



UNIVERZITET U NOVOM SADU  
FAKULTET TEHNIČKIH  
NAUKA U NOVOM SADU

---



Marko Arsenović

**DETEKCIJA BOLESTI BILJAKA TEHNIKAMA  
DUBOKOG UČENJA**

DOKTORSKA DISERTACIJA

Mentor:

Prof. dr Srđan Sladojević

Novi Sad,  
2020.



## КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА

Редни број, РБР:		
Идентификациони број, ИБР:		
Тип документације, ТД:	Монографска публикација	
Тип записа, ТЗ:	Текстуални штампани материјал	
Врста рада, ВР:	Докторска дисертација	
Аутор, АУ:	Марко Арсеновић, дипл. инж.	
Ментор, МН:	Др Срђан Сладојевић, ванредни професор	
Наслов рада, НР:	Детекција болести биљака техникама дубоког учења	
Језик публикације, ЈП:	Српски	
Језик извода, ЈИ:	Српски/Енглески	
Земља публиковања, ЗП:	Република Србија	
Уже географско подручје, УГП:		
Година, ГО:	2020.	
Издавач, ИЗ:	Ауторски репрント	
Место и адреса, МА:	Нови Сад, Трг Доситеја Обрадовића 6	
Физички опис рада, ФО: (поглавља/страница/ цитата/табела/слика/графика/прилога)	8/113/144/11/44/0/0	
Научна област, НО:	Индустријско инжењерство и инжењерски менаџмент	
Научна дисциплина, НД:	Информационо-комуникациони системи	
Предметна одредница/Кључне речи, ПО:	Дубоко учење, конволуцијске неуронске мреже, класификација, детекција објекта	
УДК		
Чува се, ЧУ:	Библиотека Факултета техничких наука, Нови Сад	
Важна напомена, ВН:		
Извод, ИЗ:	Истраживања представљена у дисертацији имала су за циљ развој нове методе базиране на дубоким конволуцијским неуронским мрежама у циљу детекције болести биљака на основу слике листа. У оквиру експерименталног дела рада приказани су досадашњи литературно доступни приступи у аутоматској детекцији болести биљака као и ограничења овако добијених модела када се користе у природним условима. У оквиру дисертације уведена је нова база слика листова, тренутно највећа по броју слика у поређењу са јавно доступним базама, потврђени су нови приступи аугментације базирани на ГАН архитектури над сликама листова уз нови специјализовани дво-корачни приступ као потенцијални одговор на недостатке постојећих решења.	
Датум прихватања теме, ДП:	31.01.2019.	
Датум одбране, ДО:		
Чланови комисије, КО:	Председник: Др Дарко Стефановић, ванредни професор	
Члан:	Др Андраш Андерла, ванредни професор	
Члан:	Др Драгослав Иванишевић, ванредни професор	Потпис ментора
Члан:	Др Александар Ракић, ванредни професор	
Члан, ментор:	Др Срђан Сладојевић, ванредни професор	



## KEY WORDS DOCUMENTATION

Accession number, <b>ANO:</b>		
Identification number, <b>INO:</b>		
Document type, <b>DT:</b>	Monographic publication	
Type of record, <b>TR:</b>	Textual material, printed	
Contents code, <b>CC:</b>	Doctoral Thesis	
Author, <b>AU:</b>	Marko Arsenović, master of sciences	
Mentor, <b>MN:</b>	Dr Srđan Sladojević, associate professor	
Title, <b>TI:</b>	Plant disease detections using deep learning techniques	
Language of text, <b>LT:</b>	Serbian	
Language of abstract, <b>LA:</b>	Serbian/English	
Country of publication, <b>CP:</b>	Republic of Serbia	
Locality of publication, <b>LP:</b>	AP Vojvodina	
Publication year, <b>PY:</b>	2020.	
Publisher, <b>PB:</b>	Authors reprint	
Publication place, <b>PP:</b>	Novi Sad, Serbia	
Physical description, <b>PD:</b> (chapters/pages/ref./tables/pictures/graphs/appendices)	8/113/144/11/44/0/0	
Scientific field, <b>SF:</b>	Industrial Engineering and Engineering Management	
Scientific discipline, <b>SD:</b>	Information and Communication Systems	
Subject/Key words, <b>S/KW:</b>	Deep learning, convolutional neural networks, classification, object detection	
<b>UC</b>		
Holding data, <b>HD:</b>	Library of the Faculty of Technical Sciences	
<b>Note, N:</b>		
Abstract, <b>AB:</b>	The research presented in this thesis was aimed at developing a novel method based on deep convolutional neural networks for automated plant disease detection. Based on current available literature, specialized two-phased deep neural network method introduced in the experimental part of thesis solves the limitations of state-of-the-art plant disease detection methods and provides the possibility for a practical usage of the newly developed model. In addition, a new dataset was introduced, that has more images of leaves than other publicly available datasets, also GAN based augmentation approach on leaves images is experimentally confirmed.	
Accepted by the Scientific Board on, <b>ASB:</b>	31.01.2019.	
Defended on, <b>DE:</b>		
Defended Board, <b>DB:</b>	President:	Dr Darko Stefanović, associate professor
	Member:	Dr Andraš Anderla, associate professor
	Member:	Dr Dragoslav Ivanišević, associate professor
	Member:	Dr Aleksandar Rakić, associate professor
Member, Mentor:	Dr Srđan Sladojević, associate professor	Menthor's sign

## **Zahvalnica**

Zahvaljujem se svom mentoru na usmeravanju, korisnim sugestijama i poverenju tokom izrade doktorske disertacije.

Rezultati prikazani u doktorskoj disertaciji proistekli su iz istraživanja koristeći resurse koje je omogućila kompanija Panonit d.o.o. iz Novog Sada.

---

# SADRŽAJ

SPISAK KORIŠĆENIH SKRAĆENICA.....	i
POPIS SLIKA .....	iii
POPIS TABELA .....	vi
Rezime .....	vii
Abstract .....	ix
1. Uvod.....	1
2. Problem i cilj istraživanja .....	6
2. 1 Osnovne postavke .....	6
2. 2 Cilj istraživanja .....	9
3. Teorijske osnove .....	11
3.1 Prepoznavanje obrazaca .....	11
3.1.1 Sistemi za automatsko prepoznavanje obrazaca.....	11
3.2 Veštačka inteligencija.....	14
3.3 Mašinsko učenje .....	16
3.3.1 Kratak istorijat mašinskog učenja .....	17
3.3.2 Tipovi mašinskog učenja.....	21
3.4 Neuronske mreže.....	23
3.4.1 Perceptron .....	23

3.4.2 Višeslojni perceptron .....	26
3.5 Duboko učenje .....	27
3.5.1 Konvolucijske neuronske mreže .....	28
3.5.2 Pregled savremenih arhitektura .....	35
3.5.3 Detekcija objekata .....	40
3.5.4 GAN .....	46
4. Pregled relevantne literature .....	48
5. Prikaz metodologije istraživanja .....	58
5.1 Baze slika.....	58
5.1.1 PlantVillage .....	58
5.1.2 PlantDisease.....	61
5.2 Metode obrade podataka .....	65
5.2.1 Standardna augmentacija .....	66
5.2.2 Generisanje sintetičkih slika neuronskim mrežama .....	69
5.3 Klasifikacija .....	75
5.4 Detekcija objekata.....	77
5.5 PlantDiseaseNet arhitektura .....	79
6. Rezultati i analiza istraživanja .....	83
6.1 Klasifikacija .....	83
6.2 Detekcija objekata.....	92
6.3 PlantDiseaseNet arhitektura .....	95

7. Zaključak i pravci daljih istraživanja.....	97
Literatura .....	100

## SPISAK KORIŠĆENIH SKRAĆENICA

IPC - Integrisana kontrola štetočina (eng. *Integrated Pest Control*)

ML – Mašinsko učenje (eng. *Machine Learning*)

CNN – Konvolucijska neuronska mreža (eng. *Convolutional Neural Network*)

IoT - Internet stvari (eng. *Internet of Things*)

DSS - Sistemi za podršku u donošenju odluka (eng. *Decision Support System*)

AI - Veštačka inteligencija (eng. *Artificial Intelligence*)

b – Prag (eng. *bias*)

w – Težine (eng. *weights*)

Conv – Konvolucijski sloj

Pool – Sloj sažimanja

FC – Potpuno povezani sloj

P, p – Dopuna (eng. *Padding*)

S, s – Korak (eng. *Stride*)

D – Dimenzija konvolucijskog sloja

F – Širina filtera

ReLU – ispravljena linearna funkcija (eng. *Rectified Linear Unit Layer*)

R-CNN – tip arhitekture konvolucijske neuronske mreže (eng. *Region-based Convolutional Network*)

SVM – Metoda potpornih vektora (eng. *Support Vector Machine*)

RPN – Tip arhitekture neuronske mreže (eng. *Region Proposal Network*)

YOLO – Tip arhitekture konvolucijske neuronske mreže (eng. *You Only Look Once*)

Mask R-CNN – Tip arhitekture konvolucijske neuronske mreže (eng. *Mask Region-based Convolutional Network*)

GAN – Tip arhitekture duboke neuronske mreže (eng. *Generative Adversial Networks*)

mAP - Srednja prosečna preciznost (eng. *mean Average Precision* - mAP)

IoU - Presek iznad unije (eng. *Intersection over Union* - IoU)

## POPIS SLIKA

3.1 Primer 4 objekta predstavljeni u dvodimenzionalnom prostoru odlika .....	13
3.2 Koraci u automatskom sistemu za prepoznavanje obrazaca.....	13
3.3 Tipovi klasifikovanja veštačke inteligencije .....	14
3.4 Uopšteni pregled polja unutar oblasti veštačke inteligencije .....	16
3.5 Prikaz perceptron modela.....	18
3.6 Tipovi algoritama mašinskog učenja.....	22
3.7 Neuron a) biološki neuron i b) Model neurona kod veštačkih neuronskih mreža .....	23
3.8 Aktivacione funkcije: a) linearna, b) koračna, c) rampa, d) sigmoidna, e) hiperbolična tangentna i f) Gausova funckija .....	25
3.9 Jednoslojna neuronska mreža .....	26
3.10 Višeslojni perceptron .....	26
3.11 Standardni slojevi konvolucijske neuronske mreže .....	29
3.12 Konvolucija filtera (kernela K) i ulaznog sloja I .....	30
3.13 Mape odlika kao rezultat konvolucijskog sloja .....	30
3.14 Konvolucija sa dopunom 0 piksela .....	31
3.15 Primer arhitekture i dimenzije slojeva na osnovu izabranih hiper-parametara.....	32

---

3.16 Varijacije ReLU aktivacione funkcije .....	33
3.17 Sažimanje maksimalnom vrednošću .....	34
3.18 ImageNet ILSVRC takmičenje .....	35
3.19 AlexNet arhitektura .....	36
3.20 VGG-16 arhitektura .....	37
3.21 "Inception" jedinica a) osnovna verzija i b) sa redukovanim dimenzijama ....	38
3.22 Razlika između a) standardnog i b) rezidualnog bloka neuronske mreže.....	40
3.23 Uopšteni prikaz rada R-CNN algoritma.....	42
3.24 Uopšteni prikaz rada Fast R-CNN algoritma.....	43
3.25 Uopšteni prikaz rada Faster R-CNN algoritma .....	44
3.26 YOLO arhitektura.....	45
3.27 SSD arhitektura .....	46
3.28 Uopšteni prikaz rada GAN arhitekture .....	47
5.1 Primeri po klasama iz PlantVillage baze slika.....	60
5.2 Primer slika iz PlantDisease baze slika .....	62
5.3 Neke od standardnih tehnika augmentacije (originalna slika – gore levo, rotacija za 270°- gore desno, okretanje u ogledalu – dole levo, promena perspektive – dole desno) .....	67
5.4 Rotacija za 37° i menjanje granica slike .....	68
5.5 DC GAN generisane sintetičke slike, 64x64 generisane slike .....	70
5.6 Style GAN kriva učenja.....	72
5.7 Style GAN trening faza generisanja slika kroz epohe .....	73

---

5.8 Style GAN generisane sintetičke slike, 256x256 generisane slike.....	74
5.9 Style GAN vizuelizacija odlika .....	75
5.10 PlantDiseaseNet arhitektura .....	80
5.11 Ilustracija detekcije lista YOLO tehnikom a) mreža ćelija, b) mapa klasnih predikcija i c) finalna detekcija .....	81
6.1 Treniranje savremenih klasifikacionih arhitektura konvolucijskih neuronskih mreža nad PlantVillage bazom slika .....	84
6.2 Style GAN nad slikama listova sa kompleksnom pozadinom .....	88
6.3 Vizuelizacija naučenih odlika: tehnika okluzije.....	90
6.4 Vizuelizacija naučenih odlika: tehnika mapa vidljivosti .....	91
6.5 Faster R-CNN sa TDM detekcijom nad PlantDisease bazom slika	
a) više objekata iste klase na jednoj slici bez fokusa i	
b) jedan objekat u fokusu na slici.....	94

## POPIS TABELA

4.1 Poređenje pristupa baziranog na dubokom učenju za detekciju bolesti biljaka.....	55
4.2 Ograničenja trenutnih pristupa baziranih na dubokom učenju za detekciju bolesti biljaka.....	56
5.1 PlantVillage baza slika po klasama .....	59
5.2 PlantDisease baza slika .....	63
5.3 Hardverske i softverske karakteristike računara korišćenog u eksperimentalnom radu .....	82
6.1 Performanse modela treniranih nad PlantVillage bazom slika (sa standardnom augmentacijom) i testiranih nad PlantDisease bazom slika.....	85
6.2 Performanse modela treniranih nad slikama iz PlantVillage i PlantDisease baze slika (sa standardnom augmentacijom) i testiranih nad PlantDisease bazom slika .....	86
6.3 Performanse modela treniranih nad slikama iz PlantVillage i PlantDisease baze slika (sa GAN augmentacijom) i testiranih nad PlantDisease bazom slika.....	87
6.4 Performanse modela za detekciju objekata treniranih i testiranih nad PlantDisease bazom slika .....	92
6.5 PlantDiseaseNet tačnost modela .....	95
6.6 Detekcija lista korišćenjem savremenih arhitekturalnih pristupa za detekciju objekta (PlantDisease baza slika) .....	96

## REZIME

Povećanje populacije uvodi dodatnu potrebu za resursima vode i hrane. U skladu sa time, poljoprivredna industrija u razvijenom delu sveta ušla je u eru "precizne poljoprivrede" sa osnovnim ciljem povećanja prinosa uz zaštitu okoline. Uzevši u obzir aktivne klimatske promene, razvijeni transport i brojne druge faktore, rasprostranjenost i ozbiljnost biljnih bolesti predstavlja veliki izazov ovoj industriji.

Veliki broj bolesti se vizuelno manifestuje na samoj biljci još u ranim fazama, što omogućuje identifikovanje same bolesti ispitivanjem "golim okom". Automatska detekcija bolesti biljaka na osnovu vidljivih simptoma omogućila bi ekonomično kontinualno praćenje useva što bi za posledicu imalo rano identifikovanje bolesti uz pravilno tretiranje. Iz tog razloga, veliki broj radova istražio je mogućnost primene algoritama mašinskog učenja radi klasifikacije i detekcije bolesti biljaka na osnovu slika listova. Veliki broj istraživača, motivisan trenutnim dostignućima dubokih neuronskih mreža u okviru širokog skupa problema u kompjuterskoj viziji, istražio je mogućnost primene konvolucijskih neuronskih mreža za problem klasifikacije i detekcije bolesti biljaka.

Iako je veliki broj istraživačkih radova prikazao uspešnost korišćenja dubokih konvolucijskih neuronskih mreža za rešavanje ovog problema i dalje postoje velika ograničenja tih pristupa kada se razvijeni klasifikacioni i detekcioni modeli koriste u praksi, u okviru realnih uslova. Jedan od primarnih razloga zašto postoji veliki jaz u performansama predstavljenih modela jeste nedostatak javno dostupnih slika iz prirodnog okruženja uz činjenicu da su razvijeni modeli najčešće bazirani na generalnim arhitekturama dubokih konvolucijskih mreža sa minimalnim promenama u strukturi, koji su samo pretrenirane nad slikama listova, prethodno preprocesirane da

odgovaraju parametrima i samoj arhitekturi mreže uz standardne tehnike augmentacije slika.

Cilj istraživanja doktorske disertacije predstavlja razvoj nove specijalizovane arhitekture za detekciju bolesti biljaka koja će smanjiti razliku u performansama detekcionog modela upoređujući rezultate nad slikama dobijenih u okviru eksperimentalnog (kontrolisanog) i u okviru prirodnog okruženja. Iz tog razloga, eksperimentalno su prikazana ograničenja dosadašnjih literaturno dostupnih pristupa. Novi specijalizvani dvo-koračni pristup, *PlantDiseaseNet*, predstavljen u ovoj disertaciji daje potencijani odgovor na nedostatke postojećih rešenja prilikom korišćenja nad slikama fotografisanim u okviru prirodnog okruženja.

Za potrebe eksperimentalnih istraživanja napravljena je nova baza slika listova, *PlantDisease*. Ova baza slika sačinjena je od oko 80 hiljada slika listova (zdravih i obolelih), grupisanih u okviru 42 klase od 12 vrsta biljaka. Slike su fotografisane u prirodnom okruženju pod različitim uslovima, što daje mogućnost ispitivanja ograničenja trenutnih pristupa u praktičnim uslovima ali i mogućnost izrade modela koji će uzeti u obzir odlike koje se potencijalno ne nalaze u eksperimentalnom prostoru podataka.

U okviru ove disertacije, takođe istražene su mogućnosti korišćenja standardnih ali i novih pristupa u augmentaciji slika listova - korišćenjem GAN modela radi dobijanja sintetičkih slika listova i prikazana su trenutna ograničenja ovog pristupa što daje nova usmerenja u toku budućeg istraživanja iz ove oblasti.

Razvijeni finalni model istrenirane *PlantDiseaseNet* arhitekture ima top-1 tačnost od 93.67% nad *PlantDisease* bazom slika. Ovako dobijeni model mogao bi se potencijalno koristiti u okviru informacionog sistema kao podrška za automatsko detektovanje bolesti biljaka.

**Ključne reči:** konvolucijske neuronske mreže, duboko učenje, klasifikacija slika, detekcija bolesti biljaka

## ABSTRACT

Rapid growth in human population brings the extra need for water and food supplies. Due to that, agricultural industry entered the era of precise agriculture with the primary focus on increasing yield but also reducing effects on environment itself. Taking into account climate changes along with the fact that places are more connected than ever before, plant diseases spreads faster and present a great challenge to the agricultural industry.

Numerous diseases show visual symptoms in early phases which provides possibility for “naked eye” examination. Automatic plant disease detection based on visual features could be financially beneficial in continuous yield monitoring process which could raise an opportunity for early disease identification along with proper treatment at early phase. Base on all of that, many researchers have worked on plant disease detection tasks based on machine learning algorithms. Due to the recent advances in deep learning methods and their state-of-the-art performances in wide range of computer vision’s tasks, many researchers have been motivated to use deep convolutional neural networks for solving plant diseases detection tasks.

Although, many research papers proved the great success of using deep learning approach for solving this task, there are many constraints of the proposed methods when used on photos captured in real-life environment. Two main reasons are highlighted as potential cause of performance drop of the currently proposed models. One of the reason is the fact that majority of the methods from the currently available literature were using pre-trained models of general purpose state-of-the-art convolutional neural network architectures, slightly modified and fine-tuned on plant diseases images. Another reason is the lack of publicly available datasets of diseased and healthy leaves that are captured at the fields holding visual features that are not available on the images captured under experimental conditions, causing simplification of the real-world conditions.

The research presented in this thesis was aimed at developing a novel method based on deep convolutional neural networks for automated plant disease detection. Specialized two-phased deep neural network method, *PlantDiseaseNet*, introduced in the experimental part of thesis solves the limitations of state-of-the-art plant disease detection methods and provides the possibility for a practical usage of the newly developed model. In addition, a new dataset, *PlantDisease*, was introduced, holding more than 80 thousands images of healthy and diseased leaves captured under real-life conditions, divided in 42 classes of 12 different plants. Along with novel detection method, various augmentation techniques were examined. Based on the results, GAN based augmentation approach on leaves images is experimentally confirmed.

Newly developed model of *PlantDiseaseNet* architecture has top-1 accuracy 93.67% if tested on *PlantDisease* dataset. Proposed method could be used as a detection model for decision support system for automated plant disease detection.

**Key words:** convolutional neural network, deep learning, image classification, plant disease detection

# 1. UVOD

Aktivne klimatske promene zajedno sa savremenim trendom života ljudi neprestano utiču na poljoprivredu i donose nove izazove u samom procesu proizvodnje.

Klimatske promene predstavljaju jednu od glavnih briga za poljoprivrednu zajednicu širom sveta. Veliki broj istraživanja potvrđuje da atmosferske i klimatske promene utiču na pojavljivanje, rasprostranjenost ali i na ozbiljnost biljnih bolesti, na taj način što promene u klimatskim parametrima utiču na promene faza i stope razvoja patogena, takođe utiču i na izdržljivost domaćina što dovodi do fizioloških promena interakcije između domaćina i samog patogena. Kao posledica ovoga, menja se i samo upravljanje bolesti bolesti biljaka (eng. *diseases management*); menja se vreme, odabir i efikasnost hemijskih, fizičkih i bioloških mera kontrole i njihove upotrebe u okvirima strategija integrisane kontrole štetočina (eng. *Integrated Pest Control - IPC*) [1, 2, 3, 4, 5].

Danas se bolesti biljaka prenose sa lakaćom globalno, usled povećanog transporta i celokupne povezanosti, što omogućuje da se bolesti specifične za pojedine oblasti mogu naći na geografskim mestima gde prethodno nisu bile identifikovane i gde postoji manjak lokalne ekspertize u borbi sa njima [6]. Nepravilno korišćenje pesticida može izazvati razvijanje dugotrajne otpornosti na patogene.

Uz trenutno rapidno povećanje populacije uzajamno ide i povećanje potrebe za resursima hrane i vode. Uzročno sa time, poljoprivreda u razvijenom delu sveta je ušla u doba „precizne poljoprivrede“, gde je primarni cilj povećanje prinosa ali i zaštita okoline korišćenjem pravih dodataka i tretmana u odgovarajuće vreme specifično za svako zemljište i useve posebno [7].

U ovom multidisciplinarnom zadatku učestvuje veliki broj akademskih istraživača ali i stručnjaka iz industrije koji korišćenjem različitih tehnologija, i vođeni podacima, razvijaju različite sisteme koji imaju ulogu podrške u procesu upravljanja ali i nadzora različitih faza ciklusa razvoja poljoprivrednih kultura [8, 9, 10].

Razvojem informacionih tehnologija, vrši se velika akvizicija podataka iz kojih istraživači pokušavaju da tehnikama mašinskog učenja (eng. *Machine Learning* skr. ML) izvuku relevantne zaključke koji bi unapredile poljoprivredne procese i omogućile optimalno korišćenje resursa uz maksimalne prinose [11, 12, 13].

U trenutnoj situaciji gde su zastupljene brze promene uslova, kako klimatskih tako i geografskih, od velike je važnosti pravovremeno identifikovanje bolesti biljaka uključujući ranu prevenciju i širenje. Postoje više različitih načina otkrivanja biljne patologije. Neke bolesti biljaka se ne mogu identifikovati na osnovu vizuelnih simptoma ili kada postaju vidljivi simpotomi, tada je i suviše kasno da se pristupi samom tretiranju. U ovakvim slučajevima, moraju se koristiti sofisticirane metode radi utvrđivanja bolesti biljaka.

Međutim, veliki broj bolesti ipak se vizuelno manifestuje na biljci još u ranim fazama, što omogućuje identifikovanje bolesti ispitivanjem „golim okom“. Ova tehnika je široko upotrebljena u praksi od strane stručnjaka, biljnih patologa, koji su obučeni da identifikuju vidljive karakteristične simptome [14].

Iz tog razloga, jedan od problema koji zaokupljuje istraživače iz ove oblasti predstavlja rana automatska detekcija bolesti biljaka na osnovu vizuelnih karakteristika sa slike ili videa. Razvoj ovakvih sistema omogućio bi ranu, brzu i jednostavnu detekciju različitih bolesti, gde bi se pravilnim tretiranjem zaustavilo dalje širenje i smanjio gubitak.

Takođe, ovakvi sistemi bi omogućili velikom broju poljoprivrednika ekonomično praćenje svojih useva uz pravilno tretiranje bolesti. Na taj način, omogućilo bi se, ne samo povećanje prinosa, već i zaštita okoline.

U cilju detekcije bolesti biljaka, istraživači iz oblasti kompjuterske vizije su u svojim radovima koristili različite tehnike i pristupe u procesiranju slika uz kombinaciju standardnih algoritama mašinskog učenja. Ovi pristupi najčešće su se bazirali na

ručnom pronalaženju odlika na osnovu kojih bi se vršila klasifikacija i detekcija i skoro uglavnom su se bazirali na malom skupu podataka što je za ograničenje imalo nemogućnost luke generalizacije takvih modela i njihovog korišćenja za veći skup klasa [15, 16, 17].

U skladu sa činjenicom da se u okviru poslednje decenije rapidno popularizovala upotreba dubokih neuronskih mreža zbog njihovih performansi u širokom spektru problema, veliki broj istraživanja koji se bave automatskom detekcijom bolesti biljaka fokusirao se na primeni algoritama dubokog učenja, konkretno u većini slučajeva dubokim konvolucijskim neuronskim mrežama (eng. *Convolutional Neural Networks* skr. CNN) [18].

U poređenju sa standardnim pristupima koji su istraživači koristili u ovoj oblasti, nova istraživanja korišćenjem dubokih konvolucijskih neuronskih mreža pokazuju značajno bolje rezultate u detekciji bolesti biljaka na osnovu slike lista. Ovo je motivisalo istraživačku zajednicu da se prikupljaju podaci i generišu značajno veće baze slika koje su javno dostupne za naučne eksperimente, sa ciljem razvijana klasifikacionih i detekcionih modela koji bi mogli da se koriste u praktičnoj primeni [19].

Iako su se dosadašnji rezultati pokazali značajno performantniji u poređenju sa ranijim istraživanjima, i dalje postoje ograničenja trenutnih rešenja kada se uzme u obzir njihovo praktično korišćenje što ostavlja prostor za dalja istraživanja i razvoj novih algoritama u ovoj oblasti.

U okviru ove disertacije biće istražena trenutna dostačuća u oblasti automatske detekcije bolesti biljaka na osnovu slike lista bazirane na algoritmima dubokog učenja i predstaviće se novi pristupi u korišćenju dubokih neuronskih mreža koji bi mogli da imaju praktičnu primenu kao klasifikacioni i detekcioni modeli u okviru nekog sistema za detekciju bolesti na osnovu slike lista u realnom vremenu.

Primarni doprinosi istraživanja opisani u okviru ove disertacije su:

- Detaljna analiza trenutnih dostačuća iz oblasti detekcije bolesti biljaka na osnovu slike lista – detaljnom analizom literature, klasifikovani su trenutni pristupi u grupe eksperimenata koje su izvršene nad najvećom trenutno javno

dostupnom bazom slika zdravih i obolelih listova. Na osnovu rezultata eksperimenata izvedeni su zaključci vezani za trenutna ograničenja ovih pristupa u njihovom praktičnom korišćenju.

- Analiza novih pristupa u procesu augmentacije slika listova – kroz skup eksperimenata verifikovan je pristup korišćenja GAN arhitektura dubokih neuronskih mreža u svrhu kreiranja sintetičkih slika listova. Na ovaj način potvrđen je ovaj pristup augmentacije kao potencijalni metod u rešavanju manjka javno dostupnih slika listova za trening skup podataka.
- Nova baza slika listova – trenutno najveća javno dostupna baza slika listova, *PlantVillage* baza, sačinjena je od oko 54 hiljade slika grupisanih u 38 klase (zdravih i obolelih) listova od 14 tipova biljaka. Ovu javno dostupnu bazu sačinjavaju samo slike iz eksperimentalnih uslova, što predstavlja značajno ograničenje u razvoju modela treniranim nad tim skupom podataka. Za potrebe eksperimentalnih istraživanja u okviru ove disertacije pripremljena je nova baza slika *PlantDisease*, sačinjena od slika fotografisanih u prirodnih uslovima. Ova baza broji oko 80 hiljada slika listova od 12 vrsta biljaka, grupisanih u 42 klase. Korišćenje ovakvog skupa podataka omogućilo je precizniju analizu trenutnih pristupa u procesu automatske detekcije bolesti biljaka na osnovu slike lista i determinisanju njihovih trenutnih ograničenja u njihovom praktičnom korišćenju.
- Novi 2-fazni algoritam za detekciju – primarni doprinos ove disertacije predstavlja razvoj *PlantDiseaseNet*, 2-faznog algoritma, baziranog na dubokim konvolucijskim neuronskim mrežama. Novi arhitekturni pristup predstavlja specijalizovanu arhitekturu za detekciju bolesti biljaka na osnovu slike listova sa ciljem rešavanja ograničenja trenutno postojećih pristupa u njihovom praktičnom korišćenju. Istrenirani *PlantDiseaseNet* model postigao je krajnju top-1 tačnost od 93.67% nad slikama iz *PlantDisease* baze slika, fotografisanim u prirodnom okruženju.

Ostatak disertacije je struktuiran na sledeći način; drugo poglavlje definiše problem i cilj istraživanja, treće poglavlje uključuje teorijske osnove uključujući terminologiju,

tehnike i metode koje su relevantne za eksperimentalni deo disertacije, dok četvrto poglavlje daje pregled relevantne literature sumirajući trenutna istraživanja i njihove rezultate. Peto poglavlje opisuje metodologiju eksperimentalnog dela ove disertacije detaljno prikazajući sve značajne korake od pripreme baze podataka, procesiranja slika do samog treniranja, validacije i testiranja dubokih konvolucijskih neuronskih mreža, šesto poglavlje predstavlja rezultate i analizu predstavljenih eksperimenata, dok sedmo ujedno i poslednje poglavlje ove disertacije prikazuje zaključke i navodi dalje moguće pravce istraživanja ove oblasti.

## 2. PROBLEM I CILJ ISTRAŽIVANJA

### 2. 1 Osnovne postavke

Prema trenutnim podacima, do 2050. godine [20], globalna ljudska populacija dostići će deset milijardi, uzročno sa tim drastično će se povećati potreba za usevima, čak dva puta više nego što je bilo početkom dvadeset i prvog veka [21].

Više od polovine trenutnog proširenja poljoprivrednog zemljišta u tropskim delovima dolazi od deforestacija, što predstavlja veliku pretnju na samo stanište i živi svet. Ovakav trend širenja poljoprivrednog zemljišta sa umerenih na tropске regije, može izazvati dalju deforestaciju pa čak i kada prestane aktivna ekspanzija poljoprivrednog zemljišta u tim regionima [22].

U toku prošlog veka uložen je veliki napor da se maksimalno iskoriste poljoprivredna zemljišta (eng. *Peak farmland*) kroz razvijanje novih mašina i tehnologija, sofisticiranih đubriva i pesticida, naprednijih metoda navodnjavanja. Ovaj period u razvoju poljoprivrede poznat je pod terminom „Zelena Revolucija“ (eng. *Green Revolution*) [23, 24, 25].

Iako je era „Zelenе Revolucije“ imala pozitivne ishode kada se uzme u obzir očuvanje zemljišta koje bi bilo pretvoreno u poljoprivredno, smanjenje krize nedostatka hrane za globalnu populaciju, relativno očuvanje staništa i divljeg životinjskog sveta [26, 27] (u poređenju sa starijim pristupima u poljoprivredi), ali takođe imala je i negativne uticaje. Nesmotreno korišćenje velikih količina đubriva, pesticida, vode i mnogih drugih dodataka uzrokovale su zagađenje okoline i iscrpljivanje izvora vode [28].

Trend prekomernog korišćenja resursa se smanjuje. Naime u toku „Zelenе Revolucije“, sedamdesetih godina prošlog veka, hemijsko tretiranje, navodnjavanje ali i proširenje obradive zemlje predstavljale su čak 93% od ukupnog povećanja globalnog poljoprivrednog prinosa, početkom dvadeset i prvog veka ove metode čine

svega 27%. Do preostalog, značajnijeg dela povećanja prinosa dolazi od same efikasnosti procesa proizvodnje [29].

Danas je poljoprivreda u mnogim delovima sveta ušla u eru „precizne poljoprivrede“ (eng. *precision agriculture*), gde je glavni fokus povećanje prinosa ali i očuvanje okoline tako što se koriste samo pravi dodaci u odgovarajućim količinama u odgovarajuće vreme, i to specifično za svako polje i kulturu.

Količina đubriva koja se ne apsorbuje od strane useva, a koja iz tog razloga odlazi dalje u vodu i vazduh se smanjuje u proteklih par decenija [30, 31]. Korišćenje vode je značajno kontrolisanje, količina utrošene vode po toni useva je umanjena, a takodje u skladu sa tim i erozija tla se smanjuje u razvijenim zemljama [32]. Po istraživanju navedenom u [33], iako je u globalu povećana poljoprivredna proizvodnja, poljoprivreda generiše oko 40% manje emisije gasova po jedinici proizvodnje u poređenju sa poljoprivrednom proizvodnjom od pre pola veka.

Uz rapidan razvoj naprednih tehnologija iz različitih sfera industrije i nauke, trend precizne poljoprivrede je u kontinualnom razvoju. Nove mašine omogućuju preciznije nanošenje tečnog đubriva, i na taj način se ono ravnomerno rasporedjuje medju biljkama. Dodatno, količina djubriva zavisi i od varijacija sastava zemljišta na samom polju [34].

Pored samog kontrolisanja unosa, precizna poljoprivreda koristi savremenu tehnologiju kako bi povećala gustinu sadnica. Istraživanja iz [35] navode da se u prethodnih sedamdeset godina sa svega 30 hiljada sadnica po hektaru napređovalo do 80 hiljada sadnica po hektaru, što je veoma jasan pokazatelj koliko se povećala uspešnost korišćenja obradivog zemljišta. Povećanje gustine sadnica omogućeno je korišćenjem savremenih tehnologija kao što su na primer traktori vođeni GPS-om, koji se kreću ravno po uskim redovima kao i sofiticiranim sadilicama koje omogućuju postavljanje individualnih semena na određenim distancama [36].

Pored unapređenja mašina, tehnologije i pristupa kultivacije, poljoprivrednicima su dostupne velike količine podataka akvizirane od strane različitih senzora koji se koriste u samom procesu proizvodnje.

Razvojem IoT uređaja (eng. *Internet of Things*) koji se koriste u poljoprivredi radi kontrolisanog nadzora i upravljanja samim procesima pospešuje se proizvodnja. Ovi uređaji sakupljaju različite tipove podataka kao što su temperatura, vlažnost, podaci o samim usevima i mnogi drugi, te omogućuju skladištenje velike količine relevantnih podataka [37, 38].

Analizom ovih podataka mogu se doneti odluke kada i gde da se zasade biljke, kolika gustina sadnica bi trebala da bude, kada navodnjavati i koliko je đubriva potrebno. Ove odluke su često optimizovane za svako polje u zavisnosti od lokacije, mikroklimatskih uslova, tipa zemljišta i slično [39]. Na taj način se značajno povećava sama efikasnost jer se ceo pristup individualizuje za svako obradivo zemljište posebno. Za analizu podataka, izvođenje zaključaka i upravljanje procesima u skladu sa time koriste se sistemi za pomoć donošenju odluka (eng. *Decision Support System* skr. DSS) [40, 41], koji pomažu da se ceo proces ubrza, ali primarna uloga je unapređivanje samog procesa.

Ovakvi sistemi povećavaju efikasnost i nalaze primenu u različitim aspektima procesa poljoprivredne proizvodnje. Jedan od primera korišćenja ovakvih sistema je u optimalnom upravljanju vodom za navodnjavanje korišćenjem podataka o potrebama za navodnjavanje, stvarnih zaliha i drugih lokalnih faktora [42, 43, 44]. Takođe, velika primena ovakvih sistema nalazi se u procesu đubrenja gde se razvijaju modeli bazirani na podacima, a u svrhu donošenja odluka o načinu, količini kao i samim pristupima postupku đubrenja [45, 46, 47].

Zahvaljujući velikoj količini podataka koja se danas sakuplja kroz različite uređaje u savremenom pristupu poljoprivredi, veliki broj sistema koristi različite tehnike mašinskog učenja u svrhu generisanja modela koji pomažu u procesu donošenja odluka. Algoritmi mašinskog učenja mogu doprineti u različitim aspektima, od predviđanja prinosa, detekcije korova, detekcije vrsta useva, klasifikovanju kvaliteta useva i slično. Na ovaj način poljoprivrednicima se omogućuje primena sistema baziranih na veštačkoj inteligenciji koji im omogućuje proces donošenja odluka u realnom vremenu [48].

Pored standardnih tekstualnih podataka sistemi u preciznoj poljoprivredi koriste i vizuelne podatke u vidu slika i frejmova video materijala. Kompjuterska vizija ima značajnu ulogu u okviru takvih sistema radi izrade odgovarajućeg modela.

Sistemi koji se koriste u precizoj poljoprivredi bazirani na tehnikama kompjuterske vizije imaju višestruku primenu: u detekciji bolesti zrna, detekciji napada insekata, otkrivanju truleži, detekciji faze cvetanja, u fenologiji i slično [49].

Ovakvi sistemi bazirani na veštačkoj inteligenciji omogućuju brzo i precizno upravljanje bez trošenja ljudskih resursa u velikoj meri, što daje mogućnost da se koriste u različitim uslovima gde su resursi značajno ograničeni. Iz tog razloga ovakvi sistemi predstavljaju jedan od važnih pristupa u procesu precizne poljoprivrede.

## 2. 2 Cilj istraživanja

U skladu sa rapidnim razvojem tehnologija u svrhu maksimalnog korišćenja resursa uz minimalni procenat zagađenja i narušavanja prirodnog okruženja, veliki broj radova usredsređen je na automatsku ranu detekciju bolesti biljaka. Na taj način omogućeno je da se usevi tretiraju na vreme uz minimalne troškove.

U skladu sa eksponencijalnim uspesima algoritama dubokog učenja u oblasti kompjuterske vizije, značajan broj istraživačkih radova usredsredio se na oblast automatske klasifikacije i detekcije bolesti biljaka na osnovu slike lišća korišćenjem dubokih neuronskih mreža.

Veliki nedostak trenutnih istraživanja u oblasti automatske detekcije bolesti biljaka jeste deficit javno dostupnih baza slika verifikovanih od strane stručnjaka. Većina dosadašnjih istraživanja poznata autoru ove disertacije koristila je jedinu veliku javno dostupnu bazu slika listova (zdravih i obolelih) različitih tipova biljaka fotografisanih u eksperimentalnim uslovima. U skladu sa tim, istrenirani algoritmi bez obzira na uspešnost nad ovim skupom podataka i dalje pokazuju značajno lošije rezultate nad slikama iz prirodnog okruženja.

Takođe, većina trenutnih radova iz ove oblasti bazira se na korišćenju savremenih generalizovanih arhitektura dubokih neuronskih mreža u svrhu izrade modela za

detekciju bolesti biljaka, korišćenjem različitih tehnika procesiranja i treniranja nad bazom slika lišća.

U skladu sa tim, osnovni cilj ove disertacije predstavlja izrada arhitekture duboke konvolucijske neuronske mreže specijalizovane za detekciju bolesti biljaka na osnovu slike lista. Kroz detaljnu analizu postojećih pristupa, definisće se glavni nedostaci trenutnih rešenja i predstaviće se novi pristup kao odgovor na njih.

Motiv autora ove disertacije je izrada modela baziranog na novoj specijalizovanoj arhitekturi neuronske mreže istreniranoj na posebno prikupljenoj bazi slika zdravih i obolelih listova biljaka. Ovako dobijen model bio bi uspešan u procesu detekcije bolesti pomoću slika fotografisanih u okviru prirodnog okruženja pod različitim vremenskim uslovima.

Samim tim, predstavljeni model potencijalno bi mogao da predstavlja osnovu nekog automatskog sistema za detekciju bolesti biljaka. Ovakav sistem omogućio bi lako i jeftino kontinualno praćenje useva i predstavljaо bi pomoć u procesu donošenja odluka kako stručnim licima tako i hobistima.

## 3. TEORIJSKE OSNOVE

U okviru ovog poglavlja biće uvedeni pojmovi i tehnike koje su relevantne za predmet istraživanja u okviru disertacije.

### 3.1 Prepoznavanje obrazaca

Prepoznavanje obrazaca (eng. *Pattern Recognition*) predstavlja istraživačku oblast koja se bavi opisom objekata i klasifikacionih metoda koje uključuju kolekciju matematičkih, statističkih, induktivnih i heurističkih tehniki radi izrade modela za izvršavanje zadataka na računaru.

Automatsko (mašinsko) prepoznavanje, opis i klasifikacija (grupisanje različitih obrazaca u okviru jedne klase) postali su važna tehnika za rešavanje problema u širokom opsegu inženjerskih i naučnih disciplina [50].

Danas se ove tehnike uspešno koriste u propoznavanju karaktera (eng. *Character recognition*), biometričkom prepoznavanju (eng. *Biometric recognition*), prepoznavanju govora (eng. *Speech recognition*), analizi signala (eng. *Sygnal analysis*) i u mnogim drugim oblastima [51].

#### 3.1.1 Sistemi za automatsko prepoznavanje obrazaca

Veliki napredak u računarskim tehnologijama povratilo je interesovanje istraživača i industrije u razvijanje sistema baziranog na modelima za prepoznavanje obrazaca. Zahvaljujući velikoj količini podataka (eng. *Big data*) i mogućnosti njihove brze obrade omogućava se znatno brži razvoj ove oblasti.

Sistemi bazirani na prepoznavanju obrazaca uključuju nekoliko važnih koraka:

- **Prikupljane i obrada podataka** (eng. *Data acquisition and preprocessing*) – ovaj korak obuhvata proces prikupljanja podataka koristeći različite tehnike u

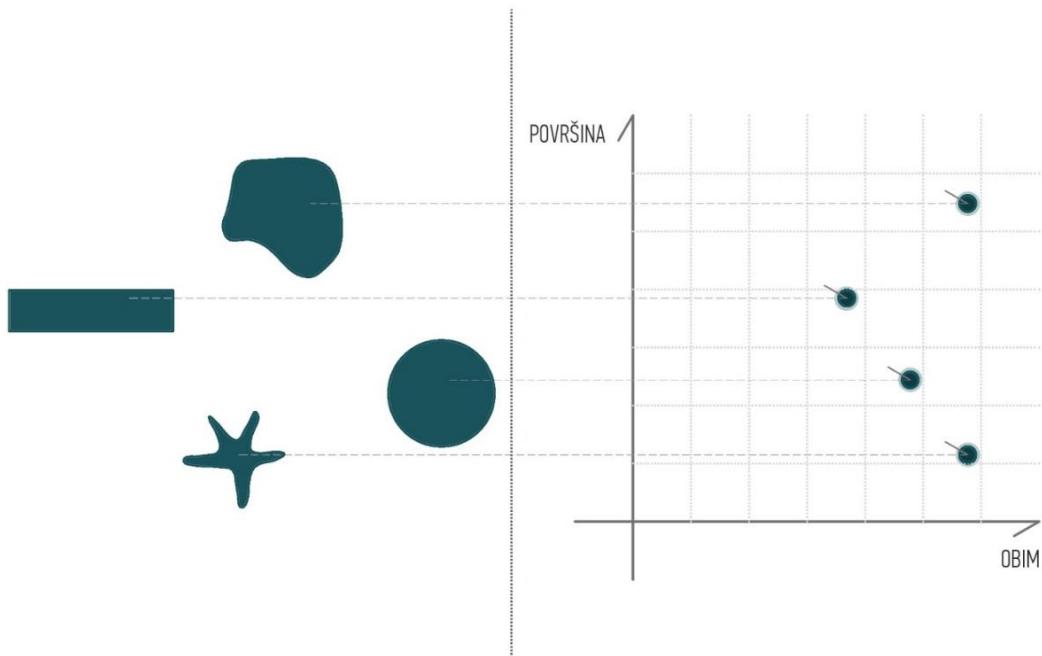
zavisnosti od resursa i prirode problema koji se istražuje. Takođe, u ovom koraku se radi inicijalna obrada podataka koja može obuhvatati različite tehnike koje su takođe u sprezi sa samom problematikom zadataka. Neke od tehniki relevantnih za predmet istraživanja ove disertacije biće objašnjene u daljim sekcijama.

- **Odabir odlika** (eng. *Feature extraction*) – u ovom koraku koriste se različite tehnike ručnog i algoritamskog prikupljanja relevantnih odlika za automatski proces prepoznavanja obrazaca.
- **Trening** – predstavlja kreiranje modela za donošenje odluka. Učenje na osnovu skupa primeraka, odnosno trening skupa podataka (eng. *Training set*) je važna i poželjna karakteristika sistema bazirana na prepoznavanju obrazaca, što je i glavna razlika u poređenju sa sistemima baziranim na ručno određenim pravilama na osnovu kojih se donosi odluka (eng. *Handcrafted decision rules*).
- Mogu se izdvojiti nekoliko standardnih pristupa:

- **Upoređivanje šablonu** (eng. *Template matching*) – Objekti se direktno upoređuju sa nekoliko sačuvanih primeraka ili prototipa koji reprezentuju skup podataka u okviru neke klase.

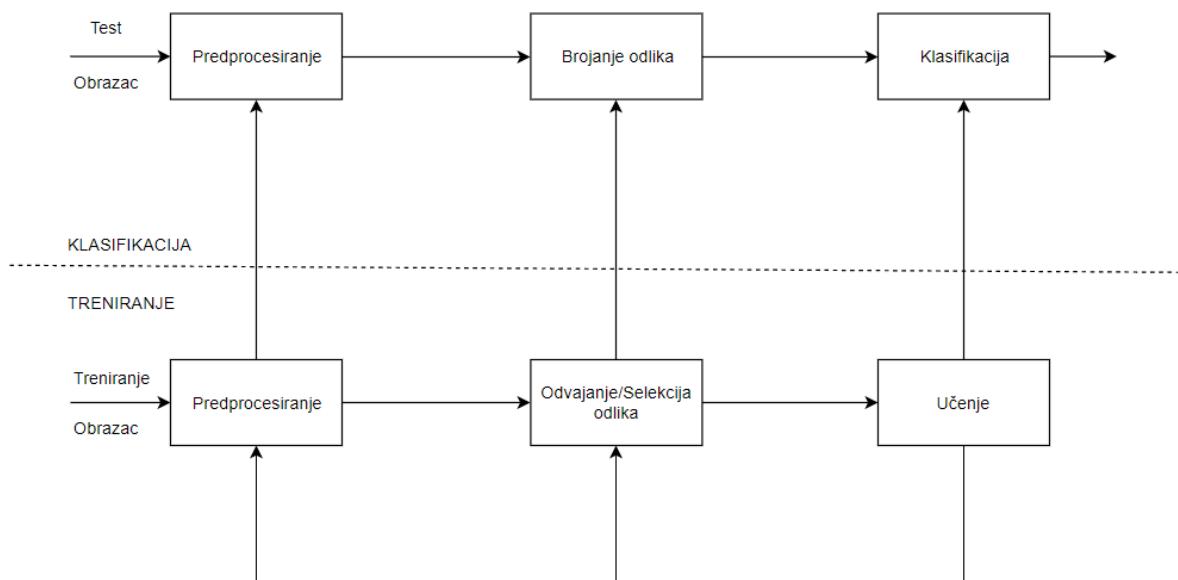
Zbog velikih varijacija u podacima u okviru jedne klase, uobičajeno dolazi do poteškoća da se sa svega nekoliko klasnih primeraka donosi odluka za širi skup podataka sa visokom tačnošću. Stoga, ova tehnika ne spada u najefikasnije metode prepoznavanja obrazaca [52].

- **Geometrijska klasifikacija** (eng. *Geometrical classification*) – klase su predstavljene regionima u reprezentativnom skupu podataka koji je definisan jednostavnim funkcijama [53].
  - **Statistička klasifikacija** (eng. *Statistical classification*) – U svakoj tački ili koordinati u reprezentativnom skupu podataka može se odrediti verovatnoća pripadnosti određenoj klasi, ovaj metod se razlikuje od prethodnog što klase nisu definisane u zavisnosti od nekih regularnih oblika unutar reprezenativnog skupa podataka [54].



**Slika 3.1** Primer 4 objekta predstavljeni u dvodimenzionalnom prostoru odlika

- **Sintetičko ili strukturalno poređenje** (eng. *Syntactic or structural matching*) – u okviru ovog pristupa, kompleksni obrasci su opisani u odnosu na obrasce bazirane na komponentama i njihovim vezama [55].



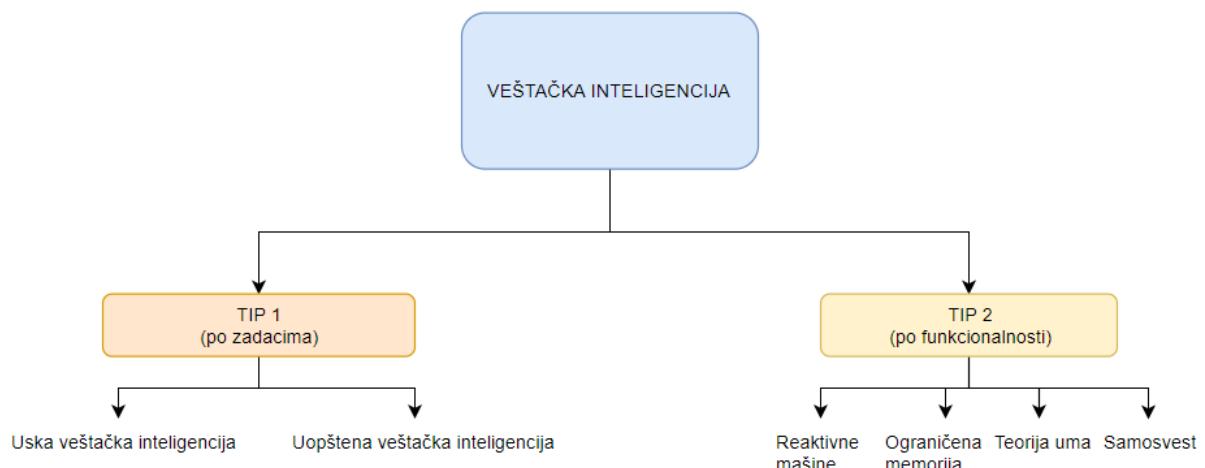
**Slika 3.2** Koraci u automatskom sistemu za prepoznavanje obrazaca

- **Veštačke neuronske mreže** (eng. *Artificial neural networks*) – neuronske mreže biće detaljno opisane u sekciji 3.4 jer predstavljaju osnovu svih algoritama koji će biti predstavljeni u okviru ove disertacije.

### 3.2 Veštačka inteligencija

Veštačka inteligencija (eng. *Artificial Intelligence* skr. **AI**) predstavlja oblast računarstva čiji je cilj razvijanje programa koji bi omogućio računarima ponašanje na način koji bi se mogao smatrati intelligentnim [56].

Iako ovaj termin u literaturi ima veliki broj definicija, najčešće se mogu naći dva tipa klasifikacije veštačke inteligencije, po zadacima i po funkcionalnosti.



**Slika 3.3** Tipovi klasifikovanja veštačke inteligencije

Prvi tip klasifikacije deli veštačku inteligenciju po zadacima koji se obavljaju [56]:

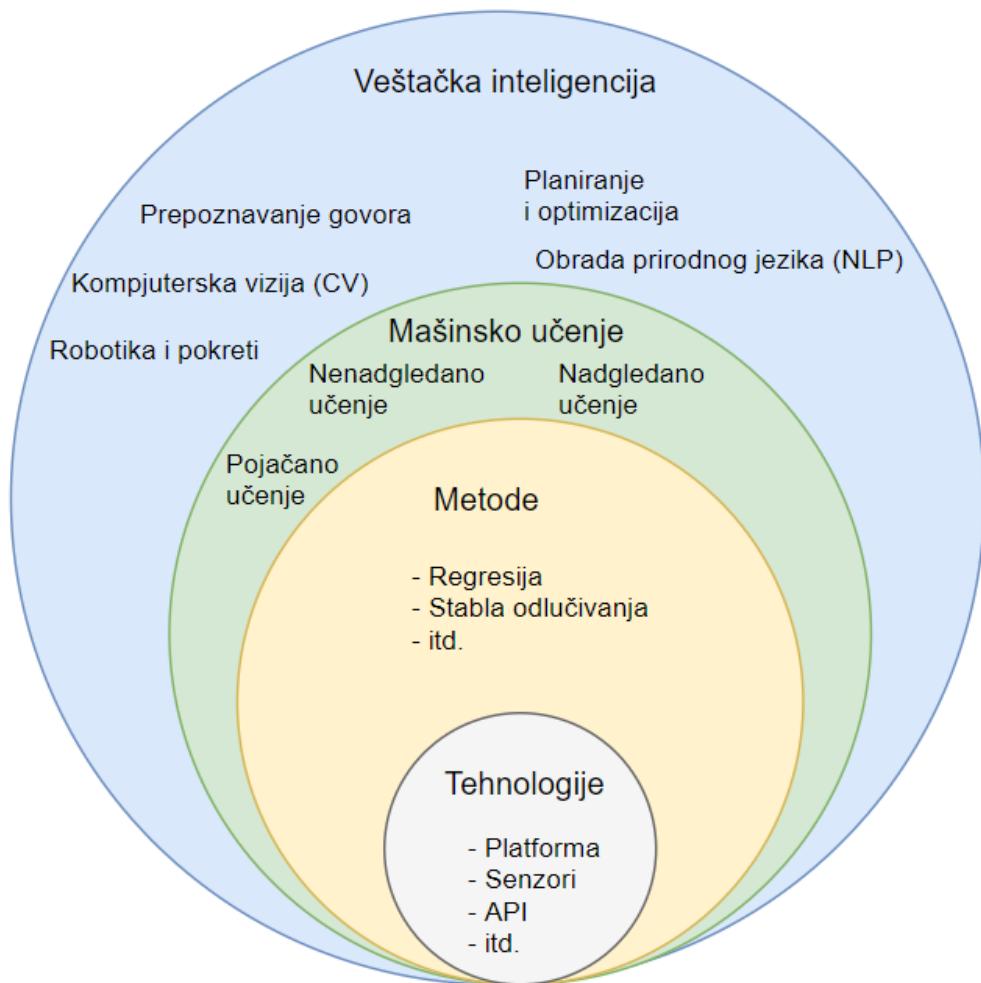
- **Uska veštačka inteligencija** (eng. *Narrow AI*) - sistem gde je definisan fokus samo na određene, usko definisane zadatke (na primer detekcija tablica vozila u saobraćaju, glasovne komande na pametnom uređaju i slično)
- **Uopštena veštačka inteligencija** (eng. *General AI*) - u literaturi može se naći i termin „Prava veštačka inteligencija“, predstavlja sistem ili mašinu koja ima potpunu mogućnost donošenja odluke generalno, bez fokusa na jedan ili na manju grupu zadataka. Nezavistan proces učenja na osnovu prethodnih

iskustava, što predstavlja i način na koji ljudi takođe uče. Do sada, u okviru ovog tipa veštačke inteligencije ne postoji praktičan primer koji bi u potpunosti zadovoljio ove kriterijume.

Drugi tip klasifikacije deli veštačku inteligenciju na osnovu funkcionalnosti [57]:

- **Reaktivne mašine** (eng. *Reactive machines*) – predstavljaju najosnovniji tip sistema veštačke inteligencije. Ova grupa sistema ne može da koristi prethodna iskustva u donošenju trenutnih odluka, iz tog razloga oni reaguju samo u zavisnosti od trenutne situacije – reaktivno. Glavna karakteristika ovih mašina jeste da ne spoznaju koncept okoline i ponašaju se isto bez daljeg razvoja, bez obzira na vreme i mesto. Posebno su dizajnirane za izradu određenog zadatka bez daljeg proširenja. Ovakav tip mašine predstavlja *Deep Blue*, posebno dizajniranog računara za igru šaha, više o tome u sledećoj sekciji.
- **Orgraničena memorija** (eng. *Limited memory*) – mašine sastavljene od modela mašinskog učenja koji donose odluke na osnovu prethodno skladištenih podataka. Za razliku od prethodne grupacije, ovaj tip razvija iskustveno znanje na osnovu prethodnih akcija. Ovakav tip mašina predstavlja sponu prethodno programiranih i obzervativnih podataka. Primer ovakvog tipa veštačke inteligencije može se pronaći u autonomnoj vožnji gde se očitavaju podaci okoline, detektuju različiti obrasci i promene u eksternim faktorima i vrše se promene u vožnji u skladu sa time.
- **Teorija uma** (eng. *Theory of mind*) – ovaj tip veštačke inteligencije predstavlja futurističku grupu mašina koje su u stanju da razumeju ljudske emocije, razmišljanja i očekivanja. Jedan od trenutnih razvoja u ovoj grupi mašina veštačke inteligencije predstavlja humanoidni bot, *Sophia*, razvijen od strane *Hanson Robotics*-a 2016. godine. *Sophia* ima mogućnost da raspoznaće facijalne ekspresije i da odgovori u skladu sa time.
- **Samosvest** (eng. *Self-awareness*) – predstavlja tip veštačke inteligencije koji bi posedovao svest na nivou ljudske svesti. Ovaj tip veštačke inteligencije predstavlja krajnji cilj u razvoju ove oblasti.

Na slici 3.4 je prikazan uprošteni pregled oblasti veštačke inteligencije.



**Slika 3.4** Uopšteni pregled polja unutar oblasti veštačke inteligencije

### 3.3 Mašinsko učenje

Mašinsko učenje predstavlja podoblast računarske nauke koja je evoluirala iz oblasti prepoznavanja obrazaca i teorije računarskog učenja (eng. *Computational learning theory*). Iz tog razloga, vrlo često se može primetiti da se mašinsko učenje i prepoznavanje obrazaca mogu posmatrati kao dve strane iste istraživačke oblasti [58].

Mašinsko učenje istražuje izradu i korišćenje algoritama koji su u mogućnosti da „uče“ i izvršavaju predikcije na osnovu skupa podataka. Ovakvi algoritmi funkcionišu tako

što se izrade modeli na osnovu ulaznih primeraka iz skupa podataka kako bi se na osnovu tih primeraka mogla izvršiti predikcija ili odluka (eng. *Data driven learning*).

Artur Samuel (eng. *Arthur Samuel*) je 1959. godine definisao mašinsko učenje kao:

„Polje istraživanja koje omogućuje računarima da uče bez eksplicitnog programiranja“ [59].

Tom M. Mičel (eng. *Tom M. Mitchell*) je dao širu i formalniju definiciju mašinskog učenja:

„Za računarski program se kaže da je naučio iz iskustva E (eng. **E**xperience) za određene klase zadataka T (eng. **T**ask) i metrike performansi P (eng. **P**erformance), ako se performanse za zadatak T, izmerene sa P, poboljšaju sa iskustvom E“ [60].

### 3.3.1 Kratak istorijat mašinskog učenja

Alen Tjuring (eng. *Alan Turing*), Engleski matematičar i jedan od pionira veštačke inteligencije 1940-ih i 1950-ih, kreirao je „Tjuringov Test“ radi određivanja da li računar poseduje pravu inteligenciju [61].

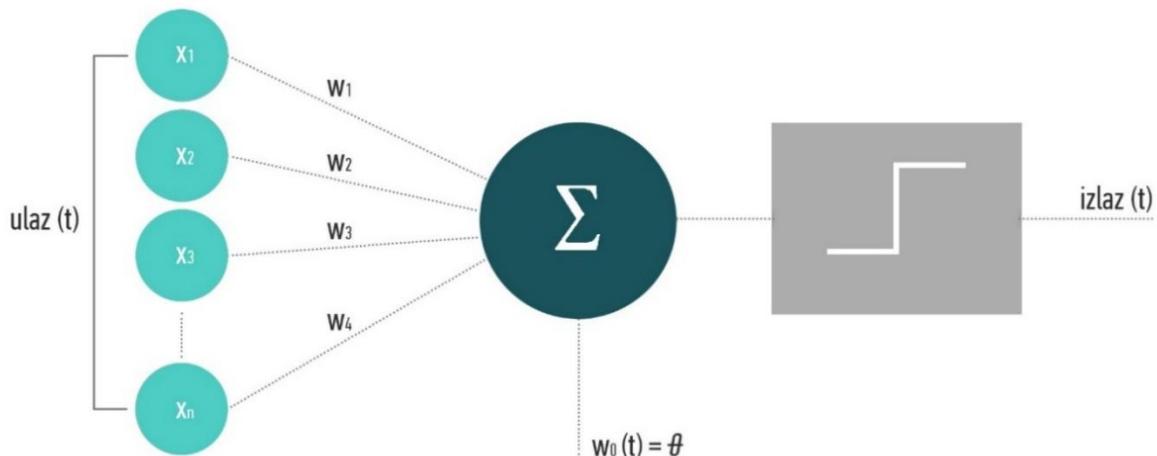
Da bi prošao test, računar mora biti u mogućnosti da „prevari“ čoveka da računar nije računar, već čovek. Na osnovu ovog testa, računar bi se smatrao da poseduje veštačku inteligenciju u koliko je u mogućnosti da mimikuje ljudske odgovore pod određenim uslovima.

U osnovi Tjuringovog testa nalaze se tri glavne uloge, prve dve su upravljane od strane čoveka dok je treća rukovođena od strane računara. Svaka uloga je fizički odvojena od druge dve. Jedna osoba ima ulogu ispitiča dok druga osoba i računar učestvuju u testu tako što odgovaraju na pitanja. Ispitiča ispituje i računar i čoveka koristeći predodređeni format koji se sastojao od predefinisanih oblasti i konteksta. Ispitivanje je bilo u ograničenom vremenskom periodu. Nakon isteka vremena, ispitiča je pokušavao da odredi koji odgovori su od strane čoveka a koji od strane računara. Test se ponavljao više puta, ukoliko je ispitiča tačno odlučio u polovini slučajeva ili manje, računar se smatrao da poseduje veštačku inteligenciju.

Artur Samuel (eng. *Arthur Samuel*) je 1952. godine napisao prvi program baziran na računarskom učenju. Program je bila igra Dama (eng. *checkers*) vrsta kombinatorne igre namenjena za dva igrača na  $10 \times 10$  tabli crno-belih polja, gde se računar poboljšavao vremenom kako se igra više igrala, proučavajući poteze koji su predstavljali pobedničku strategiju i uvrštavajući te poteze u sledećim igrama [62].

Zbog ograničenosti računarske memorije, Samuel je koristio alfa-beta pretragu (eng. *alpha-beta pruning*) [63], algoritam koji se bazira na smanjenju broja čvorova koji su predstavljeni od strane minimax algoritma u stablu pretrage [64]. Ovaj algoritam odstranjuje grane stabala koje ne vrše uticaj na konačni ishod. Samuelsov dizajn algoritma u igri Dama koristio je funkciju vrednovanja (eng. *scoring function*) koja koristi pozicije na samoj tabli, gde je funkcija vrednovanja pokušavala da odredi trenutne šanse za pobedu oba igrača.

Frenk Rozenblat (eng. *Frank Rosenblatt*) dizajnirao je prvu veštačku neuronsku mrežu 1958. godine, perceptron [65].



**Slika 3.5** Prikaz perceptron modela

Perceptron je inicijalno planiran kao mašina, a ne program. Softver je originalno dizajniran za IBM 704, ali je kasnije instaliran na posebno dizajniranoj mašini zvanoj Mark I perceptron, koja je izgrađena u cilju prepoznavanja slika (prepoznavanje obrazaca i oblika tačnije). Na ovaj način softver kao i sam algoritam je bio prenosiv i dostupan za korišćenje na drugim mašinama. Opisan kao prvi uspešan neuro-računar,

Mark I perceptron nije ispunio očekivanja, imao je problema u prepoznavanju velikog broja vizuelnih obrazaca (kao što su na primer lica).

Takođe, jedna od ranijih upotreba neuronskih mreža, samo godinu dana kasnije od upotrebe perceptrona, 1959. godine, gde su Bernard Widrow (eng. *Bernard Widrow*) i Maršan Hof (eng. *Marcian Hoff*) kreirali dva modela neuronskih mreža na Stendfordskom Univerzitetu. Prvi model se nazivao ADELINe (eng. *Adaptive Linear Neuron* ili kasnije eng. *Adaptive Linear Element*) koji je detektovao binarne obrasce, na primer u toku bitova (eng. *stream of bytes*) mogla se izvršiti predikcija sledećeg bita u nizu. Sledеća generacija nazvana je MADELINe (eng. *Many ADELINe*) i mogla je da eleminiše echo sa telefonske linije, što je dalo i prvu pravu primenu u praksi, koja se u određenom obliku i danas koristi [66].

Godine 1967. algoritam najbližih suseda je predstavljen u radu [67], što takođe označava početak osnove prepoznavanja i klasifikaciju obrazaca. Algoritam se koristio za mapiranje ruta i jedan je od ranijih algoritama korišćenih za pronalaženje najefikasnijih rešenja problema trgovackog putnika (eng. *The traveling salesperson's problem*).

Tokom 1960-ih godina otkriće korišćenja više slojeva otvorilo je nove puteve u istraživanju neuronskih mreža. Pokazano je da korišćenje dva ili više slojeva perceptrona omogućuje više perceptivne moći nego korišćenjem samo jednog perceptrona. Prvi sloj se naziva ulazni, a poslednji izlazni, dok se slojevi između nazivaju skriveni slojevi. Različite verzije neuronskih mreža su kasnije kreirane posle otkrivanja slojeva u mreži perceptrona. Korišćenje višeslojnog pristupa dovelo je do neuronskih mreža sa propagacijom unapred (eng. *Feedforward neural networks*) i algoritma propagacije unazad (eng. *Backpropagation algorithm*).

Algoritam propagacije unazad razvijen je 1970-ih godina, što je omogućilo podešavanje skrivenih slojeva neurona da se adaptira na nove situacije tako što se procesuirala greška na izlazu i distribuirala unazad kroz slojeve mreže radi procesa učenja. Ovaj algoritam predstavlja osnovu savremenih neuronskih mreža, više o samom algoritmu biće prikazano unutar sekcije 3.4.

Tokom kasnih 1970-ih i ranih 1980-ih godina, istraživanje u okviru veštačke inteligencije se fokusiralo na logičke, pristupe baziranim na znanjima više nego na pristupe bazirane na algoritmima.

Čuveni Lajthilov izveštaj Britanskom parlamentu [68] izneo je pesimističke prognoze upotrebe neuronskih mreža i veštačke inteligencije u kome su se navodila dotadašnja istraživanja u ovoj oblasti navodeći nemogućnosti ispunjenja grandioznih obećanja. Na osnovu toga, istraživanja iz oblasti neuronskih mreža bila su odbačena u tom periodu i sva finansiranja ovakvih istraživanja bila su skoro potpuno ukinuta. Ovaj period poznat je kao i „Zima Veštačke Inteligencije“ (eng. *AI Winter*). U toku ovog perioda došlo je do raskola između veštačke inteligencije i mašinskog učenja, od tada termin mašinskog učenja odnosi se na istrenirani program upotrebljiv od strane veštačke inteligencije.

„Boosting“ algoritmi predstavljali su značajnu tačku u razvoju oblasti mašinskog učenja. Njihova značajna uloga leži u redukovavanju biasa (eng. Bias) u toku nadgledanog učenja (jedan od tipova mašinskog učenja objašnjen u sledećoj sekciji) i uključuje algoritme mašinskog učenja koji transformišu slabo u jako učenje. Koncept boosting-a predstavljen je u radu [69] iz 1990. godine Roberta Šapirea (eng. *Robert Schapire*). Šapire je izneo činjenicu da skup algoritama slabog učenja mogu da kreiraju jedinstveni algoritam jakog učenja, gde su pod algoritmima slabog učenja smatrani klasifikatori koji su maloj korelaciji sa tačnom klasifikacijom (ali i dalje bolji od nasumičnog pogađanja), a pod algoritmima jakog učenja smatrani su oni klasifikatori koji su u jakoj korelaciji sa tačnom klasifikacijom.

Godine 1997. IBM-ov računar *Deep Blue*, specijalizovan računar za igru šaha, pobedio je svetskog šampiona [70].

Naredne godine, 1998., istraživanje iz AT&T Bell Laboratorije vezano za prepoznavanje cifara pomoću algoritma propagacije unazad omogućilo je izradu modela za detekciju ručno pisanih poštanskih brojeva [71] korišćen u Američkoj pošti (eng. *US Postal Service*).

Početkom 2000-ih godina razvojem performantnijeg hardvera, veliki broj poslovnih procesa koristio je algoritme mašinskog učenja.

---

Razvoj novih algoritama mašinskog učenja ali i novih algoritama dubokih neuronskih mreža sa izvanrednim performansama u mnogim poljima omogućio je njihovu praktičnu primenu u različitim oblastima industrije.

### 3.3.2 Tipovi mašinskog učenja

Tipovi zadataka mašinskog učenja mogu se podeliti u tri uopštene kategorije u zavisnosti od prirode učenja "signala", odnosno "povratne vrednosti" dostupne učenom sistemu:

- **Nadgledano učenje** (eng. *Supervised Learning*)
- **Nenadgledano učenje** (eng. *Unsupervised Learning*)
- **Pojačano učenje** (eng. *Reinforcement Learning*)

U okviru grupe nadgledanog učenja, algoritmu je predstavljen skup ulaznih i izlaznih podataka sa ciljem razvoja funkcije mapiranja koja bi dovoljno dobro mogla da izvrši predikciju izlaznih vrednosti na osnovu ulaznih podataka.

U tipove nadgledanog učenja spadaju problemi:

- **Klasifikacije** (eng. *Classification*): izlazne promenljive predstavljene u obliku kategorije
- **Regresije** (eng. *Regression*): izlazne promenljive predstavljene su realnim vrednostima

U nenadgledanom učenju, algoritmu nisu dostavljene izlazne vrednosti, pri tome ostavljajući samom algoritmu da pronađe strukturu ulaznih podataka.

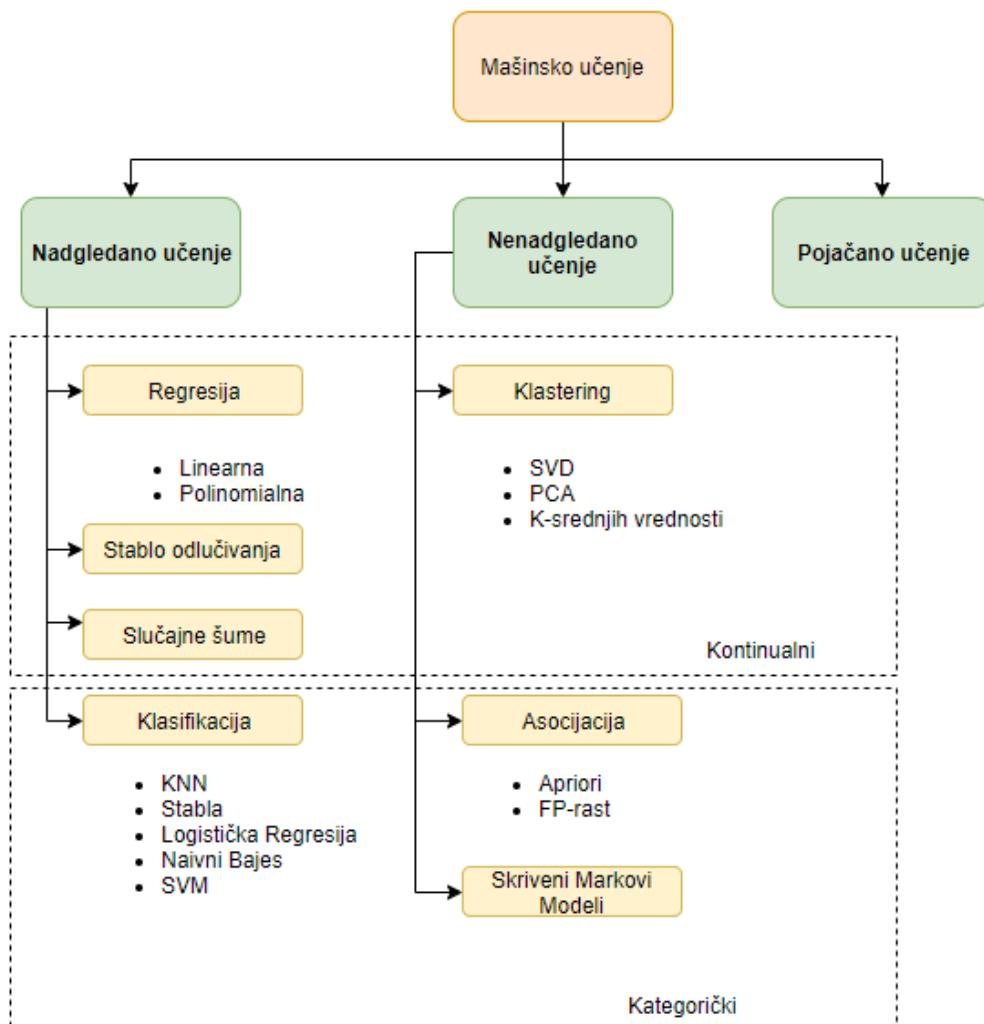
U tipove nenadgledanog učenja spadaju problemi:

- **Klasterizacije** (eng. *Clustering*): potreba da se pronađu grupe unutar podataka.
- **Asocijacije** (eng. *Association analysis*): potreba da se pronađu pravila koja opisuju određene delove unutar skupa podataka

- **Redukcija dimenzionalnosti** (eng. *Dimensionality reduction*): potreba da se pojednostavi ulaz tako što se mapira na prostor podataka manjih dimenzija

U problemima pojačanog učenja, algoritam (agent) vrši interakciju sa dinamičkom okolinom unutar koje mora da izvrši određeni zadatak, bez da se eksplisitno navodi algoritmu da li je blizu cilja ili ne. U ovakvom tipu učenja, agent se nagrađuje ukoliko se ponaša tačno i penalizuje ukoliko napravi grešku. Agent uči bez ljudske intervencije tako što se maksimizuje nagrada a minimizuje kazna. To je tip dinamičkog programiranja gde se algoritam trenira u sistemu nagrade i kazne.

Na slici 3.6 prikazana je uopštena kategorizacija osnovnih algoritama mašinskog učenja.



**Slika 3.6** Tipovi algoritama mašinskog učenja

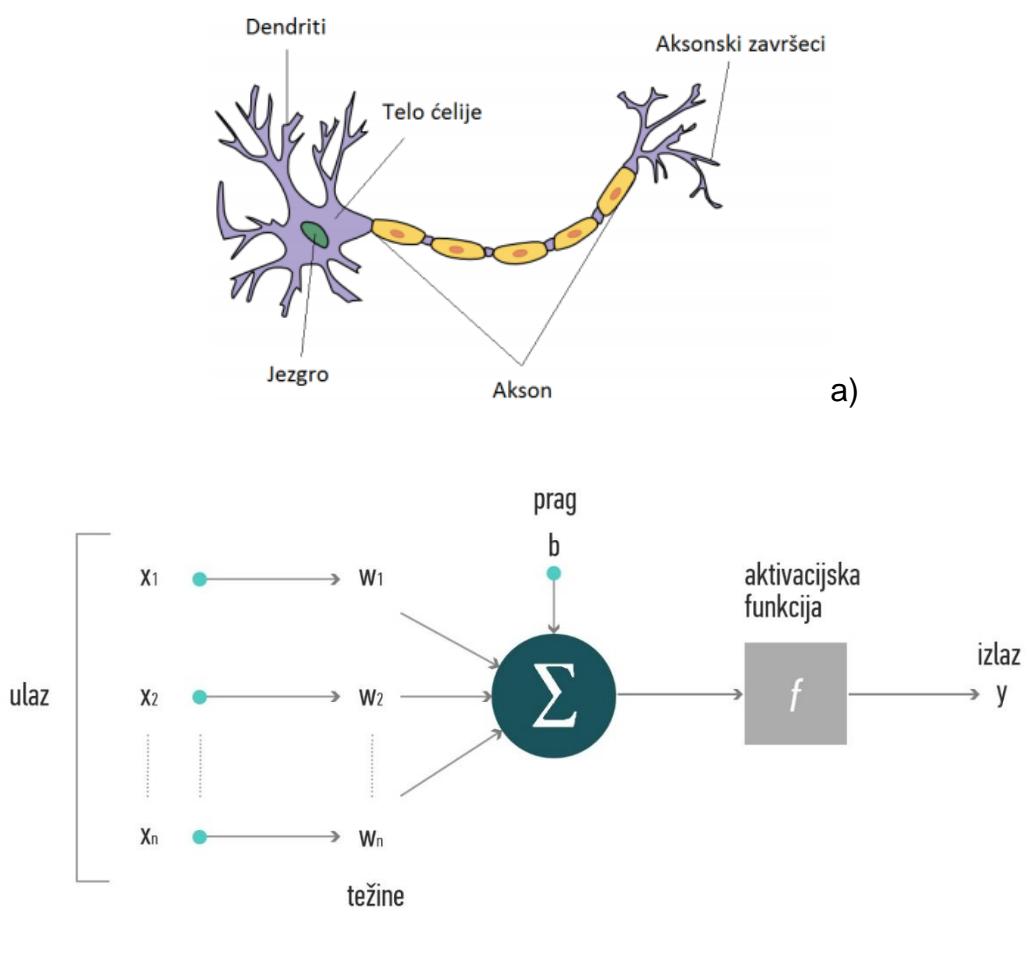
### 3.4 Neuronske mreže

Algortmi dubokih neuronskih mreža korišćeni u okviru eksperimentalnog dela ove disertacije iako se značajno razlikuju od klasičnih neuronskih mreža, koriste osnovne principe i pristupe koji potiču od standardnih, tradicionalnih neuronskih mreža.

U okviru ove sekcije prikazaće se osnovne gradivne jedinice jedne neuronske mreže kao i njen uopšteni princip rada.

#### 3.4.1 Perceptron

Neuron predstavlja osnovnu gradivnu jedinicu neuronskih mreža. Prvi matematički model neurona predstavili su Mekalok (eng. McCulloch) i Pits (eng. Pitts) po uzoru na biološki neuron [72], slika 3.7.



**Slika 3.7** Neuron a) biološki neuron i b) Model neurona kod veštačkih neuronskih mreža

Neuron predstavlja jedinicu za izračunavanje koja na osnovu ulaznih vrednosti  $x$  i težinskih faktora (obično nasumično inicijalizovani, koji se menjaju posle svake iteracije algoritma)  $w$  (eng. *weights*) uz konstantan član, odnosno prag  $b$  (eng. *bias*) daje izlaz  $y$ :

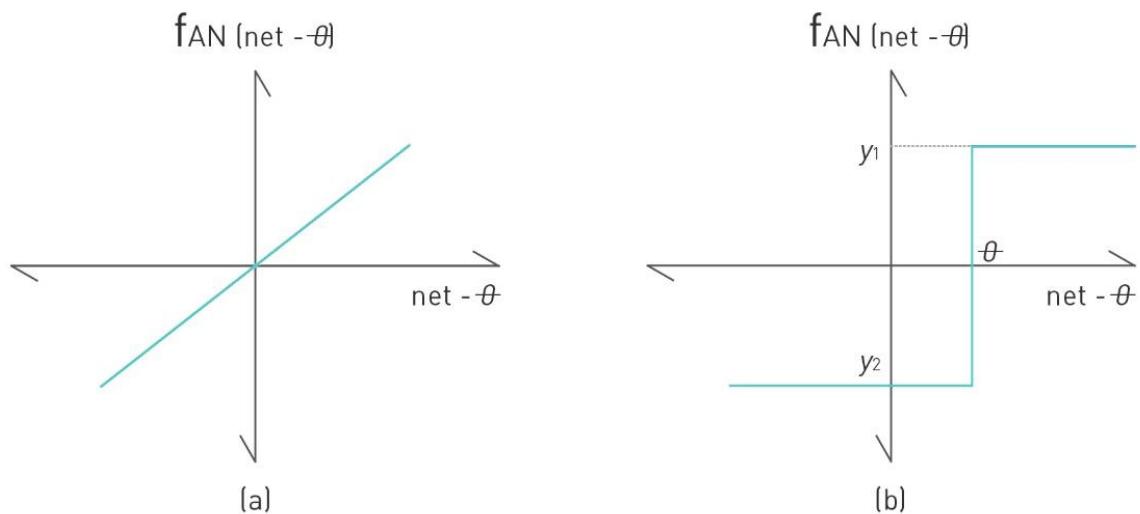
$$h_{W,b}(x) = f(W^T x) = f\left(\sum_{i=1}^3 W_i x_i + b\right), \quad (3.1)$$

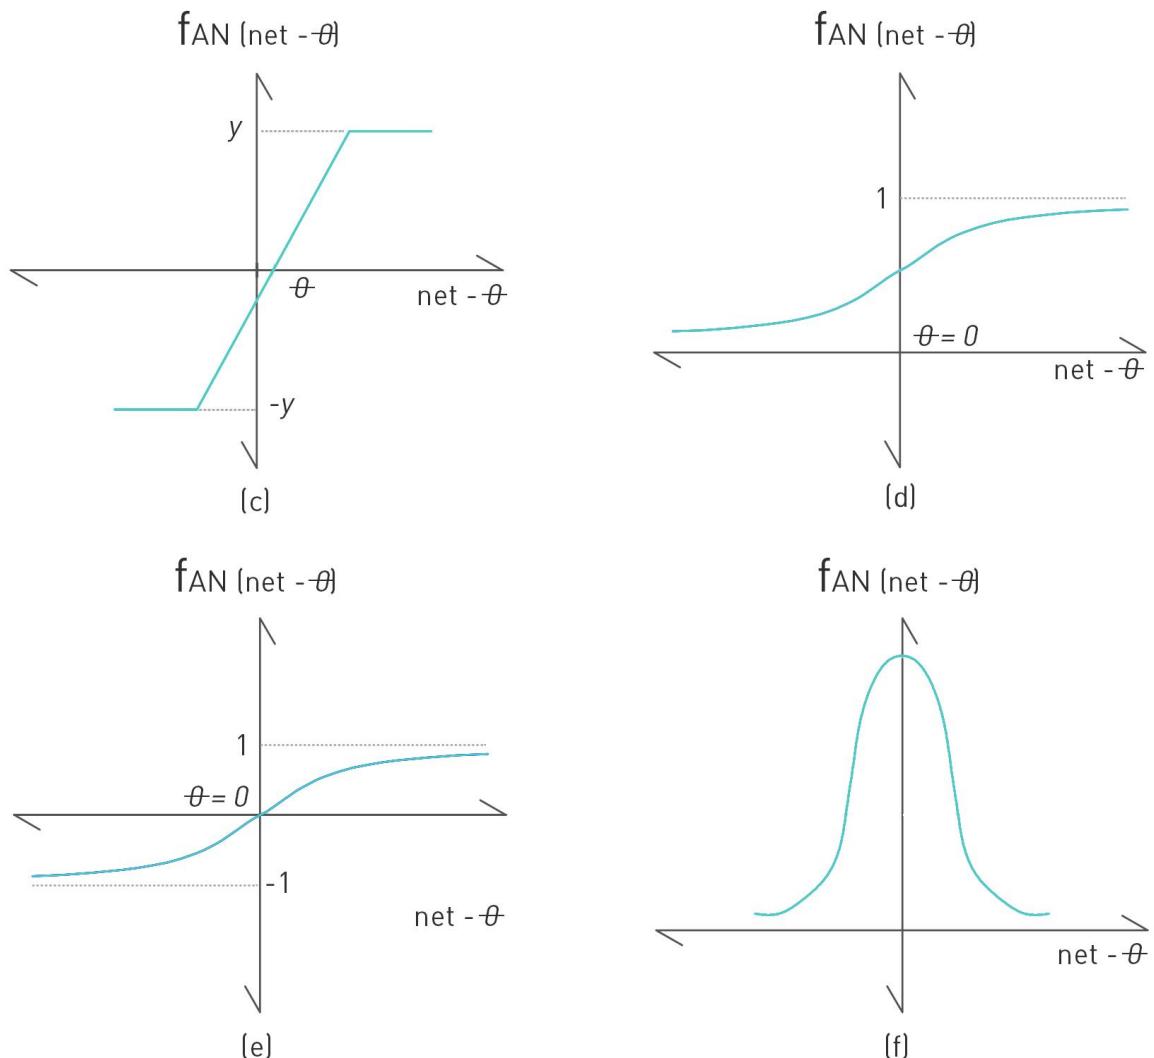
gde funkcija  $f$  predstavlja aktivacionu funkciju (eng. *activation function*). Uloga aktivacione funkcije dolazi iz prirode rada samog biološkog neurona, gde se sam signal neurona propagira ka sledećim neuronima, ako i samo ako, je sam ulaz tog neurona dovoljno snažan.

Praktično aktivaciona funkcija definiše izlaz neurona u zavisnosti od njegovog ulaza. U okviru inicijalnog rada gde je predstavljen Mekalok-Pits model, koristila se sigmoidna aktivaciona funkcija:

$$f(z) = \frac{1}{1 + e^{-z}}. \quad (3.2)$$

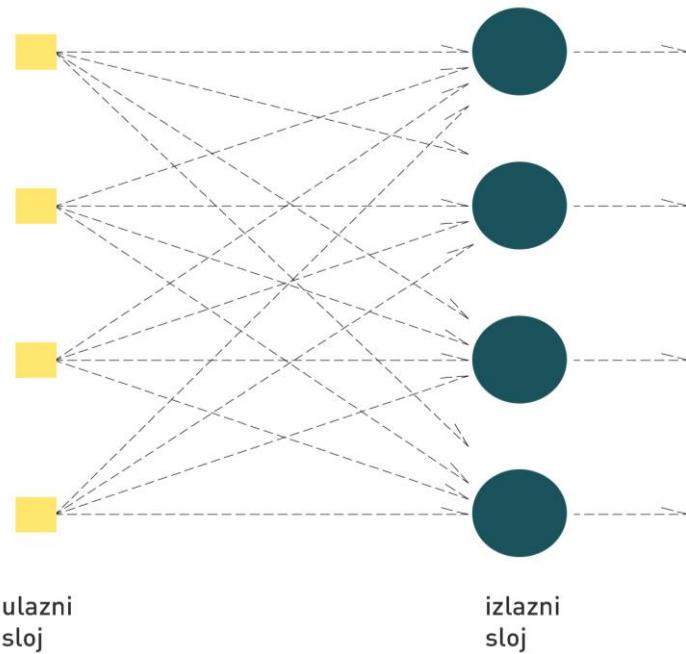
Pored sigmoidne funkcije, danas se koriste i druge diferencijabilne funkcije, slika 3.8





**Slika 3.8** Aktivacione funkcije: a) linear, b) koračna, c) rampa, d) sigmoidna, e) hiperbolična tangentna i f) Gausova funkcija

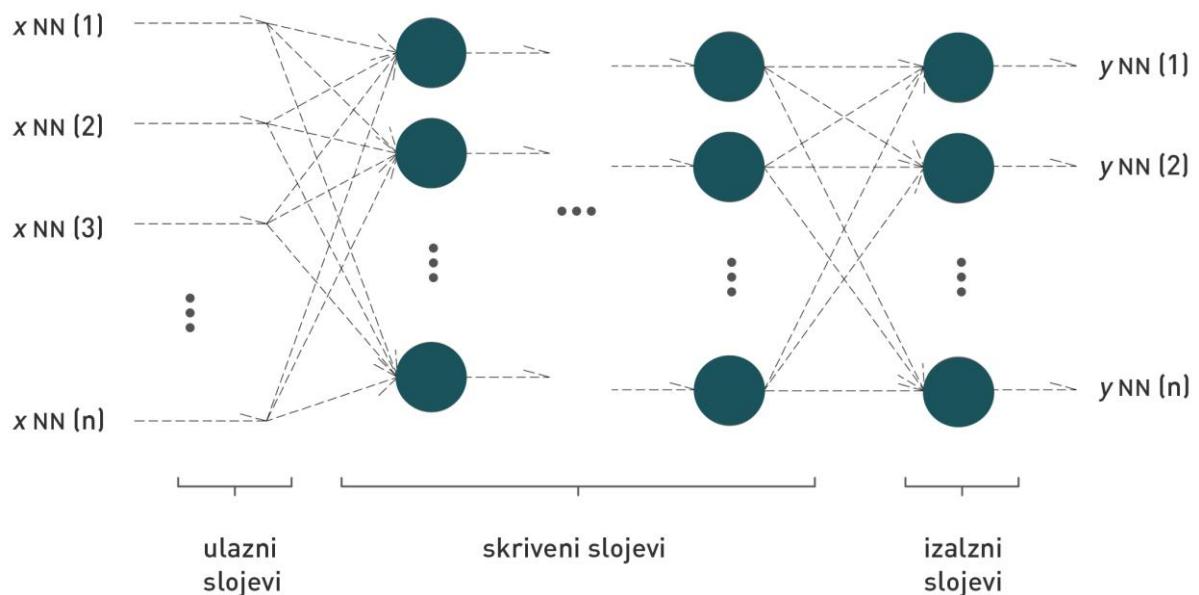
Ovakav predstavljen model u literaturi se naziva i perceptron. Za višeklasne probleme potrebno je koristiti više perceptrona, jedan za svaku klasu. Izlaz svakog perceptrona predstavlja verovatnoću pripadnosti te klase, za kranji izlaz uzima se klasa sa najvećom verovatnoćom, prikaz ovakve neuronske mreže nalazi se na slici 3.9.



**Slika 3.9** Jednoslojna neuronska mreža

### 3.4.2 Višeslojni perceptron

Neuronska mreža se karakteriše kao višeslojni perceptron (eng. *Multilayer perceptron*) u koliko se u okviru neuronske mreže nalaze dodatni slojevi neurona (perceptrona) između ulaznog i izlaznog sloja, tzv. skriveni slojevi.



**Slika 3.10** Višeslojni perceptron

Dodavanjem slojeva neuronskoj mreži, pronalaženje odgovrajuće kombinacije težina za funkciju neuronske mreže postaje znatno kompleksnije.

Treniranje ovakve neuronske mreže odraduje se u nekoliko važnih koraka.

Prvi korak predstavlja prelaz unapred (eng. *forward pass*). Inicijalno ovom koraku prethodi nasumično inicijalizovanje težina. Prelaz unapred podrazumeva prolaz ulaznog signala (vektor ulaznih podataka) kroz sve slojeve neuronske mreže i računanje izlaza modela.

Podaci se kreću u jednom smeru, svaki neuron u svakom sloju višeslojnog perceptronra računa svoj izlaz zasnovan na sumi svojih težinskih parametara u skladu sa svojom aktivacionom funkcijom.

Sledeći korak podrazumeva računanje greške, odnosno koliko se dobijeni izlaz neuronske mreže sa ovakvim vrednostima težinskih parametara razlikuje od željenje izlazne vrednosti. U ovu svrhu koriste se različiti tipovi funkcija greške.

Samim tim, proces obučavanja mreže se zasniva na podešavanju težina korišćenjem procedure porpagacije greške unazad (eng. *Backpropagation algorithm*). U ovom koraku greška se sekvensijalno propagira unazad, počevši od izlaznog sloja do prvog skrivenog sloja neuronske mreže. Za svaku vezu ažuriraju se vrednosti težinskih parametara proporcionalno sa greškom.

Kada se ovi koraci izvrše za svaki ulaz iz skupa podataka za treniranje obavlja se jedna epoha treninga. Obučavanje traje do unapred određenog broja epoha ili do trenutka kada greška dostigne prihvatljivu granicu.

### 3.5 Duboko učenje

Pod terminom dubokog učenja, podgrupa mašinskog učenja, podrazumevaju se metode bazirane na veštačkim neuronskim mrežama.

Veštačke neuronske mreže mogu se grupisati po metodama učenja:

- nadgledano,

- 
- polu-nadgledano i
  - ne-nadlegadano učenje.

Takođe, mogu se razgraničiti i po arhitekturi na:

- Neuronske mreže bez povratnog prenosa (eng. *feedforward*) - Autoenkoderi, Ograničene Boltzmanove mašine i slično,
- Konvolucijske neuronske mreže
- Rekurentne neuronske mreže – LSTM (eng. *Long Short-Term Memory*), GRU (eng. *Gated Recurrent Unit*) i sl.,
- Rekurzivne neuronske mreže – Rekurzivni autoenkoderi, Neuronske tenzor mreže (eng. *Neural Tensor Networks*)

U literaturi, pored ovih gore navedenih podela po arhitekturi i tipu učenja, metode dubokog učenja se mogu klasifikovati po različitim kriterijumima.

U okviru ove disertacije, glavni arhitekturalni pristup koji se koristi za detekciju bolesti biljaka na osnovu slike lista bazira se na konvolucijskim neuronskim mrežama, pa će se u okviru daljih sekcija ovog poglavlja detaljnije prikazati glavne odlike konvolucijskih neuronskih mreža kao i njihove arhitekture specijalizovane za rešavanje različitih zadataka.

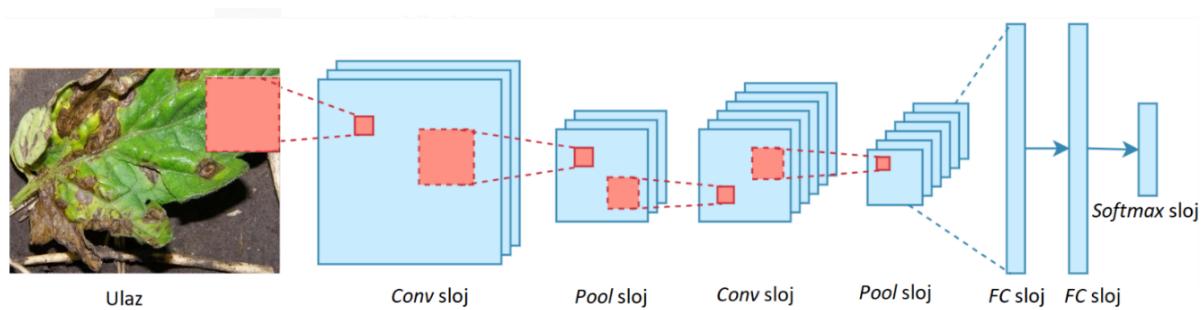
### 3.5.1 Konvolucijske neuronske mreže

Konvolucijske neuronske mreže predstavljaju najpopularniju arhitekturu dubokih neuronskih mreža. U poslednjoj deceniji zauzele su primarnu ulogu u rešavanju brojnih industrijskih problema iz oblasti kompjuterske vizije i obrade govora, ali i u drugim oblastima mašinskog učenja ovaj tip mreže predstavlja jednu od uspešnijih tehniki.

Važno je napomenuti da će u ovom poglavlju opis i primena konvolucijskih neuronskih mreža biti fokusirana na RGB slikama, ali sama arhitektura, princip rada, tehnike

treniranja i finog podešavanja vrlo su slične i za druge tipove podataka, jednodimenzionalne ili višedimenzionalne.

Struktura standardne konvolucijske neuronske mreže sačinjena je od nekoliko važnih gradivnih blokova koji predstavljaju slojeve ove mreže. Broj slojeva i kombinacija gradivnih blokova varira u zavisnosti od arhitekture, na slici 3.11 predstavljena je jedna standardna konvolucijska neuronska mreža sačinjena od konvolucijskih slojeva (*Conv* slojevi), slojeva sažimanja (*Pool* slojevi), potpuno povezanih slojeva (*FC* slojevi) i klasifikacionog sloja (*Softmax* sloj).



**Slika 3.11** Standardni slojevi konvolucijske neuronske mreže

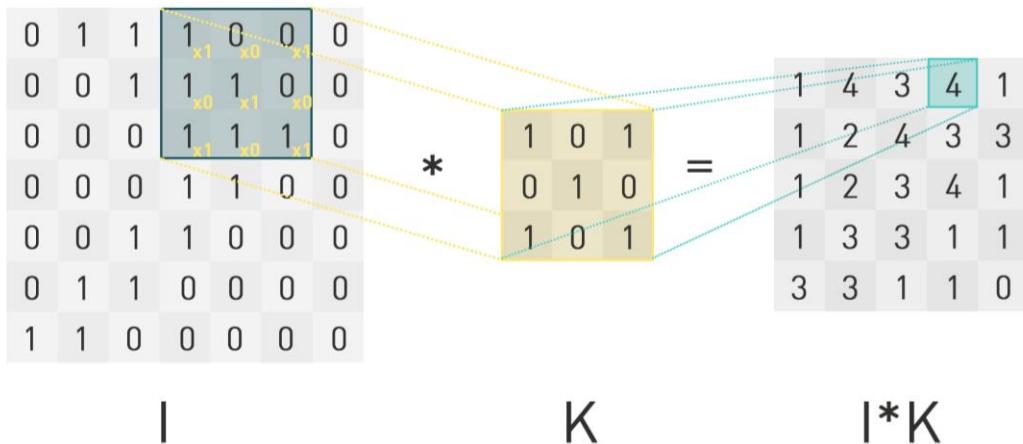
### 3.5.2.1 Konvolucijski sloj

Konvolucija predstavlja osnovnu operaciju obučavanja neurona mreže kroz postupak primene filtera na sliku (ulazni podatak). Ovaj postupak predstavlja osnovni gradivni element svake arhitekture konvolucijske neuronske mreže.

Konvolucijski filteri (u literaturi poznati još kao i konvolucijski kerneli) sačinjeni su od dvodimenzionalnih matrica realnih vrednosti, manjih dimenzija u poređenju sa dimenzijama ulaznih podataka (ulazne slike) koje se koriste za obuku neuronske mreže. Elementi ovih matrica predstavljaju parametre za obučavanje konvolucijske neuronske mreže.

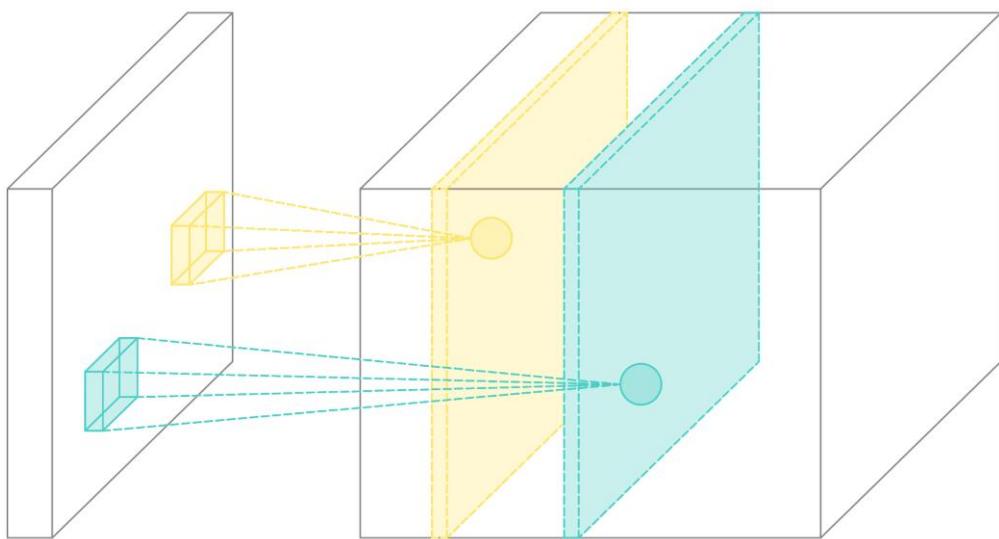
U fazi procesa prolaza unapred (eng. *Forward pass*), filteri rade konvoluciju sa trenutnim ulaznim podatkom (slikom) i računaju skalarni proizvod preko cele dužine i širine datog filtera. Pošto su dimenzije filtera manje od ulaznih dimenzija, pomeranjem filtera dobija se vrednost za svaki deo slike. Filter se pomera desno počevši od gornjeg

levog ugla slike sve do kranje desne ivice slike, zatim se filter pomera prema dole, i ovaj postupak se ponavlja duž celog ulaznog sloja (slike). Slika 3.12 predstavlja konvoluciju ulaznog sloja slike i filtera.



**Slika 3.12** Konvolucija filtera (kernela  $K$ ) i ulaznog sloja  $I$

Rezultat ovakve konvolucijske operacije je izlazna mapa odlika (eng. *Feature map*) koju je filter pronašao. Važno je napomenuti da se na ulaznom sloju primjenjuje više ovakvih konvolucija sa različitim filterima što prouzrokuje dobijanje većeg broja jedinstvenih mapa odlika. Spajanjem ovih mapa odlika dobija se izlazni, rezultujući sloj konvolucijskog bloka, slika 3.13 [73].



**Slika 3.13** Mape odlika kao rezultat konvolucijskog sloja

Dimenzije ovako dobijenog izlaznog sloja zavise od nekoliko različitih parametara, a to su:

- **Dubina** – određena brojem filtera koji se koristi, veći broj filtera uzrokuje veći broj odlika
- **Dimenzije filtera** – dimenzije dvodimenzionalne matrice koje koristimo kao filter u okviru konvolucijskog sloja, najčešće korišćene dimenzije filtera su  $3 \times 3$ ,  $5 \times 5$  ili  $7 \times 7$ , ali koriste se i druge dimenzije u zavisnosti od arhitekture i njene primene.
- **Korak** (eng. *stride*) – predstavlja broj piksela koji se preskaču prilikom pomeranja filtera. Na primer, korak veličine 2 označava da se filter pomera za dva polja.
- **Dopuna** (eng. *padding*) – predstavlja dopunu visine i širine izlazne mape sa pikselima po ivicama. Konvolucija utiče na smanjenje dimenzije slike, smanjenjem originalne slike u početnim slojevima dovodi do gubitka potencijalno vrednih informacija. Iz tog razloga, koristi se tehnika dopune koja oivičava matricu nekim konstantnim vrednostima. Često se koristi dopuna sa nulama (eng. *Zero-padding*).

Slika 3.14 predstavlja operaciju konvolucije nad ulaznim slojem dimenzija  $6 \times 6$  sa filterom dimenzije  $3 \times 3$ , koristeci dopunu sa nula pikselima  $p = 1$ . U ovom primeru sačuvana je dimenzija izlazne mape odlika.

0	0	0	0	0	0	0	0
0	3	3	4	4	7	0	0
0	9	7	6	5	8	2	0
0	6	5	5	6	9	2	0
0	7	1	3	2	7	8	0
0	0	3	7	1	8	3	0
0	4	0	4	3	2	2	0
0	0	0	0	0	0	0	0

$\xrightarrow{6 \times 6 \rightarrow 8 \times 8}$

\*

1	0	-1					
1	0	-1					
1	0	-1					

3x3

=

-10	-13	1					
-9	3	0					

$\xrightarrow{8 \times 8 \rightarrow 6 \times 6}$

**Slika 3.14** Konvolucija sa dopunom 0 piksela

Pored izbora slojeva i njihovog rasporeda u sekvenci blokova koji sačinjavaju jednu arhitekturu konvolucijske neuronske mreže, gore navedeni parametri takođe utiču na specifičnost arhitekture konvolucijske neuronske mreže.

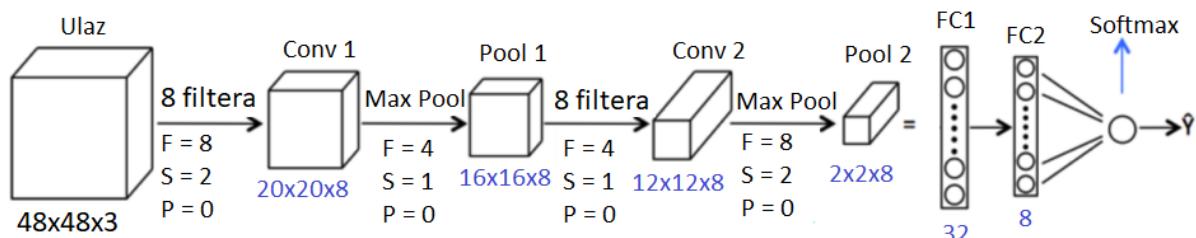
Ova četiri parametra su poznati kao hiper-parametri (eng. *hyperparameters*). Izbor ovih parametara utiče na dimenzije (veličinu) same neuronske mreže kao i na samu performantnost arhitekture [74].

U konvolucijskim slojevima rezultujuća dimenzija računa se kao:

$$D_{nova} = \frac{D - F + 2P}{S} + 1 \quad (3.3)$$

gde  $D$  predstavlja staru dimenziju (ulaznu dimenziju konvolucijskog sloja), može da predstavlja širinu ili visinu.  $P$  predstavlja dopunu u vidu broja piksela, dok  $F$  predstavlja širinu filtera (kernela), dok  $S$  predstavlja korak prilikom prelaza između konvolucija. Dubina izlazne mape odlika predstavlja broj filtera koji se koristi.

Slika 3.15 predstavlja izračunate dimenzije za primer standardne arhitekture sa slike 3.11 na osnovu izabranih hiper-parametara za ulaznu dimenziju slike  $48x48x3$ .



**Slika 3.15** Primer arhitekture i dimenzije slojeva na osnovu izabranih hiper-parametara

Broj težina za obučavanje na ovom primeru arhitekture predstavlja ukupan broj parametara za učenje po svakom sloju.

Pošto slojevi sažimanja nemaju težine za učenje, ukupan broj parametara je suma težina na konvolucijskim slojevima i potpuno povezanim slojevima:

$$\sum \text{Conv 1} + \sum \text{Conv 2} + \sum \text{FC1} \cdot \text{FC2} = 8 \cdot 8 \cdot 8 + 4 \cdot 4 \cdot 8 + 32 \cdot 8 = 896 \quad (3.4)$$

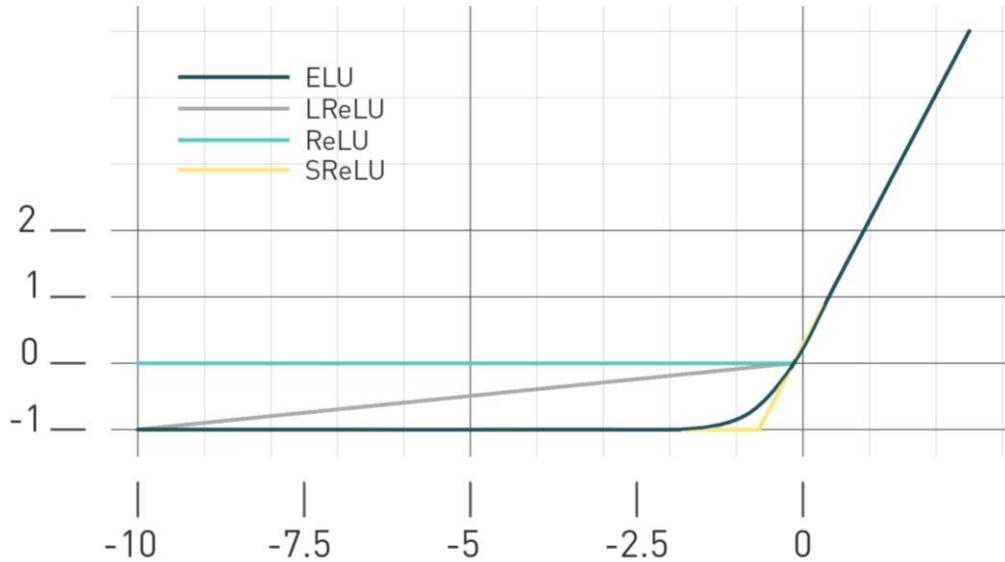
Broj težina za učenje standardnom potpuno povezanom neuronskom mrežom bi bio znatno veći u poređenju sa konvolucijskom, što predstavlja veliku prednost ove arhitekture.

### 3.5.2.2 Aktivaciona funkcija

U savremenim arhitekturama, u svrhu normalizacije, često se nakon konvolucijskog sloja primenjuje aktivaciona funkcija na trodimenzionalni izlaz. Najčešće primenjena aktivaciona funkcija je ReLu funkcija (eng. *Rectified Linear Unit Layer*). Uloga ove aktivacione funkcije je da „imitira“ mogućnost biološkog neurona da bude aktiviran ili ne. ReLU aktivaciona funkcija odbacuje negativne vrednosti tako što svaka negativna vrednost piksela se postavlja na 0:

$$\text{ReLU}(x) = \max(x, 0) \quad (3.5)$$

Pored standardne ReLU funkcije koriste se i LReLU (eng. *Leaky ReLU*), PReLU (eng. *Parametric ReLU*), ELU (eng. *Exponential Linear Unit*), SReLU (eng. *S-shaped ReLU*) i mnoge druge [75].



**Slika 3.16** Varijacije ReLU aktivacione funkcije

### 3.5.2.3 Sloj sažimanja

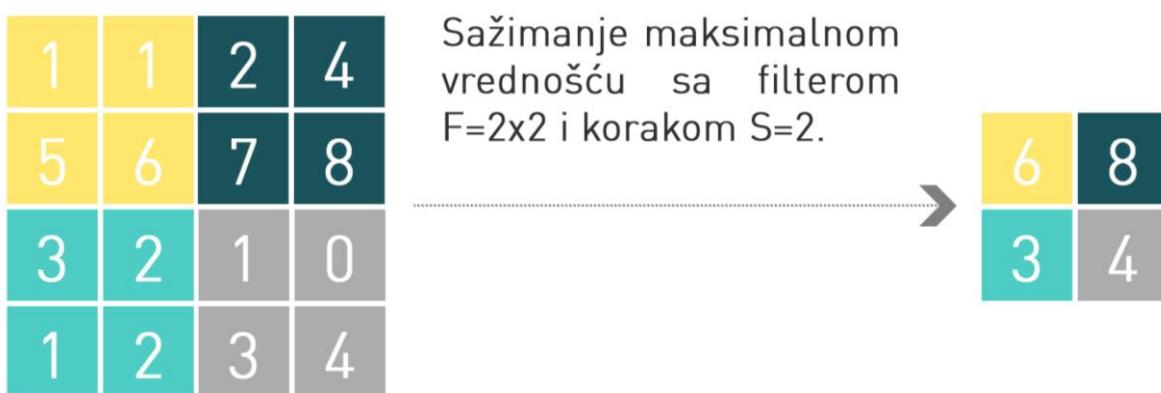
Sloj sažimanje predstavlja filter koji nelinearno redukuje broj piksela, odnosno sažima dimenziju slike (eng. *Down-sampling*). Ovaj filter ne sadrži učene težine.

Kod arhitektura konvolucijskih neuronskih mreža najčešće se koristi tehniku sažimanja maksimumom (eng. *Max pooling*) koja se zasniva na tome da se određeni region piksela zamjenjuje maksimalnom vrednošću piksela u datom regionu. Na ovaj način najizraženije informacije se propagiraju dalje kroz neuronsku mrežu.

Nekada se u arhitekturama konvolucijskih neuronskih mreža koristila i tehniku sažimanja srednjom vrednošću (eng. *Average pooling*), dok savremene arhitekture najčešće koriste prethodno navedenu tehniku sažimanja.

Izlazne dimenzije nakon primene sažimanja računaju se kao:

$$D_{nova} = \frac{D - F}{S} + 1 \quad (3.6)$$



**Slika 3.17** Sažimanje maksimalnom vrednošću

### 3.5.2.4 Potpuno povezani sloj

U nekim arhitekturama konvolucijskih neuronskih mreža u finalnim delovima koristi se standardni potpuno povezani slojevi – svi neuroni ovog sloja povezani su sa svim izlazima iz prethodnog sloja.

U klasifikacionim problemima izlaz konvolucijske neuronske mreže dovodi se na aktivacionu funkciju, najčešće korišćena funkcija je Softmax:

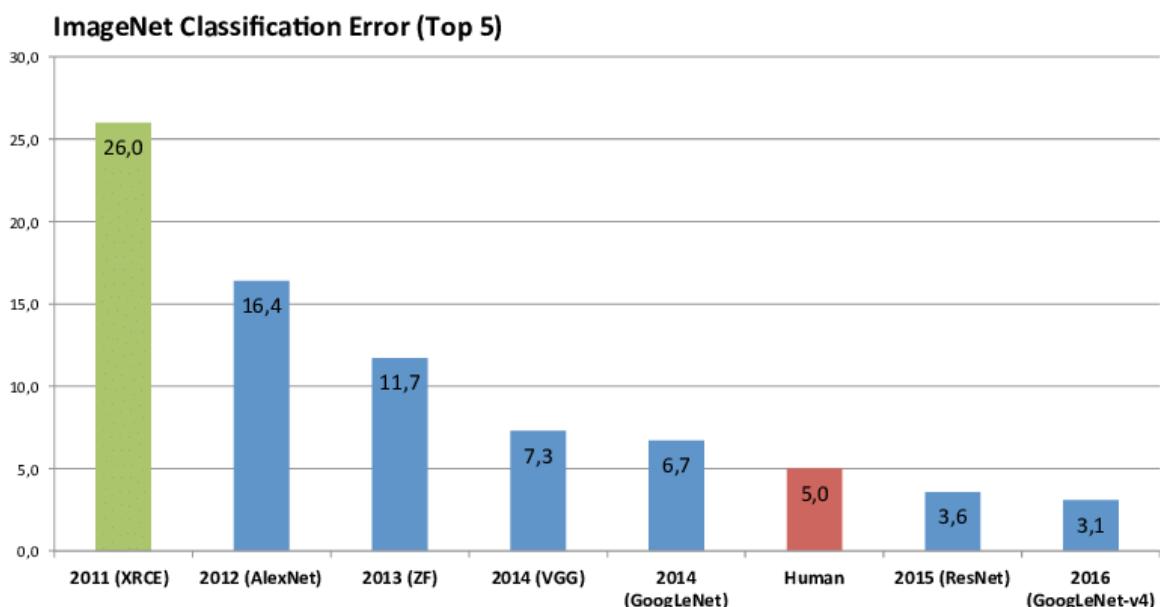
$$s(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}} \quad . \quad (3.7)$$

Ova funkcija normalizuje rezultate dobijene na izlazu mreže u opsegu [0,1], što je pogodno za klasifikacionu upotrebu.

### 3.5.2 Pregled savremenih arhitektura

Još 2012. godine je duboka neuronska mreža postigla značajne rezultate u zadacima klasifikacije i detekcije objekata nad velikom bazom slika *ImageNet* [76] u okviru takmičenja ILSVRC (eng. *ImageNet Large Scale Visual Recognition Challenge*). Tu je po prvi put tehnika dubokog učenja, odnosno konvolucijske neuronske mreže, pokazala značajno unapređenje dotadašnjih rezultata dobijenih standardnim tehnikama mašinskog učenja i ručne obrade odlika. *ImageNet* baza slika sačinjena je od više od 20 hiljada kategorija (klasa) sa preko 80 miliona slika.

Na slici 3.18 prikazan je grafikon koji prikazuje pobedničke arhitekture na ILSVRC takmičenju sa



**Slika 3.18** ImageNet ILSVRC takmičenje [77]

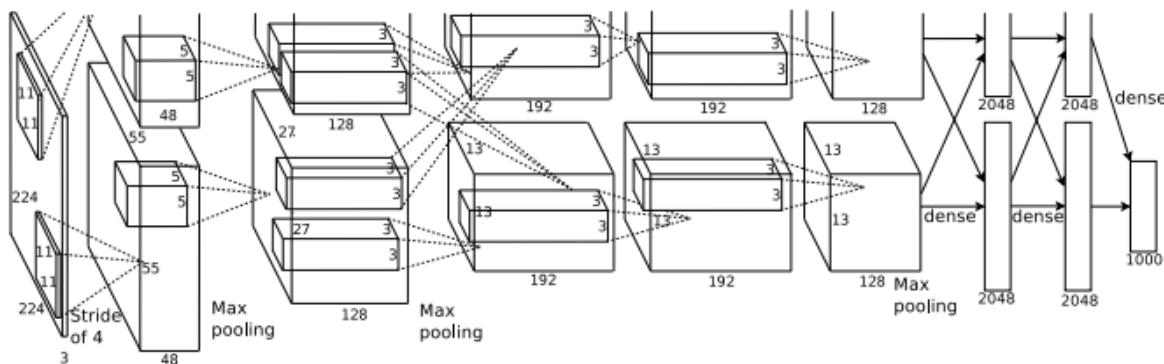
njihovim rezultatima. Od 2012. do 2017. godine, kada je i poslednji put održano ovo takmičenje, pobedničke arhitekture su bile konvolucijske neuronske mreže.

Ove arhitekture su vremenom postale uspešnije od samog čoveka u zadacima klasifikacije i detekcije nad *ImageNet* bazom slika. Razvijene arhitekture postale su standardne arhitekture koje su se pokazale uspešne ne samo nad *ImageNet* bazom slike već na značajno širem opsegu problema, preko tehnika prenošenog učenja (eng. *Transfer learning*) ili kao osnova ili ideja za nove arhitekture. Više detalja o samim ovim tehnikama i pristupima biće dato u drugoj polovini ove disertacije.

Zbog svoje široke upotrebe, u okviru narednih sekcija biće opisane ove standardne arhitekture koje su bile prikazane na ILSVRC takmičenjima u toku godina.

### 3.5.2.1 AlexNet

AlexNet arhitektura predstavlja početak dominacije konvolucijskih neuronskih mreža u kompjuterskoj viziji [78]. Ova neuronska mreža je vrlo slične arhitekture kao LeNet mreža [71] iz 1998 godine.



**Slika 3.19** AlexNet arhitektura [80]

AlexNet je sačinjena od  $11 \times 11$ ,  $5 \times 5$  i  $3 \times 3$  konvolucija, koristeći slojeve sažimanja sa maksimalnom vrednošću. ReLU aktivacije bile su primenjene posle svakog konvolucijskog i potpuno povezanog sloja.

### 3.5.2.2 VGGNet

VGGNet je bila druga arhitektura na ILSVRC takmičenju iz 2014. godine, ali je dosta korišćena kao osnovna arhitektura za rešavanje mnogih problema klasifikacije i detekcije. Osnovna verzija iz rada [81] sačinjena je od 16 i 19 slojeva, sadrži samo konvolucije  $3 \times 3$  sa pomerajem od 1, dok slojevi sažimanja su uvek dimenzije  $2 \times 2$  sa pomerajem 2.

Odlikuje je veli broj parametara učenja i uzročno sa tim i jedna je od sporijih u poređenju sa drugim savremenim arhitekturama konvolucijskih neuronskih mreža, slika 3.20 prikazuje slojeve VGG-16 arhitekture.

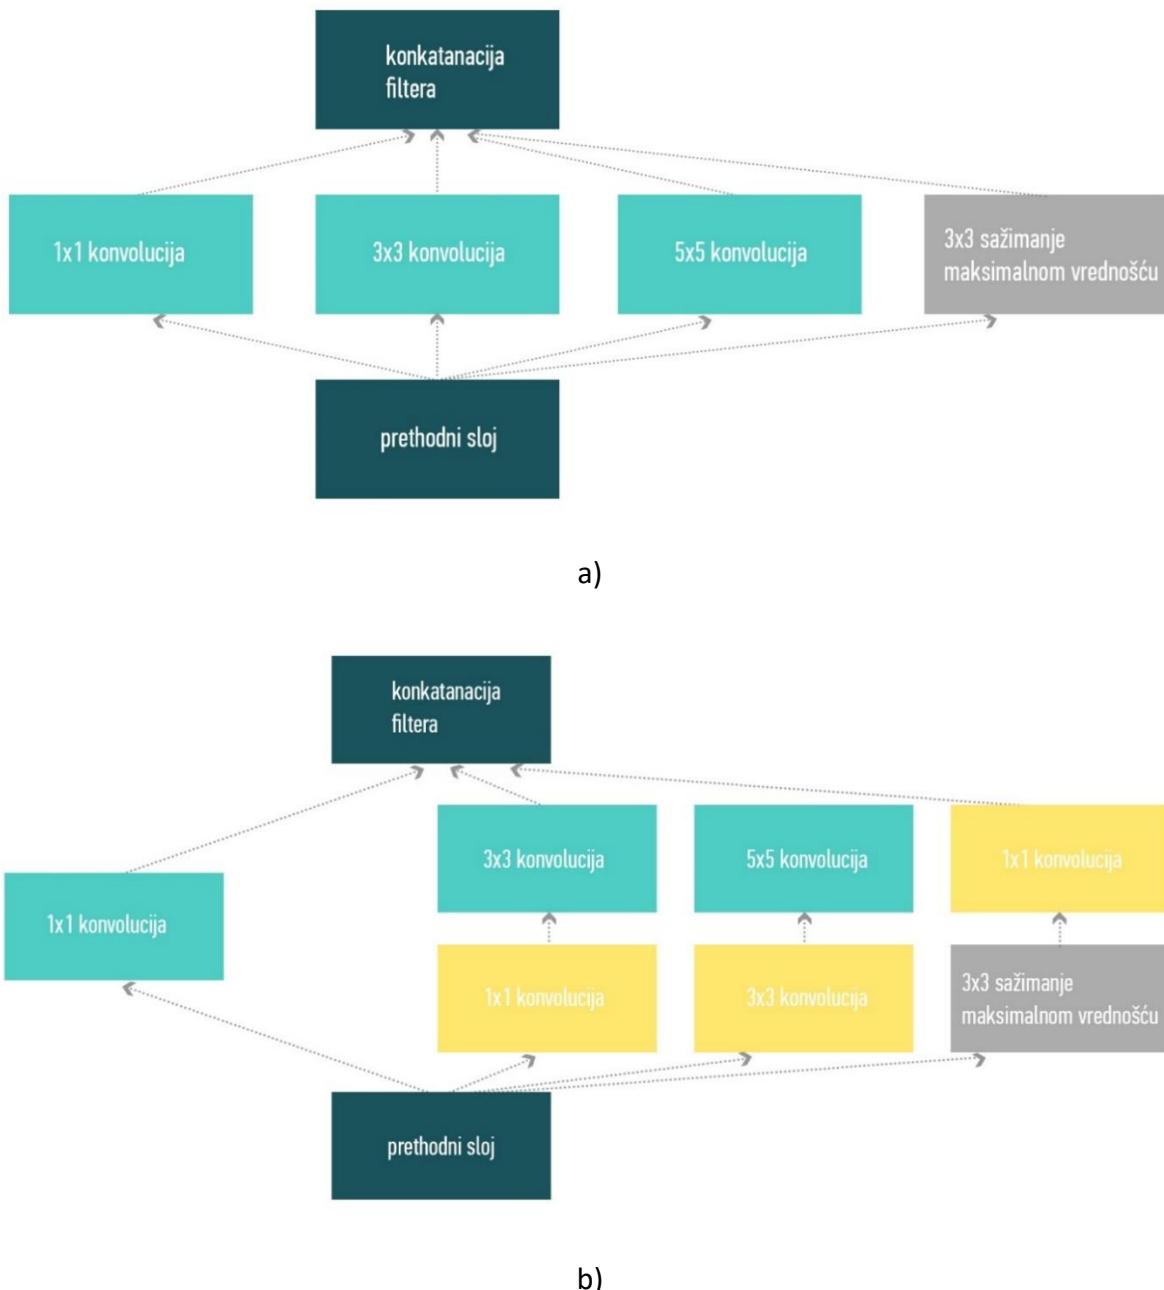


**Slika 3.20** VGG-16 arhitektura [82]

### 3.5.2.3 GoogLeNet

GoogLeNet, još poznatija kao Inception V1, je pobednička arhitektura iz 2014. godine [83]. Ova arhitektura je bila prva konvolucijska neuronska mreža koja je bila približne tačnosti kao i sam čovek, top-5 greška je bila 6.67%, dok je ljudska top-5 greška iznosila 5.1%.

GoogLeNet je iako sačinjena od 22 sloja (27 slojeva ako se računaju i slojevi sažimanja), ima svega oko 4 miliona težina za obučavanje za razliku od AlexNet arhitekture koja ima oko 60 miliona parametara za obučavanje.



**Slika 3.21** “Inception” jedinica a) osnovna verzija i b) sa redukovanim dimenzijama [84]

Glavni gradivni blok ove mreže predstavlja “inception” jedinica koja je sačinjena od ulaza prethodnog sloja koji se propagira na 3 različita filtera dimenzija  $1 \times 1$ ,  $3 \times 3$  i  $5 \times 5$  uz sloj sažimanja sa maksimalnom vrednošću.

Izlazi tih filtera se spajaju i propagiraju na sledeću “inception” jedinicu. Redukovana “inception” jedinica sadrži dodatni sloj  $1 \times 1$  konvolucije pre  $3 \times 3$  i  $5 \times 5$  konvolucije radi

---

redukovana broja ulaznih kanala i samim tim se dobija na uštedi u vremenu obrade. Slika 3.18 prikazuje "inception" jedinicu.

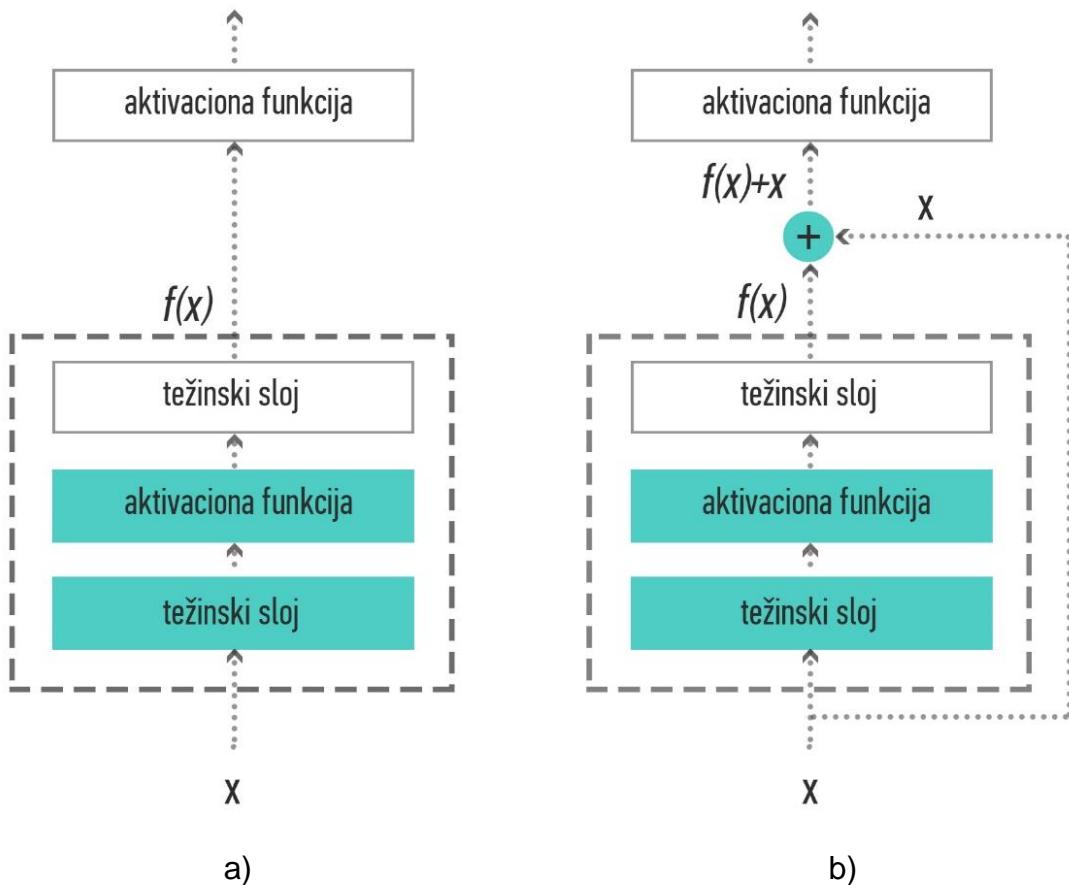
### 3.5.2.3 ResNet

ResNet (eng. *Residual Neural Network*) predstavlja pobedničku arhitekturu iz 2015. ILSVRC takmičenja [85]. Novitet ove arhitekture predstavljaju rezidualni blokovi (eng. *residual blocks*) koji omogućuju treniranje veoma „dubokih“ neuronskih mreža jer ovaj pristup rešava problem nestajućih gradijenata (eng. *vanishing gradient*).

Neuronska mreža trenirana metodom propagacije unazad oslanja se na optimizacione tehnike opadajućih gradijenata za nalaženje optimalnih težinskih vrednosti radi minimizacije funkcije gubitaka. Kada se dodaje veći broj slojeva, ponavljajući proces proizvoda izvoda, gradijenti postaju veoma mali, dodavanjem većeg broja slojeva neće unaprediti performanse mreže.

Autori ResNet arhitekture predstavili su prečice u konekciji slojeva (eng. *Identity shortcut connections*) – slojeve koji nemaju praktičnu ulogu. Ovi slojevi se preskaču, ponovnim korišćenjem aktivacione funkcije iz prethodnog sloja.

Zahvaljujući ovom pristupu, ResNet arhitektura korišćena na ILSVRC takmičenju bila je sačinjena od čak 152 sloja, zadržavajući jednostavnost treniranja kao i samu brzinu.



**Slika 3.22** Razlika između a) standardnog i b) rezidualnog bloka neuronske mreže [86]

### 3.5.3 Detekcija objekata

Od kako su konvolucijske neuronske mreže pokazale dominantnost na takmičenjima u klasifikacionim zadacima, tako su počeli da se predstavljaju i detekcioni algoritmi bazirani na konvolucijskim neuronskim mrežama koji pokazuju značajno bolje performanse i rezultate u poređenju sa tradicionalnim pristupima.

Nekoliko baza slika zajedno sa odgovarajućim meta-podacima se koriste kao referentne baze za uspešnost algoritama za detekciju.

*PASCAL VOC* (eng. *PASCAL Visual Object Classification*) je baza slika koja se koristila na takmičenjima vezanim za problem detekcije. Sačinjena je od oko 10 hiljada slika i 20 različitih klasa [87]. Microsoft je za svrhu takmičenja u oblasti detekcije

---

objavio bazu od preko 160 hiljada slika, odnosno oko 120 hiljada za trening i validaciju i oko 40 hiljada za testiranje, sa 80 različitih klasa [79].

*ImageNet* baza, predstavljena 2013. godine, predstavlja bazu od oko 500 hiljada slika sa 200 različitih klasa za detekciju. Ova baza slika je ujedno i jedna od najvećih ove vrste, ali je retko korišćena na takmičenjima zbog svoje veličine.

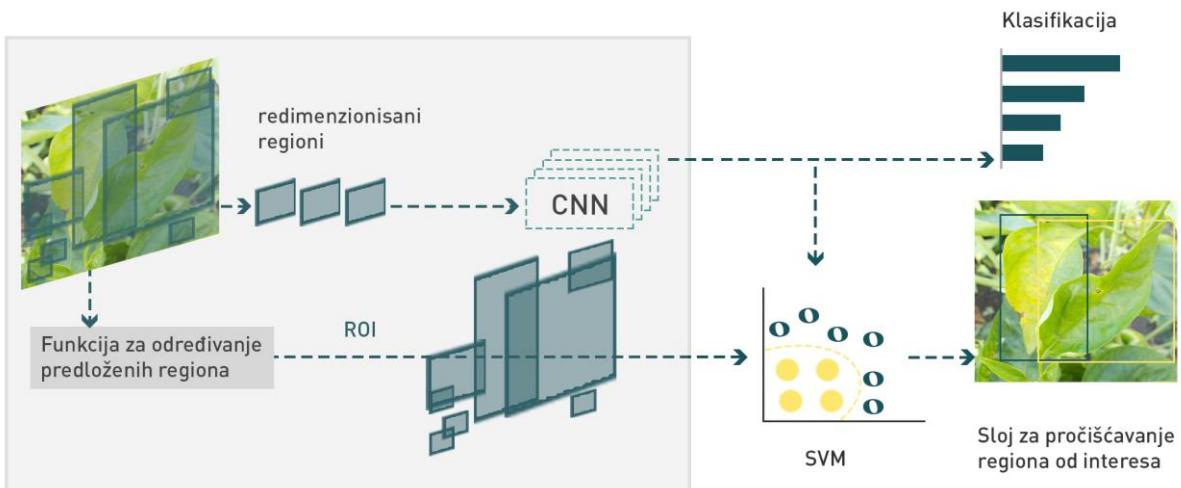
### 3.5.3.1 R-CNN

Prvi od uspešnih algoritama za prepoznavanje obrazaca koji su bazirani na konvolucijskim neuronskim mrežama je R-CNN (eng. *Region-based Convolutional Network*) [88].

Ova arhitektura oslanja se na algoritam selektivne pretrage (eng. *Selective search*) da bi se pronašli svi predloženi regioni gde se nalazi objekat od interesa (eng. *Region proposals*) [89]. Algoritam selektivne pretrage počinje inicijalno sa malim regionima u slici koje hijerarhijski grupiše, sve dok se ne dođe do finalne grupe, koja predstavlja region koji sadrži sliku u celosti.

Predloženim regionima dobijenim selektivnom pretragom se menja veličina na dimenzije odgovarajuće arhitekture konvolucijske neuronske mreže koja se koristi u R-CNN algoritmu. Zatim se ti regioni sa izmenjenim dimenzijama prosleđuju konvolucijskoj neuronskoj mreži. Izlaz ove neuronske mreže je vektor odlika koji se prosljeđuje SVM (eng. *Support Vector Machine*) klasifikatoru da bi se odredila verovatnica pripadnosti tog ulaznog vektora klasi.

R-CNN algoritam je veoma intuitivan ali je zbog svog načina rada veoma spor. Slika 3.23 predstavlja način funkcionisanja R-CNN algoritma za detekciju objekata.



**Slika 3.23** Uopšteni prikaz rada R-CNN algoritma

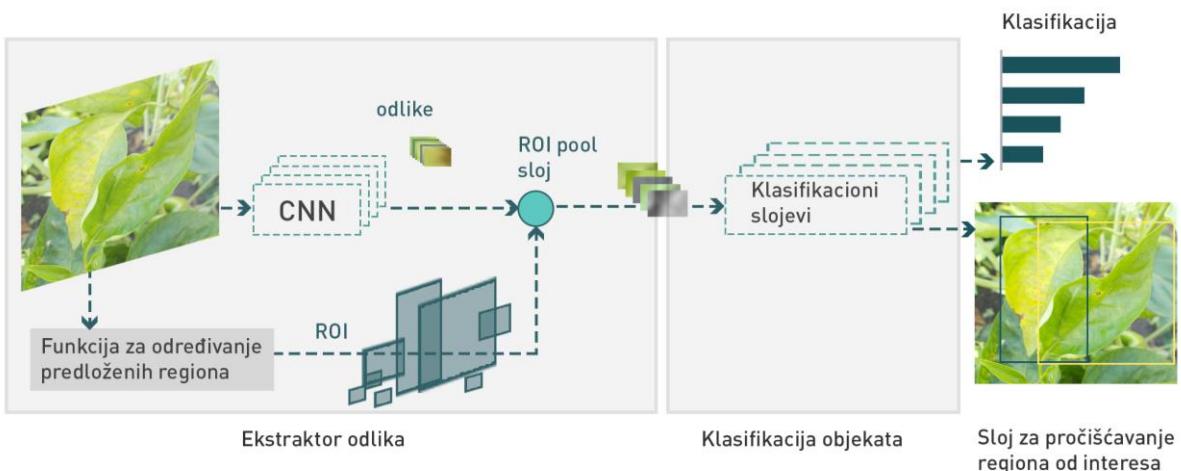
### 3.5.3.2 Fast R-CNN

Fast R-CNN predstavlja modifikaciju originalnog R-CNN algoritma [90] radi ubrzanja procesa detekcije. Izmene uključuju da se ekstrakcija odlika vrši pre samog računanja predloženih regiona, na taj način će se vršiti samo jedan prolaz kroz konvolucijsku neuronsku mrežu umesto  $N$ , gde  $N$  predstavlja broj regiona dobijenih selektivnom pretragom.

Takođe, Fast R-CNN algoritam zamenjuje SVM klasifikator sa Softmax slojem, na taj način sama neuronska mreža vrši proces klasifikacije. Umesto treniranja više različitih SVM klasifikatora (broj klasifikatora odgovara broju klasa objekata) koristi se Softmax sloj unutar konvolucijske neuronske mreže za računanje verovatnoće pripadnosti.

Generisanje predloženih regiona se vrši nad mapom odlika sa poslednjeg konvolucijskog sloja umesto sa originalne slike.

Sa ovakvim promenama, Fast R-CNN algoritam je značajno brži od svog prethodnika. Slika 3.24 predstavlja način funkcionisanja Fast R-CNN algoritma za detekciju objekata.



**Slika 3.24** Uopšteni prikaz rada Fast R-CNN algoritma

### 3.5.3.3 Faster R-CNN

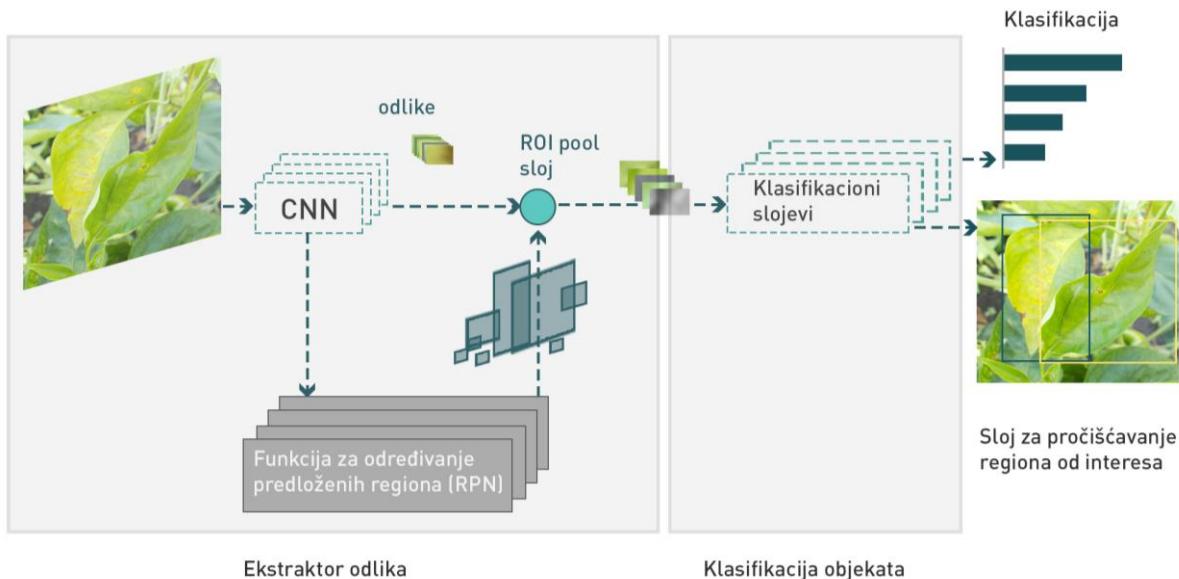
Iako značajno brži algoritam, Fast R-CNN se i dalje oslanjao na selektivnu pretragu radi dobijanja predloženih regiona, što je predstavljalo usko grlo te arhitekture, jer je računski skupa operacija.

Faster R-CNN predstavlja novu RPN (eng. *Region Proposal Network*) mrežu koja direktno pronalazi predložene regije, vrši predikciju regije i detekciju objekata [91]. Na ovaj način se eliminiše upotreba algoritma za selektivnu pretragu.

RPN funkcioniše tako što se na posljednji sloj inicijalne konvolucijske neuronske mreže definiše prozor dimenzija  $3 \times 3$  koji se pomera po mapi odlika i mapira je u manje dimenzije. Za svaku lokaciju prozora generiše se više mogućih  $k$  fiksiranih dimenzija pravougaonih regija (eng. *Bounding boxes*), na primer mali, veliki, dugački pravougaoni regiji i slično.

Svaki predloženi region sadrži verovatnoću da li je objekat detektovan ili ne u ovom regionu (eng. *Objectness score*) i koordinate regije. Ovih  $k$  predloženih regija detektovanih pomeranjem prozora kroz mapu odlika se nazivaju usidreni regiji (eng. *Anchor regions*). Na osnovu određenog praga vrednosti da li je objekat detektovan ili ne, odbacuju se određeni usidreni regiji i ostaju samo oni koji se smatraju relevantnim.

Mapa odlike dobijena inicijalnom konvolucijskom neuronskom mrežom zajedno sa usidrenim regionima dobijenim RPN-om se prosleđuju na Fast R-CNN model. Na taj način upotrebom RPN-a eleminiše se sporo preračunavanje regiona selektivnom pretragom. Faster R-CNN predstavlja praktično kombinaciju RPN sa Fast R-CNN-om.



**Slika 3.25** Uopšteni prikaz rada Faster R-CNN algoritma

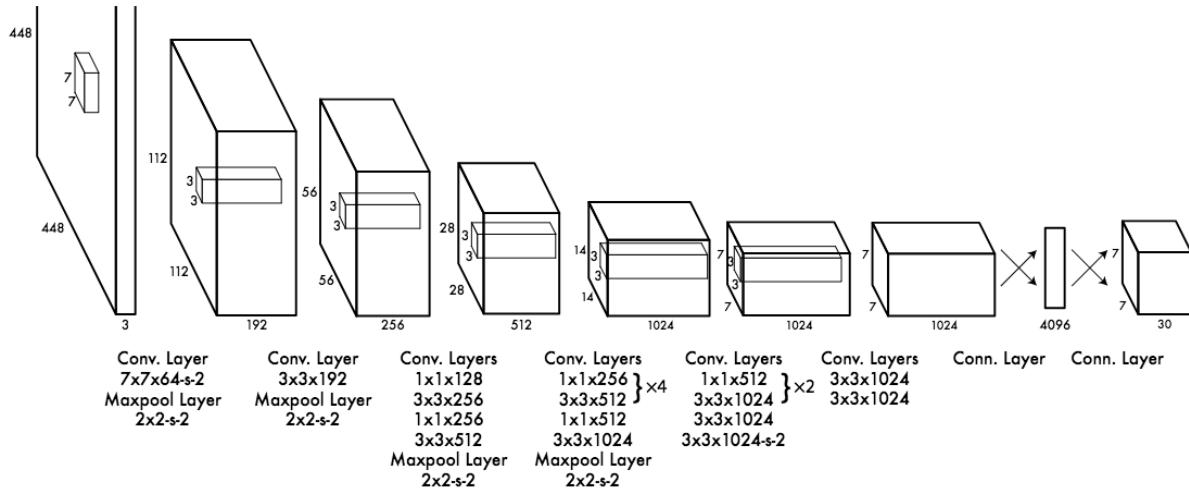
### 3.5.3.4 YOLO

Prethodni algoritmi iako uspešni u rešavanju problema detekcije, i dalje nisu dovoljno performantni za predikciju u „realnom vremenu“ (eng. *Real-time prediction*).

YOLO (eng. *You Only Look Once*) algoritam detekcije predstavljen u radu [92] omogućuje da model izvršava dovoljno brzu detekciju da bi mogao da se koristi u realnom vremenu, 45 frejmova u sekundi.

Algoritam preuzima sliku kao ulaz, deli je na matricu dimenzija  $S \times S$ , svaka ćelija matrice vrši predikciju  $B$  broja regiona zajedno sa vrednošću predikcije. YOLO arhitektura oslanja se na konvolucijsku neuronsku mrežu od 24 konvolucijska sloja zajedno sa dva potpuno povezana sloja. Autori ove arhitekture predstavili su i jednostavniji model sa svega 9 konvolucijskih slojeva.

YOLO model vrši predikciju velikog broja regiona. Često ti regioni ne sadrže objekte, i iz tog razloga NMS (eng. *Non-Maximum Suppression*) metoda se primenjuje na samom kraju mreže radi povezivanja regiona koji se u velikoj meri preklapaju.



**Slika 3.26** YOLO arhitektura [92]

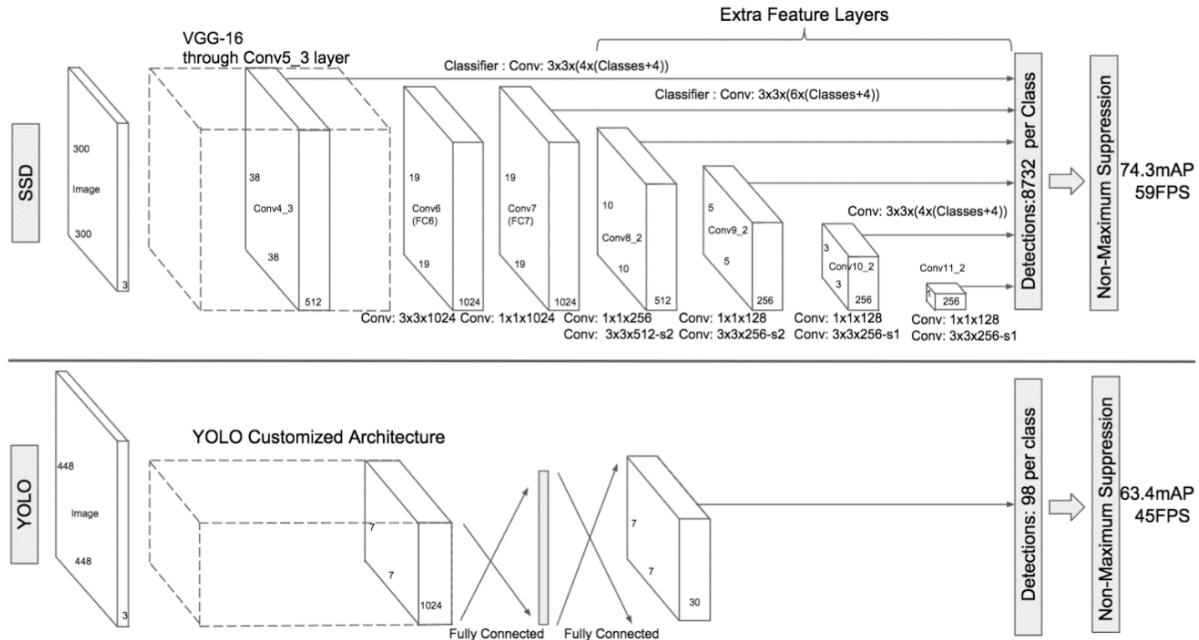
### 3.5.3.5 SSD

SSD (eng. *Single-Shot Detector*) je algoritam koji vrši pronalaženje regiona i klasnu predikciju u vidu jedne specijalizovane konvolucijske neuronske mreže [93].

Ulagana slika prolazi kroz slojeve konvolucija sa filterima različitih dimenzija ( $3 \times 3$ ,  $5 \times 5$  i  $10 \times 10$ ). Specifični konvolucijski slojevi sa  $3 \times 3$  filterima, slojevi za dodatne odlike (eng. *Extra feature layers*), su služili da procesiraju mape odlika sa određenih slojeva mreže radi predikcije regiona. Ovo je sličan pristup kao i kod usidrenih regiona u Fast R-CNN algoritmu.

Kao i kod gore navedenog YOLO algoritma, NMS metoda se koristila da bi se koristili samo najrelevantniji regioni. Pored toga, koristio se i HNM (eng. *Hard Negative Mining*) radi pročišćavanja negativnih regiona koji su bili predloženi.

Pored gore navedenih algoritama za detekciju objekata na slikama, u skorije vreme vredno pomena su algoritmi kao što su NASNet (eng. *Neural Architecture Search Net*) predstavljen u radu [94], Mask R-CNN (eng. *Mask Region-based Convolutional Network*) [95], brojne varijacije i unapređenja YOLO algoritama kao i mnogi drugi.



**Slika 3.27** SSD arhitektura [93]

### 3.5.4 GAN

GAN (eng. *Generative Adversial Networks*) mreže predstavljene su u radu [96] iz 2014. godine, i za razliku od prethodnih arhitektura u ovom poglavlju imaju drugačiju namenu.

GAN arhitektura predstavlja generativni model sastavljen od dve neuronske mreže koje imaju različite uloge, generatorske i diskriminatorske neuronske mreže.

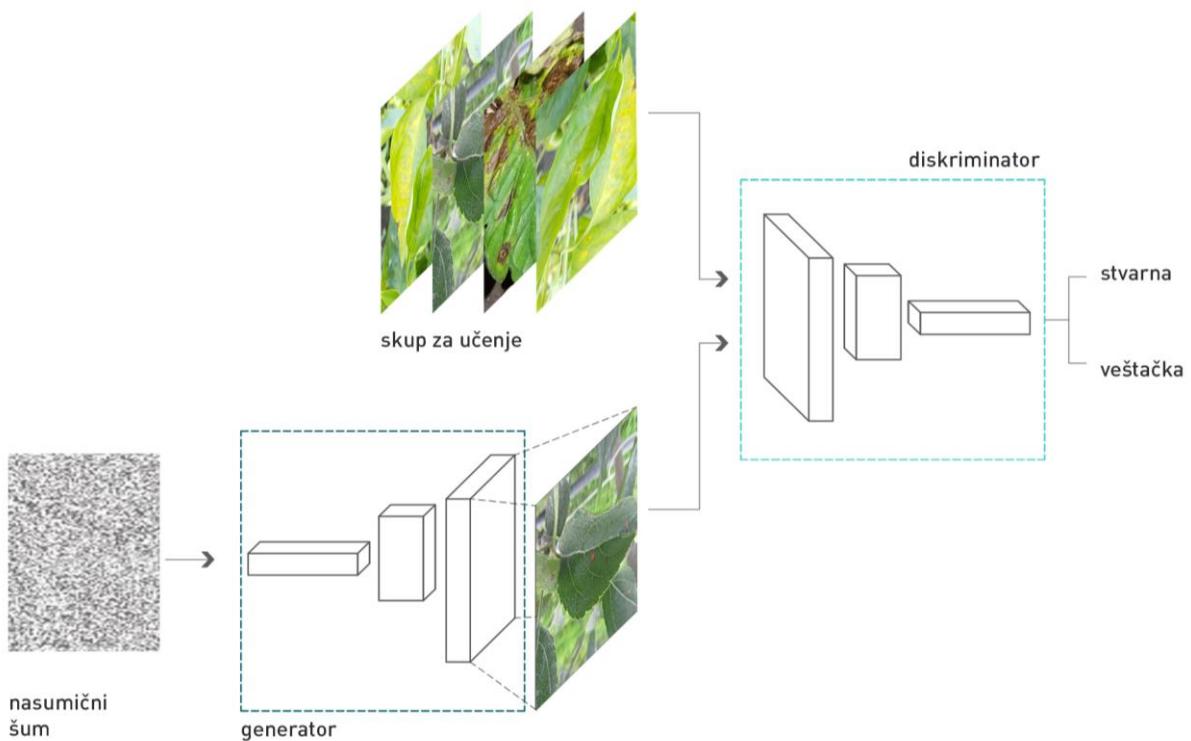
Ulaz u generator predstavlja šum  $n$ , na osnovu koga generiše sliku  $x$ , gde je  $x=G(n)$ . Šum  $n$  predstavlja prostor latentnih odlika slike koja se generiše.

U klasifikaciji dubokog učenja se ne kontrolišu odlike koje predstavljaju model, slično i u GAN arhitekturi se ne kontroliše semantičko značenje šuma  $n$ , prepušta se samoj mreži da u toku procesa treniranja odredi značenje.

Diskriminator predstavlja nadgledanu mrežu koja ima ulogu klasifikacije da li je slika „lažna“ (generisana od strane generatorske mreže) ili originalna. Diskriminatorska

mreža se trenira korišćenjem kako slika originalnih tako i slika pristiglih iz generatorske mreže.

Na slici 3.28 prikazan je uopšteni izgled GAN arhitekture.



**Slika 3.28** Uopšteni prikaz rada GAN arhitekture

Primena GAN mreža je široka. Veliki broj radova predstavlja specijalizovane GAN arhitekture u cilju predikcije sledećeg frejma u videu [97], povećanja rezolucije slike [98], prevodenja slike u sliku [99], generisanje slike na osnovu teksta (eng. *Text-to-Image*) [100] i mnogi drugi.

## 4. Pregled relevantne literature

Identifikovanje bolesti biljaka na osnovu vizuelne obzervacije je vremenski zahtevan i kompleksan zadatak. Obično je potrebno kontinualno praćenje stanja što je veoma skupo i u većini slučajeva neizvodljivo. Iz tog razloga istraživači se fokusiraju na pronalaženje alternativnih rešenja u vidu automatskih sistema baziranih na algoritmima koji bi na osnovu vizuelnih podataka donosili prediktivnu odluku. Različiti pristupi bazirani na mašinskom učenju su se koristili do sada za rešavanje ovog problema u cilju povećanja tačnosti donošenja odluke, smanjenju cene i odstranjivanja subjektivnosti u samom procesu.

Veliki broj radova je istraživao uspešnost tradicionalnih algoritama mašinskog učenja za detekciju bolesti biljaka na osnovu slike lista. Autori rada [101] koristili su SVM klasifikator istreniran da razlikuje zdrav pirinač i pirinač oboleo od Bakanae (jap. *Bakanae* = „ludi klijanci“) bolesti, koja predstavlja vrlo čestu bolest pirinča koja izaziva izrazito izduživanje stabljike i listova što izaziva da se biljka polegne na tlo, što rezultuje nemogućnošću produkcije semena. Autori ovog rada doneli su zaključak da predloženi metod, u poređenju sa standardnom tehnikom detekcije (istraživanje golim okom) je značajno brži i manje subjektivan.

Autori rada [102] istražili su nad pet klasa bolesti sojinog lista mogućnost smanjenja ljudskog faktora u determinisanju bolesti tako što su trenirali tri različita klasifikatora: SVM, KNN i probabilističku neuronsku mrežu (eng. *Probabilistic Neural Network*). Autori su istakli važnost izvlačenja relevantnih odlika, a takođe i uticaj pozadine na performantnost modela. Izdvajanje pozadine, odnosno segmentacija dela od interesa (obolelih regionala) povećava tačnost samog klasifikatora. Slični zaključci donešeni su i iz eksperimenata u radu [103] gde se takođe koristio SVM model treniran nad listovima pamuka. Razvijajući modele za detekciju lisnih vaši na pšenici, autorи rada [104] došli su do zaključaka da odlike kao što su boja, gustina i lokacija obolelog dela

značajno utiču na tačnost modela. Takođe primetili su korelaciju performantnosti modela i vremenskih uslova pod kojima je slika načinjena.

Autori rada [105] poredili su performantnost algoritama za detekciju bolesti biljaka na osnovu slike lista. Koristili su malu bazu podataka od svega 40 primeraka nad kojim su trenirali sledeće algoritme: KNN, NB, SVM, DT i RNN. Rezultati su pokazali da je SVM pristup bio performantniji od ostalih algoritama koji su bili uzeti u obzir u okviru eksperimenta.

Autori radova [106-108] istraživali su napredne algoritme koji pokazuju da sistemi bazirani na neuronskim mrežama mogu biti uspešniji za detekciju bolesti biljaka od standardnih pristupa koji su prethodno navedeni.

Za sve klasične modele mašinskog učenja koji su se koristili za rešavanje automatskog detektovanja bolesti biljaka pokazalo se da su efikasni pod specifičnim uslovima i da ukoliko dođe do varijacija u uslovima, performanse ovih modela značajno opadaju [109]. Iako ovi standarni algoritmi predstavljaju fundamentalni pristup u rešavanju ovih problema trenutna istraživanja pokazuju potencijal u novim, naprednjijim algoritmima. Pošto su tehnike dubokog učenja demonstrirale velike mogućnosti i primene u različitim sferama, gde su po performansama daleko bolje od tradicionalnih metoda, ove tehnike našle su interesovanje među istraživačima koji pronalaze rešenja u okviru precizne poljoprivrede [110].

Od samog početka uspona algoritama dubokog učenja [111] postizani su najsavremeniji rezultati i performanse u različitim domenima: automatskom igranju računarskih igrica [112], procesiranju govornog jezika (eng. *natural language processing*) [113], autonomnoj vožnji [114] i mnogim drugim sferama. Različitost primene i uspešni rezultati algoritama dubokog učenja ohrabljaju istraživače da primenjuju ove tehnike i u oblasti poljoprivrede. Iz tog razloga u prethodnih nekoliko godina veliki broj radova u oblasti precizne poljoprivrede istražuje uticaj ovih metoda za rešavanje problema automatske detekcije bolesti biljaka.

Ostatak ovog poglavlja baviće se pregledom trenutnih istraživanja baziranih na tehnikama dubokog učenja i njihovim rezultatima.

U radu [115], slike lista banane preuzete su iz *PlantVillage* baze slika [116]. Dve uobičajene klase bolesti lista banane su uzete u obzir u ovikru eksperimentalnog dela ovog rada. Baza korišćena u ovom eksperimentu sačinjena je od ukupno 3700 slika koje su bile isečene na 60x60 piksela. Takođe, eksperiment se izvodio nad slikama u boji i crno belim slikama, kako bi se istražio uticaj boje kao odlike u procesu donošenja odluke algoritma. Model korišćen u eksperimentu je baziran na LeNet [117] arhitekturi konvolucijske neuronske mreže. Uzete su u obzir različite proporcije trening i test skupa podataka, i tako su postignute tačnosti u opsegu od 92% do 99%. Na osnovu rezultata eksperimenata autori su primetili značajan pad tačnosti modela koji je treniran nad crno belim slikama, što dovodi do zaključaka da boja predstavlja jednu od relevantnih odlika u procesu detekcije bolesti biljaka. Takođe, autori su istakli bitnost lokalizacije bolesti, a takođe i uticaj sredine i realnog okruženja u kome se nalaze listovi od interesa.

Autori rada [118] koristili su proširenu verziju *PlantVillage* baze slika, koja sadrži 58 klasa (zdravih i obolelih listova) od 25 različitih vrsta biljaka. Eksperiment je uključivao treniranje pet različitih poznatih arhitektura konvolucijskih neuronskih mreža: AlexNet, AlexNetOWTBn, 129 GoogLeNet, OverFeat i VGG. Najveća finalna tačnost dobijena je poslednjom arhitekturom i iznosila je 99.53%. Važno je napomenuti da je 62.7% baze podataka sačinjeno od slika iz kontrolisanih uslova i da su i trening i test rezultati dobijeni korišćenjem iste baze podataka, što značajno utiče na finalni procenat tačnosti istreniranih modela.

Sličan pristup opisan je i u radu [119] gde je korišćena baza od 1053 slike listova jabuke zajedno sa 13689 augmentovanih slika. Eksperiment u ovom radu uključivao je istraživanje više različitih algoritama, kako standardnog mašinskog učenja, SVM i neuronske mreže sa propagacijom unazad, tako i duboke konvolucijske neuronske mreže, gde su autori rada trenirali arhitekture kao što su AlexNet, GoogLeNet, 136 ResNet-20 i VGGNet-16. Modifikovana AlexNet arhitektura je pokazala najbolje rezultate u detekciji četiri česta tipa bolesti koje se manifestuju na listu jabuke, sa ukupnom tačnošću od 97.62%. Jedan od glavnih fokusa ovog rada je na preprocesiraju sliku na način koji bi simulirao realna okruženja. Takođe autori rada istakli su značaj veće baze podataka i da bi potencijalni veći doprinos bio korišćenje nekih od algoritama detekcije objekata kao što su Faster R-CNN, YOLO ili SSD

algoritmi umesto standardnih klasifikacionih konvolucijskih arhitektura korišćenih u eksperimentu ovog rada.

U radu [120], autori su kroz eksperimentalne metode pokušali da prevaziđu trenutna ograničenja vezana za automatsku detekciju bolesti biljaka što uključuje: različita osvetljenja pod kojima se list može naći, vrlo složene pozadine slike, lokacije same bolesti na listu i sl. Autori rada prikupili su 5000 slika listova pradajza i uključili su augmentaciju u preprocesiranje koristeći tehnike geometrijske transformacije i transformacije nad intezitetom piksela. Na taj način, autori rada su proširili bazu podataka na ukupno 43398 primeraka sačinjenih od inicijalnih originalnih slika i sintetičkih slika dobijenih u fazi preprocesiranja. Autori ovog rada za razliku od prethodnih istraživanja koristili su detekciju objekata kao primarni metod za razliku od klasifikacionih arhitektura koje su istraživači koristili do sada. U okviru eksperimenta uključili su najčešće korišćene konvolucijske arhitekture za detekciju objekata: R-FCNN, Faster R-CNN i SSD. Kao osnovnu klasifikacionu arhitekturu (ekstraktore odlika) za ove metode detekcije objekata su koristili VGG i ResNet konvolucijske neuronske mreže. Finalni modeli mogli su da raspoznaju devet različitih tipova bolesti sa ukupnom srednjom tačnošću od 85.98%, čak i u slučajevima kada se nalaze više različitih bolesti lista u okviru jedne slike. Kao najperformantniji sistem im se pokazao R-FCNN u kombinaciji sa ResNet-50 arhitekturom za izvlačenje odlika. Autori ovog rada naglasili su značajnost augmentacije na uticaj finalne tačnosti modela, i takođe kao jedan od pristupa koji je neophodan u slučaju manjeg skupa podataka.

U radovima [109, 121, 122] dati su detaljni pregledi trenutnih pristupa u automatskoj detekciji bolesti biljaka, gde su sumirane većine ograničenja trenutnih metoda. Takođe, navedeni su i najvažniji izazovi u rešavanju ovih problema:

- Nedostatak podataka – mali broj dostupnih baza podataka i slika
- Korišćenje slika iz prirodnog okruženja
- Veća tačnost klasifikacije bolesti
- Detekcija stadijuma bolesti

Vrlo složena pozadina slike može biti jedan od glavnih uticaja na kvalitet modela i njegovih performansi. Autori u radu [122] predlažu korišćenje segmentacije kao prvi korak procesiranja što bi ujedno bilo i potencijalno rešenje drugog problema – detekcija više bolesti na jednoj biljci. Računska kompleksnost i potreba za memorijom se mora uzeti u obzir kada se kreiraju sistemi za detekciju bolesti biljaka bazirani na tehnikama dubokog učenja [121] iz razloga što bi oni mogli da se koriste unutar sistema za pomoć u donošenju odluka prilikom determinacije bolesti biljaka na osnovu slike lista. Takvi sistemi bi potencijalno mogli da budu bazirani na mobilnim uređajima ograničenih hardverskih mogućnosti, pa je važno uzeti u obzir fizičke zahteve modela prilikom procesa razvoja.

Velik broj radova i istraživanja vezanih za korišćenje tehnika dubokog učenja zbog nedostatka slika, pored procesa augmentacije pribegavaju još i tehnici prenošenog učenja.

Autori rada [123], pokazali su da tehnika prenošenog učenja na modifikovanoj LeNet arhitekturi može da poveća finalne performanse modela kako na *PlantVillage* bazi slika, tako i na bazi slika koju su autori rada sami sakupili. Glavni fokus rada bio je da se napravi sistem za detekciju OQDS-a (eng. *Olive quick decline syndrome*), bolesti maslina koja uzrokuje propadanje listova i grančica tako da stabla više ne proizvode useve maslina. Finalna tačnost modela iznosila je  $98.6\% \pm 1.47\%$ . Trebalo bi naglasiti da su slike korišćene u procesu treniranja i testiranja modela bile iz eksperimentalnih uslova, ne uzimajući u obzir slike maslina iz prirodnog okruženja.

Jedan od prvih radova [124] iz oblasti detekcije bolesti biljaka tehnikama dubokog učenja, takođe predstavlja i osnovu ove disertacije, uključuje prenošeno učenje na modifikovanoj CaffeNet arhitekturi incijalno treniranoj nad ImageNet bazom slika [76]. Za trening i testiranje modela koristila se ručno sakupljena baza slika sa Interneta koja sadrži 13 različitih klasa bolesti sa ukupno 3000 slika. Pored klasa bolesti korišćene su dodatne dve klase, gde je jedna klasa (565 originalnih slika) sadržala slike zdravih listova različitih tipova biljaka, a druga klasa predstavljala je pozadinske slike (1235 originalnih slika različitog sadržaja sa puno detalja). Ovim pristupom autori rada su pokušali da reše probleme kompleksne pozadine kao i mogućnost razgraničavanja zdravih i obolelih listova. Takođe, ova baza slika predstavlja osnovu koja se kasnije

proširila za bazu slika (detaljno opisana u sledećem poglavlju) koja se koristi u eksperimentalnoj fazi ove disertacije. Istrenirani model imao je finalnu tačnost od 96.3%. U okviru ovog rada pokazala se mogućnost primene dubokih neuronskih mreža u oblasti detekcije bolesti biljaka ali takođe je pokazana važnost procesa augmentacije i prenošenog učenja u slučajevima malog skupa podataka.

Prenošeno učenje su koristili i autori rada [125] (što je takođe jedan od radova koji su prethodili ovoj disertaciji) koji su isto tako koristili tehnike augmentacije nad *PlantVillage* bazom slika. Eksperiment je uključivao šest različitih arhitektura konvolucijske neuronske mreže (AlexNet, DenseNet-169, Inception v3, ResNet-34, 187 SqueezeNet-1.1 i VGG13) koje su trenirane korišćenjem tri različite strategije. Svih šest arhitektura pokazale su se najuspešnijim u strategiji prenošenog učenja gde se samo poslednji sloj mreže trenira sa nasumičnim težinama a ostali slojevi se „zamrzavaju“, tj. čuvaju se naučene težine neuronske mreže iz prethodne obuke nad velikim bazama podataka gde se čuvaju naučene uopštene odlike koje se mogu iskoristiti i u procesu detekcije bolesti biljaka. Svi finalni modeli imali su preko 99.2% tačnosti nad *PlantVillage* bazom slika. Autori ovog rada koristili su tehnike vizuelizacije neuronske mreže radi verifikacije naučenih odlika modela, ova tehnika predstavljala je pristup dobijanja detaljnijeg uvida u rad samog modela.

Takođe, u radu [126] koristile su se tehnike prenošenog učenja nad *PlantVillage* bazom slika u različitim finim podešavanjima hiperparametara dubokih konvolucijskih neuronskih mreža. U okviru eksperimenta, GoogLeNet arhitektura postiže finalnu tačnost od 99.35%. Autori ovog rada su naglasili ograničenja koja uključuju da su sve slike lišća samo sa jedne strane, uticaj homogene pozadine jer su slike iz eksperimentalnih uslova, takođe i da se sam proces treniranja i testiranja obavljao nad istom bazom podataka pa se ne može utvrditi prava vrednost istreniranih modela.

U jednom od skorijih radova [127], pokazalo se da i sa manjim brojem originalnih slika dobrog kvaliteta mogu da se istreniraju duboke neuronske mreže koje bi mogle da imaju zadovoljavajuće performanse. U ovom eksperimentu, autori rada su se fokusirali na segmentaciju oštećenih i obolelih regiona na 1567 slika, od kojih je 60% iz kontrolisanih uslova a 40% slika je napravljeno u prirodnom okruženju. U okviru faze pretprocesiranja, pored segmentacije radilo se i sakrivanje pozadine tako što se

pozadina zacrnjavala. Trening je obuhvatao prenošeno učenje nad GoogLeNet arhitekturom. Model je imao tačnosti koje su varirale od 75% do 100% u zavisnosti od klase. Autori rada su naglasili važnost segmentacije i izvlačenja pozadine i njihov uticaj na finalnu tačnost modela. Takođe, istaknuta je mogućnost detektovanja više različitih bolesti na jednoj slici korišćenjem tehnika segmentacije.

Zbog nedostatka dostupnih baza slika zdravih i obolelih listova, veliki broj istraživača se fokusirao na implementiranje različitih metoda kako bi proširili postojeći broj slika. U najčešći pristup spadaju transformacije nad slikom, kao što su rotacija, skaliranje, rotacija u ogledalu i mnogi drugi slični pristupi [124, 126, 129]. Bez obzira, gore napomenuti pristupi ne moraju doprineti poboljšanju performansi modela. U koliko standardni pristupi ne donesu zadovoljavajuće rezultate, istraživači koriste druge metode kao što su generisanje veštačkih slika. U nekoliko prethodnih godina GAN arhitektura je uspešno obavljala različite zadatke u pogledu menjanja stila slike, generisanje nedostataka u slici kao i generisanju novih uzoraka vođeni prethodnim iskustvom. Iz tog razloga, različite GAN arhitekture (Deep Convolutional GAN, Cycle-consistent GAN, Conditional GAN i druge) su se koristile za generisanje sintetičkih slika.

U radu [129] autori su predstavili sistem koji se sastoji od konvolucijskog modela smeštenog na pametnom mobilnom uređaju radi automatske detekcije bolesti biljaka na osnovu slike lista. Za kreiranje klasifikacionog modela, trenirale su se Inception V3 i MobileNet arhitekture, finalna tačnost modela na test slikama je bila 88.3% i 92%. Preprocesiranje slika uključivalo je smanjenje rezolucije slika i eliminisanje šuma (segmentacija i isecanje delova slike). Takođe, u preprocesiranju koristio se i DCGAN za generisanje novih sintetičkih slika.

Radovi [130, 131, 132], takođe demonstriraju mogućnost korišćenja GAN arhitekture za generisanje realističnih slika na osnovu postojeće baze slika. Tabela 4.1 sadrži sumiran pregled relevantnih radova u oblasti detekcije bolesti biljaka korišćenjem tehnika dubokog učenja.

**Tabela 4.1** Poređenje pristupa baziranog na dubokom učenju za detekciju bolesti biljaka [133]

Rad	Baza slika			Preprocesiranje i tehničke augmentacije	Neuronska mreža		Tačnost [%]	
	Ime (Vrsta/Klasa)	Ukupan broj slika	Broj slika nakon preprocesiranja		(Najbolja) CNN arhitektura	Prenošeno učenje	Ukupno	Po klasama
[115]	PlantVillage (1/3)	3700	3700	Re	Modifikovan LeNet	Ne	92.88	Nije definisano
[118]	PlantVillage (25/58)	54,309	87,848	Cr, Re	VGG	Ne	99.53	Nije definisano
[120]	Ručno sakupljen (1/9)	5000	43,398	AB, AC, Cr, Fl, NR, Re, Ro	R-FCN i ResNet-50	Ne	85.98	75–95
[123]	Ručno sakupljen (1/3)	299	Nije definisano	NR, Re, Sg	Modifikovan LeNet	Da	98.60	Nije definisano
[119]	Ručno sakupljen (1/4)	1053	13,689	AB, AC, AS, AT, NR, MS, PCA jittering	Modifikovan AlexNet	Ne	97.62	91–100
[127]	Ručno sakupljen (14/56)	1567	46,409	BR, Re, Sg	GoogLeNet	Da	94	75–100
[126]	PlantVillage (14/38)	54,306	Nije definisano	Re, Sg	GoogLeNet	Da	99.35	Nije definisano
[124]	Ručno sakupljen (6/15)	4483	33,469	AT, Cr, PT, Re, Ro	Modifikovan CaffeNet	Ne	96.30	91–98
[125]	PlantVillage (14/38)	54,323	55,038	Cr, Re, DCGAN	Inception_v3	Da	99.76	Nije definisano
[132]	PlantVillage (1/4)	2086	Nije definisano	Re, No, Ro, Fl, Zo	VGG16	Da	90.40	83–100

Tehnike augmentacije:	
Geometrijske transformacije:	Transformacije intenziteta:
AT – Afina transformacija, translacija i rotacija (eng. <i>Affine Transformation</i> )	AB – Podesavanje osvetljenja (eng. <i>Adjusting Brightness</i> )
Cr – Isecanje (eng. <i>Cropping</i> )	AC – Podesavanje kontrasta (eng. <i>Adjusting Contrast</i> )
Fl – Obrtanje (eng. <i>Flipping</i> )	AS – Podesavanje ostrine (eng. <i>Adjusting Sharpness</i> )
MS – Simetrija u ogledalu (eng. <i>Mirror Symmetry</i> )	Dodatno:
PT – Transformacija perspective (eng. <i>Perspective Transformation</i> )	BR – Izbacivanje pozadine (eng. <i>Background Removal</i> )
Re – Promena veličine (eng. <i>Resizing</i> )	NR – Izbacivanje šuma (eng. <i>Noise Removal</i> )
Ro – Rotacija (eng. <i>Rotation</i> )	Sg – Segmentacija (eng. <i>Segmentation</i> )
	Zo – Zumiranje (eng. <i>Zooming</i> )

Tabela 4.2 prikazuje trenutna ograničenja metoda baziranih na tehnikama dubokog učenja.

**Tabela 4.2** Ograničenja trenutnih pristupa baziranih na dubokom učenju za detekciju bolesti biljaka [133]

Rad	Ograničenja							
	Mali broj primera u bazi slika	Mali broj vrsta biljaka/klasa bolesti	Mala tačnost kada se testira u realnim uslovima	Kompleksna pozadina	Više klase bolesti na jednoj slici	Lokalizacija	Status infekcije	Trening i test skup podataka iz jedne baze slika
[115]	-	-	-	*	-	-	-	-
[118]	*	+	-	-	-	-	-	-
[120]	-	-	*	+	+	+	+	-
[123]	-	-	-	-	-	-	-	-
[119]	-	-	+	-	-	-	-	-
[127]	-	+	*	-	+	-	-	-
[126]	*	+	-	-	-	-	-	-
[124]	-	*	-	+	-	-	-	-
[125]	*	+	-	*	-	-	-	-
[132]	-	-	-	-	-	-	+	-

Legenda

- + Rešeno
- Nerešeno
- \* Delimično rešeno

Iako su u dosadašnjim radovima istraživači donekle odgovorili na trenutne izazove i probleme u ovoj oblasti, postoji veliki prostor za dalje poboljšanje. Veći deo gore spomenutih istraživanja je bio usredsređen na povećanje tačnosti modela korišćenjem različitih standardnih arhitektura konvolucijskih neuronskih mreža koje su se dobro pokazale u nekim drugim poljima bez uvođenja specijalizovanih arhitektura za ovaj tip problema koje bi potencijalno pokazale veću stopu tačnosti i omogućile korišćenje takvih modela u praksi.

Takođe, zbog nedostatka javno dostupnih baza slika većina istraživača je koristila *PlantVillage* bazu slika ili ručno sakupljane baze slike koje su u jako ograničenom broju originalnih uzoraka. Iz razloga što su se koristile slike većinom iz eksperimentalnih uslova, gde su pozadine, različita oštećenja ili defekti u vidu osvetljenja odstranjeni, većina modela ima značajno lošije performanse u realnim uslovima.

Pored toga, mali broj istraživanja je uopšte bio usredsređen na rešavanje problema koji se mogu naći u praktičnom korišćenju sistema baziranih na ovim modelima, kao što je na primer detekcija više različitih bolesti u okviru jednog ili više listova na slici.

Na osnovu postojećih istraživanja, dolazi se do zaključka da i dalje postoje otvorena pitanja i izazovi koji bi trebali da se reše i omoguće da se sistemi bazirani na modelima dubokog učenja mogu koristiti u različitim sistemima za automatsku detekciju bolesti biljaka na osnovu slike lista.

U sledećim poglavljima opisaće se novi pristupi i zaključci na osnovu iscrpnih eksperimentalnih rezultata koji bi potencijalno rešili gore navedene izazove.

## 5. PRIKAZ METODOLOGIJE ISTRAŽIVANJA

U okviru ovog poglavlja biće opisan jedan novi pristup u rešavanju trenutnih ograničenja i problema u oblasti automatske detekcije bolesti biljaka na osnovu slike lista. Biće opisane baze podataka koje su se koristile, tehnike i metode pretprocesiranja kao i sami algoritmi koje su se koristili u eksperimentalnom delu, a koji su izdvojeni u nekoliko različitih grupa po prirodi rešavanja problema:

- Klasifikacija
- Detekcija objekata
- 2-fazni algoritam kao novi arhitekturalni pristup za detekciju bolesti biljaka.

### 5.1 Baze slika

Kao što je već navedeno u pregledu literature u prethodnim poglavljima, jedan od većih nedostataka u ovoj oblasti jeste manjak javno dostupnih baza slika, što primorava istraživače da prikupljaju slike iz svojih izvora što često predstavlja težak i vremenski zahtevan posao. Pošto ovaj tip problema spada u nadgledano učenje, iz tog razloga potrebno je slike verifikovati tj. ispravno obeležiti, što zahteva ekspertsку pomoć.

#### 5.1.1 *PlantVillage*

Najveća javna baza slika listova je *PlantVillage* [116], sakupljena i održavana od strane neprofitabilnog projekta vođenog od strane Penn State Univerziteta u Sjedinjenim Američkim Državama i EPFL-a u Švajcarskoj. Baza se sastoji od 54309 slika, od 14 tipova biljaka, podeljenih u 38 klasa (zdravih i obolelih listova).

Tabela 5.1 predstavlja ukupan broj slika po klasama iz *PlantVillage* baze slika.

**Tabela 5.1** PlantVillage baza slika po klasama

Broj klase	Ime klase (vrsta biljke)	Broj slika
1.	Gymnosporangium juniperi virginianae ( <b>Jabuka</b> )	276
2.	Venturia inaequalis ( <b>Jabuka</b> )	630
3.	Botryosphaeria obtusa ( <b>Jabuka</b> )	621
4.	Zdrav list ( <b>Jabuka</b> )	1645
5.	Zdrav list ( <b>Borovnica</b> )	1502
6.	Podosphaera spp ( <b>Višnja</b> )	1052
7.	Zdrav list ( <b>Višnja</b> )	854
8.	Cercospora zeae maydis ( <b>Kukuruz</b> )	513
9.	Puccinia sorghi ( <b>Kukuruz</b> )	1192
10.	Exserohilum turcicum ( <b>Kukuruz</b> )	985
11.	Zdrav list ( <b>Kukuruz</b> )	1162
12.	Guignardia bidwellii ( <b>Grožđe</b> )	1180
13.	Phaeomoniella spp. ( <b>Grožđe</b> )	1384
14.	Pseudocercospora vitis ( <b>Grožđe</b> )	1076
15.	Zdrav list ( <b>Grožđe</b> )	423
16.	Candidatus Liberibacter ( <b>Pomorandža</b> )	5507
17.	Xanthomonas campestris ( <b>Breskva</b> )	2291
18.	Zdrav list ( <b>Breskva</b> )	360
19.	Xanthomonas campestris ( <b>Paprika</b> )	997
20.	Zdrav list ( <b>Paprika</b> )	1478
21.	Alternaria solani ( <b>Krompir</b> )	1000
22.	Phytophthora Infestans ( <b>Krompir</b> )	1000
23.	Zdrav list ( <b>Krompir</b> )	152
24.	Zdrav list ( <b>Malina</b> )	371
25.	Zdrav list ( <b>Soja</b> )	5090
26.	Erysiphe cichoracearum / Sphaerotheca fuliginea ( <b>Tikva</b> )	1835
27.	Diplocarpon earlianum ( <b>Jagoda</b> )	1109
28.	Zdrav list ( <b>Jagoda</b> )	456

29.	Alternaria solani ( <b>Paradajz</b> )	1000
30.	Septoria lycopersici ( <b>Paradajz</b> )	1771
31.	Corynespora cassiicola ( <b>Paradajz</b> )	1404
32.	Fulvia fulva ( <b>Paradajz</b> )	952
33.	Xanthomonas campestris pv. Vesicatoria ( <b>Paradajz</b> )	2127
34.	Phytophthora Infestans ( <b>Paradajz</b> )	1910
35.	Tomato Yello Leaf Curl Virus ( <b>Paradajz</b> )	5357
36.	Tomato Mosaic Virus ( <b>Paradajz</b> )	373
37.	Tetranychus urticae ( <b>Paradajz</b> )	1676
38.	Zdrav list ( <b>Paradajz</b> )	1592

Na slici 5.1 prikazani su primeri listova iz svake klase *PlantVillage* baze slika.



**Slika 5.1** Primeri po klasama iz PlantVillage baze slika [116]

Svaka slika je načinjena u strogo kontrolisanim uslovima i uvek sadrži samo jedan list sa homogenom pozadinom sa dobrom osvetljenjem.

Kao najveća javno dostupna baza slika ove vrsta, *PlantVillage* je postala osnovna metrika za beleženje performansi modela za detekciju bolesti biljaka. Iz razloga što su sve slike u kontrolisanim uslovima, performantnost modela može biti drastično lošija kada se testira nad nekim drugim skupom podataka sačinjenim od slika načinjenih u realnim uslovima.

Ova baza slika ima samo obeležene klase pripadnosti kao metapodatak. Bilo je potrebno dodatno proširiti ovu javnu bazu sa regionima od interesa zbog treniranja algoritama za detekciju objekata. Sva beleženja regiona od interesa su verifikovana od strane eksperata iz oblasti.

### 5.1.2 *PlantDisease*

Pored javno dostupnih baza slika istraživači često prave nove baze slika sačinjene od slika koje su ručno napravili fotografisanjem listova ili korišćenjem javno dostupnih izvora.

U prvom istraživanju [124] koji je prethodio ovoj disertaciji sačinjena je baza slika prikupljanjem javno dostupnih slika za korišćenje sa interneta. Pošto su slike dolazile iz različitih izvora, one su bile različitih formata, kvaliteta i rezolucija.

Iz tog razloga, sve slike su prolazile kroz proces pretprocesiranja koji je sačinjen od filtriranja i isecanja. Takođe, slike koje su bile u dimenzijsama manjim od 500 piksela su se odbacivale iz baze, nisu se koristile u procesu treniranja duboke neuronske mreže. Nakon prve faze pretprocesiranja i verifikacije po klasama od strane eksperata, veličine slika su promenjene na 256x256 piksela. Prva baza slika koja je korišćena u gore navedenom radu imala je svega 4483 slike grupisane u 14 klasa zdravih i bolesnih listova i jednu klasu slika pozadine.

U vremenskom periodu od više od godinu dana, nastavljeno je sa skupljanjem slika. U ovom periodu nisu se sakupljale slike sa interneta, već su ih fotografisali stručnjaci na poljima u prirodnom okruženju. U toku procesa sakupljanja novih slika, uzimale su

se u obzir različite situacije koje mogu biti moguće u toku praktičnog korišćenja nekog automatskog sistema za detekciju bolesti biljaka. Slike su pravljene iz različitih uglova, i udaljenosti, nekada fokus na jednom listu nekada na više listova sa pozadinom, u različitim vremenskim uslovima i pod različitim intenzitetima dnevne svetlosti. Na taj način dobija se na različitosti podataka koji bi omogućili modelu da se adaptira na širok dijapazon odlika. Ovaj bogati skup odlika je značajan za donošenje odluka modela na osnovu slika napravljenih u prirodnim uslovima.

Na slici 5.2 prikazano je nekoliko različitih slika iz *PlantDisease* baze slika.



**Slika 5.2** Primer slika iz *PlantDisease* baze slika

Finalna *PlantDisease* baza slika sačinjena je od 42 različite klase zdravih i obolelih listova od 12 tipova biljaka koje su se koristile u eksperimentalnom delu rada [133]. Slike su obeležene od strane stručnjaka u svrhu klasifikacije, gde se beležila samo klasa u okviru slike (kada se nalazilo više klase, samo primarna je bila obeležena) i za detekciju gde su se beležili celokupni regioni koji su pripadali jednoj klasi.

Tabela 5.2 prikazuje osnovne brojevne podatke *PlantDisease* baze slika. Na osnovu trenutnih informacija poznatih autoru, sa svojih skoro osamdeset hiljada slika, *PlantDisease* predstavlja jednu od najvećih baza slika iz ove oblasti.

**Tabela 5.2** *PlantDisease* baza slika

Broj klase	Ime klase (vrsta biljke)	Broj slika PlantDisease	Broj slika (PlantVillage)	Broj objekata
1.	Venturia inaequalis (Jabuka)	1736	630	3423
2.	Gymnosporangium juniperi-virginianae (Jabuka)	2538	276	4296
3.	Podosphaera leucotricha (Jabuka)	1302		2478
4.	Botryosphaeria obtusa (Jabuka)	705	621	1207
5.	Alternaria pomorum (Jabuka)	3084		5436
6.	Malus domestica (Jabuka – zdrav list)	2058	1645	3552
7.	Xanthomonas euvesicatoria (Paprika)	2402		4044
8.	Xanthomonas campestris (Paprika)	1344	997	2445
9.	Capsicum (Paprika – zdrav list)	2414	1478	4443
10.	Blumeriella jaapii (Višnja)	1914		3480
11.	Podosphaera spp (Višnja)	1064	1052	1851
12.	Prunus cerasus (Višnja – zdrav list)	1022	854	1863
13.	Uncinula necator (Grožđe)	1708		2811
14.	Plasmopara viticola (Grožđe)	2038		3372
15.	Botrytis cinerea (Grožđe)	2254		4560
16.	Botryosphaeria obtusa (Grožđe)	1790		3549

Prikaz metodologije istraživanja

17.	Pseudocercospor a vitis (Grožđe)	1704	1076	3087
18.	Guignardia bidwellii (Grožđe)	1584	1180	2613
19.	Phaeomoniella spp. (Grožđe)	1692	1284	2739
20.	Vitis vinifera (Grožđe – zdrav list)	1898		3657
21.	Peronospora destructor (Luk)	2984		5199
22.	Allium cepa (Luk – zdrav list)	1361		2448
23.	Claserosporium carpophilum (Breskva)	804		1401
24.	Prunus persica (Breskva – zdrav list)	901	360	1831
25.	Alternaria solani (Krompir)	2310	1000	3948
26.	Solanum tuberosum (Krompir – zdrav list)	1718	152	3345
27.	Polystigma rubrum (Šljiva)	2482		4182
28.	Plum Plox (Šljiva)	1806		3474
29.	Tranzschelia pruni-spinosae (Šljiva)	1746		3228
30.	Stigmina carpofilia (Šljiva)	2192		4149
31.	(Šljiva – zdrav list)	2653		3423
32.	Mycosphaerella fragariae (Jagoda)	1242		2181
33.	Fragaria (Jagoda – zdrav list)	1686	456	2700
34.	Cercospora beticola (Šećerna repa)	2748		4629
35.	Beta vulgaris (Šećerna repa- zdrav list)	2953		4387
36.	Phytophthora infestans (Paradajz)	2792	1910	4755
37.	Septoria lycopersici (Paradajz)	2214	1771	3837
38.	Solanum lycopersicum (Paradajz – zdrav list)	2826	1592	4683
39.	Erysiphe graminis (Pšenica)	1566		2940
40.	Puccinia spp (Pšenica)	2036		3690
41.	Septoria spp.(Pšenica)	1204		2028
42.	Triticum sp. (Pšenica – zdrav list)	790		1647
Ukupno		79265	18334	139011

U okviru Tabele 5.2 obeležene su klase koje se podudaraju sa *PlantVillage* bazom slika. Te klase su kasnije u eksperimentalnoj fazi korišćene radi komparacije performansi modela na slikama iz različitih okruženja, eksperimentalnih i iz prirodnih okruženja.

Za potrebe beleženja regiona od interesa potrebne za treniranje algoritama baziranih na detekciji objekata, izrađena je posebna desktop aplikacija koju su koristili stručnjaci u fazi pripreme *PlantDisease* baze slika. Na taj način dobijeno je uniformno skladištenje metapodataka ali i ubrzan je proces beleženja regiona od interesa i sam proces verifikacije, uz smanjenje mogućnosti za grešku.

## 5.2 Metode obrade podataka

Jedan od glavnih izazova sa kojim se istraživači i korisnici dubokog učenja suočavaju u toku trening faze jeste problem preprilagođavanja odnosno varijanse (eng. *overfitting*). Svojstvo dobrog modela predstavlja visok stepen generalizacije, ukoliko se radi sa malim skupom podataka jedna od tehnika prevazilaženja ovog problema jeste proces augmentacije – sintetičko generisanje novih primeraka na osnovu postojećih primeraka iz skupa podataka [134].

U oblasti detekcije bolesti biljaka kao što je naglašeno u prethodnim poglavljima, postoji samo mali broj javno dostupnih baza slika. Većina autora dosadašnjih istraživanja su uključili neki vid tehnika augmentacije unutar faze obrade podataka baš radi povećanja generalizacije modela, tabela 4.1.

Dva različita pristupa u procesu augmentacije biće istražena u okviru eksperimentalnog dela rada gde će se predstaviti uticaj ovih tehnika na finalne perfomance modela:

- standardne tehnike, koje se koriste decenijama unazad u oblasti mašinskog učenja i
- nove tehnike generisanja sintetičkih podataka bazirane na korišćenju savremenih specijalizovanih arhitektura neuronskih mreža – GAN neuronske mreže.

U zavisnosti od veličine baze slika, ove tehnike po pogledu faze kada se primenjuju se mogu podeliti na: „*online*“ i „*offline*“.

Prvi tip podrazumeva da se tehnike augmentacije koriste nad postojećom bazom slika pre faze treniranja i da se skladište u fizičkoj memoriji, ovaj pristup se najčešće koristi kada se trenira nad malim skupom podataka.

Drugi tip se koristi kada je baza slika veća i postoje određene limitacije u vidu hardverskih komponenti.

To podrazumeva da se tehnike augmentacije primenjuju u fazi samog treniranja nad manjom grupom podataka (eng. *mini batch size*) koji čini jednu trening iteraciju.

Zbog dovoljnih hardverskih mogućnosti, u okviru eksperimenata predstavljenih u ovom radu, koristio se samo prvi pristup. U eksperimentalnoj fazi treniran je veliki broj dubokih neuronskih mreža, pa bi proces augmentacije u samoj trening fazi značajno usporio proces kada se uzme u obzir kumulativno vreme trajanja svih treniranja.

### 5.2.1 Standardna augmentacija

U ove tehnike spadaju svi pristupi bazirani na geometrijskim transformacijama, transformacijama nad pikselima, interpolacije i slično.

Neke od popularnih tehnika geometrijskih transformacija su okretanje u ogledalu, rotacije pod različitim uglovima i dr. Takođe, jedna od popularnih transformacija predstavlja skaliranje, koje može biti spoljno ili skaliranje iznutra. Isecanje predstavlja jednu od čestih augmentacionih metoda, a najčešće se koristi pristup nasumičnog isecanja koji preuzima samo jednu nasumičnu sekciju slike i skalira je na originalnu veličinu slike.

Translacije takođe predstavljaju jednu od često korišćenih pristupa u augmentaciji. Zasniva se na pomeranju slike duž X ili Y ose, ili duž obe ose.

Vrlo čest pristup zasniva se na dodavanju šuma unutar same slike. Na taj način dodaje se distorzija i dodavanje pravog inteziteta šuma može doprineti povećanju učenja

samog modela. Jedna od čestih tehnika ove grupe augmentacionih metoda jeste Gausov šum.

Slika 5.3 prikazuje neke od gorespomenutih standardnih tehnika augmentacije.



**Slika 5.3** Neke od standardnih tehnika augmentacije (originalna slika – gore levo, rotacija za  $270^{\circ}$ - gore desno, okretanje u ogledalu – dole levo, promena perspektive – dole desno)

Neke od gore navedenih tehnika mogu da promene granice same slike. Naime, u koliko na primer se skalira slika iznutra ili se slika rotira pod nekim manjim uglom, ove transformacije potencijalno mogu da promene dimenzije slike a ukoliko želimo da sačuvamo originalne dimenzije slike mora se dodati pozadina slike van samih granica dobijene transformisane slike.

Slika 5.4 prikazuje dodavanje crne pozadine nakon rotacije slike.



**Slika 5.4** Rotacija za  $37^\circ$  i menjanje granica slike

Ukoliko nakon ovakvih transformacija želimo da sačuvamo pozadinu slike kao i samu veličinu slike potrebno je pored standardnih augmentacionih tehnika koje su gore spomenute koristiti i tehnike interpolacije. Najjednostavnija tehnika interpolacije podrazumeva popunjavanje praznina sa nekom konstantnom vrednošću. Ovakav tip interpolacije se ne može koristiti nad slikama sa prirodnom pozadinom. Granične interpolacije su još jedan vrlo čest pristup koji podrazumeva proširenje slike sa graničnim vrednostima piksela, pristup prilagođen prilikom blagih translacija.

Kod slika sa prirodnom pozadinom, kakve su slike lišća gde se u pozadini mogu naći trava, drveće i slično mogu se primeni tehnike interpolacije bazirane nad refleksijom

– vrednosti piksela se reflektuju po granicama slike. Još jedna od jednostavnijih tehnika interpolacije podrazumeva samo ponavljanje slike van njenih granica.

Gore navedene standardne tehnike augmentacije su često korišćene u praksi zbog svoje jednostavnosti ali i zato što u velikom broju slučajeva doprinosi poboljšanju generalizacije samog modela, kao što je i prikazano u dosadašnjim radovima u oblasti detekcije bolesti biljaka, tabela 4.1.

### *5.2.2 Generisanje sintetičkih slika neuronskim mrežama*

Pored gore opisanih standardnih tehnika iz prethodne sekcije, u proteklih par godina istraživači koriste specijalizovane arhitekture dubokih neuronskih mreža, GAN duboke neuronske mreže, kao neke od metoda augmentacije slika. GAN mreže se mogu trenirati za generisanje sintetičkih podataka na osnovu postojećeg skupa podataka.

U ovom radu istraživale su se mogućnosti GAN arhitektura za generisanje sintetičkih slika listova (obolelih i zdravih). Standardna GAN arhitektura se sastoji od dve neuronske mreže koje funkcionišu kao dva suparnička tima u okviru neke takmičarske igre.

Jedna neuronska mreža, diskriminator, pokušava da determiniše da li je podatak (slika) lažna ili originalna, dok druga neuronska mreža, generator, pokušava da generiše podatak (sliku) koji sadrži sve odlike originalnog podatka koji bi omogućili pogrešnu klasifikaciju diskriminatora što bi dovelo do toga da mreža prepozna podatak kao originalan. Kroz ovakav pristup u treniranju, omogućuje se učenje svih relevantnih odlika nad originalnim podacima i definisanje novih podataka koji obuhvataju te naučene odlike koje reprezentuju same inicijalne originalne podatke.

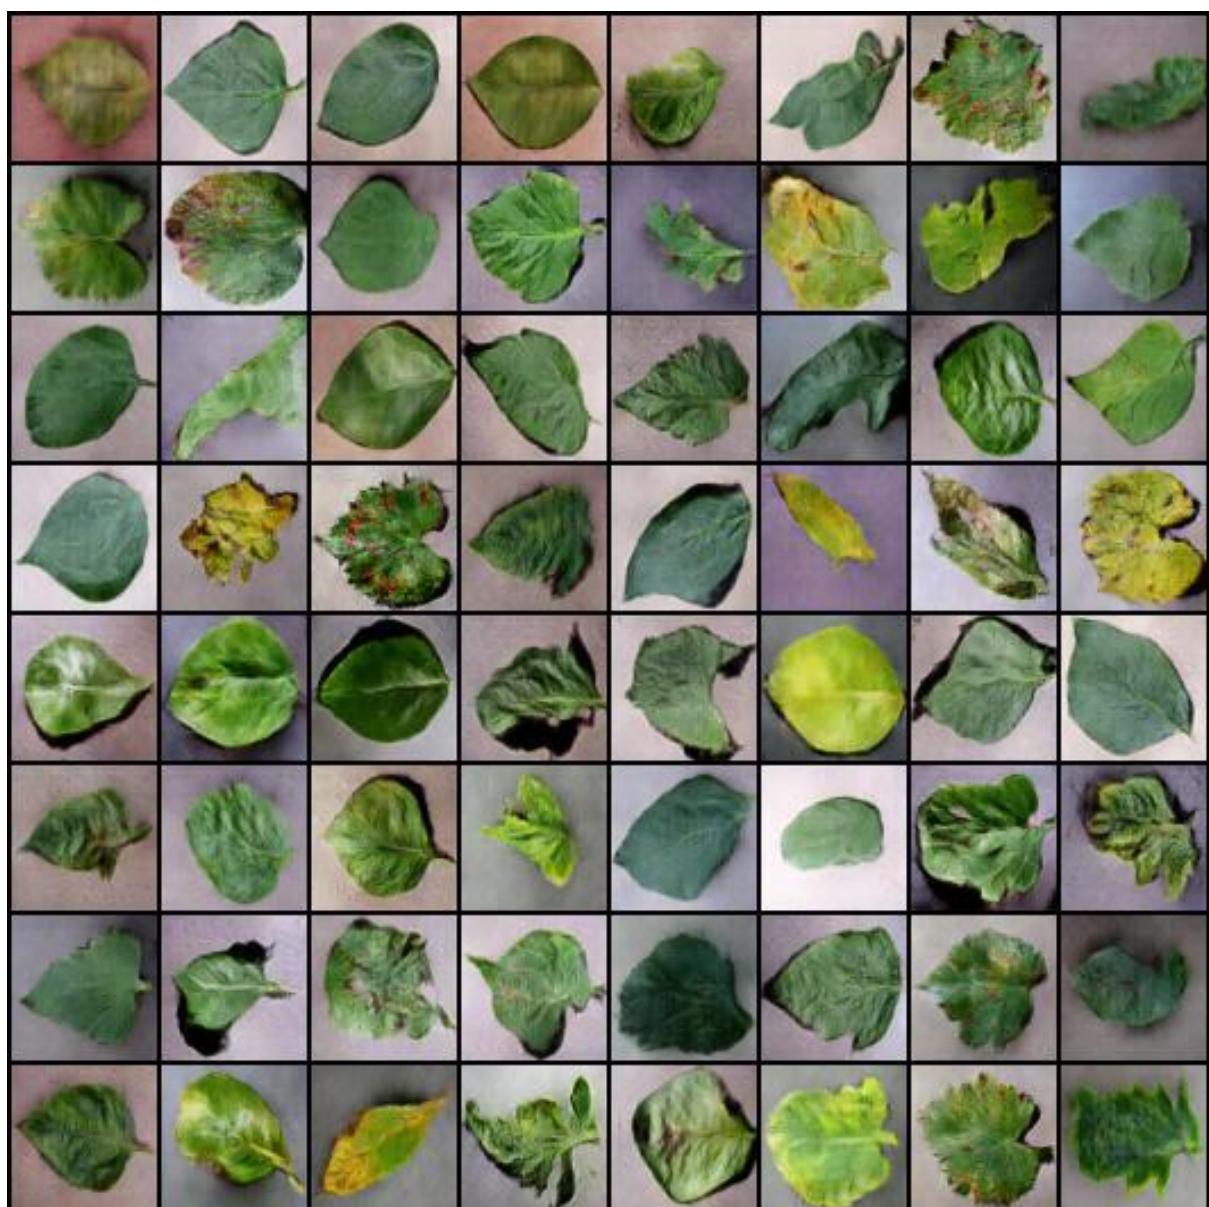
U okviru daljih sekcija ispitaće se da li se može ovakav pristup iskoristiti i u kreiranju novih slika za treniranje dubokih neuronskih mreža i koliki bi bio krajnji uticaj na perfomantnost modela.

U ovoj disertaciji koristilo se nekoliko GAN arhitektura za generisanje novih slika lišća. DC GAN arhitektura [135] se koristila zbog svoje jednostavnosti gde se kao glavni cilj imala provera mogućnosti da li GAN bazirane neuronske mreže mogu da nauče odlike

relevantne za generisanje sintetičkih slika listova kao što su boja, oblik, tekstura i slično.

DC GAN arhitektura se sastoji od diskriminatora i generatora od svega 5 slojeva i dizajnirana je za generisanje slika  $64 \times 64$  dimenzije, gde je trening za slike veće rezolucije veoma nestabilan jer se prouzrokuje da jedna od dve mreže postaje dominantna što sprečava proces učenja.

**Na slici 5.5** prikazane su generisane slike listova od strane DC GAN mreže trenirane nad *PlantVillage* bazom slika.



**Slika 5.5** DC GAN generisane sintetičke slike,  $64 \times 64$  generisane slike

Kako bi se koristile sintetičke slike generisane od strane GAN mreže u procesu treniranja duboke neuronske mreže za detekciju bolesti biljaka potrebno je da su generisane slike veće rezolucije. Većina savremenih arhitektura konvolucijskih neuronskih mreža dizajnirane su za ulazne slike veličine oko 256x256.

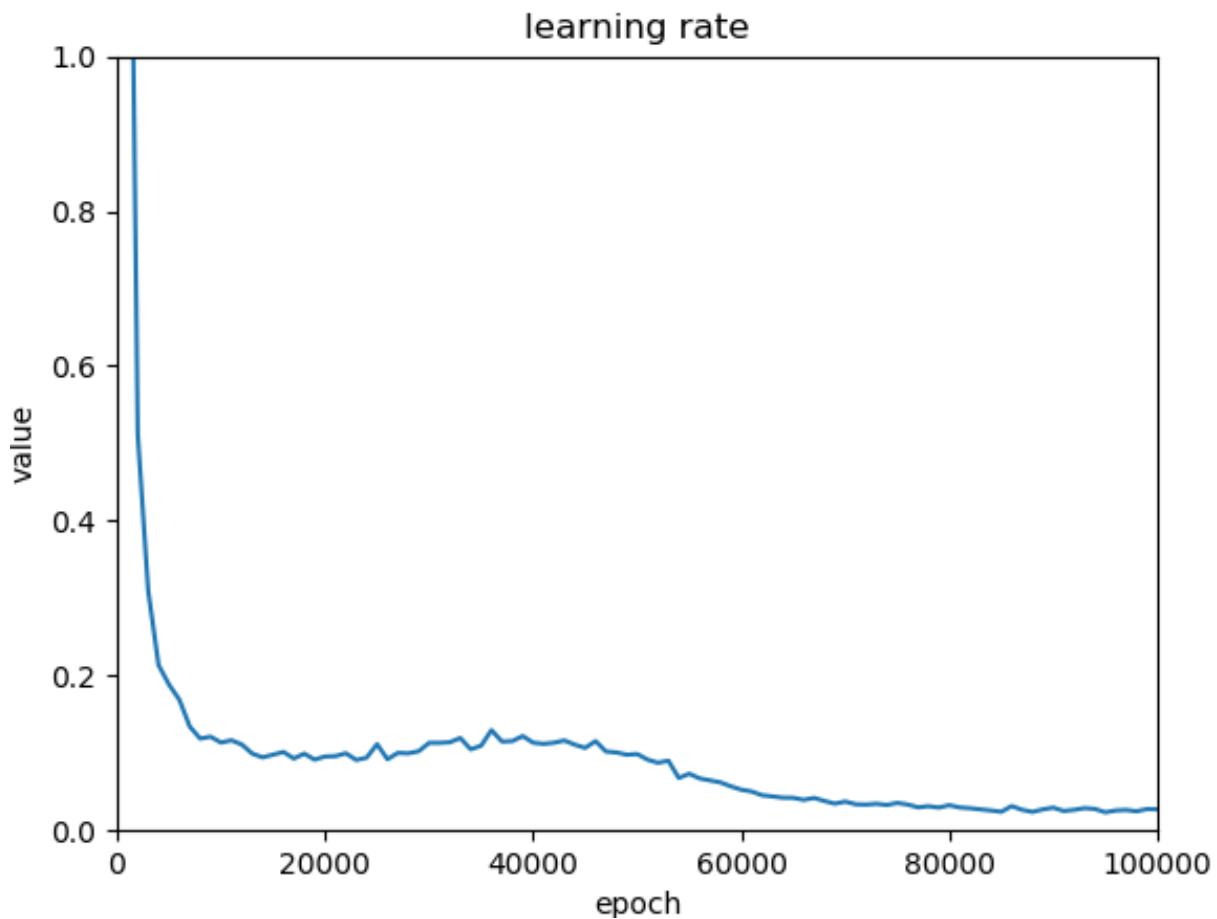
Iz tog razloga, korišćena je takođe i ProGAN arhitektura [136] jer potrebno je koristiti GAN arhitekture dizajnirane za veće rezolucije. ProGAN je treniran da generiše slike listova dimenzije 256x256. Ova arhitektura u procesu treniranja kreće od generisanja slika malih rezolucija, 4x4 ili 8x8, sve dok diskriminatore ne determiniše slike kao dovoljno realne (približne po odlikama originalnih slika).

Kada se završi ovaj inicijalni proces učenja, ProGAN dodaje slojeve većih rezolucija koje će se trenirati dalje. Proces se nastavlja sve dok se ne generišu slike dimenzija 1024x1024, ili manjih dimenzija u zavisnosti od broja slojeva koji su se dodali za trening. Za razliku od DC GAN arhitekture, ovaj tip mreže za generisanje slika većih dimenzija ima stabilnu trening fazu ali ProGAN arhitektura nije uspešno generisala slike listova sa dovoljnim skupom odlika koji bi mogli dovoljno dobro da reprezentuju originalne slike listova.

Slična arhitektura, Style GAN [137], pored stabilnog treniranja uspešno generiše i relevantne odlike listova u dimenzijama 256x256. Ova novija arhitektura kombinuje dizajn ProGAN-a i neuronski prenos stila (eng. *neural style transfer*). Za potrebe ovog rada, originalna arhitektura je izmenjena kako bi se generisale slike željene dimenzije. Iz tog razloga, dodat je konvolucijski blok za stil dimenzija 128x64x3 zajedno sa 64x3 konvolucijskim blokom koji predstavlja poslednji sloj generatorske mreže. Takođe, dodat je konvolucijski blok dimenzija 64x128x3 zajedno sa 3x64 konvolucijskim blokom kao prvi sloj diskriminatorske mreže.

Style GAN neuronska mreža trenirana je nad celom *PlantVillage* bazom slika koristeći stopu učenja  $3 \cdot 10^{-3}$ , sa mini grupom podataka veličine 5 slika koristeći AMSGrad optimizator.

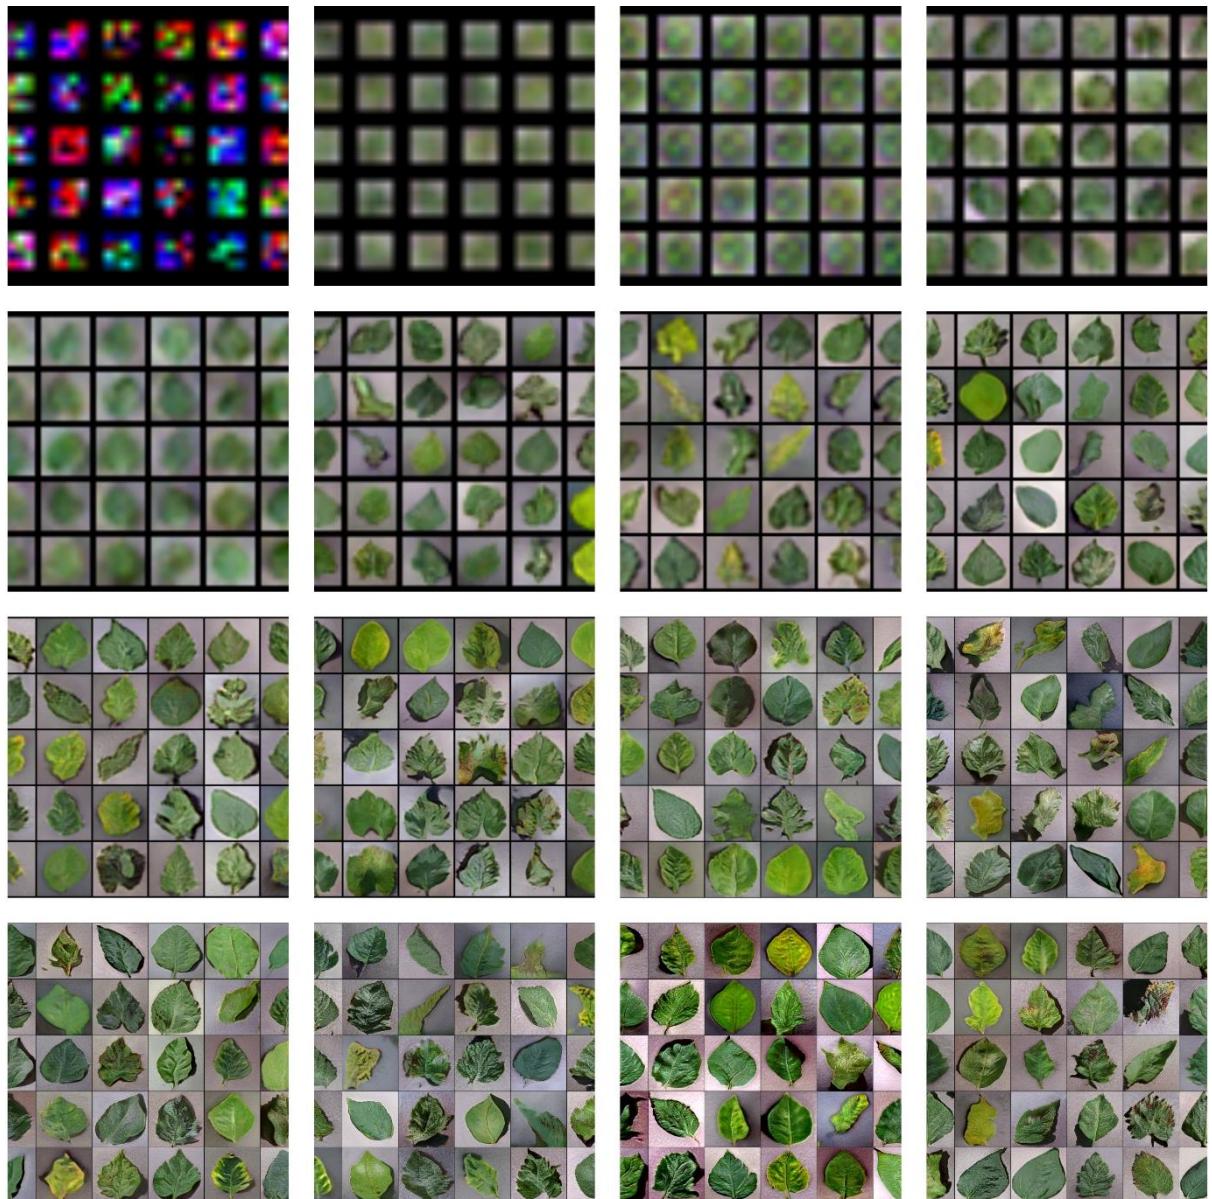
Kriva učenja StyleGAN mreže predstavljena je na slici 5.6.



**Slika 5.6** Style GAN kriva učenja

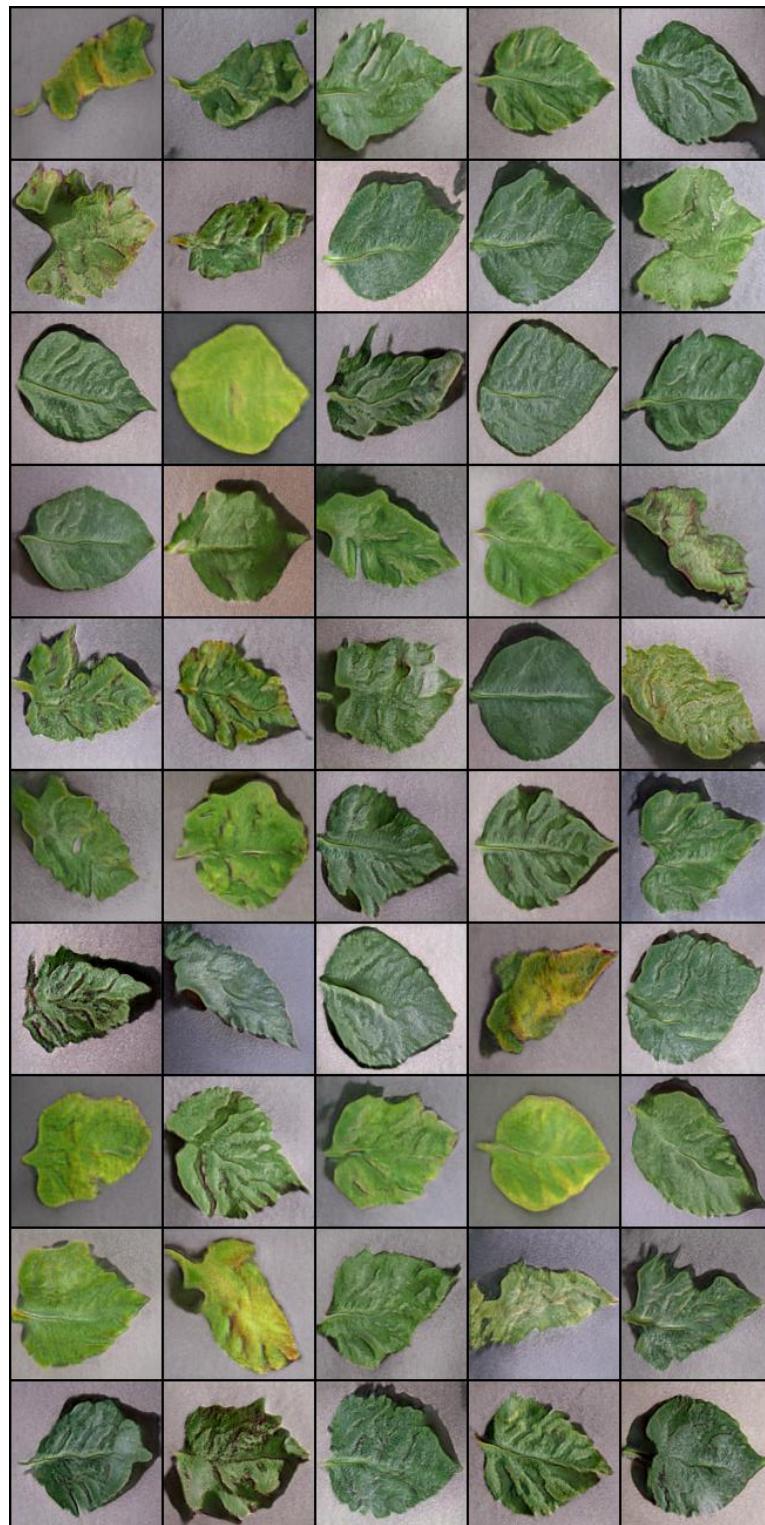
Kao i ProGAN, ovaj tip GAN arhitekture takođe počinje trening fazu generisanjem slika malih dimenzija i kasnije dodavanjem slojeva učenja u daljim epohama generišu se slike većih dimenzija koje su bogatije odlikama iz originalnih slika.

Slika 5.7 prikazuje trening fazu kroz epohe, gde se u gornjem levom uglu vide početne faze treninga nad slikama malih dimenzija obuhvatanjem samo jednostavnih odlika, a u krajnjem desnom uglu vide se slike većih dimenzija sa bogatijim skupom odlika koje reprezentuju i originalne slike listova.



**Slika 5.7** Style GAN trening faza generisanja slika kroz epohe

Na slici 5.8 mogu se videti generisane sintetičke slike listova dobijene treniranjem Style GAN arhitekture nad *PlantVillage* bazom slika.



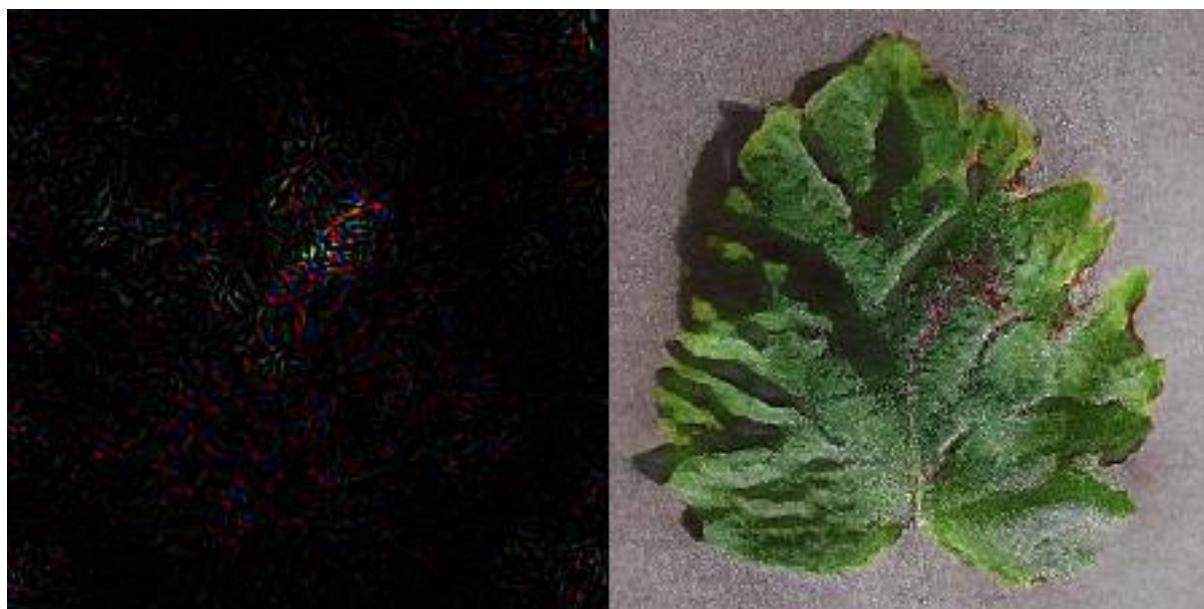
**Slika 5.8** Style GAN generisane sintetičke slike, 256x256 generisane slike

Učenje relevantnih odlika je potpuno automatizovano i u jednoj meri sakriveno unutar samog modela. Tehnikama vizuelizacija odlika moguće je dobiti dodatne informacije

o naučenim odlikama modela, tj. ne tretirati model kao „crnu kutiju“ kada se govori o odlikama relevantnim za predikciju.

Kako bi istražili naučene odlike istreniranog Style GAN-a za generisanje sintetičkih slika lišća koristila se tehnika vođenje propagacije unazad (eng. *Guided backpropagation technique*). Ovaj metod se zasniva na aktivacionom prolazu unazad za jedan neuron nakon prolaza unapred kroz mrežu radi vizuelizacije regiona slike koji najviše aktivira taj određeni neuron.

Slika 5.9 prikazuje vizuelizaciju odlika nad sintetičkom slikom lista.



**Slika 5.9** Style GAN vizualizacija odlika

Na osnovu vizualizacije može se videti kako su registrovani oboljni regioni na slici, što dovodi do zaključka da su u velikom stepenu uspešno naučene odlike relevantne za generisanje sintetičkih slika.

### 5.3 Klasifikacija

Jedan od glavnih ciljeva istraživanja u ovoj oblasti jeste razvoj modela koji bi se koristio u sistemima za automatsku detekciju bolesti biljaka na osnovu slika listova iz prirodnog okruženja. Ovakvi modeli bi morali da imaju dobre performanse za različite slučajeve

iz prirodnog okruženja, i iz tog razloga potrebno je istražiti uticaj različitih varijansi podataka na samu tačnost klasifikacionih modela.

Na osnovu toga, uključeno je nekoliko različitih eksperimenata koji bi pomogli da se donesu neki relevantni zaključci vezano za uticaj različitosti podataka i njihovo preprocesiranje (iz kontrolisanog i prirodnog okruženja) u samoj trening fazi dubokih konvolucijskih neuronskih mreža za klasifikaciju bolesti biljaka.

Prvi eksperiment uključuje treniranje nekoliko različitih savremenih arhitektura dubokih konvolucijskih neuronskih mreža (AlexNet, VGG 19, Inception version 3, DenseNet 201 i ResNet 152) nad *PlantVillage* bazom slika, a zatim testiranje dobijenih modela nad *PlantDisease* bazom slika. Na ovaj način moguće je istražiti mogućnost adaptacije modela nad novim skupom podataka (slike iz prirodnog okruženja) dobijenim treniranjem nad slikama iz kontrolisanog okruženja, tj. da li takvi modeli mogu da odgovore na neke od izazova i prepreka koji su česti u prirodnom okruženju.

U okviru ovog eksperimenta nije se koristila cela *PlantVillage* baza slika, već samo njenih 18 klasa. Razlog tome jeste što se samo tih 18 klasa podudaraju kod obe baze slika (*PlantVillage* i *PlantDisease*), tabela 5.1.

U trening fazi *PlantVillage* baza slika (18 klasa sa ukupno 18334 slike) se podelila u distribuciji 80-20, gde se nasumičnih 80% slika uzelo za trening fazu a 20% za validaciju modela. Pre same trening faze prethodilo je preprocesiranje koje je obuhvatalo samo standardne tehnike opisane u sekciji 5.2.1.

Za treniranje modela koristila se tehnikika dubokog prenošenog učenja, iz razloga što se u okviru autorovog prethodnog istraživanja u [125] ta strategija pokazala najuspešnijom kada se govori o tačnosti modela treniranog nad *PlantVillage* bazom slika. Duboko prenošeno učenje odnosi se na pristup gde se fino podešavaju svi slojevi duboke neuronske mreže dok se inicira optimizacija propagacije unazad sa prethodno pretrenirane mreže nad nekom od velikih baza slika.

U okviru trening faze koristio se Adam optimizator sa različitim koracima učenja (0.0008, 0.001, 0.002, 0.003). Eksponencijalnu stopu opadanja (eng. *Exponential decay rate*) za prvi moment postavljena je na 0.9, a 0.999 za drugi moment. Epsilon

parametar je fino podešavan sa različitim vrednostima u zavisnosti od arhitekture konvolucijske neuronske mreže ( $10^{-8}$ ,  $10^{-7}$ , 0.1, 1).

Drugi eksperiment predstavlja pristup gde se koriste iste arhitekture konvolucijskih neuronskih mreža zajedno sa istim vrednostima hiperparametara iz prvog eksperimenta, sa tim što se sada pored test faze, u trening i validacionu fazu uključuju slike i iz *PlantDisease* baze. Na ovaj način može se posmatrati uticaj uvođenja slika iz prirodnog okruženja u treniranje dubokih neuronskih mreža i učenje nekih odlika koje su relevantne za povećanje performansi modela prilikom njegovog praktičnog korišćenja. Faza preprocesiranja takođe kao i u prvom eksperimentu uključuje samo standardne tehnike augmentacije.

Treći eksperiment se razlikuje od prethodnog eksperimenta samo u fazi preprocesiranja. Naime, pored standardnih tehnika augmentacije trening skup podataka je obogaćen sintetičkim slikama listova generisanih od strane Style GAN duboke neuronke mreže trenirane nad *PlantVillage* bazom slika iz sekcije 5.2.2.

Skoro 5000 sintetičkih slika dodato je u tening skup podataka, broj slika po klasi varira od 100 do 300, iz razloga što se održava balansiranost po klasama unutar test skupa podataka. Cilj ovog eksperimenta je utvrditi upotrebnu vrednost novog pristupa u augmentaciji na finalnu tačnost klasifikacionih modela upoređivanjem sa rezultatima drugog eksperimenta koji je uključivao samo standardne tehnike augmentacije.

## 5.4 Detekcija objekata

Iako klasifikacioni modeli bazirani nad konvolucijskim neuronskim mrežama imaju visoku tačnost, postoje praktična ograničenja i izazovi na koje ovakvi tipovi modela ne mogu odgovoriti. Naime, situacije u kojima se nalaze više listova različitih klasa (zdravi ili oboleli listovi od istih ili različitih tipova biljaka) unutar jedne slike, slike koje sadrže kompleksne pozadine i slično, predstavljaju problem klasifikacionim modelima predstavljenim u eksperimentima iz prethodne sekcije.

Dva različita tipa arhitektura dubokih neuronskih mreža za detekciju objekata su se koristila u eksperimentalnom delu: jedno-koračne i dvo-koračne metode. Glavna

razlika između ta dva arhitekturalna pristupa jeste što se kod dvo-koračnih arhitektura prvo pronađu kandidati za lokaciju objekta od interesa u prvom koraku, korišćenjem različitih algoritama za predlog regiona odnosno lokacija, suzi se broj kandidata, a zatim se u drugom koraku izvrši klasifikacija nad svakim kandidatom (potencijalnoj lokaciji objekta od interesa).

Nekoliko arhitektura za oba pristupa u detekciji objekata koje su pokazale najbolje rezultate na COCO bazi slika [79] su se trenirale nad *PlantDisease* bazom slika, radi ispitivanja njihove uspešnosti prevazilaženja gore navedenih ograničenja na koje standardni konvolucijski klasifikatori nisu imali uspeha.

Baza slika podeljena je u distribuciji 70-20-10, gde se nasumično izabranih 70% slika koristilo za treniranje, 20% za validaciju i nasumičnih 10% za testiranje performansi dobijenih modela.

Faster R-CNN algoritmi (dvo-koračni) su se trenirali korišćenjem mini grupe veličine od 32 slike, koristeći stohastičko gradijentno opadanje kao optimizacioni algoritam (eng. *Stochastic Gradient Descent*) sa momentumom od 0.9. Stopa učenja je počinjala od 0.001 i zatim se smanjivala za 0.0001 na svakih 35000 iteracija.

Od jedno-koračnih pristupa koristili su se YOLOv3 [138], SSD513 [93] i RetinaNet [139] koji trenutno predstavljaju jedne od najsavremenijih arhitektura iz ove grupe algoritama za detekciju objekta.

YOLOv3 algoritam se trenirao korišćenjem mini grupe podataka veličina 64, sa momentumom od 0.9 i stopom učenja od 0.001 koja se za prvih 15000 iteracija nije menjala, a zatim je postavljena na 0.0001.

SSD je treniran korišćenjem mini grupe veličine od 16 slika, korišćen je Adam optimizator sa stopom učenja od 0.004 za prvih 10000 iteracija, koja se kasnije spustila na 0.0004.

RetinaNet se trenirao korišćenjem mini grupe veličine od 32 slike, sa smanjenjem težina (eng. *weight decay*) od 0.0001 i momentumom od 0.9. Za prvih 20000 iteracija koristila se stopa učenja od 0.02, koja se u kasnijim iteracijama smanjila na 0.002.

## 5.5 PlantDiseaseNet arhitektura

Na osnovu zaključaka izvedenih iz rezultata prethodno navedenih eksperimenata u ovoj disertaciji (detaljna analiza eksperimenata biće izneta u sledećem poglavlju) predstavljen je nov pristup u detekciji bolesti biljaka imajući u vidu rešavanje ograničenja u praktičnom korišćenju modela dobijenih u dosadašnjim istraživanjima.

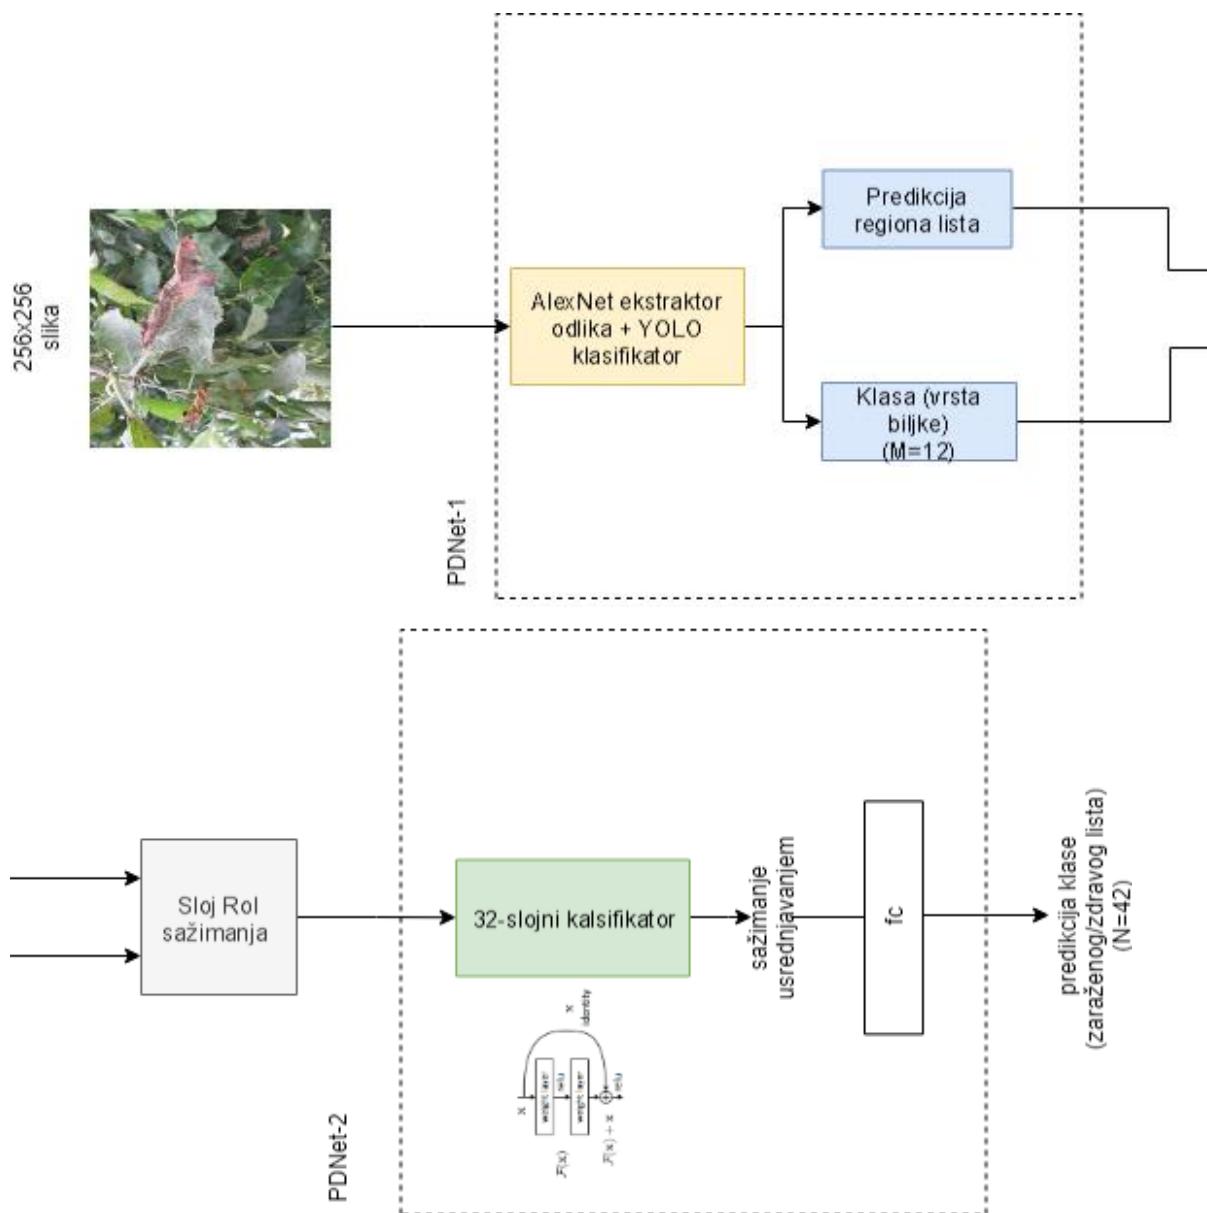
Novi pristup se sastoји od arhitekture dubokih neuronskih mreža iz dve faze, *PlantDiseaseNet*, posebno struktuiran i treniran sistem mreža za povećanje performansi nad praktičnim primerima detekcije bolesti biljaka.

*PlantDiseaseNet* arhitektura se sastoje od dve zasebne duboke neuronske mreže, PDNet-1 i PDNet-2, koje su trenirane simultano. PDNet-1 neuronska mreža je odgovorna za detekciju listova biljaka i njeno kategorizovanje po vrsti, dok je PDNet-2 neuronska mreža odgovorna za klasifikovanje obolelih (ili zdravih) prethodno detektovanih listova biljaka.

Na slici 5.10 predstavljena je *PlantDiseaseNet* arhitektura.

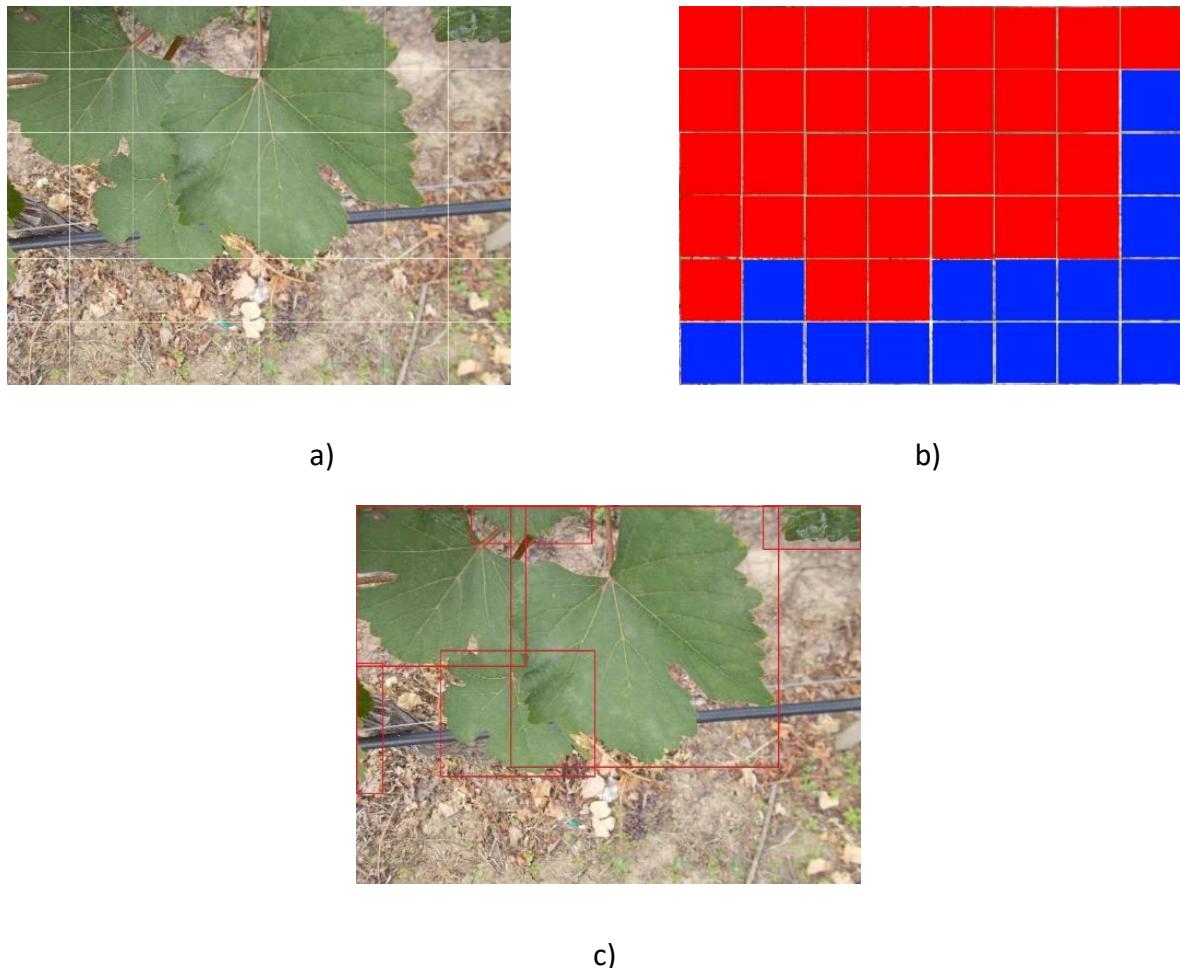
Iz prethodnih eksperimenata u ovom poglavlju ali i iz istraživanja opisanih u prethodnom poglavlju, može se zaključiti da određivanje regiona od interesa može igrati značajnu ulogu u rešavanju problema detekcije bolesti biljaka u praktičnim situacijama kada se u okviru iste slike (sa ili bez kompleksne pozadine) nađu više vrsta biljaka i/ili više klase obolelih odnosno zdravih listova.

Na osnovu toga prvi korak *PlantDiseaseNet* arhitekture predstavlja PDNet-1, koja koristi YOLO algoritam u cilju detekcije listova biljaka. Pretrenirana AlexNet duboka neuronska mreža se koristi kao osnova PDNet-1 arhitekture. Slojevi klasifikacije AlexNet arhitekture su izdvojeni kako bi se ova neuronska mreža koristila samo kao ekstraktor odlika (eng. *feature extractor*). Na kraj tako modifikovane AlexNet mreže dodaje se YOLO klasifikacioni sloj sa nasumično inicijalizovanim težinama.



**Slika 5.10** PlantDiseaseNet arhitektura

Detekcija objekata korišćenjem YOLO strategije zahteva podelu slike u mrežu ćelija, gde je svaka ćelija unutar te mreže zadužena za detektovanje i predikciju graničnih okvira. U okviru ovog rada, korišćena je 8x8 mreža sa dva granična okvira za predikciju po ćeliji mreže. Na ovaj način sačuvana je dovoljna rezolucija po ćeliji sa manjim brojem izlaza predikcije potrebnim za treniranje, slika 5.11.



**Slika 5.11** Ilustracija detekcije lista YOLO tehnikom a) mreža celija, b) mapa klasnih predikcija i c) finalna detekcija

U okviru drugog koraka, mape odlika u okviru svakog graničnog okvira dobijenog predikcijom u prvom koraku kroz PDNet-1 mrežu se uniformišu po veličini korišćenjem sloja sa Rol sažimanjem (eng. *Region of Interest - Rol pooling layer*). Ovaj sloj se često koristi u okviru algoritama baziranim na Faster R-CNN strategiji. Na ovaj način se mape odlika uniformisane po veličini prosleđuju PDNet-2 mreži zaduženoj za klasifikaciju obolelih/zdravih listova.

PDNet-2 je duboka neuronska mreža sačinjena od 34 sloja, gde prvih 32 sloja su sačinjena od sekvensijalnih  $3 \times 3$  rezidualnih blokova filtera koji su na kraju povezani sa globalnim slojem sažimanja koji je praćen potpuno povezanim slojem (sa Softmax aktivacionom funkcijom) sa 42 izlaza (42 klase trenutno podržane u okviru *PlantDisease* baze slika). Razlog za korišćenje rezidualnih blokova kao slojeva za učenje PDNet-2 klasifikatora jeste to što su u okviru prethodnih istraživanja već

pokazane dobre performanse ResNet arhitektura [125] za klasifikaciju bolesti biljaka na osnovu slike lista.

Za potrebe treniranja *PlantDiseaseNet* neuronske mreže koristila se *PlantDisease* baza slika koja je podeljena u odnosu 70-20-10, za treniranje, validaciju i testiranje respektivno.

*PlantDiseaseNet* se trenirala nad mini grupom od 32 slike. Posebno izrađena kriterijumska funkcija gubitaka (definisana u inicijalnom YOLO radu) je korišćena za PDNet-1 mrežu. Inicijalna stopa učenja za PDNet-1 tokom treniranja bila je u početku postavljena na 0.01 a zatim smanjivana za jednu desetinu na svakih 10000 iteracija. PDNet-2 mreža je trenirana fiksiranom stopom učenja u vrednosti od 0.001, korišćenjem SGD optimizatora sa momentumom od 0.9.

Svi tri grupe eksperimenata opisane u okviru ovog poglavlja izvršavane su pod jednim personalnim računarom čije su karakteristike navedene u okviru tabele 5.3.

**Tabela 5.3** Hardverske i softverske karakteristike računara korišćenog u eksperimentalnom radu

Hardver i Softver	Karakteristike
Memorija	16 Gb
Procesor	Intel Core i7-4790 CPU @ 3.60GHz x8
Grafika	GeForce GTX TITAN X 12Gb
Operativni sistem	Ubuntu 16.04

Za izradu i treniranje samih neuronskih mreža koristio se Python programski jezik i specijalizovane biblioteke za mašinsko učenje, Tensorflow [140] i PyTorch [141].

U okviru sledećeg poglavlja biće prikazani rezultati eksperimenata, opisanih u ovom poglavlju, zajedno sa detaljnom analizom.

## 6. REZULTATI I ANALIZA ISTRAŽIVANJA

U okviru ovog poglavlja dati su rezultati eksperimenata predstavljenih u prethodnom poglavlju. Rezultati kao i sama analiza biće podeljeni po pristupima koji su se koristili, odnosno po grupi eksperimenata: klasifikacioni algoritmi, detekcioni algoritmi i novi pristup kroz dvo-koračnu *PlantDiseaseNet* arhitekturu.

### 6.1 Klasifikacija

U okviru prve grupe eksperimenta istraživale su se mogućnosti klasifikacije pomoću dubokih konvolucijskih neuronskih mreža i njihove praktične primene.

Prvi od eksperimenata iz ove grupe uključivao je ispitivanje performansi modela testiranih nad *PlantDisease* bazom slika koja koristi slike iz prirodnog okruženja, dok je sam model dobijen treniranjem savremenih arhitektura konvolucijskih neuronskih mreža nad *PlantVillage* bazom slika koja sadrži samo slike iz kontrolisanog okruženja.

Rezultati prethodnog istraživanja [125], koji je prethodio ovoj disertaciji, uzeti su u obzir prilikom izrade ove grupe eksperimenta.

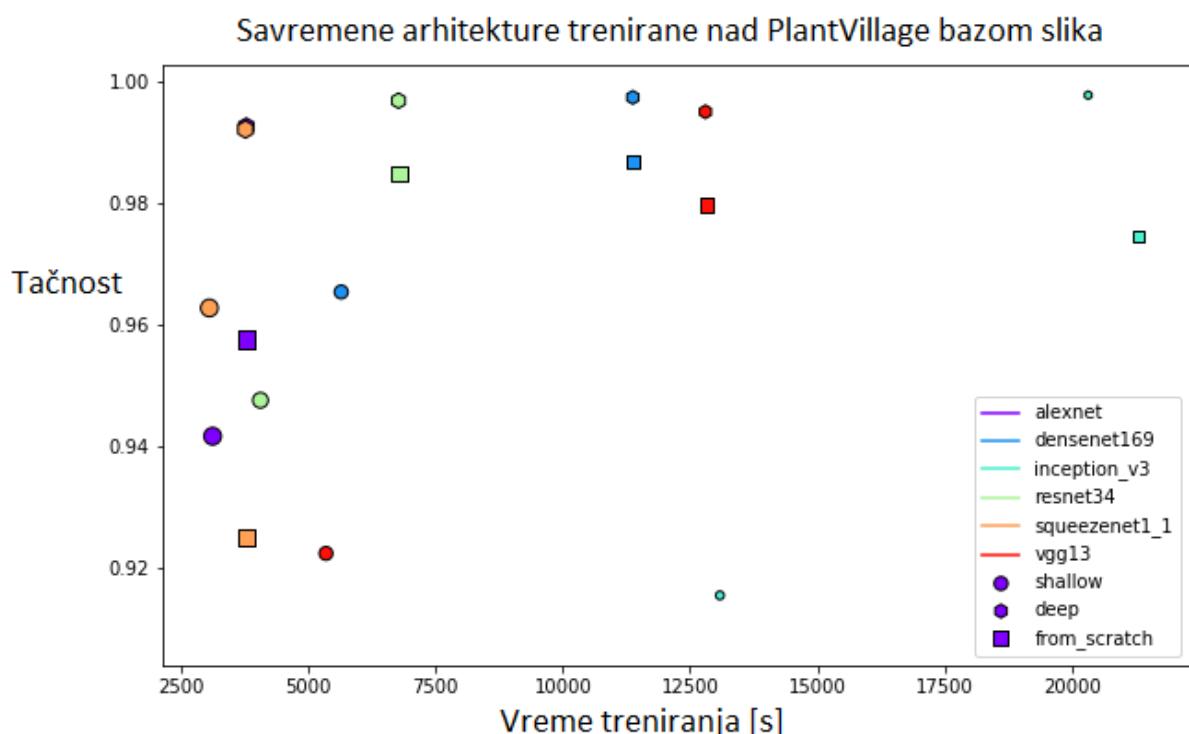
Naime, u radu [125], savremene arhitekture konvolucijskih neuronskih mreža trenirane su i testirane nad *PlantVillage* bazom slika i beležile su se njihove performanse u vidu tačnosti i vremena trajanja trening faze.

Izabrane arhitekture trenirale su se koršćenjem tri tipa trening strategija, od kojih su prve dve strategije prenošenog učenja:

1. „**plitka strategija**“ (eng. *Shallow strategy*) koja zahteva samo fino podešavanje najčešće poslednjeg potpuno povezanog sloja, dok se ostatak neuronske mreže koristi kao ekstraktor odlika,

2. „**duboka strategija**“ (eng. *Deep strategy*) uključuje fino podešavanje svih slojeva neuronske mreže dok se optimizacioni algoritam propagacije greške unazad pokreće od prethodno pretrenirane neuronske mreže.
3. „**strategija od nule**“ (eng. *From scratch strategy*) uključuje treniranje duboke neuronske mreže od početka (bez prenošenog učenja) tako što se inicijalno težine konfigurišu na nasumične vrednosti.

Rezultati treniranja savremenih dubokih konvolucijskih neuronskih mreža u okviru tri gore spomenute strategije prikazane su u okviru slike 6.1.



**Slika 6.1** Treniranje savremenih klasifikacionih arhitektura konvolucijskih neuronskih mreža nad PlantVillage bazom slika [125]

Na osnovu slike 6.1 možemo videti da se „duboka strategija“ što se tiče tačnosti modela pokazala kao najbolji pristup, dok je vreme treniranja značajno veće za „duboku“ i „strategiju od nule“ u poređenju sa „plitkom strategijom“.

U okviru prve grupe eksperimenata uzeto je u obzir 5 savremenih arhitektura koje su imale velike uspehe pri raznim klasifikacionim problemima i na osnovu rezultata iz

[109] korišćena je samo „duboka strategija“ treniranja, jer se pokazala najboljom po pitanju tačnosti modela.

U okviru tabele 6.1 prikazana je top-1 tačnost (tačno pogodjena klasa) nad validacionim i test skupom podataka.

**Tabela 6.1** Performanse modela treniranih nad PlantVillage bazom slika (sa standardnom augmentacijom) i testiranih nad PlantDisease bazom slika

Arhitektura	Validacija (PlantVillage baza slika) Top 1 Tačnost	Test (PlantDisease baza slika) Top 1 Tačnost
AlexNet	0.9913	0.8124
VGG 19	0.9931	0.8275
Inception version 3	0.9974	0.8352
DenseNet 201	0.9981	0.8390
ResNet 152	0.9975	0.8292

Na osnovu rezulata iz tabele 6.1 može se primetiti drastičan pad u performansama modela kada se upoređuje tačnost dobijena nad validacionim i test skupom podataka. Analizom pogrešno klasifikovanih slika iz validacionog skupa podataka, primećena je nemogućnost istreniranih modela da prevaziđu situacije kao što su slike sa kompleksnim pozadinama, više listova na slici bez fokusa na određen list, različiti uglovi i osvetljenja iz prirodnog okruženja.

Ovakav pad performansi modela može se objasniti korišćenjem samo jednog skupa podataka za trening koji je samo deo nelinearnog prostora podataka od interesa, što izaziva nemogućnost generalizacije modela za širi skup podataka, pogotovo kada se uzme u obzir da se u trening fazi koristila samo *PlantVillage* baza slika sačinjena od slika iz kontrolisanih uslova.

Većina dosadašnjih istraživanja bazira se baš na ovoj bazi slika, što predstavlja jedno od velikih ograničenja u ovoj oblasti. Tabela 6.2 prikazuje rezultate drugog eksperimenta iz ove grupe. Naime, ovo je samo proširenje prethodnog eksperimenta gde je sada trening i validacioni skup podataka dodatno proširen sa slikama iz *PlantDisease* baze slika.

**Tabela 6.2** Performanse modela treniranih nad slikama iz PlantVillage i PlantDisease baze slika (sa standardnom augmentacijom) i testiranih nad PlantDisease bazom slika

Arhitektura	Validacija (PlantVillage/PlantDisease baza slika) Top 1 Tačnost	Test (PlantDisease dataset) Top 1 Tačnost
AlexNet	0.9051	0.8617
VGG 19	0.9121	0.8710
Inception version 3	0.9257	0.8872
DenseNet 201	0.9293	0.8805
ResNet 152	0.9327	0.8995

Na osnovu rezultata iz tabele 6.2 može se primetiti značajan pad u tačnosti modela unutar validacionog skupa podataka ali takođe i značajan porast u tačnosti kada se gledaju rezultati nad test skupom podataka.

Detaljnom analizom pogrešno klasifikovanih podataka primećeno je da se uvođenjem novog skupa podataka unutar trening i validacione faze koji sadrži slike iz prirodnog okruženja generalno pomaže finalnom modelu u klasifikovanju u situacijama koje su prethodno navedene. Naime, i dalje, ograničenja u vidu kompleksnih pozadina sa različitim klasama, slike listova koje nisu u fokusu, i slične situacije iz prirodnog okruženja predstavljaju problem praktičnog korišćenja ovog pristupa. Iz tog razloga, postoji jasan pad performansi unutar validacionog skupa kada se upoređuje sa prvim eksperimentom gde su uključene samo slike iz kontrolisanih uslova.

Treći eksperiment iz ove grupe predstavlja analizu uticaja novog pristupa augmentacije na samu tačnost finalnih modela. Naime, preprocesiranje pored standardnih tehnika augmentacije koje su navedene u okviru sekcije 5.2.1 uključuje i generisane sintetičke slike listova dobijene treniranjem Style GAN duboke neuronske mreže nad *PlantVillage* bazom slika.

U tabeli 6.3 predstavljeni su rezulati korišćenjem novog pristupa u generisanju sintetičkih slika listova radi povećanja trening skupa podataka.

**Tabela 6.3** Performanse modela treniranih nad slikama iz PlantVillage i PlantDisease baze slika (sa GAN augmentacijom) i testiranih nad PlantDisease bazom slika

Arhitektura	Validacija (PlantVillage/PlantDisease baza slika) Top 1 Tačnost	Test (PlantDisease baza slika) Top 1 Tačnost
AlexNet	0.9145	0.8688
VGG 19	0.9205	0.8801
Inception version 3	0.9315	0.8935
DenseNet 201	0.9382	0.8901
ResNet 152	0.9439	0.9088

Na osnovu rezultata iz tabele 6.3 može se primetiti mali rast u tačnosti modela u poređenju sa korišćenjem samo standardnih tehnika augmentacije, tabela 6.2.

U okviru ovog trećeg eksperimenta iz ove grupe, može se primetiti da generisanjem sintetičkih podataka GAN dubokim neuronskim mrežama može da se proširi postojeća baza slika i poveća performantnost modela nad test podacima. Potrebno je navesti da su sve sintetičke slike generisane u ovoj disertaciji korišćenjem Style GAN arhitekture trenirane nad *PlantVillage* bazom slika.

U toku eksperimentalne faze ove disertacije pored slika iz *PlantVillage* baze slika (gde su sve slike listova sa uniformnom monohromatskom pozadinom) za potrebe treniranja GAN mreže dodate su i slike iz *PlantDisease* baze slika (gde su slike listova sa različitim pozadinama iz prirodnog okruženja, kompleksne pozadine kao što je ljudska ruka koja drži list i sl.).

Naime, u tom eksperimentu primećeno je da različite GAN arhitekture iz sekcije 5.2.2 nisu uspele da u potpunosti prevaziđu veliki broj varijacija u kompleksnosti pozadina slika, slika 6.2.



**Slika 6.2** Style GAN nad slikama listova sa kompleksnom pozadinom

Iz tog razloga, za ispitivanje uticaja sintetičkih podataka na samu performantnost modela koristile su se slike generisane od strane modela treniranih samo nad *PlantVillage* bazom slika.

Korišćenjem ovog novog pristupa u kreiranju slika listova pomoću GAN baziranih arhitekturama mreža, mogao bi se potencijalno prevazići problem nedostatka originalnih slika. Takođe korišćenjem ovog pristupa, značajno bi se smanjila cena i

vreme prikupljanja podataka, iz razloga što bi bio potreban samo manji skup originalnih slika koje bi predstavljale osnovu za generisanje sintetičkih slika listova.

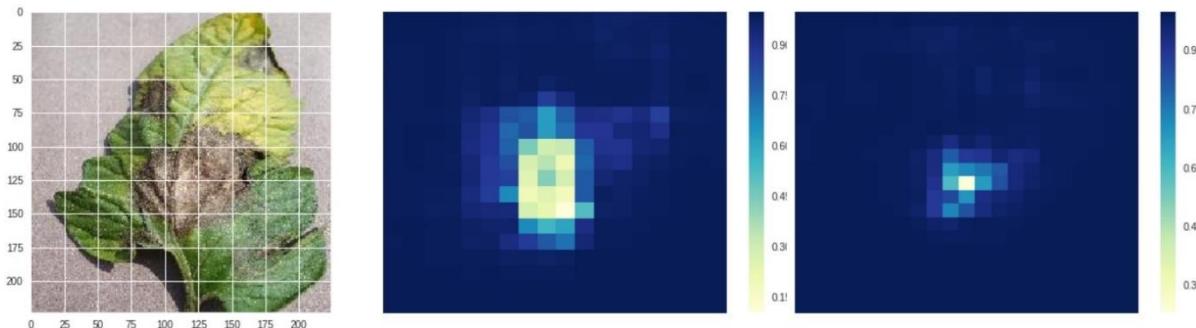
Na ovaj način, korišćenjem ove nove tehnike augmentacije, potencijalno bi se otvorile nove mogućnosti za dalji razvoj modela za detekciju bolesti biljaka i njihovog praktičnog korišćenja. Na osnovu toga, razvoj specijalno dizajniranih GAN arhitektura za generisanje sintetičkih slika listova sa kompleksnim pozadinama bi imao veliki značaj za dalja istraživanja iz ove oblasti.

Važno je napomenuti da pored same tačnosti modela nad validacionim i test podacima, koristile su se i tehnike vizuelizacije nad naučenim modelima kao i prilikom izrade GAN modela za sintetičko generisanje slika lišća, sekcija 5.2.2. Razlog tome je upoznavanje sa naučenim odlikama samih modela i dobijanje uvida u sam taj proces učenja odlika klasifikatora koji su karakteristični za determinaciju bolesti biljaka na osnovu slike lista. Na taj način moguće je dobiti značajne informacije o validnosti samog modela pored same analize tačnosti klasifikacije.

U okviru ovih eksperimenata koristile su se dve tehnike vizuelizacije, okluzija (eng. *Occlusion visualization technique*) i mapa vidljivosti (eng. *Saliency map technique*) [125].

Tehnikom okluzije ispituje se osetljivost neuronske mreže na okluzije određenih regiona slike i kako to utiče na sam proces klasifikacije. Na problemu detekcije bolesti biljaka jedna od stvari koje se mogu ispitati ovom tehnikom jeste uticaj same pozadine lista na samu klasifikaciju. Krajnji cilj je da klasifikacija ne bude bazirana na samoj pozadini već samo na odlikama obolelih regiona koji se nalaze nad samim listom. Kako bi se izvela ova tehnika vizuelizacije, koristio se crni četvrtasti region koji je zaklanjao (okluzija) određeni deo slike. Takva slika bi se zatim klasifikovala od strane neuronske mreže i generisao bi se izlazni vektor. Takav vektor bi se kasnije ispitivao radi spoznavanja koliko je taj zaklon uticao na samu klasifikaciju, tj. ispituje se osetljivost same mreže kada je određeni region zaklonjen. Ukoliko je taj region od značaja, korespondentna vrednost unutar tog vektora značajno opada u odnosu na vrednost unutar originalnog vektora (bez okluzije), u suprotnom promena vrednosti je mala.

Crni četvrtasti region se pomera unutar slike koračno kako bi se proizvela mapa odlika korišćenjem vrednosti izlaznih vektora. Na slici 6.3 možemo videti vizuelizaciju mape odlika korišćenjem ove tehnike. Svetlijih regioni su verovatniji da utiču na sam proces klasifikacije. Na osnovu ove slike, može se utvrditi da je model naučio odlike relevantne za raspoznavanje obolelih regiona na samom listu biljke.



**Slika 6.3** Vizuelizacija naučenih odlika: tehniku okluzije

Da bi se ovom tehnikom proizvela mapa odlika potrebno je izvršiti klasifikaciju nad velikim brojem slika sa promenom regiona lokacije, što čini ovaj pristup veoma sporim i računarski zahtevnim.

Često radi potrebe analize, radi se vizuelizacija odlika nad velikim brojem slika, pa korišćenje ove tehnike nad velikim brojem slika bi mogao da predstavlja njen glavni nedostatak.

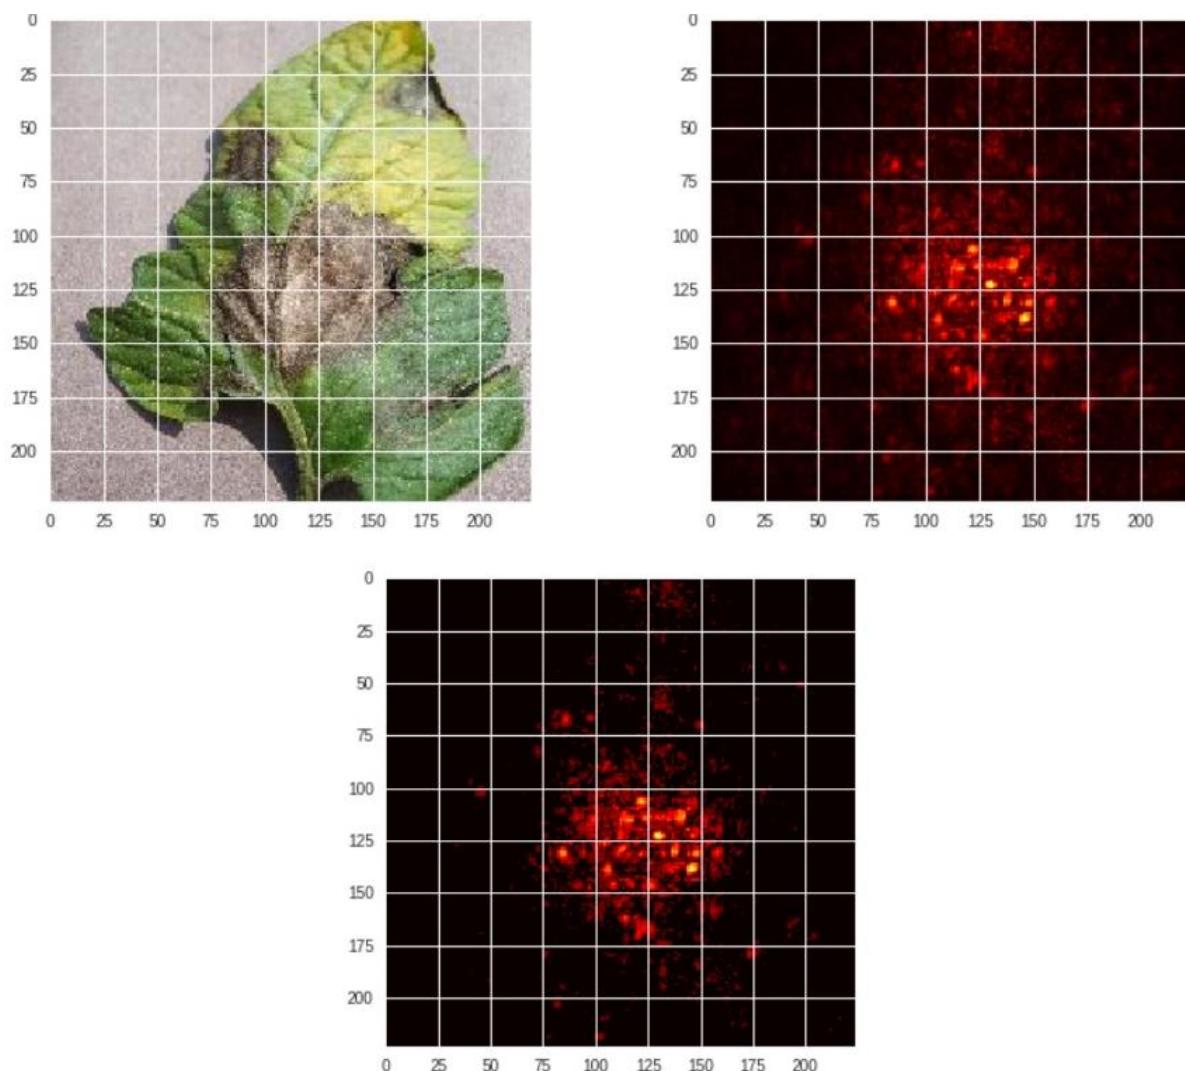
Druga tehnika vizuelizacije mape odlika koja se koristila prilikom izrade klasifikatorskih modela jeste mapa vidljivosti. Ova tehnika spada u analitičke metode koje omogućuju određivanje važnosti svakog piksela u procesu donošenja klasifikacione odluke korišćenjem samo jednog prolaza (prolaz napred i prolaz unazad) kroz duboku neuronsku mrežu.

Pristup ove metode se bazira na tome da ukoliko je jedan piksel važan za određenu vrednost unutar izlaznog vektora, onda će promena vrednosti tog piksela dovesti i do velike promene u samom izlaznom vektoru. Samim tim, ako je apsolutna vrednost gradijenta u tom pikselu velika, onda je taj piksel značajan za samu klasifikaciju,

suprotno, ako je gradijent isti ili blizu nule, taj piksel ne utiče na samu klasifikaciju i njegova promena ne utiče na korespondentnu vrednost unutar izlaznog vektora. Agregacija vrednosti piksela se radi kroz sve kanale slike (kroz 3 kanala za RGB slike kao što je u eksperimentima ovog rada) kako bi se uzela celokupna važnost piksela, a ne samo u okviru jednog kanala.

Za razliku od tehnike okluzije gde se mapa odlika računala numerički, modifikovanjem piksela i analizom izlaznih promena (računanje gradijenata na numerički način), generisanje mape odlika kod ove tehnike podrazumeva računanje gradijenata analitički samo jednim prolazom unapred i unazad kroz duboku konvolucijsku neuronsku mrežu.

Slika 6.4 predstavlja vizuelizaciju mape odlika tehnikom mape vidljivosti.



**Slika 6.4** Vizuelizacija naučenih odlika: tehnika mapa vidljivosti

Na osnovu slike 6.4, može se primetiti da se i ovom tehnikom mogu uspešno prikazati naučene odlike karakteristične za obolele regije unutar slike lista.

Ove tehnike koristile su se u svim klasifikacionim eksperimentima ovog rada, kao cilj validacije naučenog modela i detaljne analize samog procesa učenja algoritma i njegovog ponašanja nad različitim skupovima podataka. Ovakav vid informacija može pomoći daljem usavršavanju kako modela tako i njegovih performansi u vidu promene arhitekture, njegovih parametara treniranja kao i samog pristupa u preprocesiraju podataka.

## 6.2 Detekcija objekata

Neki od glavnih nedostataka klasifikacionog pristupa iz prve grupe eksperimenata predstavlja nemogućnost rešavanja situacija kada se na slici nađu listovi više različitih vrsta biljaka ili klasa (zdravih ili obolelih listova).

Iz tog razloga potrebno je istražiti performantnost modela baziranih na algoritmima za detekciju objekata koji koriste konvolucijske neuronske mreže. U okviru ove grupe eksperimenata, kao što je detaljno navedeno u prethodnom poglavlju, istraživane su mogućnosti dve vrste strategija u detekciji objekata: jedno-koračne i dvo-koračne metode.

Rezultati savremenih arhitektura iz obe vrste strategija trenirane i testirane nad *PlantDisease* bazom slika predstavljene su u okviru tabele 6.4.

**Tabela 6.4** Performanse modela za detekciju objekata treniranih i testiranih nad *PlantDisease* bazom slika

2-koračne metode	Osnovna arhitektura	mAP
Faster R-CNN	ResNet-101	0.834
Faster R-CNN sa FPN [142]	ResNet-101-FPN	0.852
Faster R-CNN sa TDM [143]	Inception-ResNet-v2-TDM	0.859
1-koračne metode	Osnovna arhitektura	mAP
YOLOv3	DarkNet-53	0.812
SSD513	ResNet-101-SSD	0.798
RetinaNet	ResNetXt-101-FPN	0.818

Kao metrika za performanse modela koristila se srednja prosečna preciznost (eng. *mean Average Precision* - mAP). Ova metrika predstavlja jednu od standardnih metrika u oblasti detekcije objekata i iz tog razloga se u ovom radu uzela kao osnovna metrika radi lakše komparacije rezultata kako sa dosadašnjim tako i sa budućim istraživanjima u ovoj oblasti.

Presek iznad unije (eng. *Intersection over Union* - IoU) korišćen u ovom eksperimentu iznosi 0.5. IoU predstavlja čest pristup za određivanje da li je predlog gde se objekat nalazi dobar.

Ako se za  $X$  uzme skup vrednosti piksela predloga gde se objekat nalazi u okviru slike, a  $Y$  se uzme kao skup piksela gde se zaista objekat nalazi na slici, IoU se može računati kao:

$$IoU(X, Y) = \frac{X \cap Y}{X \cup Y} \quad (6.1)$$

gde se prosečna preciznost može računati kao:

$$AP(k) = \frac{\#TP(k)}{\#TP(k) + \#FP(k)} \quad (6.2)$$

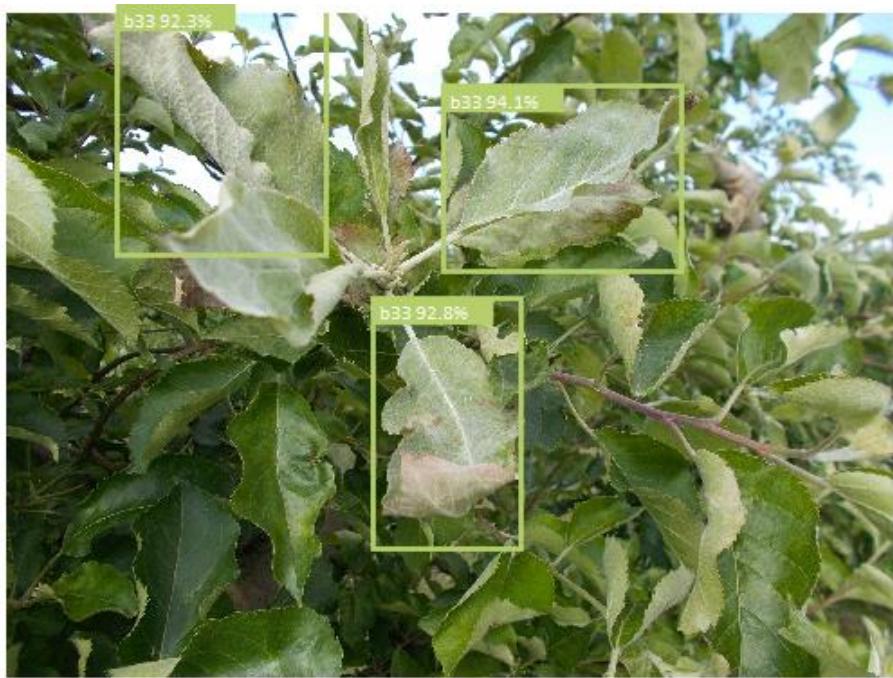
a na osnovu toga srednja prosečna preciznost, mAP, može računati kao:

$$mAP = \frac{1}{|classes|} \sum_{k \in classes} \frac{\#TP(k)}{\#TP(k) + \#FP(k)} \quad (6.3)$$

Na osnovu rezultata iz tabele 5.4 može se primetiti da su dvo-koračne metode pokazale bolje performanse u odnosu na jedno-koračni pristup nad *PlantDisease* bazom slika.

Uopšteno, zbog svoje prirode dizajna, dvo-koračne metode pružaju veću tačnost nego jedno-koračne metode, ali su značajno sporije [144].

Faster R-CNN sa TDM (eng. *Top-Down Modulation*) je pokazao najbolje performanse nad *PlantDisease* bazom slika. Primeri detekcije mogu se videti na slici 6.5.



a)



b)

**Slika 6.5** Faster R-CNN sa TDM detekcijom nad PlantDisease bazom slika a) više objekata iste klase na jednoj slici bez fokusa i b) jedan objekat u fokusu na slici

Posmatranjem eksperimentalnih test rezultata može se doći do zaključka da su ograničenja koja su bila nerešiva metodama predstavljenim u okviru prve grupe eksperimenata većim delom su rešiva korišćenjem algoritama detekcije objekata kao osnovne strategije za automatsko detektovanje bolesti biljaka.

### 6.3 PlantDiseaseNet arhitektura

Iako su postignuti dobri rezultati sa prethodnom grupom eksperimenata, postoji veliki prostor za napredak u vidu performansi.

U okviru prethodne grupe eksperimenata koristili su se algoritmi opšte namene za detekciju. Razvoj specijalizovane arhitekture bazirane na dubokim neuronskim mrežama za detekciju bolesti biljaka bi potencijalno mogao da podigne trenutno dostignute granice u performansama modela.

U toku samog procesa razvoja prototipa specijalizovane arhitekture za detekciju bolesti biljaka na osnovu slike lišća, primećeno je da algoritmi za detekciju objekata imaju značajno veće performanse kada se radi detekcija lista uz određivanje samo vrsta biljke u poređenju kada se radi detekcija lista biljke određivanjem njene klase bolesti.

Iz tog razloga, predložena arhitektura u ovoj disertaciji, *PlantDiseaseNet*, za svoj prvi deo koristi neuronsku mrežu za detekciju lista biljke koja se kasnije propagira kroz dalje slojeve druge neuronske mreže odgovorne za samu klasifikaciju.

Tabela 6.5 prikazuje rezultate, same detekcije (PDNet-1) i klasifikacije (PDNet-2).

**Tabela 6.5** PlantDiseaseNet tačnost modela

mAP (PDNet-1)	Top 1 Tačnost (PDNet-2)
0.9165	0.9367

Na osnovu top-1 tačnosti, može se primetiti da je *PlantDiseaseNet* arhitektura postigla bolje rezultate od trenutno najsavremenijih klasifikacionih arhitektura konvolucijskih neuronskih mreža, iz razloga što PDNet-2 se pothranjuje samo regionima od interesa koji su određeni od strane PDNet-1 mreže sa visokom preciznošću, mAP je daleko

veći od savremenih detekcionih algoritama iz prethodne grupe eksperimenata gde su savremeni detekcioni algoritmi trenirani nad *PlantDisease* bazom slika, Tabele 6.4 i 6.5.

Pored toga, prilikom izrade *PlantDiseaseNet* arhitekture, upoređivale su se i druge savremene arhitekture konvolucijske neuronske mreže kao osnova ekstraktora odlika za PDNet-1, ali na osnovu finalnih mAP rezultata može se doći do zaključka da je neznatno povećanje performansi u poređenju sa izmenjenom AlexNet arhitekturom, Tabela 6.6.

**Tabela 6.6** Detekcija lista korišćenjem savremenih arhitekturalnih pristupa za detekciju objekta (*PlantDisease* baza slika)

2-koračne metode	Osnovna arhitektura	mAP
Faster R-CNN	ResNet-101	0.918
Faster R-CNN sa FPN	ResNet-101-FPN	0.924
Faster R-CNN sa TDM	Inception-ResNet-v2-TDM	0.927
1-koračne metode	Osnovna arhitektura	mAP
YOLOv3	DarkNet-53	0.919
SSD513	ResNet-101-SSD	0.925
RetinaNet	ResNetXt-101-FPN	0.921

Predstavljena *PlantDiseaseNet*, nova specijalizovana arhitektura generisana sa fokusom za detekciju bolesti biljaka, na osnovu predstavljenih rezultata dostiže bolje performanse u poređenju sa generalizovanim pristupima analiziranim u prethodna dva eksperimenta uz rešavanje trenutnih ograničenja iz praktičnog korišćenja kao što su višeklasni problemi u okviru iste slike, kompleksne pozadine i kvalitet slike, kao i drugi navedeni problemi u prethodnim poglavljima.

## 7. ZAKLJUČAK I PRAVCI DALJIH ISTRAŽIVANJA

Tačno i blagovremeno dijagnostikovanje bolesti biljaka je od krucijalnog značaja i predstavlja jednu od osnova precizne poljoprivrede. U današnje vreme, uz klimatske promene i globalni transport biljaka, razvoj i brzo širenje patogena je drastično povećano. Rana detekcija bolesti biljaka i dalja prevencija širenja bolesti su jedan od primarnih interesa u samom procesu kultivacije.

Veliki broj bolesti biljaka ima svoju vizuelnu interpretaciju. Pregledanje biljaka „golim okom“ od strane stručnjaka je jedan od najčešćih pristupa u detekciji bolesti. Međutim, bolesti koje nemaju vizuelno manifestovanje (ili se ono dešava u njenim kasnijim fazama gde je mogućnost tretiranja nemoguća ili komercijalno neisplativa) zahtevaju druge, sofisticiranije vrste analiza.

U slučaju vizuelnog manifestovanja bolesti, razvoj automatskog sistema za detekciju, omogućio bi lakše kontinualno praćenje useva, preciznije tretiranje bolesti odgovarajućim tretmanima u situacijama kada je dostupnost stručnog osoblja ograničena. U većini situacija omogućila bi se pravovremena reakcija, uštede, povećanje prihoda, ali i bolja zaštita životne sredine.

Prethodnih godina razvoj dubokih konvolucijskih neuronskih mreža, koje su pokazale izvanredne rezultate u različitim domenima kompjuterske vizije, omogućio je njihovu primenu u širokom spektru oblasti.

U okviru ove disertacije predstavljeni su savremeni pristupi u rešavanju problema automatske detekcije bolesti biljaka korišćenjem dubokih neuronskih mreža. Predstavljena su trenutna dostignuća u ovoj oblasti. Kroz eksperimentalni deo disertacije prikazani su najnoviji pristupi u rešavanju problema automatske detekcije bolesti biljaka kroz metode klasifikacije i detekcije objekata, gde su se koristile

---

najsavremenije arhitekture konvolucijskih neuronskih mreža. Detaljnom analizom determinisani su glavni problemi i ograničenja ovih trenutnih pristupa u njihovom praktičnom korišćenju.

U okviru ove disertacije predstavljena je nova baza slika, *PlantDisease*, sačinjena od listova fotografisanih u prirodnom okruženju u različitim uslovima. Po trenutnim informacijama dostupnim autoru, ova baza ujedno predstavlja najveću bazu slika listova od 12 vrsta biljaka sa svojih skoro 80 hiljada listova kategorisanih od strane stručnjaka u 42 klase (zdravih i obolelih listova). Korišćenje ove baze doprinelo je jasnom određivanju koja su ograničenja trenutnih savremenih pristupa u detekciji bolesti biljaka.

Takođe, u okviru ove disertacije verifikovana je i mogućnost korišćenja jednog od novijih pristupa augmentacije slika listova pomoću GAN arhitektura odgovornih za generisanje sintetičkih slika listova. Ovaj pristup potencijalno bi omogućio jefitiniji i brži način pripreme skupa podataka za treniranje novih modela za detekciju bolesti biljaka. Prikazana su trenutni nedostaci ovog pristupa, odnosno nemogućnost generalnih GAN arhitektura da generišu dovoljno dobre sintetičke slike listova biljaka sa kompleksnijom pozadinom. Jedan od pravaca daljeg istraživanja mogao bi uključiti definisanje i razvoj specijalizovane GAN arhitekture u svrhu generisanja slika listova iz prirodnog okruženja. Ovakva arhitektura imala bi značajan doprinos u rešavanju problema manjka trenutno javno dostupnih baza slika listova. Takođe, imao bi i potencijalan doprinos u povećanju same generalizacije modela.

Kao primarni doprinos ove disertacije, predstavljen je novi specijalizovani algoritam, *PlantDiseaseNet*, sastavljen iz dve faze koje uključuju duboke konvolucijske neuronske mreže sa ciljem rešavanja nedostataka trenutnih pristupa u procesu detekcije bolesti biljaka na osnovu slike lista u prirodnim uslovima. Dobijeni finalni model imao je top-1 tačnost od 93.67% nad slikama iz prirodnog okruženja.

Dalji pravci predmetnog istraživanja mogli bi uključiti ispitivanje korišćenja segmentacije uz ili umesto procesa detekcije u višefaznom arhitekturalnom pristupu za determinaciju bolesti biljaka. Takođe jedan od pravaca bi mogao uključiti ispitivanje uticaja generalnog pristupa treniranju na samu tačnost modela, odnosno da li bi

---

treniranjem zasebnih dubokih neuronskih mreža za pojedinačne tipove biljaka imao značajno veću tačnost u odnosu na jedan uopšteni model.

Razmatra se razvoj informacionog sistema koji bi mogao da koristi razvijeni sistem mreža kao klasifikator u realnom okruženju što bi podrazumevalo i optimizaciju razvijene arhitekture za upotrebu klasifikatora na mobilnim platformama koje imaju znatno manju procesorsku snagu.

I na kraju, najvažniji pravac je utabana staza ka praktičnoj primeni razvijenog sistema.

## LITERATURA

- [1] Zayan, Sahar Abdou. "Impact of Climate Change on Plant Diseases and IPM Strategies." *Plant Pathology and Management of Plant Diseases*. IntechOpen, 2019.
- [2] Garrett, Karen A., et al. "Plant pathogens as indicators of climate change." *Climate change*. Elsevier, 2016. 325-338.
- [3] Pautasso, Marco, et al. "Impacts of climate change on plant diseases—opinions and trends." *European Journal of Plant Pathology* 133.1 (2012): 295-313.
- [4] Coakley, Stella Melugin, Harald Scherm, and Sukumar Chakraborty. "Climate change and plant disease management." *Annual review of phytopathology* 37.1 (1999): 399-426.
- [5] Garrett, Karen A., et al. "Climate change effects on plant disease: genomes to ecosystems." *Annu. Rev. Phytopathol.* 44 (2006): 489-509.
- [6] Aylor, Donald E. "Spread of plant disease on a continental scale: role of aerial dispersal of pathogens." *Ecology* 84.8 (2003): 1989-1997.
- [7] Lipper, Leslie, et al. "Climate-smart agriculture for food security." *Nature climate change* 4.12 (2014): 1068-1072.
- [8] Li, Shining, Jin Cui, and Zhigang Li. "Wireless sensor network for precise agriculture monitoring." *2011 Fourth International Conference on Intelligent Computation Technology and Automation*. Vol. 1. IEEE, 2011.
- [9] Xia, Jianfa, et al. "An environment monitoring system for precise agriculture based on wireless sensor networks." *2011 Seventh International Conference on Mobile Ad-hoc and Sensor Networks*. IEEE, 2011.

- [10] Budaev, D., et al. "Conceptual design of smart farming solution for precise agriculture." (2018).
- [11] Dimitriadis, Savvas, and Christos Goumopoulos. "Applying machine learning to extract new knowledge in precision agriculture applications." *2008 Panhellenic Conference on Informatics*. IEEE, 2008.
- [12] Behmann, Jan, et al. "A review of advanced machine learning methods for the detection of biotic stress in precision crop protection." *Precision Agriculture* 16.3 (2015): 239-260.
- [13] Treboux, Jérôme, and Dominique Genoud. "Improved machine learning methodology for high precision agriculture." *2018 Global Internet of Things Summit (GloTS)*. IEEE, 2018.
- [14] Miller, Sally A., Fen D. Beed, and Carrie Lapaire Harmon. "Plant disease diagnostic capabilities and networks." *Annual review of phytopathology* 47 (2009): 15-38.
- [15] Kaundal, Rakesh, Amar S. Kapoor, and Gajendra PS Raghava. "Machine learning techniques in disease forecasting: a case study on rice blast prediction." *BMC bioinformatics* 7.1 (2006): 485.
- [16] Rumpf, T., et al. "Early detection and classification of plant diseases with support vector machines based on hyperspectral reflectance." *Computers and electronics in agriculture* 74.1 (2010): 91-99.
- [17] Behmann, Jan, et al. "A review of advanced machine learning methods for the detection of biotic stress in precision crop protection." *Precision Agriculture* 16.3 (2015): 239-260.
- [18] Hanson, A. M. G. J., et al. "Plant leaf disease detection using deep learning and convolutional neural network." *International Journal of Engineering Science* 5324 (2017).
- [19] Wiesner-Hanks, Tyr, et al. "Image set for deep learning: field images of maize annotated with disease symptoms." *BMC research notes* 11.1 (2018): 440.

- [20] Gerland, Patrick, et al. "World population stabilization unlikely this century." *Science* 346.6206 (2014): 234-237.
- [21] Tilman, David, et al. "Global food demand and the sustainable intensification of agriculture." *Proceedings of the national academy of sciences* 108.50 (2011): 20260-20264.
- [22] Gibbs, Holly K., et al. "Tropical forests were the primary sources of new agricultural land in the 1980s and 1990s." *Proceedings of the National Academy of Sciences* 107.38 (2010): 16732-16737.
- [23] Evenson, Robert E., and Douglas Gollin. "Assessing the impact of the Green Revolution, 1960 to 2000." *science* 300.5620 (2003): 758-762.
- [24] Egli, Dennis B. "Comparison of corn and soybean yields in the United States: Historical trends and future prospects." *Agronomy journal* 100.Supplement\_3 (2008): S-79.
- [25] Pingali, Prabhu L. "Green revolution: impacts, limits, and the path ahead." *Proceedings of the National Academy of Sciences* 109.31 (2012): 12302-12308.
- [26] Hertel, Thomas W., Navin Ramankutty, and Uris Lantz C. Baldos. "Global market integration increases likelihood that a future African Green Revolution could increase crop land use and CO<sub>2</sub> emissions." *Proceedings of the National Academy of Sciences* 111.38 (2014): 13799-13804.
- [27] Stevenson, James R., et al. "Green Revolution research saved an estimated 18 to 27 million hectares from being brought into agricultural production." *Proceedings of the National Academy of Sciences* 110.21 (2013): 8363-8368.
- [28] Griffin, Keith. *The political economy of agrarian change: An essay on the Green Revolution*. Springer, 1979.
- [29] Fuglie, Keith Owen, Sun Ling Wang, and V. Eldon Ball, eds. *Productivity growth in agriculture: an international perspective*. CABI, 2012.

- [30] Organisation for Economic Co-operation and Development. *OECD compendium of agri-environmental indicators*. OECD Publishing, 2013.
- [31] Lassaletta, Luis, et al. "50 year trends in nitrogen use efficiency of world cropping systems: the relationship between yield and nitrogen input to cropland." *Environmental Research Letters* 9.10 (2014): 105011.
- [32] Field to Market. "Environmental and Socioeconomic Indicators for Measuring Outcomes of On-Farm Agricultural Production in the United States: Second Report." (2012).
- [33] Bennetzen, E. H., P. Smith, and J. R. Porter. "Greenhouse gas emissions from agriculture can fall despite increased food production." *Glob. Change Biol* 22 (2016): 763-781.
- [34] Gebbers, Robin, and Viacheslav I. Adamchuk. "Precision agriculture and food security." *Science* 327.5967 (2010): 828-831.
- [35] Duvick, Donald N. "The contribution of breeding to yield advances in maize (*Zea mays L.*)." *Advances in agronomy* 86 (2005): 83-145.
- [36] Lowenberg-DeBoer, Jess. "The Procision Agriculture Revolution." *Foreign Aff.* 94 (2015): 105.
- [37] Suma, N., et al. "IOT based smart agriculture monitoring system." *International Journal on Recent and Innovation Trends in computing and communication* 5.2 (2017): 177-181.
- [38] Gondchawar, Nikesh, and R. S. Kawitkar. "IoT based smart agriculture." *International Journal of advanced research in Computer and Communication Engineering* 5.6 (2016): 838-842.
- [39] Ingale, Vinod B., and Dhanaji K. Jadhav. "Big Data A Great Revolution in Precision Agriculture using Predictive Weather Analysis and Soil Analysis." *International Journal of Agriculture Innovations and Research* 5 (2016).

- 
- [40] Rose, David C., et al. "Decision support tools for agriculture: Towards effective design and delivery." *Agricultural systems* 149 (2016): 165-174.
  - [41] Lindblom, Jessica, et al. "Promoting sustainable intensification in precision agriculture: review of decision support systems development and strategies." *Precision Agriculture* 18.3 (2017): 309-331.
  - [42] Navarro-Hellín, Honorio, et al. "A decision support system for managing irrigation in agriculture." *Computers and Electronics in Agriculture* 124 (2016): 121-131.
  - [43] Viani, Federico, et al. "Low-cost wireless monitoring and decision support for water saving in agriculture." *IEEE sensors journal* 17.13 (2017): 4299-4309
  - [44] Karim, Foughali, and Fathalah Karim. "Monitoring system using web of things in precision agriculture." *Procedia Computer Science* 110 (2017): 402-409.
  - [45] Nugraheni, P. H. T., et al. "Development of a decision support system for mapping variable rate fertilizing application on Soybean (*Glycine max*) cultivation." *IOP Conference Series: Earth and Environmental Science*. Vol. 355. No. 1. IOP Publishing, 2019.
  - [46] Fanghua, Zhao, and Jiang Bo. "The Research of Decision Support System about Processing Tomatoes Precise Fertilization." *Journal of Agricultural Mechanization Research* 4 (2016): 4.
  - [47] Zhang, Xueyan, et al. "Monitoring citrus soil moisture and nutrients using an iot based system." *Sensors* 17.3 (2017): 447.
  - [48] Liakos, Konstantinos G., et al. "Machine learning in agriculture: A review." *Sensors* 18.8 (2018): 2674.
  - [49] Patrício, Diego Inácio, and Rafael Rieder. "Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review." *Computers and electronics in agriculture* 153 (2018): 69-81.

- [50] Bishop, Christopher M. *Pattern recognition and machine learning*. Springer, 2006.
- [51] Batchelor, Bruce G. *Pattern recognition: ideas in practice*. Springer Science & Business Media, 2012.
- [52] Brunelli, Roberto. Template matching techniques in computer vision: theory and practice. John Wiley & Sons, 2009.
- [53] Chen, Yan Qiu, Mark S. Nixon, and David W. Thomas. "Statistical geometrical features for texture classification." *Pattern recognition* 28.4 (1995): 537-552.
- [54] Warfield, Simon K., et al. "Adaptive, template moderated, spatially varying statistical classification." *Medical image analysis* 4.1 (2000): 43-55.
- [55] Christmas, William J., Josef Kittler, and Maria Petrou. "Structural matching in computer vision using probabilistic relaxation." *IEEE Transactions on pattern analysis and machine intelligence* 17.8 (1995): 749-764.
- [56] Goertzel, Ben. *Artificial general intelligence*. Ed. Cassio Pennachin. Vol. 2. New York: Springer, 2007.
- [57] Russell, Stuart J., and Peter Norvig. *Artificial intelligence: a modern approach*. Malaysia; Pearson Education Limited,, 2016.
- [58] Alpaydin, Ethem. *Introduction to machine learning*. MIT press, 2009.
- [59] Simon, Phil. Too big to ignore: the business case for big data. Vol. 72. John Wiley & Sons, 2013.
- [60] Mitchell, Tom M. "Machine learning. 1997." *Burr Ridge, IL: McGraw Hill* 45.37 (1997): 870-877.
- [61] Moor, James, ed. The Turing test: the elusive standard of artificial intelligence. Vol. 30. Springer Science & Business Media, 2003.

- [62] Samuel, Arthur L. "Some studies in machine learning using the game of checkers. II—Recent progress." *IBM Journal of research and development* 11.6 (1967): 601-617
- [63] Knuth, Donald E., and Ronald W. Moore. "An analysis of alpha-beta pruning." *Artificial intelligence* 6.4 (1975): 293-326.
- [64] Stockman, George C. "A minimax algorithm better than alpha-beta?." *Artificial Intelligence* 12.2 (1979): 179-196.
- [65] Rosenblatt, Frank. "The perceptron: a probabilistic model for information storage and organization in the brain." *Psychological review* 65.6 (1958): 386
- [66] Widrow, Bernard, and Michael A. Lehr. "Perceptrons, Adalines, and backpropagation." *The handbook of brain theory and neural networks* (1995): 719-724.
- [67] Cover, Thomas M., and Peter Hart. "Nearest neighbor pattern classification." *IEEE transactions on information theory* 13.1 (1967): 21-27.
- [68] Lighthill, J. "Artificial intelligence: a paper symposium." *Science Research Council, London* (1973).
- [69] Schapire, Robert E. "The strength of weak learnability." *Machine learning* 5.2 (1990): 197-227.
- [70] Campbell, Murray, A. Joseph Hoane Jr, and Feng-hsiung Hsu. "Deep blue." *Artificial intelligence* 134.1-2 (2002): 57-83.
- [71] LeCun, Yann, et al. "Gradient-based learning applied to document recognition." *Proceedings of the IEEE* 86.11 (1998): 2278-2324.
- [72] McCulloch, Warren S., and Walter Pitts. "A logical calculus of the ideas immanent in nervous activity." *The bulletin of mathematical biophysics* 5.4 (1943): 115-133.

- 
- [73] Mrđen, Josip. *Prepoznavanje rukopisa strojnim učenjem i primjena u identifikaciji popunjениh polja na uplatnici*. Diss. University of Zagreb. Faculty of Electrical Engineering and Computing., 2018.
  - [74] Dabović, Marko M., and Igor I. Tartalja. "Duboke konvolucijske neuronske mreže–koncepti i aktuelna istraživanja." (2017).
  - [75] Clevert, Djork-Arné, Thomas Unterthiner, and Sepp Hochreiter. "Fast and accurate deep network learning by exponential linear units (elus)." *arXiv preprint arXiv:1511.07289* (2015).
  - [76] Deng, Jia, et al. "Imagenet: A large-scale hierarchical image database." *2009 IEEE conference on computer vision and pattern recognition*. Ieee, 2009.
  - [77] Internet izvor: <https://devopedia.org/imagenet>,[pristupljeno 05.05.2020.].
  - [78] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." *Advances in neural information processing systems*. 2012.
  - [79] Lin, Tsung-Yi, et al. "Microsoft coco: Common objects in context." European conference on computer vision. Springer, Cham, 2014.
  - [80] Internet izvor: <https://towardsdatascience.com/alexnet-the-architecture-that-challenged-cnns-e406d5297951>,[pristupljeno 05.05.2020.].
  - [81] Simonyan, Karen, and Andrew Zisserman. "Very deep convolutional networks for large-scale image recognition." *arXiv preprint arXiv:1409.1556* (2014).
  - [82] Internet izvor: <https://neurohive.io/en/popular-networks/vgg16/>,[pristupljeno 05.05.2020.].
  - [83] Szegedy, Christian, et al. "Going deeper with convolutions." Proceedings of the IEEE conference on computer vision and pattern recognition. 2015
  - [84] Internet izvor: <https://deeppai.org/machine-learning-glossary-and-terms/inception-module>,[pristupljeno 05.05.2020.].

- [85] He, Kaiming, et al. "Deep residual learning for image recognition." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
- [86] Internet izvor: [https://d2l.ai/chapter\\_convolutional-modern/resnet.html](https://d2l.ai/chapter_convolutional-modern/resnet.html), [pristupljeno 05.05.2020.]
- [87] Everingham, Mark, et al. "The pascal visual object classes (voc) challenge." *International journal of computer vision* 88.2 (2010): 303-338.
- [88] Girshick, Ross, et al. "Region-based convolutional networks for accurate object detection and segmentation." *IEEE transactions on pattern analysis and machine intelligence* 38.1 (2015): 142-158.
- [89] Uijlings, Jasper RR, et al. "Selective search for object recognition." *International journal of computer vision* 104.2 (2013): 154-171.
- [90] Girshick, Ross. "Fast r-cnn." Proceedings of the IEEE international conference on computer vision. 2015.
- [91] Ren, Shaoqing, et al. "Faster r-cnn: Towards real-time object detection with region proposal networks." *Advances in neural information processing systems*. 2015.
- [92] Redmon, Joseph, et al. "You only look once: Unified, real-time object detection." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
- [93] Liu, Wei, et al. "Ssd: Single shot multibox detector." *European conference on computer vision*. Springer, Cham, 2016.
- [94] Zoph, Barret, et al. "Learning transferable architectures for scalable image recognition." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018.
- [95] He, Kaiming, et al. "Mask r-cnn." Proceedings of the IEEE international conference on computer vision. 2017.

- [96] Goodfellow, Ian, et al. "Generative adversarial nets." *Advances in neural information processing systems*. 2014.
- [97] Lotter, William, Gabriel Kreiman, and David Cox. "Unsupervised learning of visual structure using predictive generative networks." *arXiv preprint arXiv:1511.06380* (2015).
- [98] Ledig, Christian, et al. "Photo-realistic single image super-resolution using a generative adversarial network." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
- [99] Isola, Phillip, et al. "Image-to-image translation with conditional adversarial networks." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
- [100] Zhang, Han, et al. "Stackgan: Text to photo-realistic image synthesis with stacked generative adversarial networks." *Proceedings of the IEEE International Conference on Computer Vision*. 2017.
- [101] Chung, Chia-Lin, et al. "Detecting Bakanae disease in rice seedlings by machine vision." *Computers and electronics in agriculture* 121 (2016): 404-411.
- [102] Shrivastava, Sourabh, Satish Kumar Singh, and Dhara Singh Hooda. "Soybean plant foliar disease detection using image retrieval approaches." *Multimedia Tools and Applications* 76.24 (2017): 26647-26674.
- [103] Camargo, A., and J. S. Smith. "Image pattern classification for the identification of disease causing agents in plants." *Computers and Electronics in Agriculture* 66.2 (2009): 121-125.
- [104] Liu, Tao, et al. "Detection of aphids in wheat fields using a computer vision technique." *Biosystems Engineering* 141 (2016): 82-93.
- [105] Akhtar, Asma, et al. "Automated Plant Disease Analysis (APDA): Performance comparison of machine learning techniques." *2013 11th International Conference on Frontiers of Information Technology*. IEEE, 2013.

- [106] Wang, X., et al. "Spectral prediction of Phytophthora infestans infection on tomatoes using artificial neural network (ANN)." *International Journal of Remote Sensing* 29.6 (2008): 1693-1706.
- [107] Al-Hiary, Heba, et al. "Fast and accurate detection and classification of plant diseases." *International Journal of Computer Applications* 17.1 (2011): 31-38.
- [108] Al Bashish, Dheeb, Malik Braik, and Sulieman Bani-Ahmad. "Detection and classification of leaf diseases using K-means-based segmentation and." *Information Technology Journal* 10.2 (2011): 267-275.
- [109] Barbedo, Jayme GA. "Factors influencing the use of deep learning for plant disease recognition." *Biosystems engineering* 172 (2018): 84-91.
- [110] Kamilaris, Andreas, and Francesc X. Prenafeta-Boldu. "Deep learning in agriculture: A survey." *Computers and Electronics in Agriculture* 147 (2018): 70-90.
- [111] LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. "Deep learning." *nature* 521.7553 (2015): 436.
- [112] Silver, David, et al. "Mastering the game of Go with deep neural networks and tree search." *nature* 529.7587 (2016): 484.
- [113] Young, Tom, et al. "Recent trends in deep learning based natural language processing." *ieee Computational intelligenCe magazine* 13.3 (2018): 55-75.
- [114] Janai, Joel, et al. "Computer Vision for Autonomous Vehicles: Problems." *Datasets and State-of-the-Art* (2017).
- [115] Amara, Jihen, Bassem Bouaziz, and Alsayed Algergawy. "A Deep Learning-based Approach for Banana Leaf Diseases Classification." *BTW (Workshops)*. 2017.
- [116] Hughes, David, and Marcel Salathé. "An open access repository of images on plant health to enable the development of mobile disease diagnostics." *arXiv preprint arXiv:1511.08060* (2015).

- [117] LeCun, Yann. "LeNet-5, convolutional neural networks." *URL: http://yann.lecun.com/exdb/lenet* 20 (2015).
- [118] Ferentinos, Konstantinos P. "Deep learning models for plant disease detection and diagnosis." *Computers and Electronics in Agriculture* 145 (2018): 311-318.
- [119] Liu, Bin, et al. "Identification of apple leaf diseases based on deep convolutional neural networks." *Symmetry* 10.1 (2017): 11.
- [120] Fuentes, Alvaro, et al. "A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition." *Sensors* 17.9 (2017): 2022.
- [121] Kaur, Sukhvir, Shreelekha Pandey, and Shivani Goel. "Plants disease identification and classification through leaf images: A survey." *Archives of Computational Methods in Engineering*(2018): 1-24.
- [122] Barbedo, Jayme Garcia Arnal. "A review on the main challenges in automatic plant disease identification based on visible range images." *Biosystems engineering* 144 (2016): 52-60.
- [123] Cruz, Albert C., et al. "X-FIDO: An effective application for detecting olive quick decline syndrome with deep learning and data fusion." *Frontiers in plant science* 8 (2017): 1741.
- [124] Sladojevic, Srdjan, et al. "Deep neural networks based recognition of plant diseases by leaf image classification." *Computational intelligence and neuroscience* 2016 (2016).
- [125] Brahimi, Mohammed, et al. "Deep learning for plant diseases: detection and saliency map visualisation." *Human and Machine Learning*. Springer, Cham, 2018. 93-117.
- [126] Mohanty, Sharada P., David P. Hughes, and Marcel Salathé. "Using deep learning for image-based plant disease detection." *Frontiers in plant science* 7 (2016): 1419.

- 
- [127] Barbedo, Jayme Garcia Arnal. "Plant disease identification from individual lesions and spots using deep learning." *Biosystems Engineering* 180 (2019): 96-107
  - [128] Gandhi, Rutu, et al. "Plant disease detection using CNNs and GANs as an augmentative approach." *2018 IEEE International Conference on Innovative Research and Development (ICIRD)*. IEEE, 2018.
  - [129] Barth, R., et al. "Optimising realism of synthetic agricultural images using cycle generative adversarial networks." *Proceedings of the IEEE IROS workshop on Agricultural Robotics*. 2017.
  - [130] Zhu, Yezi, et al. "Data augmentation using conditional generative adversarial networks for leaf counting in arabidopsis plants." *Computer Vision Problems in Plant Phenotyping (CVPPP2018)* 1 (2018).
  - [131] Barth, Ruud, Jochen Hemming, and Eldert J. van Henten. "Improved part segmentation performance by optimising realism of synthetic images using cycle generative adversarial networks." *arXiv preprint arXiv:1803.06301* (2018).
  - [132] Wang, Guan, Yu Sun, and Jianxin Wang. "Automatic image-based plant disease severity estimation using deep learning." *Computational intelligence and neuroscience* 2017 (2017).
  - [133] Arsenovic, Marko, et al. "Solving Current Limitations of Deep Learning Based Approaches for Plant Disease Detection." *Symmetry* 11.7 (2 019): 939.
  - [134] Douarre, Clément, et al. "Transfer learning from synthetic data applied to soil–root segmentation in x-ray tomography images." *Journal of Imaging* 4.5 (2018): 65.
  - [135] Radford, Alec, Luke Metz, and Soumith Chintala. "Unsupervised representation learning with deep convolutional generative adversarial networks." *arXiv preprint arXiv:1511.06434* (2015).

- [136] Karras, Tero, et al. "Progressive growing of gans for improved quality, stability, and variation." *arXiv preprint arXiv:1710.10196*(2017).
- [137] Karras, Tero, Samuli Laine, and Timo Aila. "A style-based generator architecture for generative adversarial networks." *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2019.
- [138] Redmon, Joseph, and Ali Farhadi. "Yolov3: An incremental improvement." *arXiv preprint arXiv:1804.02767* (2018).
- [139] Lin, Tsung-Yi, et al. "Focal loss for dense object detection." *Proceedings of the IEEE international conference on computer vision*. 2017.
- [140] Abadi, Martín, et al. "Tensorflow: A system for large-scale machine learning." *12th {USENIX} Symposium on Operating Systems Design and Implementation ({OSDI} 16)*. 2016.
- [141] Paszke, Adam, et al. "Automatic differentiation in pytorch." (2017).
- [142] Lin, Tsung-Yi, et al. "Feature pyramid networks for object detection." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
- [143] Shrivastava, Abhinav, et al. "Beyond skip connections: Top-down modulation for object detection." *arXiv preprint arXiv:1612.06851*(2016).
- [144] Soviany, Petru, and Radu Tudor Ionescu. "Optimizing the trade-off between single-stage and two-stage object detectors using image difficulty prediction." *arXiv preprint arXiv:1803.08707*(2018).