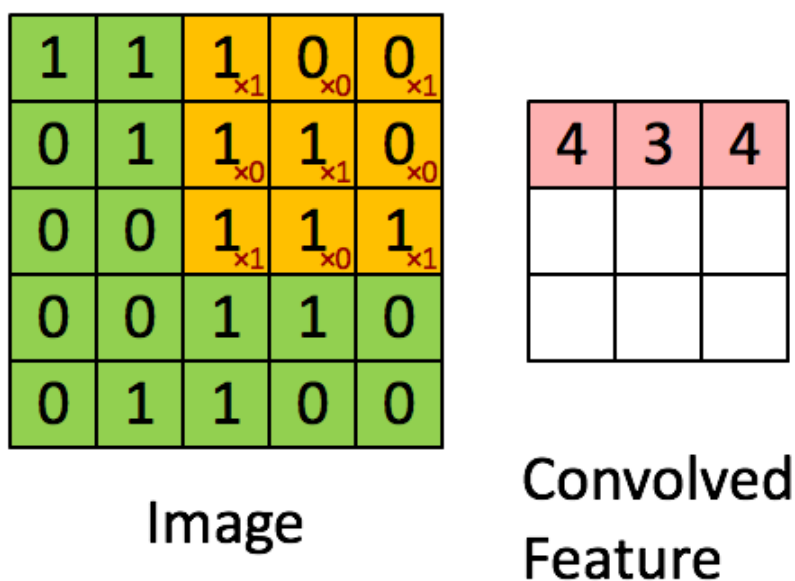
Konvolucijske neuronske mreže (engl. *Convolutional Neural Networks, ConvNet, CNN*) su neuronske mreže koje su bazirane na konvolucijskim operacijama. Više o neuronskim mrežama može se saznati na [5].

Obične neuronske mreže (potpuno povezane unaprijedne mreže) su jako osjetljive na varijacije i translacije u ulaznim podacima stoga je potreban velik broj težina koje su često redundantne i sklone prenaučavanju. Takve mreže osim većih računalnih resursa trebaju i veći skup podataka za učenje.

Konvolucijske neuronske mreže rješavaju te probleme. Konvolucijske neuronske mreže reduciraju ulazne podatke kako bi bili lakši za procesiranje bez gubitaka važnih značajki (engl. *features*). To se postiže primjenom konvolucijskog sloja i sloja sažimanje (engl. *pooling layer*).

Konvolucijski sloj se sastoji od maske veličine  $N \times M$  koja se pomiče po ulaznoj matrici i množi po elementima s vrijednostima matrice na ulazu i zbraja (Slika 3.2.). Lako se vidi da što je bolje poklapanje ulazne matrice i maske vrijednosti i uz prikladne vrijednosti maske može detektirati neki uzorak npr. vodoravnu liniju na području  $3 \times 3$  (Slika 3.3.). Kako se maska uči mogu se izvući (engl. *extract*) važne značajke kao što su rubovi, kutovi, presjeci, krivine i sl. s time da što je konvolucijski sloj više u arhitekturi (bliže izlazu) može izvlačiti kompleksnije značajke.

Sloj sažimanja je sličan konvolucijskom sloju no on pronalazi srednju ili najveću vrijed-



**Slika 3.2.** Računanje konvolucije jednog sloja. Zelena matrica je ulazna slika, žuta je maska, a ružičasta je matrica konvoluiranih značajki.

$$\begin{bmatrix} 0 & 0 & 0 \\ 2 & 4 & 2 \\ 0 & 0 & 0 \end{bmatrix}$$

**Slika 3.3.** Konvolucijska matrica

nost za dani pomični prozor (engl.*sliding window*). To je korisno radi smanjenja prostorne rezolucije, izvlačenja dominantnih značajki i združivanja lokalnih informacija što dovodi do smanjenja računalne kompleksnosti i dobivanja novih korisnih značajki (Slika. 3.4.).

Podaci i slike o konvolucijskim neuronskim mrežama i njihovim dijelovima preuzete su s [6].

### 3.2. Ekstraktor značajki

Ekstrakcija značajki (engl.*feature extraction*) je proces izvlačenja bitnih značajki iz skupa podataka, temelji se na smanjenju dimenzionalnosti radi smanjenja potrebe za računalnim resursima i redundantnosti [7].

Ekstraktor značajki je predtreniran CNN koji kao izlaz daje značajke i koji se u fazi tre-

3.0	3.0	3.0
3.0	3.0	3.0
3.0	2.0	3.0

3	3	2	1	0
0	0	1	3	1
3	1	2	2	3
2	0	0	2	2
2	0	0	0	1

**Slika 3.4.** Sažimanje najveće vrijednosti (engl. *max pooling*).

niranja ne mijenja.

### 3.3. EfficientNet


EfficientNet je konvolucijska neuronska mreža i metoda skaliranja modela. Skaliranje modela je skaliranje dimenzija modela koje su dubina modela, širina modela i rezolucija ulazne slike. U radu „EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks“ je uvedena nova metoda skaliranja modela „compound scaling“ koja umjesto skaliranja samo jedne dimenzije modela skalira sve dimenzije modela uniformno za „compound coefficient“  $\phi$  (3.1). Prikaz vrsta skaliranja prikazan je an slici 3.5.

Formula skaliranja dimenzija je dana u formuli (3.1).

$$\begin{aligned}
 \text{dubina} : d &= \alpha^\phi \\
 \text{širina} : w &= \beta^\phi \\
 \text{rezolucija} : r &= \gamma^\phi \\
 \alpha \cdot \beta^2 \cdot \gamma^2 &\approx 2 \\
 \alpha \geq 1, \beta \geq 1, \gamma \geq 1
 \end{aligned}
 \tag{3.1}$$

Koeficijent  $\phi$  je korisnički definiran i određuje koliko se dodatno želi dodijeliti resursa modelu, dok su koeficijenti  $\alpha$ ,  $\beta$ ,  $\gamma$  konstante koje određuju kako će se dodatni





**Slika 3.5.** Skaliranje modela. (a) osnovni model, (b) – (d) skaliranje pojedine dimenzije, (e) compound skaliranje.

resursi raspodijeliti. FLOPS (engl. *Floating Point Operations*) konvolucijskih operacija je proporcionalan s  $\alpha$ ,  $\beta^2$  i  $\gamma^2$ , pošto su većina računanja u konvolucijskim neuronskim mrežama konvolucijske operacije možemo aproksimativno izračunati koliko će se FLOPS-a povećati u odnosu na bazni model za dani  $\phi$  po formuli (3.2).

$$(\alpha \cdot \beta^2 \cdot \gamma^2)^\phi \approx 2^\phi \quad (3.2)$$

Bazni model je EfficientNet B0 dok se povećanjem  $\phi$ -a dobivaju modeli B1 – B7. U sklopu ovog rada koristi se B7 zbog najveće preciznosti. Usporedba performansi varijanti EfficientNet-a i ostalih popularnih modela je vidljiva na Slici 3.6. .

Podaci i slike o EfficientNetu i njegovim performansama preuzete su s [8].

### 3.4. Parametri modela

Korišteni model se sastoji od dva dijela: pretreniranog ekstraktora značajki te završnih slojeva. Kako ekstraktor značajki već zna prepoznati određene značajke njega nije potrebno dodatno trenirati, dok završne slojeve koji koriste postojeće značajke tek treba naučiti da na temelju značajki daju dijagnozu. Stoga u modelu postoje parametri koje bi trebali ostati fiksni i oni koji se trebaju naučiti, 3.1.

Model	Top-1 Acc.	Top-5 Acc.	#Params	Ratio-to-EfficientNet	#FLOPs	Ratio-to-EfficientNet
<b>EfficientNet-B0</b>	<b>77.1%</b>	<b>93.3%</b>	<b>5.3M</b>	<b>1x</b>	<b>0.39B</b>	<b>1x</b>
ResNet-50 (He et al., 2016)	76.0%	93.0%	26M	4.9x	4.1B	11x
DenseNet-169 (Huang et al., 2017)	76.2%	93.2%	14M	2.6x	3.5B	8.9x
<b>EfficientNet-B1</b>	<b>79.1%</b>	<b>94.4%</b>	<b>7.8M</b>	<b>1x</b>	<b>0.70B</b>	<b>1x</b>
ResNet-152 (He et al., 2016)	77.8%	93.8%	60M	7.6x	11B	16x
DenseNet-264 (Huang et al., 2017)	77.9%	93.9%	34M	4.3x	6.0B	8.6x
Inception-v3 (Szegedy et al., 2016)	78.8%	94.4%	24M	3.0x	5.7B	8.1x
Xception (Chollet, 2017)	79.0%	94.5%	23M	3.0x	8.4B	12x
<b>EfficientNet-B2</b>	<b>80.1%</b>	<b>94.9%</b>	<b>9.2M</b>	<b>1x</b>	<b>1.0B</b>	<b>1x</b>
Inception-v4 (Szegedy et al., 2017)	80.0%	95.0%	48M	5.2x	13B	13x
Inception-resnet-v2 (Szegedy et al., 2017)	80.1%	95.1%	56M	6.1x	13B	13x
<b>EfficientNet-B3</b>	<b>81.6%</b>	<b>95.7%</b>	<b>12M</b>	<b>1x</b>	<b>1.8B</b>	<b>1x</b>
ResNeXt-101 (Xie et al., 2017)	80.9%	95.6%	84M	7.0x	32B	18x
PolyNet (Zhang et al., 2017)	81.3%	95.8%	92M	7.7x	35B	19x
<b>EfficientNet-B4</b>	<b>82.9%</b>	<b>96.4%</b>	<b>19M</b>	<b>1x</b>	<b>4.2B</b>	<b>1x</b>
SENet (Hu et al., 2018)	82.7%	96.2%	146M	7.7x	42B	10x
NASNet-A (Zoph et al., 2018)	82.7%	96.2%	89M	4.7x	24B	5.7x
AmoebaNet-A (Real et al., 2019)	82.8%	96.1%	87M	4.6x	23B	5.5x
PNASNet (Liu et al., 2018)	82.9%	96.2%	86M	4.5x	23B	6.0x
<b>EfficientNet-B5</b>	<b>83.6%</b>	<b>96.7%</b>	<b>30M</b>	<b>1x</b>	<b>9.9B</b>	<b>1x</b>
AmoebaNet-C (Cubuk et al., 2019)	83.5%	96.5%	155M	5.2x	41B	4.1x
<b>EfficientNet-B6</b>	<b>84.0%</b>	<b>96.8%</b>	<b>43M</b>	<b>1x</b>	<b>19B</b>	<b>1x</b>
<b>EfficientNet-B7</b>	<b>84.3%</b>	<b>97.0%</b>	<b>66M</b>	<b>1x</b>	<b>37B</b>	<b>1x</b>
GPipe (Huang et al., 2018)	84.3%	97.0%	557M	8.4x	-	-

**Slika 3.6.** Usporedba EfficientNet modela i nekih popularnih modela na *ImageNet* skupu podataka. Metrike usporedbe su **Top - 1 Acc.** i **Top - 5 Acc.**, dok **#Params** i **#FLOPs** prikazuju računalnu zahtjevnost.

# skinutih gornjih slojeva ekstraktora značajki	# učljivih parametara	# neučljivih parametara	# parametara
1	10242	64102807	64113049
4	2562	62450327	62452889
8	15362	59996567	60011929

Tablica 3.1. Broj parametara modela

## 4. Predobrada

Ulaz u EfficientNet B7 model je RGB (engl. *Red Green Blue*) slika 600 x 600 piksela (engl. *pixel*), dok su histološke snimke crijeva nekoliko redova veličina veći, npr. 109440 x 41728 piksela. Uz to što se sami ulazi u mrežu mogu skalirati prije njihovog hranjenja u EfficientNet, postoji i problem nedostatka memorije.

### 4.1. Smanjivanje veličine (engl. *downscaling*)

Prvi očiti potez je smanjenje veličine samih histoloških slika i njihovo zasebno spremanje kao novi skup podataka. NDPI slike imaju više razina (engl. *levels*) koje se razlikuju po svojim rezolucijama (engl. *resolution*), stoga je uzeta najmanja histološka snimka koja zadovoljava uvjet da su njene obje dimenzije veće ili jednake očekivanim dimenzijama ulaza EfficientNeta. Tako se dobiva sljedeća raspodjela skupa za treniranje i skupa za testiranje.

### 4.2. Segmentacija

Dani skup podataka je premalen i pun šuma. U idućim koracima pokušat ćemo povećati broj slika u skupu podataka i pročitati/filtrirati same slike (engl. *cleanup*).

#### 4.2.1. Multi - Otsu dovođenje praga

Ulazna slika je 2D funkcija intenziteta koja se sastoji od  $N$  piksela diskretnih cjelobrojnih vrijednosti od 1 do  $L$ . Frekvencija piksela koji imaju vrijednost  $i$  je  $f_i$  te je vjerojatnost pojavljivanja piksela intenziteta  $i$  u danoj slici.

$$p_i = f_i/N \tag{4.1}$$

Ako se radi o dovođenju pragova za M klasa, za klase  $C_1, C_2, \dots, C_M$  se određuje M-1 pragova tako da klasi  $C_1$  pripadaju pikseli intenziteta  $[1, t_1]$ , klasi  $C_2$  pripadaju pikseli intenziteta  $[t_1 + 1, t_2], \dots$ . Vjerojatnosne distribucije klasa su prikazane formulom (4.2). Iz toga proizlazi da je očekivanje unutar svake klase (4.3). Očekivanje cijele slike je prikazano u (4.4).

$$\begin{aligned}
C_1 &: p_1/\omega(1, t_1), \dots, p_{1,t_1}/\omega(t_2), \\
C_2 &: p_{t_1+1}/\omega(t_1, t_2), p_{t_1+2}/\omega(t_1, t_2), \dots, p_{t_2}/\omega(t_1, t_2) \\
C_M &: p_{t_{M-1}+1}/\omega(t_{M-1}, L), p_{t_{M-1}+2}/\omega(t_{M-1}, L), \dots, p_L/\omega(t_{M-1}, L)
\end{aligned} \tag{4.2}$$

$$\omega(a, b) = \sum_{i=a}^b p_i$$

$$\mu_m = \sum_{i=t_{m-1}}^{t_m} i \cdot p_i/\omega(t_m - 1, t_m) \tag{4.3}$$

$$\mu_T = \sum_{i=1}^M \omega(t_{i-1}, t_i) \tag{4.4}$$

Međuklasna varijanta segmentirane slike je (4.5).

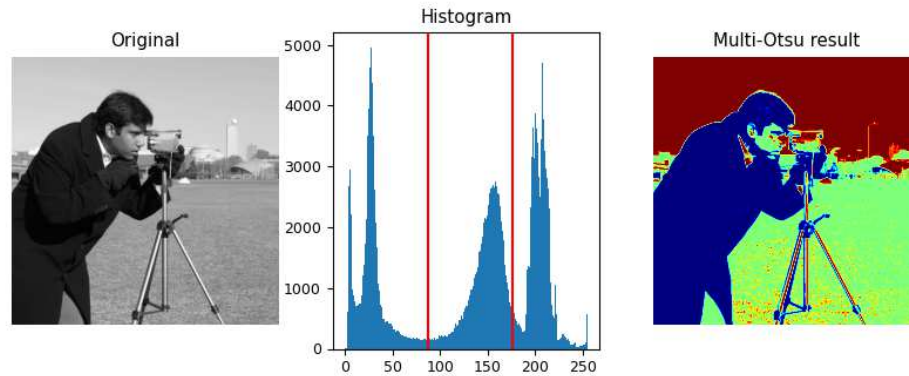
$$\sigma_B^2 = \sum_{k=1}^M (\mu_k - \mu_T)^2 \cdot \omega(t_{k-1}, t_k) \tag{4.5}$$

Optimalni pragovi  $t^*$  su oni za koje je međuklasna varijanca  $\sigma_B^2$  maksimalna, (4.6).

$$\begin{aligned}
\{t_1^*, t_2^*, \dots, t_M^*\} &= \operatorname{argmax}\{\sigma_B^2(t_1, t_2, \dots, t_M)\} \\
1 &\leq t_1 < t_2 < \dots < t_M \leq L
\end{aligned} \tag{4.6}$$

Podaci i matematički izrazi su preuzeti iz [9].

Primjer Multi - Otsu segmentacije je dan na Slici 4.1.



**Slika 4.1.** Primjer multiotsu segmentacije [10]

#### 4.2.2. Obrada temeljena na zakrpama (engl.*patch-based processing*)

Svaka pojedina slika je podijeljena na blokove određene veličine i nad njima se provodi određena analiza. S time dobivamo više manjih podataka, ali potencijalno gubimo strukturnu informaciju razlomljenu među susjednim zakrpama.

#### 4.2.3. Cjevovod (engl.*pipeline*) izgradnje novog skupa podataka

Pseudokod cjevovoda izrade novih skupova podataka iz izvornog skupa koji sadrži potpune RGB histološke snimke crijeva je dan u Algoritmu 1

#### 4.2.4. Siva slika (engl.*grayscale image*)

Izvorna trokanalna RGB slika se preslikava u jednodanalnu sivu sliku (engl.*grayscale image*) čije vrijednosti označavaju intenzitet svjetline. Preslikavanje se vrši po formuli 4.7[11].

$$y = 0.2125 \cdot R + 0.7154 \cdot G + 0.0721 \cdot B \quad (4.7)$$

Raspodjela po kategorijama novog skupa podataka je prikazan u tablici 4.1.

Primjer Multi - Otsu segmentacije jednog primjerka po kanalu sive slike je dan na Slici 4.2.

Primjerci zakrpa koji čine skup podataka dani su na Slici 4.3. Slike 4.3.(a)-(h) pred-

---

**Algorithm 1** Izgradnja novog skupa podataka

---

**Ulaz:**  $X$  – izvorni skup cijelih histoloških RGB snimaka

**Izlaz:** novi skup isječaka histoloških RGB slika u kojima se pojavljuje tkivo


```
x := nasumicni_uzorak(X)
mask := rgb2one_dimensional(x)    ▷ Pretvorba trokanalne slike u jednokanalnu
pragovi := multiotsu_threshold(mask) ▷ pragovi segmentacije za [tkivo, pozadina,
šum]
segmentirana_maska := segmentiranje(mask, pragovi)
prikaz_segmentirane_slike(x, segmentirana_maska)
ciljna_kategorija_segmentacije := odabir_ciljne_kategorije()

novi_skup_podataka := []
for x in X do
  ZAKRPE := stvori_zakrpe(x)
  for zakrpa in ZAKRPE do
    mask := rgb2one_dimensional(zakrpa)
    segmentirana_maska := segmentiranje(mask, pragovi)
    udio_u_zakrpi := udio_ciljne_kategorije(segmentirana_maska,
ciljna_kategorija_segmentacije)
    if udio_u_zakrpi > prag_zastupljenosti_ciljne_kategorije then
      dodaj(novi_skup_podataka, zakrpa)
    end if
  end for
end for
return novi_skup_podataka
```

---

	UC	CD
train	6910 (30.708%)	15592 (69.292%)
test	891 (16.692%)	4447 (83.308%)

Tablica 4.1. Raspodjela podataka skupa podataka segmentiranog po sivoj slici.



Slika 4.2. Primjer Multi - Otsu segmentacije po kanalu sive slike

stavljaju dobre zakrpe koje su rezultat algoritma 1, na slikama 4.3.(g)-(h) su također prisutni objekti koji nisu traženo tkivo i kao takvi predstavljaju šum. Slike 4.3.(i)-(m) predstavljaju loše zakrpe koje su rezultat algoritma 1 Slike 4.3.(i) i 4.3.(m) predstavljaju rubove stakalca, a 4.3.(j) prisutnost nekakve vanjske supstance (npr. prašina) koji su završili u skupu podataka jer se nalaze u rasponu intenziteta sive slike različitom od pozadine, za lakše razumijevanje pogledajte 4.2. Slike 4.3.(k)-(l) predstavljaju zakrpe s nedovoljnom prisutnošću tkiva (manje od praga udjela u slici) te ne bi smjele biti dio skupa podataka, no zbog prisutnosti šuma slika zadovoljava uvjet dovođenja praga.

#### 4.2.5. Zasićenje (engl.*saturation*) u HSV modelu boja (engl.*Hue Saturation Value*)


Izvorna trokanalna RGB slika se preslikava u HSV modelu boja te se kao maska uzima kanal zasićenja.

#### Prag zastupljenosti ciljne kategorije 0.3

Raspodjela po kategorijama novog skupa podataka je prikazan u tablici 4.2.

Primjerci zakrpa koji čine skup podataka dani su na Slici 4.4. Slike 4.4.(a)-(i) predstavljaju dobre zakrpe koje su rezultat algoritma 1 Slika 4.4.(i) je ispravna no sadrži i rub





**Slika 4.3.** Primjerci zakrpa u skupu za treniranje dobivenih segmentacijom po kanalu sive slike



	UC	CD
train	4294 (29.886%)	10074 (70.114%)
test	568 (15.046%)	3207 (84.954%)

Tablica 4.2. Raspodjela podataka skupa podataka segmentiranog po kanalu zasićenja u HSV modelu boja slike sa pragom ciljne kategorije 0.3.

stakalca (tamni dio slike). Slike 4.4.(j)-(p) predstavljaju loše zakrpe koje su rezultat algoritma 1 Slike 4.4.(j)-(p) su završile u skupu podataka jer se nalaze u rasponu intenziteta S kanala slike u HSV modelu boje različitom od pozadine, za lakše razumijevanje pogledajte 4.5. Slike 4.4.(j)-(m) sadrže zamućene slike tkiva te kao takve su jako šumovite, no zadovoljavaju uvjet udjela intenziteta zasićenja slike. Slika 4.4.(n) je potpuno tamna jer predstavlja rub ili prostor izvan stakalca. Slike 4.4.(o)-(p) u potpunosti sadrže vanjsku supstancu (npr. prašina, boja) stoga su šumovite. Slike 4.4.(f)-(h) su rubovi stakalca ili objekti koji nisu tkivo te su završili u skupu podataka jer se nalaze u rasponu intenziteta S kanala slike u HSV modelu boje različitom od pozadine, za lakše razumijevanje pogledajte 4.5.

#### Prag zastupljenosti ciljne kategorije 0.4


Raspodjela po kategorijama novog skupa podataka je prikazan u tablici 4.3.

	UC	CD
train	3827 (30.349%)	8783 (69.651%)
test	494 (14.782%)	2848 (85.218%)

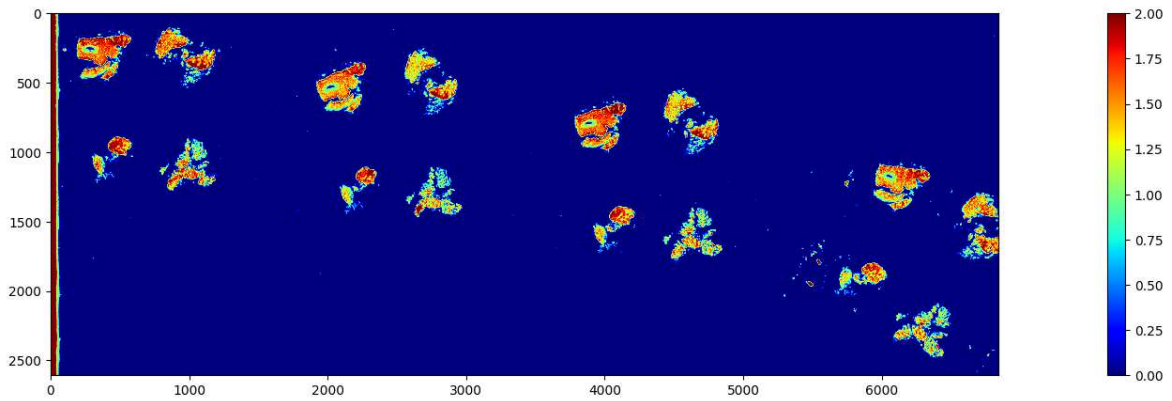
Tablica 4.3. Raspodjela podataka skupa podataka segmentiranog po kanalu zasićenja u HSV modelu boja slike sa pragom ciljne kategorije 0.4.

Primjer Multi - Otsu segmentacije jednog primjerka po S kanalu slike u HSV modelu boja je dan na Slici 4.5.

Primjerci zakrpa koji čine skup podataka dani su na Slici 4.6. Slike 4.6.(a)-(e) predstavljaju dobre zakrpe koje su rezultat algoritma 1, na slikama su također prisutni objekti koji nisu traženo tkivo i kao takvi predstavljaju šum. Slike 4.6.(f)-(l) predstavljaju loše zakrpe koje su rezultat algoritma 1 Slike 4.6.(f)-(h) su rubovi stakalca ili objekti koji nisu tkivo te su završili u skupu podataka jer se nalaze u rasponu intenziteta S kanala slike u HSV modelu boje različitom od pozadine, za lakše razumijevanje pogledajte 4.5. Slike



**Slika 4.4.** Primjerci zakrpa u skupu za treniranje dobivenih segmentacijom po po S kanalu slike u HSV modelu boja sa pragom ciljne kategorije 0.3



**Slika 4.5.** Primjer Multi - Otsu segmentacije po S kanalu slike u HSV modelu boja

4.6.(i)-(l) sadrže zamucene slike tkiva te kao takve su jako šumovite, no zadovoljavaju uvjet udjela intenziteta zasićenja slike.

#### 4.2.6. Nijansa (engl.*hue*) u HSV modelu boja (engl.*Hue Saturation Value*)

Izvorna trokanalna RGB slika se preslikava u HSV modelu boja te se kao maska uzima kanal nijanse.

#### Prag zastupljenosti ciljne kategorije 0.2


Raspodjela po kategorijama novog skupa podataka je prikazan u tablici 4.4.

	UC	CD
train	8462 (39.588%)	12913 (60.412%)
test	1939 (27.472%)	5119 (72.528%)

Tablica 4.4. Raspodjela podataka skupa podataka segmentiranog po kanalu nijanse u HSV modelu boja slike sa pragom ciljne kategorije 0.2.

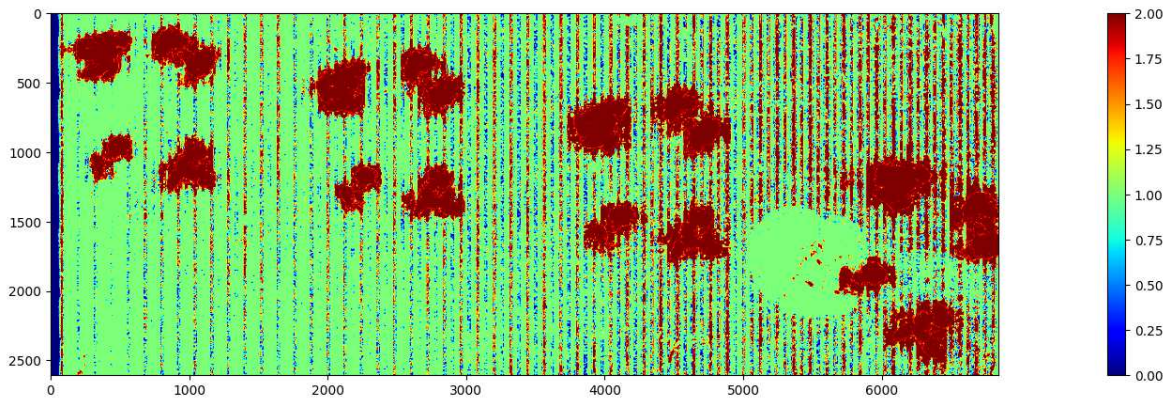
Primjer Multi - Otsu segmentacije jednog primjerka po H kanalu slike u HSV modelu boja je dan na Slici 4.7.

Primjerci zakrpa koji čine skup podataka dani su na Slici 4.8. Slike 4.8.(a)-(h) predstavljaju dobre loše zakrpe koje su rezultat algoritma 1 Slike 4.8.(i)-(n) predstavljaju loše zakrpe koje su rezultat algoritma 1 Slike 4.8.(i)-(m) su svrstane kao ispravne jer sadrže nijansu različitu od one koja većinski predstavlja pozadinu , za lakše razumijevanje pogledajte 4.2. Interpretacija je da za izrazito svijetle (zasićene) boje u HSV modelu nijansa




**Slika 4.6.** Primjerci zakrpa u skupu za treniranje dobivenih segmentacijom po po S kanalu slike u HSV modelu boja sa pragom ciljne kategorije 0.4





**Slika 4.7.** Primjer Multi - Otsu segmentacije po H kanalu slike u HSV modelu boja

nije primijetiva. Slike 4.8.(n) predstavlja zakrpu s nedovoljnom prisutnošću tkiva (manje od praga udjela u slici) te ne bi smjela biti dio skupa podataka, no zbog prisutnosti šuma slika zadovoljava uvjet dovođenja praga.



**Slika 4.8.** Primjerci zakrpa u skupu za treniranje dobivenih segmentacijom po po H kanalu slike u HSV modelu boja

## 5. Treniranje

Treniranje je postupak učenja modela rješavanja određenog zadatka na temelju danog skupa podataka za treniranje. U našem slučaju skup podataka sadrži i oznake (engl.*label*) pripadnosti kategorijama pa se stoga radi o nadziranom učenju (engl.*supervised learning*). Zadatak za koji se trenira model je klasifikacija (engl.*classification*) isječaka histoloških snimaka tkiva crijeva kao Crohnovu bolest (CD) ili ulcerozni kolitis (UC).

Treniranje se sastoji od skupa podataka za učenje, modela, funkcije gubitka (engl.*loss function*), optimizatora (engl.*optimizer*) te skupa hiperparametara (engl.*hyperparameter*) za učenje.

### 5.1. Funkcija gubitka

Pošto je zadatak klasifikacija u dvije klase, funkcija gubitka je binarna unakrsna entropija (engl.*Binary Cross Entropy, BCE*), jednačba (5.1). Stoga je jednačba gubitka (5.2). [12].

$$l_n = w_n [y_n \cdot \log x_n + (1 - y_n) \cdot \log(1 - x_n)] \quad (5.1)$$


$$L = \text{mean}(\{l_1, \dots, l_N\}^T) \quad (5.2)$$

### 5.2. Augmentacija podataka

Kao sredstvo kompenzacije za mali skup podataka koristi se augmentacija podataka (engl.*data augmentation*). Augmentacija podataka je skup metoda transformacija ulaznih podataka radi diverzifikacije skupa podataka. Augmentacije su umjetne (engl.*artificial*) te

služe kako bi se nadomjestilo skupo prikupljanje i označavanje podataka te pokrilo više varijacija ulaznih podataka. Nužno je koristiti augmentacije koje su smislene i koje mogu biti viđene u praksi jer se inače model može naučiti na nepostojeće značajke i naprotiv smanjiti performanse modela, prikaz augmentiranih slika 5.1. Augmentacije korištene u ovom radu su:

- rotacija
- translacija
- promjena razine kontrasta
- zrcaljenje



**Slika 5.1.** Augmentacija podataka

### 5.3. Optimizator

Korišteni optimizator je Adam s početnom stopom učenja (engl. *learning rate*), kod 5..1

```
optimizer = tf.keras.optimizers.Adam(learning_rate=lr)
```

Kod 5..1: Adam optimizator



## 5.4. Težine klasa

Radi korigiranja utjecaja neuravnoteženosti skupa podataka pri izračunu funkcije gubitaka svakoj klasi dodjeljujemo različite težine. To se čini kako bi pri treniranju model više kažnjavao primjerke pojedine klase te tako više korigirao parametre modela u korist te klase. U jednadžbi (5.3) je prikazano računanje težina klasa koje se koriste u jednadžbi (5.1). U jednadžbi (5.3) se vidi da klasa koja je manje reprezentirana u skupu podataka za treniranje ima veću težinu. Prednost ovog rješenja nad naduzorkovanjem (engl.*oversampling*) je ušteda računalnih resursa za isti rezultat, a prednost nad poduzorkovanjem (engl.*undersampling*) je više iskorištenih primjeraka iz zastupljenije klase te mogućih uzoraka za naučiti.

$$\begin{aligned}w_0 &= \frac{n_0 + n_1}{n_0} \\w_1 &= \frac{n_0 + n_1}{n_1}\end{aligned}\tag{5.3}$$

$n_0, n_1$  broj uzoraka u pojedinoj klasi

Stoga dobivamo za svaki skup podataka možemo dobiti 3 varijante [13]:

- neuravnoteženi (engl.*imbalanced*) - skup podataka u kojem su distribucije klasa inherentno različite
- uravnoteženi (engl.*balanced*) - skup podataka u kojem su distribucije klasa jednake
- dodatno neuravnoteženi (engl.*unbalanced*) - skup podataka koji je bio uravnotežen, no više nije. U ovom slučaju se umjetno povećava fokus na zastupljeniju klasu, to se čini kako bi mogli pratiti utjecaj na metrike

## 5.5. Hiperparametri

Model je treniran u 25 epoha (engl.*epoch*), sa veličinom mini-grupe (engl.*batch size*) 8 te početnom stopom učenja (engl.*learning rate*)  $10^{-4}$ .

## 6. Rezultati

Usporedba modela i pridruženih skupova podataka se provodi na skupu podataka za testiranje. Po pretpostavci da distribucija skupa podataka za testiranje odgovara skupu podataka za treniranje, skup podataka za testiranje je također neuravnotežen. Gubitak pri evaluaciji ne sadrži težinsko skaliranje klasa (jednako kažnjava primjerke UC i CD klasa).

Iz dane tablice 6.1. uočljivo je da najbolje performanse daju dodatno neuravnoteženi modeli, što je bilo i očekivano jer se uvela dodatna pristranost modela prema zastupljenijoj klasi.

Također je primjetljivo da modeli naučeni na skupu podataka koji je segmentiran na temelju H kanala imaju najgore performanse, vjerojatno prouzročeno količinom šuma u skupu za treniranje (isječci bez tkiva, s rubovima stakalca, prašinom i sl. česticama). Pošto je pozadina stakalca bijele boje H kanal može poprimiti bilo koju vrijednost.

Kako bismo bolje usporedili performanse modela naučenih na raznim skupovima podataka promotrit ćemo metrike temeljene na razredima. Pošto ne postoji povećana opasnost pri pogrešnoj klasifikaciji pojedine klase, kao što je npr. slučaj u dijagnozi tumora, metrike obje klase vrednujemo jednako.

Pri usporedbi metrika po skupovima podataka u obzir se uzimaju:

- vrijednosti metrika za svaku klasu (engl.*per-class*)
- mikro srednja vrijednost metrike (engl.*micro*)
- makro srednja vrijednost metrike (engl.*macro*)

Razlika između mikro i makro metrike se može pojednostaviti - mikro srednja vrijed-

Kanal segmentacije	prag segmentacije	uravnoteženost podataka	# skinutih gornjih slojeva ekstraktora značajki	Test loss	Test acc
gray	0.2	uravnotežen	1	0.702	0.649
gray	0.2	uravnotežen	4	0.665	0.65
gray	0.2	uravnotežen	8	0.67	0.519
gray	0.2	dodatno neuravnotežen	1	0.534	0.78
gray	0.2	dodatno neuravnotežen	4	0.436	0.814
gray	0.2	dodatno neuravnotežen	8	0.389	0.845
gray	0.2	neuravnotežen	1	0.519	0.762
gray	0.2	neuravnotežen	4	0.528	0.743
gray	0.2	neuravnotežen	8	0.473	0.801
H	0.2	uravnotežen	1	0.896	0.537
H	0.2	uravnotežen	4	0.863	0.507
H	0.2	uravnotežen	8	0.755	0.507
H	0.2	dodatno neuravnotežen	1	0.753	0.574
H	0.2	dodatno neuravnotežen	4	0.721	0.566
H	0.2	dodatno neuravnotežen	8	0.623	0.6035
H	0.2	neuravnotežen	1	0.771	0.564
H	0.2	neuravnotežen	4	0.758	0.538
H	0.2	neuravnotežen	8	0.669	0.518
S	0.3	uravnotežen	1	0.697	0.691
S	0.3	uravnotežen	4	0.737	0.651
S	0.3	uravnotežen	8	0.678	0.61
S	0.3	dodatno neuravnotežen	1	0.458	0.791
S	0.3	dodatno neuravnotežen	4	0.416	0.81
S	0.3	dodatno neuravnotežen	8	0.349	<b>0.85</b>
S	0.3	neuravnotežen	1	0.572	0.744
S	0.3	neuravnotežen	4	0.553	0.734
S	0.3	neuravnotežen	8	0.429	0.784
S	0.4	uravnotežen	1	0.812	0.641
S	0.4	uravnotežen	4	0.681	0.677
S	0.4	uravnotežen	8	0.673	0.613
S	0.4	dodatno neuravnotežen	1	0.514	0.776
S	0.4	dodatno neuravnotežen	4	0.417	0.8105
S	0.4	dodatno neuravnotežen	8	<b>0.345</b>	0.849
S	0.4	neuravnotežen	1	0.588	0.743
S	0.4	neuravnotežen	4	0.504	0.756
S	0.4	neuravnotežen	8	0.432	0.789

Tablica 6.1. Gubitak i točnost skupova za testiranje

nost metrike daje jednaku težinsku vrijednost svim primjercima, dok makro srednja vrijednost daje jednaku težinsku vrijednost svim klasama. Po toj definiciji makro srednja vrijednost metrike je prikladnija za usporedbu neuravnoteženih skupova podataka. [14].

Vidljiv problem favoriziranja zastupljenije klase CD se mijenja ovisno o uravnoteženosti podataka.

## 6.1. Većinsko glasovanje

Kako je svaka ulazna slika modela jedan od isječaka pojedinog stakalca, nad skupom isječaka koji proizlaze iz istog stakalca može se provesti većinsko glasovanje pojedinih klasifikacija. Svaki zasebni isječak pojedinog stakalca iz skupa za testiranje se klasificira

Kanal segmentacije	prag segmentacije	uravnoteženost podataka	# skinutih gornjih slojeva ekstraktora značajki	macro	micro	CD	UC
gray	0.2	uravnotežen	1	0.509	0.588	0.628	0.391
gray	0.2	uravnotežen	4	0.491	0.572	0.613	0.369
gray	0.2	uravnotežen	8	0.504	0.445	0.416	0.591
gray	0.2	dodatno neuravnotežen	1	0.494	0.705	0.811	0.176
gray	0.2	dodatno neuravnotežen	4	0.506	0.775	0.91	0.102
gray	0.2	dodatno neuravnotežen	8	0.504	<b>0.807</b>	<b>0.958</b>	0.051
gray	0.2	neuravnotežen	1	0.502	0.69	0.784	0.221
gray	0.2	neuravnotežen	4	0.501	0.678	0.767	0.235
gray	0.2	neuravnotežen	8	0.498	0.711	0.818	0.177
H	0.2	uravnotežen	1	0.492	0.468	0.438	0.545
H	0.2	uravnotežen	4	0.5	0.462	0.417	0.583
H	0.2	uravnotežen	8	0.497	0.437	0.362	<b>0.633</b>
H	0.2	dodatno neuravnotežen	1	0.503	0.566	0.643	0.363
H	0.2	dodatno neuravnotežen	4	0.501	0.589	0.697	0.305
H	0.2	dodatno neuravnotežen	8	0.505	0.659	0.847	0.163
H	0.2	neuravnotežen	1	<b>0.52</b>	0.537	0.558	0.481
H	0.2	neuravnotežen	4	0.509	0.537	0.572	0.445
H	0.2	neuravnotežen	8	0.5	0.554	0.621	0.379
S	0.3	uravnotežen	1	0.498	0.562	0.589	0.407
S	0.3	uravnotežen	4	0.487	0.533	0.553	0.421
S	0.3	uravnotežen	8	0.495	0.49	0.487	0.504
S	0.3	dodatno neuravnotežen	1	0.511	0.73	0.823	0.2
S	0.3	dodatno neuravnotežen	4	0.492	0.746	0.856	0.127
S	0.3	dodatno neuravnotežen	8	0.495	0.785	0.91	0.079
S	0.3	neuravnotežen	1	0.515	0.634	0.685	0.345
S	0.3	neuravnotežen	4	0.51	0.631	0.683	0.336
S	0.3	neuravnotežen	8	0.498	0.686	0.767	0.229
S	0.4	uravnotežen	1	0.483	0.516	0.529	0.436
S	0.4	uravnotežen	4	0.5	0.56	0.585	0.415
S	0.4	uravnotežen	8	0.508	0.494	0.489	0.526
S	0.4	dodatno neuravnotežen	1	0.499	0.702	0.787	0.211
S	0.4	dodatno neuravnotežen	4	0.506	0.742	0.841	0.17
S	0.4	dodatno neuravnotežen	8	0.506	0.805	0.931	0.081
S	0.4	neuravnotežen	1	0.515	0.643	0.696	0.335
S	0.4	neuravnotežen	4	0.493	0.645	0.709	0.277
S	0.4	neuravnotežen	8	0.499	0.665	0.735	0.263

Tablica 6.2. Točnost

te se nad tim klasifikacijama provodi glasovanje, klasa s najviše glasova je predviđena klasifikacija tog stakalca. Prednost ovog pristupa je smanjenje utjecaja pojedinih klasifikacija tkiva koji su potencijalno isti u slučaju CD i UC u slučaju kada je tog tkiva malo, no naspram toga u našem slučaju skup podataka za testiranje agregiran nazad na stakalca je vrlo malen i nije pouzdan kao sredstvo usporedbe instanci modela.

Najbolje rezultate dobivaju modeli trenirani na isječcima segmentiranim po S kanalu, no pokazuje se da su za skupove podataka segmentirane po S kanalu oni skupovi koji su uravnoteženi (tj. izvorni) bolji, tablica 6.7.

Kanal segmentacije	prag segmentacije	uravnoteženost podataka	# skinutih gornjih slojeva ekstraktora značajki	precision	recall	F1
gray	0.2	uravnotežen	1	0.506	0.509	0.507
gray	0.2	uravnotežen	4	0.495	0.491	0.493
gray	0.2	uravnotežen	8	0.502	0.504	0.503
gray	0.2	dodatno neuravnotežen	1	0.494	0.494	0.494
gray	0.2	dodatno neuravnotežen	4	0.51	0.506	0.508
gray	0.2	dodatno neuravnotežen	8	0.514	0.504	0.509
gray	0.2	neuravnotežen	1	0.502	0.502	0.502
gray	0.2	neuravnotežen	4	0.501	0.501	0.501
gray	0.2	neuravnotežen	8	0.498	0.498	0.498
H	0.2	uravnotežen	1	0.493	0.492	0.493
H	0.2	uravnotežen	4	0.5	0.5	0.5
H	0.2	uravnotežen	8	0.498	0.497	0.498
H	0.2	dodatno neuravnotežen	1	0.503	0.503	0.503
H	0.2	dodatno neuravnotežen	4	0.501	0.501	0.501
H	0.2	dodatno neuravnotežen	8	0.508	0.505	0.506
H	0.2	neuravnotežen	1	<b>0.516</b>	<b>0.52</b>	<b>0.518</b>
H	0.2	neuravnotežen	4	0.507	0.509	0.508
H	0.2	neuravnotežen	8	0.5	0.5	0.5
S	0.3	uravnotežen	1	0.499	0.498	0.499
S	0.3	uravnotežen	4	0.493	0.487	0.49
S	0.3	uravnotežen	8	0.498	0.495	0.496
S	0.3	dodatno neuravnotežen	1	0.51	0.511	0.511
S	0.3	dodatno neuravnotežen	4	0.491	0.492	0.491
S	0.3	dodatno neuravnotežen	8	0.492	0.495	0.493
S	0.3	neuravnotežen	1	0.509	0.515	0.512
S	0.3	neuravnotežen	4	0.506	0.51	0.508
S	0.3	neuravnotežen	8	0.498	0.498	0.498
S	0.4	uravnotežen	1	0.491	0.483	0.487
S	0.4	uravnotežen	4	0.5	0.5	0.5
S	0.4	uravnotežen	8	0.504	0.508	0.506
S	0.4	dodatno neuravnotežen	1	0.499	0.499	0.499
S	0.4	dodatno neuravnotežen	4	0.505	0.506	0.506
S	0.4	dodatno neuravnotežen	8	0.511	0.506	0.508
S	0.4	neuravnotežen	1	0.509	0.515	0.512
S	0.4	neuravnotežen	4	0.496	0.493	0.494
S	0.4	neuravnotežen	8	0.499	0.499	0.499

Tablica 6.3. Mikro preciznost, odziv i F1

## 6.2. Odabir

Kao glavno mjerilo uspješnosti modela uzeta je točnost većinskog glasovanja, a kao sekundarno mjerilo makro F1 s time da modeli istrenirani na dodatno neuravnoteženom modelu nisu uzeti u obzir. Odabrane su mjere koje predstavljaju sustav vrednovanja u kojemu su na raspolaganju sva stakalca te nema povećane opasnosti pri dijagnozi jedne od bolesti. Odabrani najbolji model je:

- kanal segmentacije: S

Kanal segmentacije	prag segmentacije	uravnoteženost podataka	# skinutih gornjih slojeva ekstraktora značajki	macro	micro	CD	UC
gray	0.2	uravnotežen	1	0.506	0.588	0.837	0.174
gray	0.2	uravnotežen	4	0.495	0.572	0.829	0.161
gray	0.2	uravnotežen	8	0.502	0.445	0.835	0.169
gray	0.2	dodatno neuravnotežen	1	0.494	0.705	0.831	0.158
gray	0.2	dodatno neuravnotežen	4	0.51	0.775	0.835	0.185
gray	0.2	dodatno neuravnotežen	8	0.514	<b>0.807</b>	0.834	0.194
gray	0.2	neuravnotežen	1	0.502	0.69	0.834	0.17
gray	0.2	neuravnotežen	4	0.501	0.678	0.833	0.168
gray	0.2	neuravnotežen	8	0.498	0.711	0.832	0.164
H	0.2	uravnotežen	1	0.493	0.468	0.718	0.269
H	0.2	uravnotežen	4	0.5	0.462	0.725	0.275
H	0.2	uravnotežen	8	0.498	0.437	0.723	0.273
H	0.2	dodatno neuravnotežen	1	0.503	0.566	0.727	0.278
H	0.2	dodatno neuravnotežen	4	0.501	0.589	0.726	0.276
H	0.2	dodatno neuravnotežen	8	0.508	0.659	0.728	0.288
H	0.2	neuravnotežen	1	<b>0.516</b>	0.537	0.74	<b>0.292</b>
H	0.2	neuravnotežen	4	0.507	0.537	0.732	0.282
H	0.2	neuravnotežen	8	0.5	0.554	0.725	0.274
S	0.3	uravnotežen	1	0.499	0.562	0.849	0.149
S	0.3	uravnotežen	4	0.493	0.533	0.844	0.143
S	0.3	uravnotežen	8	0.498	0.49	0.847	0.148
S	0.3	dodatno neuravnotežen	1	0.51	0.73	0.853	0.166
S	0.3	dodatno neuravnotežen	4	0.491	0.746	0.847	0.135
S	0.3	dodatno neuravnotežen	8	0.492	0.785	0.848	0.135
S	0.3	neuravnotežen	1	0.509	0.634	0.855	0.162
S	0.3	neuravnotežen	4	0.506	0.631	0.853	0.159
S	0.3	neuravnotežen	8	0.498	0.686	0.849	0.148
S	0.4	uravnotežen	1	0.491	0.516	0.844	0.138
S	0.4	uravnotežen	4	0.5	0.56	0.852	0.148
S	0.4	uravnotežen	8	0.504	0.494	0.856	0.152
S	0.4	dodatno neuravnotežen	1	0.499	0.702	0.852	0.147
S	0.4	dodatno neuravnotežen	4	0.505	0.742	0.854	0.157
S	0.4	dodatno neuravnotežen	8	0.511	0.805	0.854	0.169
S	0.4	neuravnotežen	1	0.509	0.643	<b>0.858</b>	0.16
S	0.4	neuravnotežen	4	0.496	0.645	0.849	0.142
S	0.4	neuravnotežen	8	0.499	0.665	0.852	0.147

Tablica 6.4. Preciznost

- prag segmentacije 0.4
- uravnoteženost podataka: neuravnotežen
- broj skinutih slojeva ekstraktora značajki: 1

stoga što ima 100% točnost na skupu za testiranje te najviši makro F1.

U slučaju drugačijeg sustava vrednovanja, stručnjak (liječnik) na raspolaganju ima tablice 6.1., 6.2., 6.3., 6.4., 6.5., 6.6., 6.7.

Kanal segmentacije	prag segmentacije	uravnoteženost podataka	# skinutih gornjih slojeva ekstraktora značajki	macro	micro	CD	UC
gray	0.2	uravnotežen	1	0.509	0.588	0.628	0.391
gray	0.2	uravnotežen	4	0.491	0.572	0.613	0.369
gray	0.2	uravnotežen	8	0.504	0.445	0.416	0.591
gray	0.2	dodatno neuravnotežen	1	0.494	0.705	0.811	0.176
gray	0.2	dodatno neuravnotežen	4	0.506	0.775	0.91	0.102
gray	0.2	dodatno neuravnotežen	8	0.504	<b>0.807</b>	<b>0.958</b>	0.051
gray	0.2	neuravnotežen	1	0.502	0.69	0.784	0.221
gray	0.2	neuravnotežen	4	0.501	0.678	0.767	0.235
gray	0.2	neuravnotežen	8	0.498	0.711	0.818	0.177
H	0.2	uravnotežen	1	0.492	0.468	0.438	0.545
H	0.2	uravnotežen	4	0.5	0.462	0.417	0.583
H	0.2	uravnotežen	8	0.497	0.437	0.362	<b>0.633</b>
H	0.2	dodatno neuravnotežen	1	0.503	0.566	0.643	0.363
H	0.2	dodatno neuravnotežen	4	0.501	0.589	0.697	0.305
H	0.2	dodatno neuravnotežen	8	0.505	0.659	0.847	0.163
H	0.2	neuravnotežen	1	<b>0.52</b>	0.537	0.558	0.481
H	0.2	neuravnotežen	4	0.509	0.537	0.572	0.445
H	0.2	neuravnotežen	8	0.5	0.554	0.621	0.379
S	0.3	uravnotežen	1	0.498	0.562	0.589	0.407
S	0.3	uravnotežen	4	0.487	0.533	0.553	0.421
S	0.3	uravnotežen	8	0.495	0.49	0.487	0.504
S	0.3	dodatno neuravnotežen	1	0.511	0.73	0.823	0.2
S	0.3	dodatno neuravnotežen	4	0.492	0.746	0.856	0.127
S	0.3	dodatno neuravnotežen	8	0.495	0.785	0.91	0.079
S	0.3	neuravnotežen	1	0.515	0.634	0.685	0.345
S	0.3	neuravnotežen	4	0.51	0.631	0.683	0.336
S	0.3	neuravnotežen	8	0.498	0.686	0.767	0.229
S	0.4	uravnotežen	1	0.483	0.516	0.529	0.436
S	0.4	uravnotežen	4	0.5	0.56	0.585	0.415
S	0.4	uravnotežen	8	0.508	0.494	0.489	0.526
S	0.4	dodatno neuravnotežen	1	0.499	0.702	0.787	0.211
S	0.4	dodatno neuravnotežen	4	0.506	0.742	0.841	0.17
S	0.4	dodatno neuravnotežen	8	0.506	0.805	0.931	0.081
S	0.4	neuravnotežen	1	0.515	0.643	0.696	0.335
S	0.4	neuravnotežen	4	0.493	0.645	0.709	0.277
S	0.4	neuravnotežen	8	0.499	0.665	0.735	0.263

Tablica 6.5. Odziv

Kanal segmentacije	prag segmentacije	uravnoteženost podataka	# skinutih gornjih slojeva ekstraktora značajki	macro	micro	CD	UC
gray	0.2	uravnotežen	1	0.479	0.588	0.718	0.241
gray	0.2	uravnotežen	4	0.464	0.572	0.705	0.224
gray	0.2	uravnotežen	8	0.409	0.445	0.555	0.263
gray	0.2	dodatno neuravnotežen	1	0.494	0.705	0.821	0.166
gray	0.2	dodatno neuravnotežen	4	0.501	0.775	0.871	0.132
gray	0.2	dodatno neuravnotežen	8	0.486	<b>0.807</b>	<b>0.892</b>	0.08
gray	0.2	neuravnotežen	1	0.5	0.69	0.808	0.192
gray	0.2	neuravnotežen	4	0.497	0.678	0.799	0.196
gray	0.2	neuravnotežen	8	0.498	0.711	0.825	0.17
H	0.2	uravnotežen	1	0.452	0.468	0.544	0.36
H	0.2	uravnotežen	4	0.451	0.462	0.529	0.373
H	0.2	uravnotežen	8	0.432	0.437	0.483	<b>0.381</b>
H	0.2	dodatno neuravnotežen	1	0.499	0.566	0.683	0.315
H	0.2	dodatno neuravnotežen	4	0.5	0.589	0.711	0.29
H	0.2	dodatno neuravnotežen	8	0.496	0.659	0.783	0.208
H	0.2	neuravnotežen	1	0.5	0.537	0.636	0.363
H	0.2	neuravnotežen	4	0.494	0.537	0.642	0.346
H	0.2	neuravnotežen	8	0.494	0.554	0.669	0.318
S	0.3	uravnotežen	1	0.457	0.562	0.696	0.219
S	0.3	uravnotežen	4	0.441	0.533	0.668	0.213
S	0.3	uravnotežen	8	0.424	0.49	0.619	0.229
S	0.3	dodatno neuravnotežen	1	<b>0.51</b>	0.73	0.838	0.182
S	0.3	dodatno neuravnotežen	4	0.491	0.746	0.851	0.131
S	0.3	dodatno neuravnotežen	8	0.489	0.785	0.878	0.1
S	0.3	neuravnotežen	1	0.491	0.634	0.761	0.22
S	0.3	neuravnotežen	4	0.487	0.631	0.759	0.215
S	0.3	neuravnotežen	8	0.493	0.686	0.806	0.18
S	0.4	uravnotežen	1	0.43	0.516	0.651	0.21
S	0.4	uravnotežen	4	0.456	0.56	0.694	0.218
S	0.4	uravnotežen	8	0.429	0.494	0.622	0.236
S	0.4	dodatno neuravnotežen	1	0.496	0.702	0.818	0.173
S	0.4	dodatno neuravnotežen	4	0.505	0.742	0.847	0.163
S	0.4	dodatno neuravnotežen	8	0.5	0.805	0.89	0.109
S	0.4	neuravnotežen	1	0.493	0.643	0.769	0.217
S	0.4	neuravnotežen	4	0.48	0.645	0.773	0.188
S	0.4	neuravnotežen	8	0.489	0.665	0.789	0.189

Tablica 6.6. F1



Kanal segmentacije	prag segmentacije	uravnoteženost podataka	# skinutih gornjih slojeva ekstraktora značajki	točnost glasovanja	makro točnost po stakalcu
gray	0.2	uravnotežen	1	0.714	0.639
gray	0.2	uravnotežen	4	0.857	0.659
gray	0.2	uravnotežen	8	0.714	0.577
gray	0.2	dodatno neuravnotežen	1	0.714	0.724
gray	0.2	dodatno neuravnotežen	4	0.714	0.731
gray	0.2	dodatno neuravnotežen	8	0.714	0.745
gray	0.2	neuravnotežen	1	0.714	0.711
gray	0.2	neuravnotežen	4	0.714	0.703
gray	0.2	neuravnotežen	8	0.714	0.76
H	0.2	uravnotežen	1	0.6	0.579
H	0.2	uravnotežen	4	0.6	0.527
H	0.2	uravnotežen	8	0.6	0.517
H	0.2	dodatno neuravnotežen	1	0.6	0.616
H	0.2	dodatno neuravnotežen	4	0.6	0.607
H	0.2	dodatno neuravnotežen	8	0.8	0.672
H	0.2	neuravnotežen	1	0.4	0.612
H	0.2	neuravnotežen	4	0.4	0.57
H	0.2	neuravnotežen	8	0.4	0.592
S	0.3	uravnotežen	1	1.0	0.708
S	0.3	uravnotežen	4	0.857	0.669
S	0.3	uravnotežen	8	0.714	0.681
S	0.3	dodatno neuravnotežen	1	0.714	0.735
S	0.3	dodatno neuravnotežen	4	0.714	0.735
S	0.3	dodatno neuravnotežen	8	0.714	0.758
S	0.3	neuravnotežen	1	1.0	0.736
S	0.3	neuravnotežen	4	1.0	0.722
S	0.3	neuravnotežen	8	0.857	0.755
S	0.4	uravnotežen	1	0.714	0.682
S	0.4	uravnotežen	4	1.0	0.688
S	0.4	uravnotežen	8	0.714	0.688
S	0.4	dodatno neuravnotežen	1	0.857	0.73
S	0.4	dodatno neuravnotežen	4	0.714	0.746
S	0.4	dodatno neuravnotežen	8	0.714	0.749
S	0.4	neuravnotežen	1	1.0	0.732
S	0.4	neuravnotežen	4	0.857	0.73
S	0.4	neuravnotežen	8	0.857	<b>0.777</b>

Tablica 6.7. Većinsko glasovanje

## 7. Zaključak

S malim i neuravnoteženim skupom podataka teško je donositi odluke o samoj arhitekturi sustava za dijagnozu bolesti. Najbolje rezultate za odabrane metrike (većinsko glasovanje i F1) daje model istreniran na skupu podataka segmentiranom po S kanalu HSV modela boja pri pragu segmentacije 0.4, bez uravnotežavanja klasa te s minimalnim brojem skinutih slojeva ekstraktora značajki. Interpretacija autora je da se segmentacijom po S kanalu i visokim pragom segmentacije odvaja tkivo od bijele pozadine i ignoriraju zakrpe koje sadrže manji broj tkiva s čime se smanjuje prisutnost šuma, a s zadržavanjem viših slojeva ekstraktora značajki prošireni model barata s kompleksnijim značajkama. S uravnoteženjem klasa poboljšavaju se metrike te klase, no mikro metrike opadaju.

Bolji rezultati bi se potencijalno mogli dobiti dodavanjem novih potpuno povezanih unaprijednih slojeva, te pročišćavanjem skupova podataka od šumovitih zakrpa.

Idući koraci za poboljšanje kvalitete sustava bi svakako bili proširivanje skupa podataka kako bi učenje i zaključivanje bilo značajnije te konzultacija s gastroenterolozima koji bi pobliže opisali proces donošenja dijagnoze te rizike krive dijagnoze što bi pomoglo u definiranju ciljnih metrika te kvalitetnijoj usporedbi sustava dijagnoza. Autor sumnja da su metrike na zakrpama loše, dok je većinsko glasovanje dobro jer možda nisu svi dijelovi tkiva zaraženi, no sumnju treba potvrditi u konzultaciji s gastroenterolozima. Ako je pretpostavka točna skup podataka s označenim lokacijama i klasifikacijama pojedinih dijelova tkiva bi znatno pospješio metrike modela te potencijalno smanjio vjerojatnost davanja dijagnoze zdravom pacijentu.

## Literatura

- [1] K. Geboes, “Histopathology of crohn’s disease and ulcerative colitis”, *Inflammatory bowel disease*, sv. 4, str. 210–28, 2003.
- [2] OpenSlide, “Hamamatsu format”, <https://openslide.org/formats/hamamatsu/>, [mrežno; stranica posjećena: siječanj 2024.].
- [3] E. Gomede, “Exploring Dataset Splitting Strategies: Techniques and Implementations in Python with Synthetic Data”, <https://medium.com/@evertongomede/exploring-dataset-splitting-strategies-techniques-and-implementations-in-python-with-synthetic-515ddacb5c1c>, [mrežno; stranica posjećena: siječanj 2024.].
- [4] F. Hrabar, “Poboljšanje rezultata detekcije kroz variranje izgleda objekta”, završni rad, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, 2021., <https://urn.nsk.hr/urn:nbn:hr:168:627479>.
- [5] B. Dickson, “What are artificial neural networks (ANN)?” <https://bdtechtalks.com/2019/08/05/what-is-artificial-neural-network-ann/>, [mrežno; stranica posjećena: siječanj 2024.].
- [6] S. Saha, “A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way”, <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>, [mrežno; stranica posjećena: siječanj 2024.].
- [7] DeepAI, “Feature Extraction”, <https://deepai.org/machine-learning-glossary-and-terms/feature-extraction>, [mrežno; stranica posjećena: siječanj 2024.].

- [8] M. Tan i Q. Le, “Efficientnet: Rethinking model scaling for convolutional neural networks”, u *International Conference on Machine Learning, 2019*, 2019. <https://doi.org/10.48550/arXiv.1905.11946>
- [9] P.-S. Liao, T.-S. Chen, i P.-C. Chung, “A fast algorithm for multilevel thresholding”, str. 713–727, rujan 2001. <https://doi.org/10.6688/JISE.2001.17.5.1>
- [10] scikit-image, “Multi-Otsu Thresholding”, [https://scikit-image.org/docs/stable/auto\\_examples/segmentation/plot\\_multiotsu.html](https://scikit-image.org/docs/stable/auto_examples/segmentation/plot_multiotsu.html), [mrežno; stranica posjećena: siječanj 2024.].
- [11] scikit image, “RGB to grayscale”, [https://scikit-image.org/docs/stable/auto\\_examples/color\\_exposure/plot\\_rgb\\_to\\_gray.html](https://scikit-image.org/docs/stable/auto_examples/color_exposure/plot_rgb_to_gray.html), [mrežno; stranica posjećena: siječanj 2024.].
- [12] PyTorch, “BCELoss”, <https://pytorch.org/docs/stable/generated/torch.nn.BCELoss.html>, [mrežno; stranica posjećena: siječanj 2024.].
- [13] J. Brownlee, “A Gentle Introduction to Imbalanced Classification”, <https://machinelearningmastery.com/what-is-imbalanced-classification/>, [mrežno; stranica posjećena: siječanj 2024.].
- [14] educative, “What is the difference between micro and macro averaging?” <https://www.educative.io/answers/what-is-the-difference-between-micro-and-macro-averaging>, [mrežno; stranica posjećena: siječanj 2024.].

# Sažetak

## Klasifikacija histoloških snimaka crijeva

Fran Hrabar

Tema ovog rada je klasifikacija Crohnove bolesti ili ulceroznog kolitisa na temelju histoloških snimki crijeva pomoću dubokih neuronskih mreža. Rad objašnjava postupak predobrade malog, visokodimenzionalnog i neuravnoteženog skupa podataka kao što su segmentacija i razlamanja snimki na zakrpe radi smanjenja dimenzija ulaza, očuvanja detalja, eliminacije šuma te povećanja primjeraka u skupu podataka te uravnotežavanje skupa podataka i podjelu skupa podataka na skup za treniranje i testiranje. Opisuju se arhitektura modela, proces treniranja i evaluacije modela na temelju odabranih metrika. Metrike pokrivaju razne zahtjeve koje bi liječnik mogao imati pri evaluaciji modela te dopušta stručnjaku da odabere najuspješniji model.

**Ključne riječi:** umjetna inteligencija; strojno učenje; duboko učenje; računalni vid; umjetne neuronske mreže; duboke neuronske mreže; konvolucijske neuronske mreže; klasifikacija; segmentacija slike; nadzirano učenje; histološke snimke; upalne bolesti crijeva; Crohnova bolest; ulcerozni kolitis; tehnologija u medicini; računalno potpomognuta dijagnostika;

# Abstract

## Classification of Histological Images of the Intestine

Fran Hrabar

The topic of this paper is the classification of Crohn's disease or ulcerative colitis based on histological images of the intestine using deep neural networks. The paper explains the preprocessing procedure of a small, high-dimensional and imbalanced dataset, such as segmentation and splitting of recordings into patches in order to reduce input dimensions, preserve details, eliminate noise and increase the number of samples in the data set, as well as balancing the data set and dividing the data set into training and testing sets. The architecture of the model, the process of training and evaluation of the model based on selected metrics are described. The metrics cover the various requirements a physician might have when evaluating a model and allow the practitioner to select the most successful model.

**Keywords:** artificial Intelligence; machine learning; deep learning; computer vision; artificial neural networks; deep neural networks; convolutional neural networks; classification; image segmentation; supervised learning; histological recordings; inflammatory bowel diseases; Crohn's disease; ulcerative colitis; technology in medicine; computer-aided diagnostics;