



Универзитет „Св. Кирил и Методиј“ во Скопје
**ФАКУЛТЕТ ЗА ИНФОРМАТИЧКИ НАУКИ И
КОМПЈУТЕРСКО ИНЖЕНЕРСТВО**

Препознавање на растителни видови преку обработка на слика и машинско учење

Докторска дисертација

Петре Ламески

Ментор:

Вон. Проф. д-р Андреа Кулаков

Работна верзија
Скопје, Април 2017

Комисија

Проф. Д-р Владимир Трајковиќ, претседател

Факултет за информатички науки и компјутерско инженерство

Универзитет Св. “Кирил и Методиј”, Скопје, Македонија

Вон. Проф. д-р Андреа Кулаков, ментор

Факултет за информатички науки и компјутерско инженерство

Универзитет Св. “Кирил и Методиј”, Скопје, Македонија

Проф. д-р Дејан Ѓорѓевиќ, член

Факултет за информатички науки и компјутерско инженерство

Универзитет Св. “Кирил и Методиј”, Скопје, Македонија

Вон. Проф. д-р Невена Ацковска, член

Факултет за информатички науки и компјутерско инженерство

Универзитет Св. “Кирил и Методиј”, Скопје, Македонија

Вон. Проф. д-р Татјана Лончар-Турукало, надворешен член

Факултет за технички науки

Универзитет во Нови Сад, Нови Сад, Србија

Препознавање на растителни видови преку обработка на слика и машинско учење

Докторска дисертација

Петре Ламески

Апстракт

Препознавањето на растителни видови преку слика и видео претставува доста актуелна тема на истражувањата во машинската визија и машинското учење. Сеуште постојат огромен број проблеми на кои треба да се најде решение со цел препознавањето на растенијата да се извршува со висока прецизност која би овозможила и развој на сериозни индустриски апликации. Препознавањето на растителните видови претставува склоп од повеќе проблеми кои може да се дефинираат на две групи во зависност од интересот и тоа, препознавање на присуство на растението на сликата (пребарување на слики) и сегментација на растението од сликата.

Во рамките на овој докторски труд се разгледуваат најновите достигнувања во науката за двата проблеми и се даваат предлози за подобрување на сегментацијата на растенија од слика со акцент на препознавањето и сегментацијата на штетни растенија, плевел во рани расади снимани на територијата на Република Македонија со помош на обични, комерцијално достапни камери. Во рамките на овој докторски труд беа генерирани две податочни множества и тоа: Множество за препознавање на плевел на расади од тутун од Прилепскиот регион на Република Македонија, под различни временски услови и различно ниво на осветлување, како и множество за препознавање на плевел во расади од спанаќ и морков снимани во Криволак, Неготинско, во Република Македонија, исто така под различно ниво на осветлување. Целта на истражувањето на овој докторски труд беше да се испита можноста за примена на алгоритми за машинско учење и

машинска визија како и алгоритми за длабоко учење за сегментација на плевелот од слики од RGB камери. Ваквиот пристап би бил првиот чекор од изградбата на сензорски систем базиран на машинска визија кој би се користел во склоп на систем за автоматска детекција и отстранување на плевел од земјоделските површини. Користењето на вакви камери би овозможило значајно намалување на цената на сензорскиот систем во однос на цените на мултиспектралните камери кои се користат за истата намена.

Резултатите од овој докторски труд покажуваат дека постои подобрување на детекцијата на плевел со користење на најновите алгоритми за машинско учење и длабоко учење, но дека сеуште постојат извесни предизвици кои треба да се разрешат при користењето на обични RGB камери при препознавањето на плевел. Исто така во рамките на овој докторски труд, се предлага и кориснички интерфејс за аотирање на податоците и решение за јавно прибирање на податоците кое би овозможило генерирање на попрецизни модели и поголеми податочни множества, не само за решавање на проблемот со препознавање на плевел, туку и генерално за било кој проблем кој би вклучувал на определени делови од интерес од множества од слики.

Клучни зборови: Обработка на слика, Машинска визија, Машинско учење, Препознавање на растенија, Препознавање на плевел, Управување со плевел, Прецизно земјоделство

Ментор: Вон. Проф. д-р Андреа Кулаков

Plant Species Recognition based on Image Processing and Machine Learning

PhD Thesis

Petre Lameski

Abstract

Plant species recognition has received a great attention from the machine learning and vision communities. There are many challenges that need to be overcome in order to have a reliable plant recognition method that could be used in serious industrial applications. The problem of plant species recognition can be seen as two separate problems, based on the goal that we want to achieve. The first problem can be defined as recognizing the presence of a certain plant on an image (retrieval problem), and the second problem is finding a certain type of plant in an image and segmenting it from the image.

In this dissertation we are reviewing state of the art achievements for both problems and give some suggestions for their improvement. The accent of the research is put on detection and segmentation of plants from images, especially from crop field images, where the main goal is detection and segmentation of unwanted weed plants. For this purpose we have recorded several datasets from seedling plantations in the Republic of Macedonia using common, commercially available cameras. We have generated two datasets, one with tobacco seedling images and the other with spinach, carrot and salad images. Both datasets were generated from images taken under variable light conditions and under slightly different heights. The tobacco seedling images were taken from the Prilep region in Macedonia, and the Salad and Carrot images were taken from the region around Negotino, Macedonia. The goal of the research was to examine the possibility of using different machine vision and learning algorithms for the purpose of plant weed segmentation from the images. This approach would be

the first step of the design and implementation of a low cost, machine learning based sensor system, that could be used for weed control automation.

The results of this dissertation show that there is significant improvement in the weed detection by using the novel machine learning and deep learning methods, however there are still some challenges that need to be overcome so that common RGB cameras can be used for weed detection. We also present a novel user interface for data generation and annotation that can be used by farmers for specialized model training for specific plant types. This approach could be used for plant-weed segmentation datasets, but it could also be used for dataset generation in other types of segmentation problems.

Keywords: Image Processing, Machine Vision, Machine Learning, Plant species recognition, Weed recognition, Weed control, Precision Agriculture

Supervisor: Prof. Andrea Kulakov, PhD

Содржина

Апстракт	iii
Abstract	v
Листа на слики	x
Листа на табели	xii
1 Вовед	1
1.1 Мотивација за изработка на докторската дисертација	2
1.2 Хипотеза на докторската дисертација	4
1.3 Структура на докторската дисертација	5
1.4 Достигнувања и научни трудови поврзани со докторската дисертација	6
2 Преглед на литература и користени алгоритми	9
2.1 Индекси и простори на бои кои се користат за сегментација на растенија	10
	vii

2.2	Дескриптори за слика кои се користат за препознавање на растенија	16
2.2.1	Дескриптори на текстура	17
2.2.2	Дескриптори на контури	22
2.2.3	Дескриптори на региони околу точки	26
2.3	Алгоритми и пристапи кои се користат за редуција на должината на дескрипторите	28
2.4	Алгоритми за машинско учење кои се користат за препознавање на растителни видови	31
2.4.1	Машини со носечки вектори	33
2.4.2	Дрва на одлука	34
2.4.3	Алгоритам К најблиски соседи	35
2.4.4	Алгоритми за ненадгледувано учење	36
2.5	Длабоко учење за препознавање растителни видови	37
2.5.1	Конволуциски мрежи	38
3	Податочни множества	44
3.1	Плевел во расад од спанаќ	45
3.2	Плевел во расад од тутун	46
3.3	Плевел во расад од морков	48
4	Препознавање на растителни видови и детекција на плевел од слики	50

4.1	Препознавање на плевел од спанаќ со надгледувано и ненадгледувано учење	51
4.2	Препознавање на плевел од слики од расад од тутун	54
4.3	Препознавање на видот на растението со користење на дескриптори на контура од слики од листови	59
4.4	Препознавање на растението според слики од листовите со користење на дескриптори на текстура	65
4.5	Класификација на плевел од слики од расад на морков	70
4.6	Архитектура на систем за детекција на плевел базирана на пресметки во облак	77
5	Заклучок	82

Листа на слики

2-1	RGB простор на бои	10
2-2	HSV простор на бои	12
2-3	CIELAB простор на бои	14
2-4	Пресметка на $LBP_{8,1}$	19
2-5	Визуелизација на градиенти од сегменти на слика при пресметка на HOG дескриптор	22
2-6	Избор на една точка, соседи и измерени величини при генерирање на дескриптор на триаголници (α е аголот помеѓу отсечките, d_l е растојанието до левата и d_r е растојанието до десната точка) . . .	24
2-7	Споредување на дескриптори на точки и детекција на претходно познат објект на слика	27
2-8	Илустрација на машини со носечки вектори на едно податочно множество во рамнина	33
2-9	Определување на припадноста на класа со наоѓање на K најблиски соседи	36
2-10	Архитектура на првата невронска мрежа која употребува конволуциски слоеви, LeNet	39

2-11	Архитектура на AlexNet	40
2-12	Сигмоидна активациска функција (лево) и ReLu активациска функција (десно)	40
2-13	Илустрација на архитектурата SegNet	41
2-14	Илустрација на операторот за конволуција	42
2-15	Илустрација на операторот за деконволуција	43
3-1	Слика од податочното множество пред сегментацијата	46
3-2	Слика со маски за површини од сликата кои после сегментацијата се прогласени за вегетација	47
3-3	Слики од спанаќ во податочното множество со расад од спанаќ	48
3-4	Слики од плевел во податочното множество со расад од спанаќ	48
3-5	Слики од плевел во податочното множество со ран расад од тутун	49
3-6	Слики од плевел во податочното множество од леи со морков (Лево - слика во RGB, Средина - вегетативна маска, Десно - маска со плевел и корисно растение)	49
4-1	Тренирање на класификационен модел и негово користење при детекција на плевел од слики од расад на спанаќ	54
4-2	Архитектура за генерирање на мапи	56
4-3	Пример слики за препознавање на растителниот вид преку контурите на листовите	60
4-4	Класификација на растенија преку контурите на нивните листови	61

4-5	AUC ROC за двата пристапи на класификација и двата дескриптори	63
4-6	Прецизност за двата пристапи на класификација и двата дескриптори	64
4-7	Шема на поделба на региони за пресметка на дескрипторот за контекст на форма	66
4-8	Пример слика од податочното множество од расад на морков (1) .	71
4-9	Пример слика од податочното множество од расад на морков (2) .	71
4-10	Пример слика од податочното множество од расад на морков (3) .	72
4-11	Архитектура на систем за детекција на плевел во облак	78
4-12	Кориснички интерфејс за аотирање на податоците за детекција на плевел	80
4-13	Архитектура за генерирање на мапи	81

Листа на табели

4.1	Матрица на конфузија на класификација со SVM	53
4.2	Матрица на конфузија на класификација со K-средни вредности	53
4.3	Перформанси на класификаторите на податочното множество	58
4.4	Број на дескриптори и просечна прецизност при вкрстена валидација при класификација со невронски мрежи	68
4.5	Резултати од сегментација на зелени површини од слика со користење на длабоко учење и индекси на бои	74
4.6	Резултати од тренирањето на модели за длабоко учење со HSV и Lab слики	76

Глава 1

Вовед

Во последните неколку децении, развојот на компјутерската обработка на слика и видео зема се поголем замав, пред сè како последица на значајните унапредувања на хардверот за дигитална аквизиција и снимање на слики и видеа, особено на квалитетот на снимените материјали. Ваквото зголемување на квалитетот, заедно со зголемените процесирачки капацитети на центрите за обработка на податоците, овозможуваат имплементација на посложени алгоритми.

Интересот за развој на овие области е побуден од огромниот број на потенцијални апликации во кои може да ги искористат алгоритмите за препознавање на објекти во слика. Областите кои би имале корист од ваквиот развој се многубројни. Дел од нив се медицината, земјоделството, инспекцијата на квалитет на производство при производството на делови за машини, воената индустрија, екологијата и многу други. Крајната цел на градењето апликации кои користат алгоритми за машинска визија и учење е автоматизација на голем број процеси во човековото живеење со цел, зголемување на продуктивноста на работната сила и олеснување на секојдневниот живот на луѓето.

Постојат повеќе задачи кои се поставуваат при обработката на слика: Препознавање на објекти во сликата, сегментација на сликата на области од интерес и

области кои не се од интерес, пребарување на слика низ база од слики и сл. Сите овие задачи се еднакво значајни за развојот на компјутерските науки, а особено за развојот на роботиката и интелигентните системи, каде што овие решенија би нашле и најголема примена.

Препознавањето на растителни видови преку слика претставува релативно нова област во компјутерските науки. Постојат голем број предизвици при користењето на алгоритмите за машинска визија и учење за препознавање на растителните видови од слика. Во последните неколку години, започната е значајна експанзија на истражувањата во областите на примена на машинската визија и учење во земјоделството. Особено значајни се истражувањата за автоматска детекција на болести, вода и детекција на плевел во растителните површини. Истражувањата имаат за цел да го автоматизираат процесот на детекција, со цел да се овозможи навремена реакција на детектираните проблеми и соодветно, зголемување на приносите по единица земјоделска површина. Алгоритмите за препознавање на растителни видови, како и за препознавање на плевел или болести, треба да бидат доста прецизни за да бидат применливи и корисни за земјоделството бидејќи непрецизностите во детекцијата може да направат поголема штета отколку користа што би ја имале земјоделците од вакви автоматски системи.

1.1 Мотивација за изработка на докторската дисертација

Според најновите истражувања на светските агенции за храна, тековниот интензитет на зголемување на приносите по единица површина во светски рамки, нема да биде доволен за да ги задоволи пазарните потреби од храна до 2050 година [1]. Ваквите трендови се последица на зголемената потреба од храна во светски рамки, која е предизвикана како од зголемувањето на бројот на жители

на планетата, така и од зголемените потреби на земјите во развој кои се повеќе сè доближуваат до развиените земји.

Еден од начините да се пресретне и задоволи динамиката на раст на производството, со оглед на тоа што квантитетот на обработливи површини е фактор на кој не може да се влијае е автоматизација на производството преку користење на роботски системи. Според [2], воведувањето на роботиката во земјоделството успева значајно да ги подобри приносите по единица обработлива површина. Главната предност на ваквиот начин на обработка на земјата е тоа што земјоделските површини не се третираат како цели површини, туку посебните делови од земјоделските површини се третираат како посебни единици со различни потреби за обработка и третман.

Ваквиот начин на третирање се нарекува прецизно земјоделство и зема сè поголем замав во развиените земји. Прецизното земјоделство овозможува зголемување на приносите, но во исто време ги зголемува трошоците за менаџирање со земјоделските површини. Сепак и покрај овој негативен ефект, докажано е дека прецизното земјоделство и автоматизацијата на производството во земјоделството ги зголемува приносите, но и профитот остварен од единица обработлива површина [3]. Покрај економските придобивки од развојот на автоматизацијата во земјоделството, евидентни се и еколошките придобивки [4], преку намалување на загадувањето од хербициди и пестициди. Еколошките придобивки се овозможени пред сè од прецизните сензорски системи кои овозможуваат таргетирана апликација, која значајно ја намалува употребата на хербициди [5, 6, 7, 8, 9, 10].

Еден од главните предизвици за примена на прецизното земјоделство претставува аквизицијата на податоци од земјоделските површини. За таа цел се користат различни сензорски системи, меѓу кои и камерите, преку кои се добиваат визуелни податоци од земјоделските површини. Користењето на камерата како сензор не е нова пракса, туку потекнува уште од седумдесетите години од минатиот век, кога камерите почнале да се користат за естимација на вегетацијата на

земјината површина преку обработка на слики од сателити.

Крајната цел на овој докторски труд претставува дизајн и имплементација на алгоритми за автоматска детекција на плевел, кои би овозможиле таргетиран третман на земјоделските површини. Ова значи дека крајната цел е таргетиран третман на растенијата со директна третирање на поединечните растенија, а не на поголеми сегменти од обработливите површини. За таа цел потребна е прецизна сегментација на растенијата и детекција на нивниот вид. Имплементацијата на ваков сензорски систем со машинска визија и учење би овозможил прецизна апликација на хербициди или физички третман на растението, како што тоа рачно би го правел човекот. Дополнително, целта на истражувањата на овој докторски труд претставува користењето на што поевтини ресурси, со цел овозможување на достапност на ваквите системи, не само на големите производители, туку и на индивидуалните фармери.

1.2 Хипотеза на докторската дисертација

Главната хипотеза на оваа докторска дисертација е дека:

Примената на машинското учење и визија, преку користење на дескриптори за текстури и контури, како и користењето на алгоритми за длабоко учење ќе даде подобрување во прецизноста на препознавање на растителните видови од слики, особено при решавање на проблемот на детекција на плевел во земјоделски обработливи површини.

Евалуацијата на оваа хипотеза е извршена преку синтеза на податочни множества од реални обработливи површини. Овие податочни множества, понатаму се анотирани и со нивна помош е извршена анализа преку користење на различни алгоритми за дескриптори на текстури и контури, сегментација, како и алгорит-

ми за длабоко учење. Направена е споредба на повеќе различни пристапи за обработка на сликите од податочните множества и градење на класификациски модели за класификација на регионите на плевел, корисно растение и останата површина. Заради природата на проблемот кој се третира во рамките на оваа докторска дисертација, самата класификација на растителните видови се сведува и на сегментација на региони од интерес на сликата во кои се наоѓа некое посакувано растение, од регионите на сликата во кои се наоѓа штетно растение. Хипотезата претставена во рамките на оваа докторска дисертација е делумно потврдена со експериментите изведени на генерираните податочни множества и добиени се реални подобрувања, но сè уште остануваат многу предизвици кои треба да се разрешат за да може ефективно да се користат предложените пристапи за автоматска детекција на плевел.

1.3 Структура на докторската дисертација

Овој докторски труд е организиран на следниот начин:

Во Глава 1 е даден краток вовед во темата, претставена е хипотезата на докторската дисертација и даден е нејзин опис. Потоа во истата глава наброени се објавените трудови од оваа докторска дисертација.

Во Глава 2 даден е преглед на користените алгоритми и преглед на научните достигнувања од потесната област поврзана со оваа докторска дисертација. Најпрво се опишани просторите на бои и индексите на бои кои се користат за сегментација на растенија од слика, потоа се опишани најдобрите дескриптори на слика кои се користат за опишување на сликите од растенија. Потоа се опишани дел од алгоритмите и пристапите кои се користат за селекција на атрибутите од дескрипторите на слика. Понатаму опишани се алгоритмите за машинско учење кои се користат за препознавање на растителни видови и за детекција на плевел. Опишани се алгоритми за надгледувано и ненадгледувано учење. На крајот на

ова поглавје се опишани алгоритмите за длабоко учење кои се користат за препознавање на објекти и растенија од слика, со особен осврт на конволуциските невронски мрежи.

Во Глава 3 претставени се и опишани податочните множества кои се користат во испитувањата во оваа докторска дисертација. Дадена е локацијата и времето на снимање на податочните множества, како и бројот на примероци кои се земенни. Исто така, даден е опис за количината на снимените материјали и нивниот квалитет, како и начинот на кој податоците се аотирани.

Во Глава 4 опишани се експериментите изведени во рамките на оваа докторска дисертација со опишаните податочни множества и алгоритми. Опишани се повеќе пристапи кои се изведени експериментално над снимените податочни множества. Пристапите вклучуваат обиди за детекција на плевел и препознавање на растителни видови со помош на дескриптори за текстура, контура, комбинација од овие дескриптори, како и алгоритми за длабоко учење кои се користат за сегментација на слики, а имаат потенцијална примена и во детекцијата на плевел во слики од расад.

На крајот во Глава 5 дадени се заклучоците донесени од истражувањата, како и идни насоки кои можат да доведат до подобрување на опишаните пристапи со кои се извршени експериментите.

1.4 Достигнувања и научни трудови поврзани со докторската дисертација

Предложените пристапи во рамките на оваа дисертација се делумно објавени во повеќе зборници од меѓународни конференции и меѓународни списанија. Покрај на слики од растителни видови, дел од користените пристапи се применети и на други податочни множества од различен карактер. Во рам-

ките на истражувањата изведени во оваа докторска дисертација објавени се повеќе научни публикации, меѓу кои како најважни ги издвојуваме следните [11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24].

Од овие трудови [21] е објавен во IEEE Access со импакт фактор 1.270, а [24] е исто така објавен во истото списание. Трудот [22] е објавен во списанието Multimedia Tools and Applications со импакт фактор 1.331. Овие трудови се во пошироката област на оваа докторска дисертација. Во нив се користат дел од пристапите за селекција на атрибути и машинско учење кои се применети во рамките на докторската дисертација.

Трудот [19] е објавен како поглавја од книги од серијата Advances in Intelligent Systems and Computing, додека трудот [18] е објавен како поглавје во книга од серијата Lecture Notes in Computer Science на издавачката куќа Springer со меѓународен уредувачки одбор. Останатите трудови [13, 17, 18, 16, 19, 20] се објавени на зборници од конференции со меѓународен уредувачки одбор. Овие трудови се во потесната област на истражувањата изведени за време на изработката на оваа докторска дисертација. Употребени се податочните множества и пристапите за процесирање слика и машинско учење опишани во оваа докторска дисертација.

Дел од дискусиите и наодите претставени во рамките на оваа дисертација се презентирани и на конференцијата ICT in Agrobusiness во Скопје на 24.11.2016 во презентацијата со наслов "Weed detection from images and its use in precision agriculture"

Како дел од оваа докторска дисертација го издвојуваме и учеството на LifeClef 2014 година заедно со колегите Ивица Димитровски, Ѓорѓи Маџаров од Факултетот за информатички науки и компјутерско инженерство од Македонија и Драги Коцев од Институтот Јожев Стефан од Словенија каде што беше освоено 5-то место во конкуренција на 10 тимови со 27 предложени решенија за препознавање на растителни видови од слики.

Исто така дел од истражувањата и резултатите добиени во истражувањата од оваа докторска дисертација беа применети за време на натпреварот Sheffield Field Robotics Challenge 2016, каде што во конкуренција од повеќе интернационални тимови, е освоено првото место. Целта на овој натпревар беше имплементација на комбиниран пристап од дрoнови и автономни возила за детекција на артефакти во полињата и нивна локализација со дрoнот, пристап до нив со автономното возило и извршување на соодветна операција во зависност од типот на артефактот.


Глава 2

Преглед на литература и користени алгоритми

Истражувањата во областа на машинското учење и визија се доста актуелни и во последните децении има огромен број на научни публикации кои ги претставуваат најновите достигнувања. Во рамките на оваа докторска дисертација ќе ги издвоиме во посебни сегменти публикациите кои имаат значење за препознавањето на растителни видови особено за сегментацијата на плевелот и корисните растенија од слики снимени со RGB (Red, Green, Blue) камери. Кога се работи за препознавање на растителните видови, историски гледано, едени од првите пристапи, кои сеуште се актуелени за сегментација на растителни површини од нерастителни површини претставуваат пристапите со вегетациските индекси на бои и просторите на бои. Овие пристапи ќе бидат подетално опишани во првиот дел од ова поглавје.

2.1 Индекси и простори на бои кои се користат за сегментација на растенија

Просторите на бои претставуваат координатни системи во кои се претставени боите. Стандардниот и најчесто користениот простор на бои е RGB просторот во кој на трите оски соодветно се претставуваат вредностите на интензитетите на црвената, зелената и сината боја. Овој простор на бои е адитивен, во смисла дека со комбинирањето на секоја од основните бои се добива било која друга боја од спектарот. На Слика 2-1¹ е прикажан RGB просторот зададен со опсег на вредностите на секој од каналите од 0 до 255, или по еден бајт за секоја боја.



Слика 2-1: RGB простор на бои

Просторот на бои RGB, претставува стандарден простор на бои за уредите за репродукција на слика, меѓутоа, како таков, има неколку недостатоци. Првиот недостаток е тоа што различните уреди, различно ги репродуцираат боите прикажани во RGB. Другиот недостаток е тоа што овој простор на бои е несоодветен за проблемот на препознавање на бои и за сегментација на сликите врз основа на боите. Причината е тоа што во RGB просторот, векторските растојанија помеѓу точките, односно боите, не соодветствуваат на реалните растојанија кои

¹Сликата е преземена од <http://bagrow.info>

одговараат на човековата перцепција. Заради тоа, во процесирањето на слики, се користат други простори на бои, кои претставуваат трансформација од RGB просторот на бои. Вакви простори на бои има повеќе, па тука ќе ги издвоиме оние кои најчесто се користат за решавање на проблеми за препознавање на облици и сегментација, а тие се HSV (Hue, Satturation, Value) и CIELAB просторот на бои.

HSV просторот на бои, во буквален превод би значел боја, заситување и осветлување. Овој простор на бои претставува конусен простор во кој едната координата, V , го означува нивото на осветлување, другата координата, S , го означува заситувањето или јачината на бојата, а третата координата, H претставува аголна координата во која соодветните опсези на аголот означуваат соодветна боја. HSV просторот овозможува едноставна сегментација на боите. На Слика 2-2 е илустриран овој простор на бои.


Овој простор на бои се добива преку трансформација на RGB просторот на бои користејќи ги равенките од 2.1 до 2.7. Овој простор на бои се користи за сегментација на растителни површини од слики во комбинација со други параметри [25].

$$r = \frac{R}{255}, g = \frac{G}{255}, b = \frac{B}{255} \quad (2.1)$$

$$Cmax = \max(r, g, b) \quad (2.2)$$

$$Cmin = \min(r, g, b) \quad (2.3)$$

$$\Delta = Cmax - Cmin \quad (2.4)$$



Слика 2-2: HSV простор на бои

$$H = \begin{cases} 0^\circ, \Delta = 0 \\ 60^\circ \left(\frac{g-b}{\Delta} \bmod 6 \right), C_{max} = r \\ 60^\circ \left(\frac{b-r}{\Delta} + 2 \right), C_{max} = g \\ 60^\circ \left(\frac{r-g}{\Delta} + 4 \right), C_{max} = b \end{cases} \quad (2.5)$$

$$S = \begin{cases} 0, C_{max} = 0 \\ \frac{\Delta}{C_{max}}, C_{max} \neq 0 \end{cases} \quad (2.6)$$

$$V = Cmax \quad (2.7)$$


CIELAB просторот на бои, претставува обид за доближување до реалниот перцепт за боја кој што го има човекот. Овој простор на бои претставува обид за линеаризација, при која најсличните бои се доближуваат поблиску во векторскиот простор, а различните бои се оддалечуваат. Овој простор на бои е дефиниран уште од 1976 и опфаќа поголемо множество на бои од оние кои се видливи во стандардниот простор на бои. CIELAB уште нарекуван и само Lab има три канали од кои првиот канал, L , има вредности од 0 до 100 и го претставува осветлувањето, каде што 0 претставува црна, а 100 претставува бела боја. Вториот канал, a , кога има позитивни вредности се доближува до црвена, а кога има негативни вредности до зелена боја. Третиот канал, b , кога има позитивни вредности се доближува до жолтата, а кога има негативни, се доближува до сината боја. На слика 2-3 се илустрирани оските од овој простор на бои.

За сегментација на растителни површини од слики се користат, таканаречени, вегетативни индекси. Овие индекси го користат видливиот дел од спектарот и невидливите инфра-црвени фреквенции на светлината за да овозможат сегментација на растителните површини од сликите. Постојат повеќе вакви вегетативни индекси кои даваат различни резултати при сегментацијата на растителните површини. Ќе ги одвоиме NDVI [26], ExG [27] и ExGExR [28] индексите, кои се користат во рамките на истражувањата во овој докторски труд.

ExG и ExGExR индексите се пресметуваат според формулите 2.8 и 2.9. И двете формули ја користат нормализираната вредност на RGB пикселите која се пресметува според формулата 2.1.

$$ExG = 2g - r - b \quad (2.8)$$

$$ExGExR = ExG - 1.4r - g \quad (2.9)$$



Слика 2-3: CIELAB простор на бои

Друг индекс кој исто така се користи за сегментација на зелени површини претставува VEG индексот користен во [29]. Овој индекс се пресметува според формулата 2.10. Според авторите, коефициентот α се поставува на вредноста 0.66(6)

$$VEG = \frac{g}{r^\alpha b^{1-\alpha}} \quad (2.10)$$

За пресметување на NDVI индексот се користи видливиот и блискиот инфрацрвен спектар. NDVI се пресметува според формулата 2.11. Во оваа равенка, NIR го означува интензитетот на светлината во блискиот инфрацрвен спектар, додека VIS го означува вкупниот интензитет на видливиот спектар. За негово

пресметување потребни се специјални камери.

$$NDVI = \frac{NIR - VIS}{NIR + VIS} \quad (2.11)$$

Иако дава подобри резултати во поглед на сегментација на растителни од останати површини, овој индекс не се користи во истражувањата опфатени со оваа докторска дисертација бидејќи целта на истражувањата беше да се користат подостапните и поевтини RGB камери. Цената на мултиспектралните камери е значително повисока, но и нивните можности во поглед на детекција на различни феномени кај растенијата се подобри.

Покрај индексите на бои кои се користат пред сè за сегментација на сликите, за самото препознавање на објекти на сликите како и за класификација на сликите, потребна е дополнителна трансформација на информациите кои се дадени на сликата. Проблемот со претставувањето на сликите само преку боите е во тоа што мали варијации на боите на сликата можат да направат големи разлики помеѓу истите објекти од сликите доколку се потпираме само на нив при споредбата на слика со слика или објект од слика со објект од слика.

Заради ова се јавува потребата од трансформирање на информациите од сликата на начин што ќе овозможи робустност при претставувањето на објектите од сликата. Оваа робустност е неопходна за успешно препознавање на објектите од слика бидејќи објектите на сликите не секогаш имаат иста големина изразена во пиксели и не секогаш се снимени од ист агол или под исти услови и осветлување. Заради тоа се користат дескрипторите за слики кои се опишани во понатамошниот текст.

2.2 Дескриптори за слика кои се користат за препознавање на растенија

Дескрипторите претставуваат описи на сликите кои овозможуваат трансформација на сликата од еден во друг векторски простор. Ваквата трансформација овозможува подобра анализа помеѓу различните делови од сликата или помеѓу различните слики. Дескрипторите на слики се делат на два вида: локални дескриптори и глобални дескриптори.

Локалните дескриптори овозможуваат локална репрезентација на определени сегменти од сликата, додека глобалните дескриптори ја опишуваат целата слика. Ваквата поделба на дескрипторите е природна, меѓутоа не е исклучива. Поделбата повеќе се однесува на начинот на кој што се третираат сликите и на проблемот кој се обидуваме да го решиме со користењето на дескрипторите.

Доколку сакаме да вршиме пребарување низ база од слики, тогаш глобалните дескриптори би биле посоодветни, со оглед на тоа што со нивна помош ќе биде извршена поголема компресија на информациите кои се содржани во сликите и пребарувањето ќе биде поедноставно. Доколку пак, сакаме да детектираме објекти во определени делови од сликата, тогаш посоодветни ќе бидат локалните дескриптори. Уште еднаш, ваквата поделба не е исклучива бидејќи истите дескриптори кои се користат за опишување на локалните делови од сликата, можат да се употребат и за опишување на целата слика, со користење на дополнителни трансформации.

Посоодветна поделба на дескрипторите може да направиме врз основа на квалитетите од сликите кои сакаме да ги опишеме. Постојат неколку квалитети кои ги имаат сите визуелни објекти, вклучително и оние кои ги набљудуваме на сликата, а тие се: боја, текстура и контура. Бидејќи бојата како квалитет и начините за нејзина репрезентација веќе ги разгледавме, ќе се задржиме на

останатите квалитети на сликите, односно, текстурите и контурите.

2.2.1 Дескриптори на текстура

Текстурите претставуваат надворешна карактеристика на некоја површина. Текстурите можат визуелно да се перцепираат и човекот е доста добар при нивното разликување. Врз основа на текстурата објектите можат да се разликуваат едни од други. Постојат повеќе начини за опишување на текстурите. Во понатамошниот текст ќе бидат опишани најновите дескриптори за опис на текстури, Локални бинарни облици (LBP - Local binary patterns) [30] и Хистограм на насочени градиенти (HOG - Histogram of oriented gradients) [31]. Постојат многу други дескриптори за текстури. Таков е на пример дескрипторот за фрактални текстури базирани на сегментација [32].

Во рамките на оваа докторска дисертација ги издвојуваме HOG и LBP како најкористени дескриптори и како дескриптори кои даваат најдобри резултати во поглед на прецизноста на класификацијата и брзината потребна за нивно генерирање.

Локални бинарни шеми

Локалните бинарни облици претставуваат еден од наједноставните пристапи за опис на текстурите на дадена слика или објект. Локалните бинарни облици се пресметуваат за секој пиксел од сликата и ги извлекуваат карактеристиките на сликата во локална област околу секој пиксел. Потоа, ваквите карактеристики формираат хистограм, кој најчесто се користи како дескриптор за опишување на сликата или на делови од сликата [33].

Локалната бинарна шема се пресметува така што се наоѓа разликата помеѓу соседните пиксели на радиус R околу пикселот за кој се врши пресметување-

то. Доколку сликата содржи само еден канал (ниво на осветлување или нијанси на сиво) и доколку вредноста на пикселот со координати (x, y) ја означиме со $g_c = I(x, y)$, тогаш локалната бинарна шема можеме да ја пресметаме со пресметување на разликите во интензитетите помеѓу централниот пиксел и P пиксели распоредени околу него на радиус R . Со равенките од 2.12 до 2.14 ги пресметуваме интензитетите на сите пиксели на радиус R од централниот пиксел. Бидејќи пикселите имаат целобројни координати, се користи билинеарна интерполација секогаш кога вредноста не е во центарот на некој пиксел.

$$g_p = I(x_p, y_p), p = 0, \dots, P - 1 \quad (2.12)$$

$$x_p = x + R \cos(2\pi \frac{p}{P}) \quad (2.13)$$

$$y_p = y - R \sin(2\pi \frac{p}{P}) \quad (2.14)$$

Потоа пресметуваме разлика на секој од пикселите со централниот пиксел. Доколку множеството интензитети го означиме со $t(g_c, g_0, \dots, g_{P-1})$ тогаш без губење на информација можеме да ја направиме следната трансформација: $t(g_c, g_0 - g_c, \dots, g_{P-1} - g_c)$ и дополнително да ја игнорираме вредноста на g_c . На тој начин добиваме P вредности $t(g_0 - g_c, \dots, g_{P-1} - g_c)$. Овие вредности ја даваат локалната карактеристика на текстурата околу точката (x, y) . Понатаму можеме да ја квантифицираме вредноста така што ќе ја искористиме функцијата за праг 2.15.

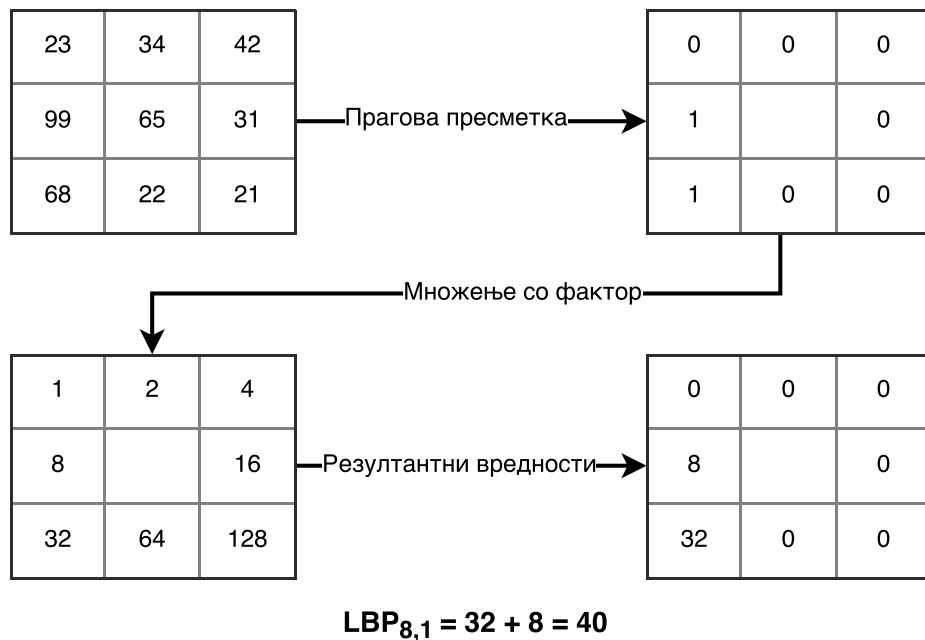
$$tr(z) = \begin{cases} 0, & z \geq 0 \\ 1, & z < 0 \end{cases} \quad (2.15)$$

Конечно можеме да го дефинираме операторот за локални бинарни шеми како $LBP_{P,R}$ според формулата 2.16.

$$LBP_{P,R} = \sum_{p=0}^{P-1} tr(g_c - g_p)2^p. \quad (2.16)$$

Според оваа формула, $LBP_{P,R}$ може да има 2^P различни вредности и според тоа, можеме да искористиме код од 2^P вредности за да ја прикажеме дистрибуцијата на локални бинарни шеми на сликата. Вака добиениот хистограм претставува дескриптор на текстурата на сликата за која се пресметува.

Интересен е случајот за $R = 1$ и $P = 8$ каде што се добиваат точно 256 можни вредности за дескрипторот, односно, LBP трансформацијата може да биде сместена во точно 1 бајт така што секоја вредност 1 или 0 ќе претставува по 1 бит. Во овој случај од едноканална слика се добива нова едноканална 8 битна слика која за секој пиксел (освен периферните пиксели за кои LBP неможе да се пресмета) ја добива вредноста на LBP трансформацијата и хистограмот кој се добива има точно 256 вредности што претставува дескриптор со релативно мала димензија. Пресметката на LBP дескрипторот за $R = 1$ и $P = 8$ е прикажана на Слика 2-4



Слика 2-4: Пресметка на $LBP_{8,1}$

Постојат и други варијации на локалните бинарни шеми како што се трансформации кои овозможуваат поголема компактност на дескрипторот со користење на униформни облици, воведување на инваријантност на ротација и слично [34]. Униформните облици кај хистограмот прават ограничување на битовите премини од 0 во 1 и од 1 во 0 во бинарната претстава на вредноста. Според [36], со воведување на униформните облици се намалува бројот на корпи во хистограмот од 256 на 59, бидејќи се земаат само оние облици кои најчесто се среќаваат во текстурите (нешто помалку од 90% од облиците за $R = 1$ и $P = 8$ се униформни), додека другите облици се игнорираат. На пример, униформен облик за $R = 1$ и $P = 8$ со 2 или помалку транзиции претставува 00111110, додека 01010100 има 6 транзиции и претставува неуниформен облик.

Инваријантноста на ротација, пак, наједноставно се добива со едноставен шифт на битовите во десно сè додека не се дојде до бит со вредност 1 на најнезначајната битова позиција. На пример, доколку обликот на пикселот е претставен со 001111100, ќе биде заменет со вредноста 00001111, и сите пиксели кои ја имаат истиот распоред на единици и нули околу нив, ќе бидат претставени со вредноста 00001111.

Локалните бинарни облици се доста користени за класификација на текстури [35] за детекција на лица [36], а се користат и за класификација на плевел [37]. Варијации на локалните бинарни облици се користат и во други области каде што објектите на сликата може да се препознаат според нивната текстура.

Хистограм од насочени градиенти

Хистограмот од насочени градиенти (НОГ) претставува уште еден локален дескриптор кој опишува делови од сликата. Хистограмот од насочени градиенти ги пресметува насоките на рабовите на сликата во локален домен. НОГ дескрипторот се пресметува за предефиниран дел од сликата кој понатаму се дели на повеќе блокови со повеќе ќелии. Така, ако димензиите на делот од сликата се

128×64 , сликата можеме да ја поделиме на блокови од 16×16 со ќелии 8×8 . Поместувањето на блоковите се врши со чекор од 8 пиксели што овозможува истата ќелија да припаѓа на повеќе блокови. За целата слика се пресметува градиентот користејќи едноставен филтер за наоѓање на рабови. Наједноставно е да се користи филтерот даден со 2.17.

$$D_x(x, y) = I(x - 1, y) - I(x, y); D_y(x, y) = I(x, y - 1) - I(x, y) \quad (2.17)$$

Потоа со добиените вредности се пресметува интензитетот и насоката (аголот) од градиентот според 2.18 и 2.19 соодветно.

$$D(x, y) = \sqrt{D_x(x, y)^2 + D_y(x, y)^2} \quad (2.18)$$

$$\Theta(x, y) = \arctan\left(\frac{D_y(x, y)}{D_x(x, y)}\right); \quad (2.19)$$

По пресметувањето на градиентите за секој пиксел од секој прозорец, се пресметува хистограмот од ориентациите на градиентите за што се користат P корпи. Потоа се формира дескрипторот кој ги содржи сите хистограми од сите ќелии од делот од сликата. Ваквиот дескриптор, понатаму може да се користи за синтеза на модели за класификација со користење на алгоритми за машинско учење. На Слика 2-5 е прикажана визуелизација на доминантните градиенти кои се пресметани за одделните сегменти од сликата.

Овој дескриптор наоѓа голема примена во детекција на објекти и луѓе[31]. Може да се користи и за класификација на медицински слики при дијагностика на болести [12]. Исто така се користи и за препознавање на листови од растенија [38] и за препознавање на растенија од нивните делови во комбинација со други



Слика 2-5: Визуелизација на градиенти од сегменти на слика при пресметка на НОГ дескриптор

дескриптори [39].

2.2.2 Дескриптори на контури

Дескрипторите на контури претставуваат едни од најстарите дескриптори кои се користени за препознавање на објекти од слика. Нивното рано користење и раните истражувања поврзани со нив се последица на начинот на кој што луѓето препознаваат објекти според нивната контура и без квалитетите на текстурата и бојата. Овие дескриптори се добиваат преку претходна сегментација на објектите и детекција на нивните рабови, односно контури од сликата.


Еден од најстарите вакви дескриптори претставува дескрипторот "Моменти на Xy " [40]. Репрезентацијата на самата контура, претставува подредено множество од точки кои можат да бидат третираани како секвенца од вредности. Ваквата претстава на контурите овозможува нивна трансформација со помош на Фуриева трансформација или други вакви видови на трансформации [41]. Во последно време една од подобрите техники за опис на контурите претставуваат дескрипторите на триаголници кои даваат добри резултати при препознавањето на објектите според нивната контура [15, 42]. Во понатамошниот текст ќе бидат опишани дескрипторите на триаголници кои се користени во рамките на истражувањата.

Дескриптори на триаголници

Пред да се синтетизираат дескрипторите на триаголници, потребно е да се добие затворена контура од објектот за кој се наменети. За таа цел може да се користи било кој детектор на рабови, меѓутоа, според литературата и искуството, најдобри резултати се добиваат со користење на Кани (Canny) детекторот на рабови [43]. После детекцијата на рабови, секоја од точките кои претставуваат раб се означува со логичка единица, додека останатите точки се означуваат со логичка нула.

При синтезата на дескрипторот, се користат предодреден број на точки N од контурата на објектот, односно од затворениот раб на објектот кој се опишува. Овие N точки се добиваат така што се земаат еквидистантни точки од контурата, односно, доколку контурата има P точки, се зема секоја P/N -та точка од контурата. За секоја од овие точки се наоѓаат најблиските соседи на растојание k од самата точка, за $k = 1..L$. Всушност се земаат најблиските точки на растојание $2^1, 2^2, \dots, 2^L$, при што растојанието се смета според бројот на точки помеѓу средишната точка и точката која е одбрана. Се земаат по една точка лево и десно од одбраната точка и за секоја од нив се пресметува растојанието до одбраната точка и аголот што го зафаќаат отсечките. Може да се зема и површината која ја зафаќа триаголникот опфатен со трите точки. Доколку се земаат растојанијата и аголот, за $L = 5$ ќе се добие дескриптор со должина $3 * 5 = 15$, а за $N = 400$ ќе се добијат 400 вакви дескриптори за контурата. Изборот на една точка со соседите и пресметаните величини е илустриран на Слика 2-6.

За секоја точка се пресметуваат три вредности, две растојанија и еден агол, за секој од избраните соседи. На ваков начин се пресметува карактеристиката на контурата како да се гледа од различно растојание. Различните растојанија зависат од изборот на L . Колку е поголемо L , од толку подалеку се гледа сликата со тоа што овој број се избира да не го надмине бројот на избраните точки од контурата.



Слика 2-6: Избор на една точка, соседи и измерени величини при генерирање на дескриптор на триаголници (α е аголот помеѓу отсечките, d_l е растојанието до левата и d_r е растојанието до десната точка)

За синтеза на моделите, ваквата репрезентација е непогодна бидејќи содржи информација за повеќе точки. За таа цел се користи пристапот на генерирање на речник од визуелни зборови (BOVW - Bag of visual words) [44] кој може да се генерира со помош на групирање на дескрипторите (k-means clustering) [45], или со помош на понапредни пробабилистички методи како што се векторите на Фишер [46] и други.

Со помош на ваквите речници може да се пресметаат хистограми од фреквенцијата на појавување на зборовите во секоја од примероците на класите за кои сакаме да го креираме моделот со алгоритми за машинско учење. Овој пристап со користење на дескриптори на контури, особено користење на дескрипторите на триаголници, претпоставува дека листот, плодот или цветот на растението се веќе сегментирани од сликата и посебно се третираат. Заради тоа ваквиот тип на дескриптори е погоден за препознавање на растителните видови според

контурите на листовите [15, 17].

Кај овој пристап, како и кај пристапите кои користат дескриптори на повеќе точки за опишување на сликите, понекогаш споредбата на дескрипторите за наоѓање на најблиски соседи, е доста бавна, особено кога бројот на точките кои треба да се споредуваат е голем. Забрзувањето на споредбата на дескрипторите за секоја точка од сликата е неопходна бидејќи често пати, природата на проблемот бара споредба на една точка со повеќе милиони други точки од повеќе различни слики, каде што и самата споредба на дескриптор со дескриптор претставува операција која бара големи процесирачки ресурси..

Постојат неколку пристапи кои може да се користат за забрзување на наоѓањето на најблиските соседи. Овие пристапи најчесто користат хеширање или репрезентација во дрво, така што наместо да се прави споредба точка со точка, се наоѓа приближно најблискиот сосед преку пребарување низ дрвото. Забрзувањето во споредбата е големо бидејќи наместо да се прават споредби на секоја со секоја точка од две слики, се прави пребарување на секоја точка од едната слика низ дрвото или директно нејзино наоѓање со хешинг функцијата.

Еден ваков пристап претставуваат КД дрвата (kd trees) [47, 48]. КД дрвата функционираат на тој начин што, за множеството точки со кои треба да се прави споредба, се прави КД дрво, а потоа за секоја точка за која сакаме да најдеме најблизок сосед, се пребарува низ КД дрвото. КД дрвата не го даваат вистинскиот најблизок сосед, туку приближно ги групираат точките и наоѓаат приближна точка како најблизок сосед. КД дрвата се погодни кога димензионалноста на дескрипторите е релативно мала. Особено се корисни за наоѓање на најблизок сосед на точки или за наоѓање на најблизок сосед при пребарување на слични бои, бидејќи боите најчесто се претставени со три димензионален вектор во просторот на бои.

Друг алгоритам за наоѓање на најблиски соседи е алгоритмот за локациски осетливо хеширање (Locality sensitive hashing - LSH) [49, 50]. Овој алгоритам

дава логаритамска временска комплексност при пребарувањето и добро скалира со зголемувањето на димензионалноста на векторите кои треба да се споредат. Во споредба со алгоритмот за КД дрвата, овој алгоритам е неколкупати побрз.

И двата прикажани алгоритми значајно го намалуваат времето потребно за наоѓање на најблиските соседи. По правило, алгоритмот за КД дрвата се користи кога дескрипторите се релативно мала димензија (<20), додека LSH се користи за дескриптори со поголема димензија.

2.2.3 Дескриптори на региони околу точки


Овој вид на дескриптори се најкористени, најраспространети и даваат најдобри резултати при решавање на проблемот за препознавање објекти, како и при решавање на проблеми кои вклучуваат пребарување низ слики. Пресметувањето на овие дескриптори се одвива така што најпрво се избираат точките кои ќе ја претставуваат сликата, а потоа околу регионот на секоја точка се пресметува дескрипторот. Значи за опишување на една точка, најпрво таа треба да се детектира, а потоа и да се опише со помош на дескриптор.

Од детекторите кои се користат можеме да ги издвоиме: SIFT - Scale invariant feature transform [51], SURF - Speeded up robust feature [52], MSER - Maximally stable extremal region extractor, FAST [53], BRISK - Binary Robust Invariant Scalable Keypoints [54], Harris детекторот на кошиња [55] и многу други.

Постојат многу алгоритми за пресметување на дескриптори и тука ќе ги издвоиме само најпознатите и најкористените, а тоа се: SIFT - Scale invariant feature transform [51], SURF - Speeded up robust feature [52], BRIEF - Binary Robust Independant Elementary Features [56], BRISK - Binary Robust Invariant Scalable Keypoints [54] и други.

При генерирањето на дескриптори за слики со помош на дескрипторите на

точки за решавање на проблемот на пребарување на слики и препознавање на објекти, најчесто се користи истиот пристап со BOVW опишан во глава 2.2.2. Доколку овие дескриптори се користат за препознавање на објекти во слика и за локализација на објектите на сликата, потребно е да се најдат најсличните точки од моделот на објектот, со приказот на објектот во самата слика. После наоѓањето на најсличните точки, односно, најблиските соседи, понекогаш, потребно е да се најде и поставеноста на објектот на сликата за негова попрецизна локализација. Во овој случај се користи пристап на споредба на дескрипторите точка по точка и наоѓање на најблиските соседи со еден од пристапите опишани во Глава 2.2.2, после што, се користи RANSAC алгоритмот [57] за наоѓање на функцијата на перспективна трансформација на точките од зачуваниот модел на објектот во точките од самата слика. На овој начин се наоѓа точната ориентација на објектот на сликата и објектот доста прецизно се локализира. Ваквиот пристап е илустриран на Слика 2-7²



Слика 2-7: Споредување на дескриптори на точки и детекција на претходно познат објект на слика

Дескрипторите на слика, честопати имаат големи димензии, независно од тоа дали се користат за директна споредба дескриптор со дескриптор, или се прави дополнителна трансформација во BOVW за добивање на дескриптори за секоја класа која треба да се определи. Ваквата голема димензионалност на дескрип-

²Преземено од <https://www.youtube.com/watch?v=zQSFzmmzR-is>

торите на сликите пречи при процесот на тренирање, бидејќи алгоритмите за машинско учење знаат да имаат голема мемориска и временска комплексност која расте повеќе од линеарно спрема бројот на влезни параметри, односно атрибути во дескрипторот. Заради ова, се јавува потребата од предобработка на дескрипторите, односно намалување на бројот на атрибути во дескрипторите. Во понатамошниот текст ќе бидат опишани неколку методи за намалување на бројот на атрибутите односно за селекција на најдобрите атрибути пред да се пристапи кон градењето на класификационите модели со помош на алгоритмите за машинско учење.

2.3 Алгоритми и пристапи кои се користат за редукција на должината на дескрипторите

При пресметката, дескрипторите може да имаат голема димензија. За некои податочни множества и за некои дескриптори на слики, оваа должина може да достигне и по неколку илјади атрибути. Од друга страна, тренирањето на моделите со машинско учење претставува временски комплексна операција. Како последица на големата временска комплексност на алгоритмите за машинско учење, потребно е долго време за тренирање на моделите. Намалувањето на времето за тренирање може да се постигне со намалување. Заради временската комплексност на повеќето алгоритми за машинско учење, потребна е редукција на бројот на атрибути, за побрзо завршување на тренирањето. Дополнително, некои од атрибутите кои се пресметани со помош на алгоритмите за пресметка на дескриптори, создаваат непожелен шум при класификацијата, не даваат доволно информации или даваат конфликтни информации за класата на која припаѓа примерокот.

Заради овие причини се јавува потреба од редукција на димензионалноста на дескрипторите. Ваквата редукција на димензионалноста, не само што го забрзува процесот на тренирање, туку во некои случаи и ја подобрува класификацијата,

правејќи го тренираниот модел поотпорен на шум во податоците и овозможува намалување на опасноста од претренирање на моделот на податочното множество (моделот да го следи податочното множество многу добро, но реално да дава погрешни резултати).

Еден од најпопуларните пристапи за редукција на димензионалноста на дескриптори претставува Алгоритмот за анализа на главните компоненти (Principal component analysis - PCA)[58]. Овој пристап претставува ортогонална трансформација која векторот на дескрипторот го трансформира во друг векторски простор, така што на крајот се добиваат главните компоненти кои се некорелирани меѓусебе. Овие компоненти претставуваат проекции на векторот на дескрипторот, така што првата компонента има најголема можна варијанса, па втората по ред најголема варијанса, и.т.н. Конечниот резултат претставува нов дескриптор со димензија помала или еднаква од димензијата на оригиналниот вектор. Иако, за прв пат е дефинирана од Пеарсон, оваа метода е независно развиена и од други научници и во зависност од областа на примена има различно име, а името го добива според [59].

Понекогаш, целта во податочните множества е да се најдат оние атрибути кои придонесуваат кон определувањето на класата повеќе од останатите атрибути и да се изврши нивно рангирање. PCA за жал прави трансформација на атрибутите после која оригиналните атрибути се губат за сметка на новите трансформирани атрибути. Селектирањето на добрите атрибути, за тренирање на модел со алгоритми за машинско учење, во исто време овозможува и подобро разбирање на природата на процесот и дава информација за тоа кои мерки, кои сензорски податоци или кои дескриптори даваат поголема информација за класата, односно кои атрибути се значајни за определување на класата. Ова е особено важно при примената на алгоритми за машинско учење во системи каде информацијата за причината за исходот на класификацијата е важна. Вакви системи се на пример, бизнис процесите, системите кои се користат во здравството при дијагностика и детекција на проблеми со здравјето [21], системи кои се користат за грижа на

постари лица и други.

Селекцијата на атрибути дава значајно подобрување во робусноста на моделите за класификација. Постојат три типа на методи за одбирање на атрибутите и тоа селектирачки, обвиткувачки и хибридни методи. Селектирачките методи за рангирање на атрибутите по важност се базирани на корелацијата на атрибутите со излезната класа [60], на информационата добивка на атрибутите [61] и други[62].

Информационата добивка претставува мерка која што покажува колку еден атрибут успешно ја предвидува класата, односно колкава информација дава атрибутот за класата. При селекција на атрибутите се дава предност на оние атрибути кои имаат поголема информациона добивка, а оние атрибути кои имаат мала информациона добивка може да се занемарат.

Корелацијата претставува мерка која го квантифицира меѓусебниот однос помеѓу два ентитета. Во нашиот случај тоа е односот помеѓу атрибутот и лабелата на класата. Корелацијата зема вредност помеѓу -1 и 1. Голема позитивна корелација значи дека со зголемување на вредноста на едниот ентитет ќе се зголемува вредноста на другиот ентитет или за вакви ентитети кажуваме дека се корелирани, додека висока негативна корелација означува дека со зголемување на едниот ентитет, другиот ќе се намалува или дека двата ентитети се антикорелирани или инверзно корелирани. Доколку вредноста на корелацијата е близу до 0 во тој случај двата ентитети немаат однос меѓу себе, односно вредноста на едниот ентитет не влијае никако на вредноста на другиот ентитет. Како статистичка мерка, корелацијата се користи при селекцијата на атрибути, наоѓајќи ги оние атрибути чија промена влијае на промената на класификацијата. При селекцијата на атрибутите секогаш се избираат оние кои имаат мала корелација меѓу себе, а голема корелација со класата.

Претходно споменатите методи вршат индивидуална селекција на атрибутите. Постојат и т.н. обвиткувачки методи кои користат алгоритми за машинско

учење за оценување на предиктивната способност на подмножества од множеството атрибути[63].

Хибридните методи, пак, за селекција на атрибутите претставуваат комбинација од селектирачките и обвиткувачките методи [64, 65]. При селекцијата на атрибути кај хибридните и обвиткувачките методи се користат алгоритми за машинско учење и препорачливо е користењето на побрзи алгоритми бидејќи бројот на атрибути може да биде многу голем. Вакви алгоритми најчесто се дрвата на одлука кои се опишани во Глава 2.4.2.

После предобработката и селекцијата на атрибути, потребно е да се тренира моделот за класификација кој се користи за препознавање на растителните видови од сликите. Во понатамошниот текст ќе бидат опишани дел од алгоритмите за машинско учење кои се користат за препознавање на растителни видови.

2.4 Алгоритми за машинско учење кои се користат за препознавање на растителни видови

Алгоритмите за машинско учење се доста популарни во науката, бидејќи со нивна помош, може да се најдат оптимални параметри за системите со користење на измерените податоци. Постојат и други алгоритми за оптимизација кои може да се користат за тренирање на модели [22], но алгоритмите за машинско учење се поробусни и поотпорни на шумови и грешки во податоците од дирекното наоѓање на функционална зависност помеѓу влезовите и излезите. Исто така, кај алгоритмите за машинско учење процесот на тренирање е пократок во однос на дирекната анализа особено кога се работи за голем број на влезни атрибути.

Алгоритмите за машинско учење наоѓаат и голема примена за препознавање на растителните видови од слика. Синтетизирањето на дескрипторите преку трансформација на сликите во вектор од вредности, кои ги извлекуваат главните

карактеристики, претставува само првиот чекор во препознавањето на растителниот вид од слика или видео. Потребно е соодветно аотирање на податоците, така што на секој дескриптор ќе му се додели соодветна ознака за тоа на која класа растенија или општо на која класа припаѓа. Потоа се врши селекција на најинформативните атрибути и елиминација на оние атрибути од дескрипторите кои пречат при тренирањето на моделите за машинско учење. Откако овој процес е завршен се пристапува кон т.н. тренирање на моделот преку користење на различни алгоритми за машинско учење. Може да се користи било кој алгоритам за машинско учење, но често се пристапува и кон користење на ансамбл од алгоритми.

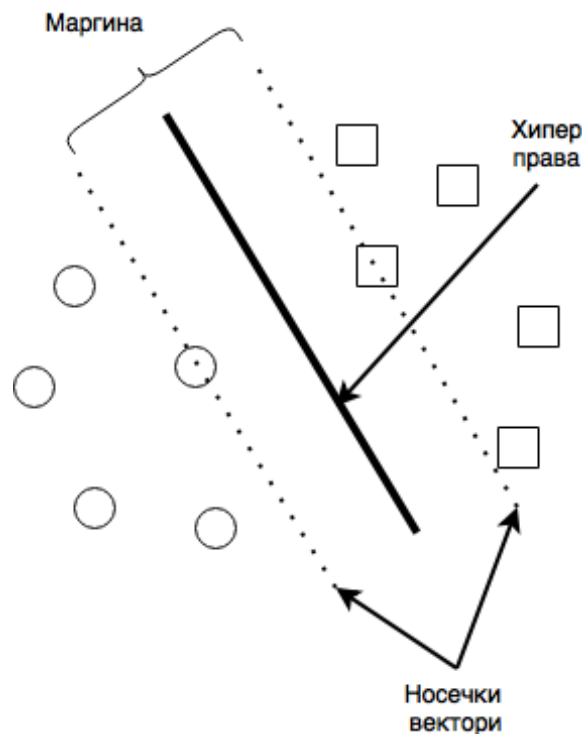
Пред тренирањето на моделот може да се користи и процес на селекција на карактеристики кој овозможува оптимизација на карактеристиките извлечени од податоците. Оваа оптимизација е во две насоки. Од една страна, при селекцијата се исфрлаат оние вредности кои даваат многу малку информација за класата, како и оние вредности кои создаваат шум при одлучувањето. Од друга страна, со намалувањето на бројот на вредностите во векторот се намалува и времето потребно за тренирање на моделот кое кај некои алгоритми за машинско учење е доста големо.

Вакви методи на селекција на атрибути пред да се користат алгоритми за машинско учење се употребени во [21] и даваат значајно подобрување на перформансите при класификацијата. Исто така, даваат подобрување на перформансите и во [19]. Во недостаток на аотирани инстанци од податочните множества, може да се користат и алгоритми за ненадгледувано учење [16]. Кај овие алгоритми, не постои претходна информација за класата на која припаѓаат примероците, туку таа се определува во самиот процес на тренирање и синтеза на моделот.

Во понатамошниот текст ќе бидат опишани алгоритмите за машинско учење кои се користени во експериментите во рамките на оваа докторска дисертација.

2.4.1 Машини со носечки вектори

Машините со носечки вектори [66] (SVM - Support vector machines) претставуваат алгоритам за надгледувано учење кој за дадено множество на примероци кои се аотирани во две соодветни класи, враќа оптимална поделба на просторот, на начин што најголем дел од примероците кои припаѓаат на првата класа се од едната страна, а останатите, кои припаѓаат на другата класа, се од другата страна на хипер-просторот. Кај овој алгоритам, сите примероци се претставуваат како точки од хипер-простор, а целта е да се најде функција која означува хипер-права или хипер-рамнина во тој простор која го дели на два дела. Во процесот на тренирање, односно оптимизација на SVM, целта е да се создаде што е можно поголема маргина помеѓу двете класи. На Слика 2-8 е илустриран приказ на една хипер-права во простор со две димензии, за две класи, каде што множеството на примероци е линеарно сепарабилно.



Слика 2-8: Илустрација на машини со носечки вектори на едно податочно множество во рамнина

Машините со носечки вектори може да се користат за решавање на проблемот на класификација или на регресија. Исто така може да се користат за едно-класна класификација каде што се определува само дали дадениот примерок припаѓа или не припаѓа на дадената класа. Едно-класната класификација се користи повеќе за отстранување на шум од податочното множество, односно на примероци кои, најверојатно, се земени со некоја значителна грешка при прибирањето на податоците.

Машините со носечки вектори претставуваат стандарден алгоритам за машинско учење, но имаат еден недостаток. Недостатокот е тоа што SVM имаат потреба од претходно дефинирање на параметарот C и доколку се работи за SVM со нелинеарно јадро, на параметарот γ . Јадрото на овој алгоритам го дефинира типот на функцијата која ќе се користи за делба на хипер-просторот.

Јадрото може да биде линеарна, полиномиална, гаусова или друг тип на функција. Најчесто користени се јадра со гаусова функција, каде покрај C треба да се зададе и параметарот γ . Изборот на овие параметри е тежок процес и најчесто се користи т.н. пребарување по мрежата на параметри. На овој начин се добиваат оптималните параметри за овој алгоритам кои потоа се користат за тренинг на моделот [18]. Дополнително е покажано дека со изборот на правилните параметри се влијае и на спречување на претренирањето на SVM моделите за класификација.

2.4.2 Дрва на одлука

Дрвата на одлука претставуваат алгоритми за синтеза на предиктивни и класификациони модели врз основа на податочните множества. И овие алгоритми се надгледувани алгоритми бидејќи за нивното градење, потребни се анотирани податоци. Постојат повеќе алгоритми за дрва на одлука кои се користат. Меѓу најпознатите е ID3 [67] кој користи ентропија како мерка за избор на најинфор-

мативните атрибути од примероците. Овие атрибути се избираат како гранки во дрвото според кои, понатаму, податоците се делат на две или повеќе подмножества во зависност од бројот на различни вредности на избраниот атрибут. Понатаму рекурзивно се продолжува со понатамошно делење на подмножествата се додека не се дојде до финална одлука за класата на која припаѓа примерокот, односно, додека не се дојде до лист (терминален јазол) од дрвото.

Подобри резултати во предидувањето даваат ансамбли од дрва на одлука. Вакви алгоритми кои прават повеќе дрва на одлука се случајните дрва (Random Forest - RF [68]), екстремно случајните дрва (Extremely Randomized Trees - ERT) [69] и други.


Кај случајните дрва, се избира случајно подмножество од примероците во тренинг множеството и се градат предефиниран број на дрва кои потоа по принцип на мнозинство гласаат за крајниот резултат од класификацијата. Јазлите во дрвото се определуваат според оптимална поделба на множеството.

Кај екстремно случајните дрва, пак, исто така се градат предодреден број на дрва на одлука, но за разлика од случајните дрва, не се прави само случаен избор на подмножествата туку и случаен избор на јазлите за одлука во самите дрва.

2.4.3 Алгоритам К најблиски соседи

Алгоритмот најблиски соседи [70] претставува алгоритам за непосредно определување на класата на примерокот во зависност од неговите најблиски, односно најслични примероци. Предноста на овој алгоритам е тоа што нема потреба од тренирање, но од друга страна, се јавува потребата за споредба на секој примерок за кој сакаме да ја определиме класата, со секој друг примерок од множеството примероци, што во случај на голем број примероци чии дескриптори имаат голема димензија, бара повеќе време за извршување.

Алгоритмот функционира така што примерокот на кој треба да му се определи класата се споредува со примероци од соседството. На Слика 2-9 е прикажан пример каде што примерокот се споредува со $K = 5$ други примероци од податочното множество. Бидејќи на сликата повеќето соседи припаѓаат на класата означена со квадратчиња, се определува дека класата на примерокот е квадратче.



Слика 2-9: Определување на припадноста на класа со наоѓање на K најблиски соседи

Постојат и подобрувања на овој алгоритам како што е алгоритмот на K најблиски соседи со матна припадност [71] и други варијации на овој алгоритам.

2.4.4 Алгоритми за ненадгледувано учење

Алгоритмите за ненадгледувано учење овозможуваат извлекување на знаење од податоците. За овие алгоритми нема потреба од аотирање на податоците пред да се пристапи кон тренинг на моделите. Најпознат алгоритам за ненадгледувано учење претставува алгоритмот - K -средни вредности (K -means clustering) [45].

Кај овој алгоритам, примероците од множеството се третираат како точки во хипер-простор и се избира метрика според која се прави споредба на растојанието помеѓу овие точки. Се врши групирање на точките според предодреден број на класи K . Групирањето се врши на тој начин што се избираат случајни центроиди кои ја претставуваат секоја класа, а потоа најблиските точки до тие центроиди се доделуваат на соодветните класи. Во следниот чекор се наоѓаат новите центроиди, како средишна точка помеѓу сите точки кои се доделени на секоја од класите. Алгоритмот продолжува со повторување на овие два чекори се додека не се дојде до конвергенција, односно додека центроидите не се стабилизираат.

Овој алгоритам е зависен од избраната метрика за растојание помеѓу точките и избраниот број на точки. Постојат варијации на овој алгоритам кои користат степен на припадност на класите [71], кои во зависност од доменот на проблемот кој се решава, може да дадат подобри резултати од тврдото одредување на класите во K -средни вредности.

2.5 Длабоко учење за препознавање растителни видови

Длабокото учење претставува пристап за синтетизирање на класификациони и предиктивни модели преку користење на повеќеслојни мрежи. Предноста на овој пристап, пред пристапот со синтеза на дескриптори и тренирање на модели за машинско учење е тоа што при длабокото учење, овој процес е споен во едно. Самата мрежа ги извлекува најважните карактеристики и потоа го тренира моделот за класификација.

Постојат повеќе видови на вакви мрежи. За процесирање на слика и за синтеза на модели од слики при решавањето на проблемите на препознавање на објекти и пребарување низ слики, се користат конволуциските невронски мрежи.

Конволуциските мрежи ја извршуваат една од основните операции при обработката на слика, конволуцијата, но со тежински параметри кои се прилагодуваат на проблемот кој се решава.


2.5.1 Конволуциски мрежи

Конволуциските невронски мрежи функционираат така што извршуваат операција конволуција со користење на јадро чии параметри се поставуваат во процесот на тренирање на невронската мрежа. За да ги разбереме подобро овие мрежи, најпрво ќе го објасниме поимот за конволуција во областа на процесирањето на слики.

Конволуцијата се извршува помеѓу сликата и некое јадро. Сликата претставува дводимензионална матрица која може да има еден или повеќе канали, а најчесто три канали. Сликата може да биде претставена во било кој од веќе опишаните простори на бои во глава 2.1. Јадрото претставува матрица со големина $p \times p$. Секој пиксел од резултантната слика се пресметува според формулата 2.20. Така во самата формула, $f_{i,j}$ претставува коефициентот на јадрото на позиција (i, j) , $d(x, y)$ претставува пиксел од сликата на позиција (x, y) . Вредноста на резултантниот пиксел ја означуваме со Q . Вредноста L е еднаква на сумата на коефициентите на јадрото, или е еднаква на еден, доколку сумата на коефициентите е нула. За пикселите кои се на периферијата на сликата, за x и y од 0 до $p/2$ и од $M - p/2$ до M односно од $N - p/2$ до N , каде што M и N се должината и широчината на сликата во пиксели, не можеме да пресметаме конволуција доколку не ја прошириме сликата. Ова најчесто се прави со проширување со 0 вредност или со средна вредност од сите пиксели на сликата, средна вредност од пикселите на целото податочно множество и слично.

$$Q(x, y) = \frac{\sum_{i=0}^p \sum_{j=0}^p f_{i,j} d_{x-\frac{p}{2}+i, y-\frac{p}{2}+j}}{L} \quad (2.20)$$

Конволуциските мрежи за прв пат се употребени во LeNet [72]. Архитектурата на оваа конволуциската невронска мрежа употребена за препознавање на слики од броеви е прикажана на Слика 2-10[72].




Слика 2-10: Архитектура на првата невронска мрежа која употребува конволуциски слоеви, LeNet

Во оваа невронска мрежа, тежините на конволуциските слоеви се прилагодуваат на моделот и ги екстрахираат од сликата оние карактеристики кои најдобро ги опишуваат моделите. Овде конволуциските невронски мрежи се искористени за екстракција на карактеристиките така што се користат повеќе конволуциски јадра одеднаш на секое ниво. На тој начин се постигнува екстракција на различни карактеристики од сликата за секое од различните јадра. После секое конволуциско ниво се користи ниво за суб-семплирање кое двојно ја намалува димензијата на добиената слика. При ова ниво најчесто се користи Max pooling или избирање на најголемиот пиксел од соседството и негово користење во следниот слој. На крајот на оваа архитектура се користи целосно поврзана, односно обична невронска мрежа со стандардни перцептрони за добивање на класите на излез.


Во [73] (AlexNet) конволуциските невронски мрежи, наместо хоризонтално се поставуваат вертикално во архитектурата, односно се користат повеќе конволуциски една по друга пред да се искористи слој за суб-семплирање. Архитектурата на AlexNet е дадена на Слика 2-11[73].

Во оваа архитектура, направена е промена на активациската функција, каде



Слика 2-11: Архитектура на AlexNet

што наместо да се користи сигмоидна активација која е дотогаш најчесто користена при тренирање на невронски мрежи, се користи ReLu активација прикажана на Слика 2-12 ³.



Слика 2-12: Сигмоидна активациска функција (лево) и ReLu активациска функција (десно)

Овие и други архитектури како што се GoogLeNet[74],VGG [75] и нивни модификации, се користат за класификација на сликите и наоѓаат примена при препознавање на растенија [76, 77, 78, 79], детекција на плевел и други аномалии во земјоделските полиња [80, 81, 82] и слично.


Постојат архитектури кои се користат и за сегментација. Така архитектурата SegNet [83], овозможува сегментација на сликите на региони, и тоа на различни

³<http://deeplish.io>

видови региони. Ваквиот пристап на решавање на проблемот за детекција на плевел е директен бидејќи повеќе не се јавува потребата за претходна сегментација на одделните растенија или сегментација на вегетација и останата површина од сликата.

Моделот заснован на SegNet е способен за семантичка сегментација директно на 3 класи, земја и останати површини, корисно растение и плевел. За разлика од останатите архитектури кои завршуваат со онолку излези колку што има класи, SegNet завршува со онолку излези колку што има пиксели сликата, а притоа, за секој пиксел се определува на која класа, односно на кој сегмент припаѓа. Кај SegNet се користат конволуциски мрежи и деконволуциски мрежи.

Со конволуциските мрежи се намалува димензијата на сликата, а со деконволуциските се враќа во природната големина. Притоа, коефициентите од нивоата за максимално одбирање од мрежата остануваат исти и при конволуциските и при деконволуциските нивоа. Архитектурата е прикажана на Слика 2-13 [83].




Слика 2-13: Илустрација на архитектурата SegNet

Како што може да се види од сликата, индексите за слоевите за максимално одбирање се исти и при намалувањето и при зголемувањето на димензиите. Последното ниво претставува Softmax или ниво со лабаво максимално одбирање.

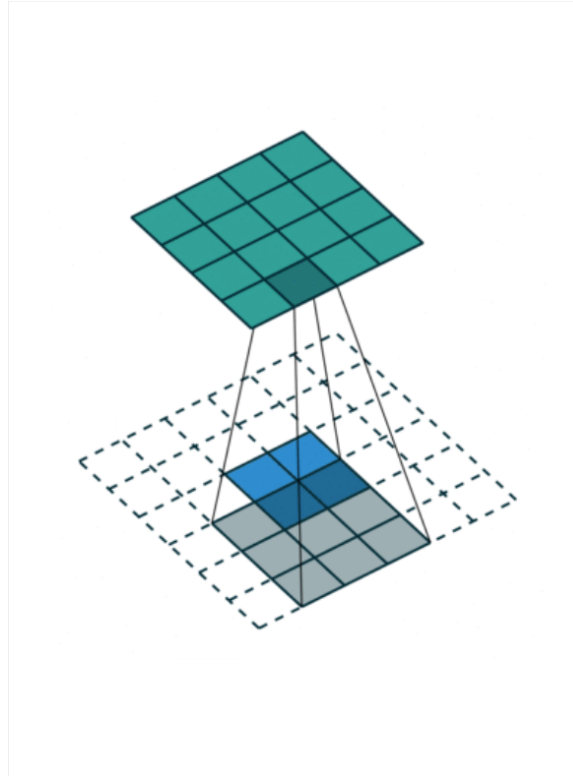
Нивоата кои ја намалуваат димензијата прават конволуција со групна нормализација и ReLu активациска функција, додека нивоата кои ја зголемуваат сликата прават деконволуција, односно конволуција од помала слика кон поголема слика со додавање на нули на периферијата на сликата.

Деконволуцијата која се користи кај SegNet за зголемување на димензиите на сликата од помали во поголеми има сличен оператор како конволуцијата со тоа што најпрво се прави проширување на сликата, а потоа се изведува операторот конволуција. Начинот на кој што функционираат операторите за конволуција е прикажан на Слика 2-14 додека операторот за деконволуција е прикажан на Слика 2-15 [84]. Во мрежата која ја користиме, конволуцијата и деконволуцијата ја зголемуваат димензијата на сликата двојно, слично како што е илустрирано на сликите.



Слика 2-14: Илустрација на операторот за конволуција

Оваа архитектура веќе се користи за сегментација на плевел при природни



Слика 2-15: Илустрација на операторот за деконволуција

и вештачки генерирани податочни множества [85] и дава одлични резултати при детекцијата на плевел. Истиот алгоритам го применуваме и на нашите податочни множества со RGB слики под различно осветлување, но со мали модификации и приспособувања.

Важно е да се напомене дека алгоритмите за длабоко учење се доста комплексни и за да се користат, мора да се обезбеди паралелизација. Паралелизацијата може да биде извршена со помош на графички процесорски уреди (GPU). Ваквата паралелизација покажува значајно подобрување на временските перформанси на алгоритмите и симулациите [23].

Глава 3

Податочни множества

Алгоритмите за надгледано учење секогаш се тренираат на определено множество на податоци за кое однапред се знае посакуваниот резултат, односно однапред се знае класата на која припаѓаат податоците. Кај алгоритмите за ненадгледано учење, повторно ни е потребна некоја база од анотирани податоци заради валидација на резултатите кои се добиваат.

За таа цел, при тренирање на моделите за препознавање на растителни видови или во нашиот случај за препознавање на плевел, потребно е да се направи прибирање и анализа на податоци, односно слики кои содржат корисни растенија и плевел.

Во рамките на оваа докторска дисертација собрани се слики од млад расад од тутун, морков и спанаќ. Бидејќи целта на истражувањата беа можностите за синтеза на модели врз основа на слики под различно осветлување и услови, сликите од морков и спанаќ се снимани со RGB камера од паметен телефон со 10 мегапиксели, додека сликите од тутун се снимани со камера со помала резолуција од 640×480 . Над различните податочни множества беа изведени различни експерименти.

Покрај синтетизираните податочни множества, во рамките на истражувањата опфатени со овој докторски труд, беа користени и податочните множества опишани во [86] и во [87]. Бидејќи истражувањата беа насочени повеќе кон видовите на дескриптори кои може да се користат и кон примената на алгоритми за машинско учење за детекција на плевел од слики под услови на различно осветлување, множеството опишано во [87] кое користи камера во блискиот црвен спектар, не беше употребено во анализата.

Мора да се напомене дека кај сликите од тоа множество, со користење на NDVI индексот, сегментацијата на вегетацијата е поуспешна од сегментацијата на слики снимани со обични камери. Во понатамошниот текст ќе бидат опишани карактеристиките на секое од податочните множества.

3.1 Плевел во расад од спанаќ

Ова податочно множество е генерирано од слики од млад расад од спанаќ. Податочното множество е сликано со користење на RGB камера од 10 мега пиксели од височина од 1m. Податочното множество е сликано во регионот на Неготино, Република Македонија, во февруари 2014 година.

Податочното множество е добиено со рачно аотирање на регионите од сликата каде што има растенија и тоа со сегментација на корисните садници и некорисниот плевел од сликата. За сегментација на регионите се користи VEG индексот кој се пресметува според формулата 2.10. Како прагова вредност за сегментација е одбрана вредноста од $VEG > 1.1$ за растителна површина, а останатите вредности од сликите се игнорираат. Пример резултат добиен од сегментацијата е прикажан на Слика 3-2, додека сликата на која се врши сегментацијата е прикажана на Слика 3-1.

После сегментацијата се користи пристап на екстракција на контури од поеди-

нечните региони во сликата [88] и се наоѓа најголемиот правоаголник кој целосно го опфаќа регионот на затворената контура. Овој правоаголник ја претставува сликата од растението која понатаму се користи за класификација.



Слика 3-1: Слика од податочното множество пред сегментацијата

На ваков начин се добиени вкупно 116 региони кои содржат плевел, 91 регион кој содржи расад од спанаќ и 76 региони кои содржат мов или зеленикава површина на земјата заради отсјај од осветлувањето. Овие 76 региони рачно се отстранети од податочното множество. Примероци од податочното множество се прикажани на Слика 3-3 и Слика 3-4

3.2 Плевел во расад од тутун

Податочното множество од расад од тутун е снимано со Vumblebee 2.0 камера. Vumblebee 2.0 камерата поддржува стерео визија, но поради малиот нарас на расадот, извлекувањето на тридимензионални модели, беше невозможно, па се пристапи кон обработка на дводимензионални слики. Сликани се и аотирани



Слика 3-2: Слика со маски за површини од сликата кои после сегментацијата се прогласени за вегетација

вкупно 66 слики од расфрлан млад расад од тутун во леи во Прилепскиот регион на Република Македонија во февруари 2014 година.

Сликите се рачно анотирани со обележување на регионите кои претставуваат плевел и регионите кои претставуваат останата површина. Сликите се снимани под различни временски услови (различно осветлување) од различна височина помеѓу 0.7 и 1.5 метри. Неколку примери од сликите од податочното множество се прикажани на Слика 3-5.

Според самите слики се воочува дека ова податочно множество е доста тешко за обработка бидејќи на различно осветлување нијансите на боите и осветлувањето се различни.



Слика 3-3: Слики од спанаќ во податочното множество со расад од спанаќ



Слика 3-4: Слики од плевел во податочното множество со расад од спанаќ

3.3 Плевел во расад од морков

Податочното множество од расад од морков беше снимано во оранжерији во Криволак, Неготино во периодот на февруари 2015 година. Ова податочно множество се состои од слики сликани со камера од 10 мега пиксели, од паметен телефон, од височина од приближно еден метар. Податочното множество содржи вкупно 40 слики од расад од морков. Сликите се аотирани во три класи и тоа плевел, корисно растение и останати површини. Пример од сликите од морков е прикажан на 3-6.



Слика 3-5: Слика од плевел во податочното множество со ран расад од тутун



Слика 3-6: Слика од плевел во податочното множество од леи со морков (Лево - слика во RGB, Средина - вегетативна маска, Десно - маска со плевел и корисно растение)

Глава 4

Препознавање на растителни видови и детекција на плевел од слики

Во рамките на оваа докторска дисертација се предлага архитектура за систем за детекција на плевел со помош на слики од RGB камери. За полесно да се објасни архитектурата на системот, најпрво ќе го дефинираме проблемот со кој се соочуваме при детекцијата на плевел од слики. Целта е да се најде множество од пиксели од сликата I кои припаѓаат на множество пиксели кои означуваат плевел P и да се добие соодветна маска M за која ќе важи равенката 4.1

$$M(x, y) = \begin{cases} 1, I(x, y) \in P \\ 0, I(x, y) \notin P \end{cases} \quad (4.1)$$

Ваквиот излез од алгоритмот овозможува локализација на сегментите од сликата кои содржат плевел, и соодветно може да биде употребен како влез во алгоритам за планирање на акции од роботска рака или друг вид на актуатор кој би овозможил соодветен третман на плевелот. Решението на вака дефинираниот проблем може да се изведе на повеќе начини. Во понатамошниот текст ќе бидат опишани пристапите и експериментите со податочните множества, извршени во рамките на оваа докторска дисертација.

4.1 Препознавање на плевел од спанаќ со надгледувано и ненадгледувано учење

Во овој пристап, е извршено снимање на расад од спанаќ во раната фаза од неговиот развој. Во оваа фаза, растенијата се добро одделени едно од друго и плевелот сеуште не е многу развиен. Заради тоа, после инспекцијата на прибраното множество податоци, констатирано е дека сегментацијата на растенијата е едноставна, што значи дека може да се добие слика од целосно растение без преклопување и шум од околните растенија. Таков пример се сликите кои се прикажани при описот на податочното множество во Слика 3-3 и во Слика 3-4.

Најпрво се прави сегментација на сликите од растенија и плевел, при што се добиваат посебни слики од растението и од плевелот. Процесот на сегментација се изведува во неколку чекори и тоа:

- Детекција на вегетативни површини на сликата со помош на VEG индексот
- Наоѓање на надворешните контури на секој посебно детектиран вегетациски регион
- Наоѓање на обиколниот правоаголник околу регионот
- Зачувување на примерокот

Секој од овие примероци, после рачната анотација е анотиран со лабела плевел или спанаќ.

После анотирањето, употребен е алгоритмот за хистограм од ориентираните градиенти опишан во 2.2.1 со кој се генерира дескриптор со должина 72. Пред да се пресмета дескрипторот се врши дополнителна предобработка на сликата преку наоѓање на рабовите како што е предложено во [89, 90]. Целта на предобработката е подобрувањето на перформансите на НОГ дескрипторот. Овој дескриптор не е инваријантен на ротација. Заради тоа пред да се пресмета дескрипторот се

ротира сликата во онаа насока во која е насочен листот. За таа цел се пресметува бројот на точки од рабовите на сликата од листот во осум региони кои се насочени на различни страни 0° , 45° , 90° и.т.н. Потоа се избира регионот кој има најмногу точки од рабовите и се ротира сликата така што регионот со најмногу точки секогаш покажува кон 0° . Преку овој дескриптор се вклучуваат рабовите на листовите и изразените текстурни карактеристики.

Дополнително треба да се вклучи и бојата на листовите. За таа цел, на дескрипторот на сликата се додаваат уште 128 елементи кои претставуваат хистограм на VEG индексот. За да се добие овој хистограм од тренинг множеството се земаат максималната и минималната вредност на VEG индексот и потоа овој опсег се дели на 128 сегменти. Хистограмот е составен од бројот на пиксели од секоја слика кои припаѓаат на даден сегмент. Вкупната должина на вака добиениот дескриптор, како комбинација од хистограмот на бои и хистограмот на ориентирани градиенти, изнесува 200 елементи.

Откако се пресметани дескрипторите, користиме алгоритам за ненадгледувано учење опишан во Глава 2.4.4. Алгоритамот на K -средни вредности го дели множеството на K делови. Доколку го поставиме $K = 2$, можеме да го користиме овој алгоритам за поделба на множеството од вектори со дескриптори на две подмножества од кои едното ќе биде плевел, а другото спанаќ. За овој експеримент ја користевме имплементацијата на алгоритмот K -средни вредности во софтверскиот пакет WEKA[91].

За да се направи споредба на перформансите на ненадгледуваното учење, се користи алгоритам за надгледуваното учење SVM кој е опишан во Глава 2.4.1. Како што веќе беше напоменато, при користењето на SVM потребна е оптимизација на параметрите за што е користен пристапот опишан во [92, 18]. При овој пристап, се врши пребарување на оптималните параметри во матрица, при што се земаат одреден број различни вредности за C и одреден број различни вредности за γ . За секоја комбинација од овие вредности, се тренира SVM модел.

Овој модел потоа се тестира на валидациско множество. На крајот од сите вакви модели се избира најдобриот и се користи за предвидување во тест множеството. На валидациското множество, во овој случај, се добиени $C = 1024$ и $\gamma = 0.016$.

За тестирање на предложениот пристап е искористена 10-делна вкрстена валидација, во која множеството се дели на 10 подмножества од кои 9 се користат за тренинг, а десеттото за тестирање. Овој процес се повторува 10 пати за да се добијат усреднети вредности. Бидејќи кај ненадгледуваното учење, лабелите не се познати, во интерес на споредбата, рачно се доделени табели на соодветните подмножества добиени со алгоритмот за К-средни вредности. Добиените резултати покажуваат прецизност од 64,3% при ненадгледуваното и 68.1% при надгледуваното учење. Сумарните резултати се прикажани во матрицата на конфузија дадена во Табела 4.1 и Табела 4.2 [16].

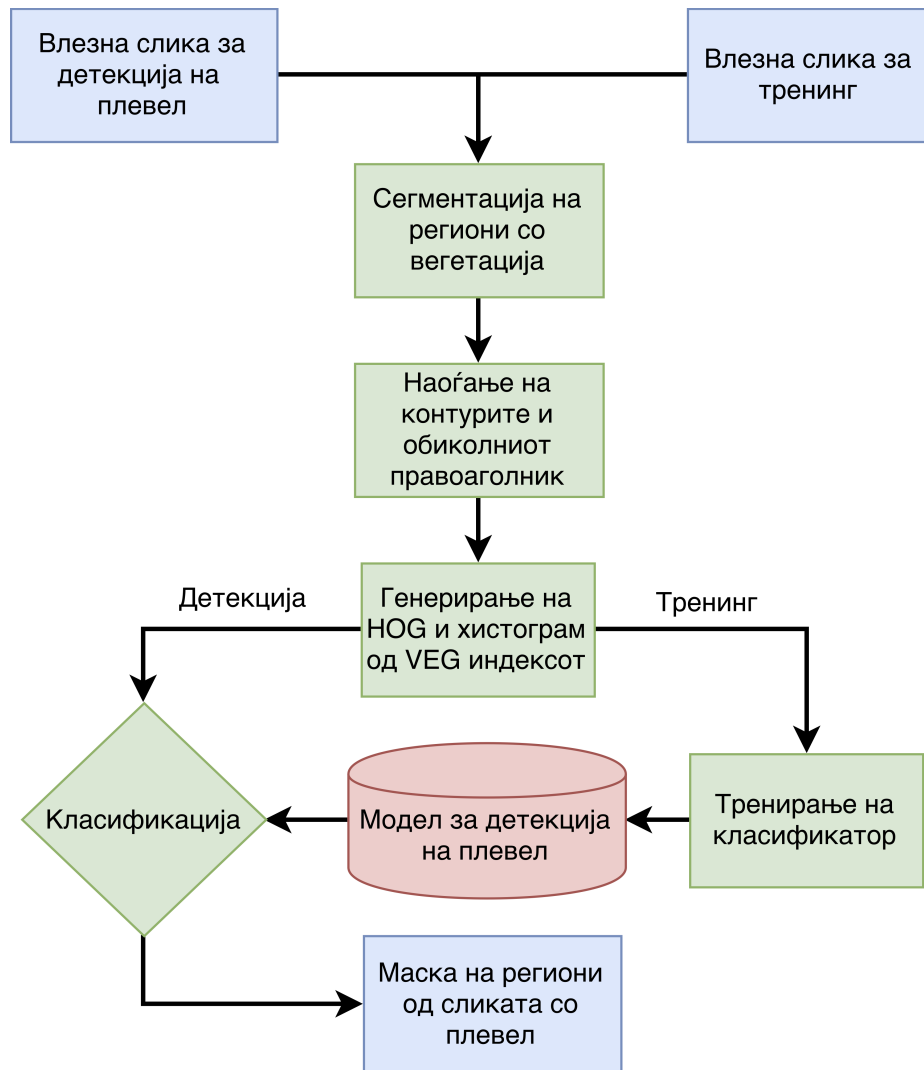
Табела 4.1: Матрица на конфузија на класификација со SVM

Класифицирано како ->	Плевел	Спанаќ
Плевел	93	23
Спанаќ	43	48

Табела 4.2: Матрица на конфузија на класификација со К-средни вредности

Класифицирано како ->	Плевел	Спанаќ
Плевел	77	39
Спанаќ	37	54

Добиените резултати покажуваат дека е можно да се користи ненадгледуваното учење за детекција на плевелот во сликите доколку постои чиста сегментација на секое од растенијата. Предложениот пристап на сегментација и екстракција на посебните растенија и нивна класификација е погоден само ако е можно да се одделат посебните растенија, односно ако нема преклопување. Целосниот тек на предложениот пристап е прикажан на слика 4-1.



Слика 4-1: Тренирање на класификационен модел и негово користење при детекција на плевел од слики од расад на спанаќ

4.2 Препознавање на плевел од слики од расад од тутун

Младиот расад од тутун во Прилепскиот регион во Република Македонија е специфичен по тоа што се расадува хаотично во леи пред неговото пресадување на нивите. Според [93] во 2010 година, производството на ориентален тутун во Република Македонија зафаќало 10,64% од вкупно произведениот ориентален

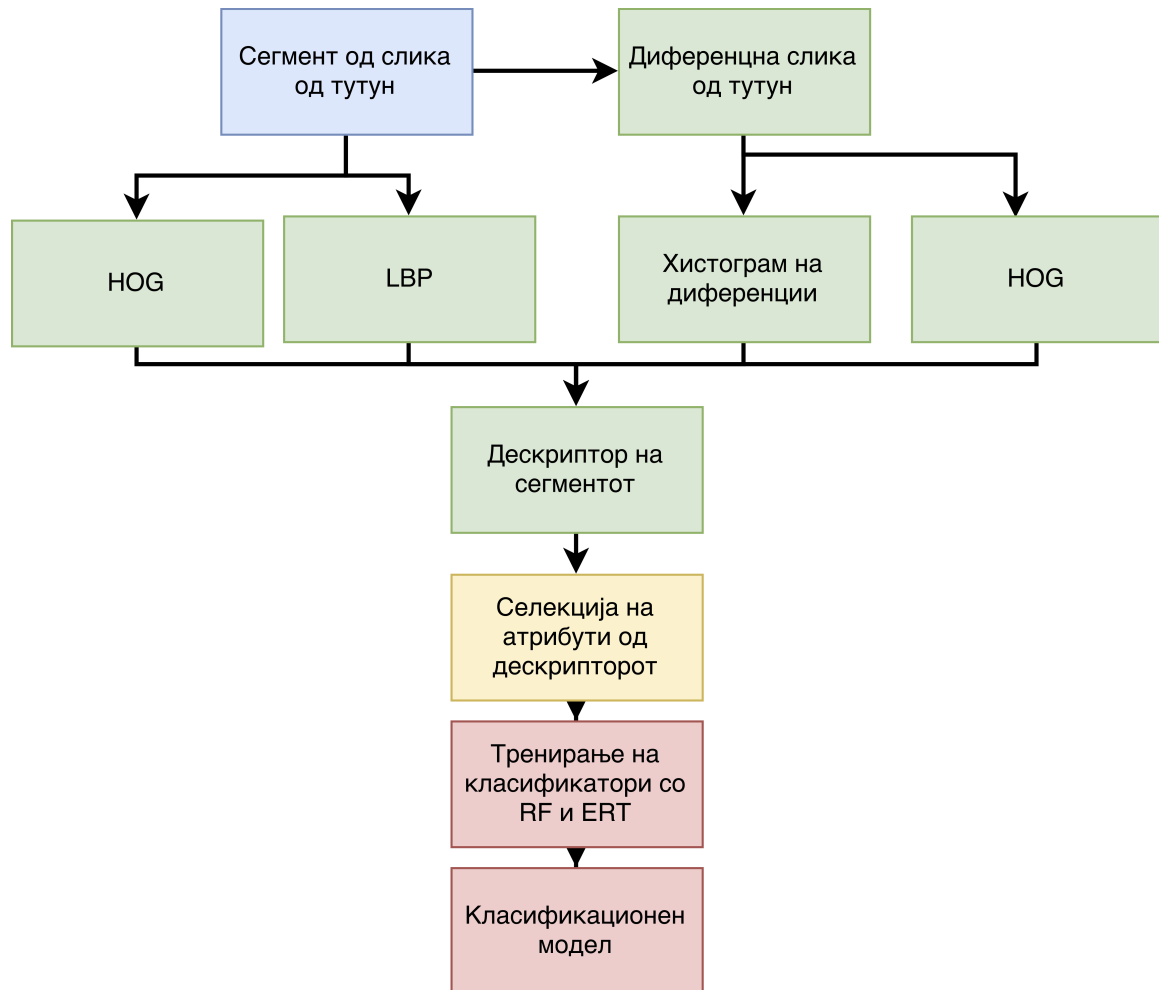
тутун во светот. Истовремено производството на тутун во Република Македонија бележи благ пораст во последниот период.

Детекцијата и отстранувањето на плевелот во овие расади се врши рачно и претставува макотрпна и временски долготрајна работа. Препознавањето и автоматското отстранување на плевел од овие површини би овозможило значајно олеснување во обработката на тутунот како стратешка култура во Република Македонија. За таа цел беше создадено податочното множество од тутун опишано во Глава 3.2.

Ова податочно множество е поделено на случајно избрани 45 слики за тренинг и 21 слика за тест. Од овие слики се земени сегменти со димензии 65×65 пиксели, или вкупно, 160000 сегменти за тренинг и 50000 сегменти за тест. За да се постигне балансирано множество, од вкупниот број сегменти од тренинг множеството беа земени случајно одбрани по 80000 од секоја класа (плевел и останато). Заради природата на сликите, дескрипторите се пресметуваат со алгоритми за дескриптори на текстура и дескриптори на сегменти од слика. Поради ова, сликите се земени во нијанси на сиво. Анотирањето на сегментите се изведува според централниот пиксел на сегментот. Доколку централниот пиксел припаѓа на класата плевел, тогаш дескрипторот од целиот сегмент се смета дека припаѓа на класата плевел.

За пресметка на дескрипторот се користат неколку алгоритми. Процесот на генерирање на дескрипторот и на тренирање на моделот е претставен на Слика 4-2 Најпрво се пресметува диференцна матрица од апсолутните разлики од сите пиксели на сегментот со централниот пиксел и се пресметува хистограм од овие разлики. Потоа се генерира НОГ дескрипторот кој е веќе опишан во Глава 2.2.1. Бидејќи НОГ може да се пресмета на слики со парен број на димензии, од сегментот се игнорираат последната колона и последниот ред од пикселите и се добива нов сегмент од 64×64 . На овој сегмент се прави пресметка на НОГ дескриптор со параметри: димензија на прозорец - 64, димензија на блок - 16,

прескокнување на пиксели при поместување на блок од - 8, димензија на ќелија - 8 и број на корпи во хистограмот - 9. Потоа се пресметува дескрипторот LBP исто така опишан во 2.2.1. Се користи стандардниот LBP дескриптор со радиус - 1 и број на точки - 8, со што се добива хистограм со 256 различни вредности.



Слика 4-2: Архитектура за генерирање на мапи

Избраните дескриптори претставуваат едни од најдобрите дескриптори за текстура познати во литературата. Вкупната должина на векторот на дескрипторот изнесува 3784 од кои: 256 за хистограмот на разлики, 256 за LBP, а останатите 1636 се HOG дескриптор од сликата и HOG дескриптор од диференцната слика.

Понатаму, должината на овој дескриптор се редуцира со помош на селекција

на атрибути со ансамбл од дрва. Најпрво се користи алгоритмот RF опишан во Глава 2.4.2 за евалуација на иницијалната оценка на податоците. После пресметката на иницијалните оценки, се користи ERT исто така опишан во Глава 2.4.2 кој е побрз од RF. Естимацијата на важноста на атрибутите со користење на ERT не е еднакво стабилна со естимацијата добиена со RF.

Бидејќи се користат различни подмножества за тренинг и тест, потребно е да се избегне вклучување на атрибути кои може да направат претренирање на класификациониот модел. Заради тоа се користи пристапот предложен во [94].

За секој атрибут од дескрипторот се пресметуваат две оценки. Едната ја оценува важноста на дескрипторот за определување на целната класа, додека другата ја оценува можноста на членот да ја предвиди припадноста на тренинг или на тест множеството на дескрипторот. Идеално намалените вектори, би имале атрибути кои добро ја предвидуваат целната класа, а лошо го предвидуваат множеството. Со користење на пребарување по матрица, оние дескриптори кои имаат слаби перформанси во однос на двете метрики се отстрануваат од множеството.

Сличен пристап на ваква селекција на атрибути е применет и во [21] но на различен тип на податоци. И во овој случај, евидентно е подобрувањето на класификационата моќ на моделот преку селекцијата на атрибутите. Овој пристап во комбинација со градењето на ансамбли од дрва на одлука и пребарување на параметрите на SVM според матрицата на параметри, овозможува подобри резултати и поголема робустност во предвидувањата.

Резултатите од овој експеримент, покажуваат дека најдобрата прецизност што се добива е 52.57% со ERT при селекција на 845 атрибути од вкупните атрибути. Важно е да се напомене дека слични перформанси се добиваат и со ERT и со RF алгоритмот.

Неколку важни заклучоци се извлечени од овој експеримент. После анализата на важноста на атрибутите, ниту еден од атрибутите генерирани со НОГ или

LBP дескрипторот не беа во врвот на избраните атрибути. Најважниот атрибут е бројот на пиксели во сегментот, кои имаат иста вредност во централниот пиксел. Всушност сите атрибути од првите десет по важност се избрани од хистограмот од диференциите со централниот пиксел.

Најдобрите два резултати за различни шеми на класификација со RF и со ERT се дадени во Табела 4.3:

Табела 4.3: Перформанси на класификаторите на податочното множество

Класификатор	Број на атрибути	Време на тренинг	Прецизност (%)	AUC ROC
ERT	845	117.96	52.57	0.5348
RF	459	83.59	52.47	0.5382
RF	6	0.97	52.42	0.5122
ERT	6	0.93	52.39	0.5106

За подобрување на прецизноста потребни се неколку подобрувања кои треба да се направат. Најпрво, потребно е да се користат камери со поголема резолуција, подобар фокус и снимањето да биде од приближно еднакво растојание. На тековното множество, дури и човек би имал проблем да го забележи плевелот бидејќи тешко се разликува од расадот на тутун.

Користењето на мулти-спектрални камери, исто така би можело да даде подобрување во прецизноста. Потребни се дополнителни експерименти со други дескриптори и класификатори, меѓутоа, на постоечкото множество, дури и архитектурата со длабоко учење [73] не даде подобри резултати од 55%.


Дополнително, важно е да се напомене дека ваков систем за детекција и елиминирање на плевел, кој би се користел на расади од ваков тип, треба да биде особено прецизен и да има што помала рата на лажна детекција на плевел, бидејќи при лажна детекција, би се уништувале корисни расади и би се нанела значителна штета на земјоделците.

4.3 Препознавање на видот на растението со користење на дескриптори на контура од слики од листови

Дескрипторите на контура, како што веќе беше опишано во Глава 2.2.2 ја опишуваат контурата околу формата на објектот кој треба да се препознае. Во рамките на оваа докторска дисертација направена е редукција на предложениот дескриптор во [42]. Авторите предлагаат неколку дескриптори кои се базирани на односите помеѓу точките од контурата. Такви дескриптори се дескрипторот за површина на триаголник (Triangle area representation - TAR), кој ја пресметува површината на триаголникот кој го образуваат избраната точка со избраните соседи, дескрипторот за должина на страните од триаголникот (Triangle side lengths - TSL), триаголник претставен со двата ориентирани агли (Triangle represented by two oriented angles - TOA) и Триаголник претставен со должините на страните и аголот помеѓу нив (Triangle represented by two side lengths and an angle - TSLA). Од овие дескриптори, најдобри перформанси има последниот TSLA. Во рамките на истражувањата, направена е редукција на овој дескриптор преку користење само на внатрешниот агол од триаголникот.

Дополнителна модификација на пристапот предложен во [42] е направена со тоа што наместо да се користи споредба слика со слика со користење на методата за K најблиски соседи со хешинг сензитивен на локација, се користи репрезентација на секоја слика од листовите со помош на пристапот BOVW опишан во Глава 2.2.2. Може да се користи и моделот за најблиски соседи, меѓутоа во овој случај, пребарувањето мора да се прави преку споредба на секоја слика од податочното множество со сликата за која сакаме да ја определиме класата и да ја избереме сликата која има најмногу најблиски соседи од базата. Ваквиот начин е погоден кога сакаме да ја определиме, можеби, точната позиција на објектот кој се пребарува на сликата преку користење на пристапот за наоѓање на најблиски

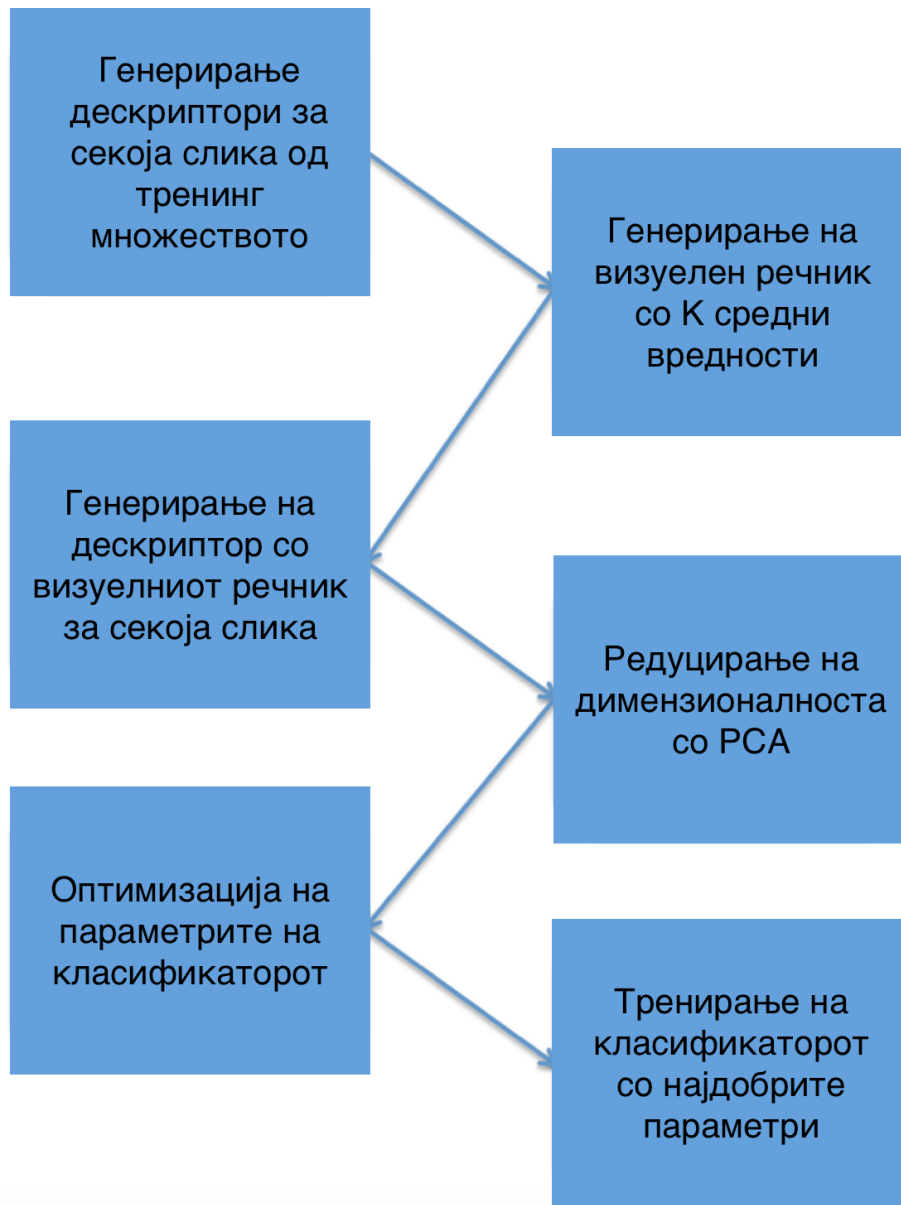
точки. Бидејќи во овој експеримент, го користиме податочното множество со 100 слики од листови на растенија [86] кое е карактеристично по тоа што секоја слика е дадена со контурата на листот. Неколку листови од ова податочно множество се прикажани на Слика 4-3.



Слика 4-3: Пример слики за препознавање на растителниот вид преку контурите на листовите

Податочното множество се состои од 100 различни видови на растенија, секое претставено со 16 слики од листовите. За тренирање на моделот користиме 2/3 случајно избрани слики од целото податочно множество, така што секое растение е претставено со по 11 слики, а останатите слики ги користиме за тестирање на класификацијата. Пристапот користен во овој експеримент е прикажан на Слика 4-4.

Во овој пристап, најпрво се пресметуваат N визуелни зборови преку користење на алгоритмот за K средни вредности за добивање на BOVW дескрипторот. Со овој алгоритам се наоѓаат средните вредности на групите определени од алгоритмот и секој од нив претставува еден збор од визуелниот речник. По наоѓањето на речникот може да се користи некој од пристапите за споредба точка со точка



Слика 4-4: Класификација на растенија преку контурите на нивните листови

за определување на најблиската вредност од речникот со било која вредност од дескрипторите од сликата за која сакаме да го пресметаме BOVW. При споредбата, важно е да се напомене дека е користена мерката Евклидово растојание за наоѓање на растојанието помеѓу два вектори од векторите на дескрипторите на точките. За овој експеримент е користен визуелен речник од 6000 зборови.

После наоѓањето на зборовите, се пресметува фреквенцијата на зборовите и

инверзната фреквенција на документите за зборовите (tf-idf) за секоја слика. Овој пристап е користен во [95] за забрзување на пребарувањето низ сликите од база на податоци. Фреквенцијата на зборовите кажува колку пати визуелниот збор е пронајден во сликата, а инверзната фреквенција на документите, кажува во колку слики е најден дадениот визуелен збор. Овие две метрики се користат и при пребарувањето на документи и даваат солидни резултати како кај документите, така и кај пребарувањето на слики. Фреквенцијата на зборот е важна карактеристика која дава информација за содржината на документот, додека инверзната фреквенција на документи дава информација за тоа колку зборот е уникатен за дадениот документ. Секогаш се претпочитаат зборови кои се карактеристични за дадениот документ, наместо зборови кои ги има во сите документи [96].


Дескрипторот кој се добива на ваков начин има должина колку што има зборови во речникот. Предноста на BOVW пристапот е тоа што се прави еден вид на компресија, па наместо да имаме многу дескриптори за секоја точка од сликата или контурата, имаме еден дескриптор кој ја претстаува сликата. Понатаму овој дескриптор е погоден за тренирање на модели за машинско учење, така што секој дескриптор од дадена класа ќе биде аотиран со соодветната лабела на таа класа.

Бидејќи бројот на зборовите во речникот е голем, потребно е да се изврши редукција на димензионалноста на векторот на дескрипторот. Во овој случај користиме PCA за редукција на димензионалноста. После редукцијата на димензионалноста применети се два пристапи за тренирање на класификационен модел, 1-NN (еден најблизок сосед) и SVM со гаусово јадро или радијална основна функција.

За добивање на најдобар можен модел се користи пристапот на пребарување по матрица за наоѓање на C и γ параметрите за SVM. Овде пребарувањето е извршено за вредности на $C = 10^{-2} - 10^6$ и $\gamma = 10^{-5} - 10^2$. Бидејќи се рабо-


ти за различни дескриптори, очекувано е да се добијат и различни оптимални параметри. За TSLA се добиени $C = 10^6$ и $\gamma = 10^{-4}$, додека за аголниот дескриптор се добиени $C = 10^5$ и $\gamma = 10^{-3}$. Како метрика за споредба се користи површината под кривата на примачкиот оператор (Area under curve of Receiving operating characteristic- AUC ROC) [97, 98]. Оваа карактеристика е добра мерка за квалитетот на класификацијата за бинарна класификација, но имплементацијата која се користи за евалуација на алгоритмот во пакетот WEKA ја користи статистиката на Ман-Витни (Mann-Whitney), која е прилагодена на повеќекратна класификација.

Добиени се резултати со двата употребени класификатори и се претставени на Слика 4-5. Како што може да се забележи од сликата, загубата во перформансите на класификацијата е доста мала за сметка на редукцијата на големината на дескрипторите за 66% (Од 3 вредности по точка на само една вредност по точка). AUC ROC за TSLA дескрипторот со 1-NN изнесува 0.699 додека за аголниот дескриптор изнесува 0.698. Кај SVM класификацијата, AUC ROC за TSLA дескрипторот изнесува 0.769 додека кај аголниот дескриптор изнесува 0.751.



Слика 4-5: AUC ROC за двата пристапи на класификација и двата дескриптори

Слични резултати се добиваат и за прецизноста која е претставена на Слика 4-6.



Слика 4-6: Прецизност за двата пристапи на класификација и двата дескриптори

Прецизноста при класификацијата со 1-NN изнесува 40.4% за моделот базиран на TSLA дескрипторот, додека за аголниот дескриптор изнесува 40.2%. Прецизноста со SVM класификаторот е очекувано поголема и изнесува 54.2% за TSLA и 50.4% за аголниот дескриптор.

Дескрипторот TSLA е имплементиран и искористен за класификација на слики од листови во натпреварот за препознавање на растенија LifeClef во 2014 година [99]. На овој натпревар, овој пристап во комбинација со други пристапи освои 5-то место во конкуренција на 10 групи од светот кои имаа 27 предложени пристапи и 4-то место за класификација на растението од сликите со скенираните листови. Целта на овој натпревар е препознавање на растителниот вид од слика, при што се користат повеќе видови на слики и тоа: слики од листовите, слики од цветови, слики од плодови, слики од стебло, слики од цело растение и сл. TSLA дескрипторот беше користен на слики од скенирани или слични на ске-

нирани листови со најпрво предобработка со екстракција на контурата со Otsu сегментација, а потоа креирање на дескрипторот со 400 избрани точки, еквидистантно од контурата од сегментираниот лист. Секоја од точките е опишана со 10 триаголници што значи за секоја точка се добива дескриптор со 30 вредности.

После градењето на дескрипторите се користи приближно групирање со K средни вредности за креирање на речникот. Овој пристап е сличен со K средни вредности, но наместо директна споредба се користат КД дрва за приближно наоѓање на најблиските центроиди. Центроидите се користат за креирање на BOVW речник кој се користи како дескриптор на сликата во процесот на класификација. Процесот на тренирање на моделите за класификација е опишан во [15].


Според добиените резултати може да се заклучи дека кај дескрипторот на точки од контурите, должината на растојанието помеѓу точките не игра голема улога при определувањето на видот на растението, додека аглиите носат доста значајна информација. Потребни се понатамошни испитувања за да се провери влијанието на другите карактеристики на контурата кои не беа вклучени во овој експеримент.

4.4 Препознавање на растението според слики од листовите со користење на дескриптори на текстура

Бидејќи на податочното множество со 100 растенија, се дадени само контурите, беше одбрано дополнително множество од листови од растенија во кое се дадени целосните листови на растението. Ова податочно множество е составено од 220 видови на растенија претставени преку нивните листови, снимени на рамна површина. Податочното множество има вкупно 16683 слики, така што гарантирано

од секоја класа има барем по 20 слики од листови. Ова податочно множество е преземено од [100].

За препознавање на растенијата во ова податочно множество се употребени неколку дескриптори на контура и текстура. Употребен е дескрипторот за контекст на форми (Shape context descriptor) [101] кој се користи за опишување на формата на даден објект на слика. Овој дескриптор се пресметува, така што најпрво се користи детекторот на рабови Кани [43]. Со детекторот се наоѓаат точките од рабовите на сликата и се добива бинарна слика каде што со 1 се означени рабовите, а со 0 се означени пикселите од сликата каде што нема раб. После наоѓањето на рабовите, сликата се центрира и се опишуваат кружници кои се делат на сегменти околу неа. Оваа шема на поделба е прикажана на Слика 4-7.



Слика 4-7: Шема на поделба на региони за пресметка на дескрипторот за контекст на форма

Понатаму се прави пресметка на бројот на пиксели анотирани со 1 во сликата кои припаѓаат на секој од сегментите. На крајот се добива вектор од броеви кои кажуваат по колку пиксели има во секој од сегментите кои припаѓаат на раб. Дескрипторот за контекст на форми повеќе се фокусира на центарот на сликата под претпоставка дека најважните детали се наоѓаат таму. Заради тоа се избира токму ваквиот начин на поделба каде што регионите на поделба се погусто кон центарот на сликата отколку во периферијата.

Други дескриптори кои се користени во рамките на експериментот со ова податочно множество е дескрипторот за текстура со пресметка на фракталните

димензии на текстурата (Segmentation-based Fractal Texture Analysis algorithm - SFTA) [32], HOG дескрипторот, и варијанта на дескрипторот LBP наречена Комплетна локална бинарна шема или (Complete Local Binary Pattern- CLBP) [102, 103].

Комплетната локална бинарна шема, за разлика од обичната локална бинарна шема, зема предвид и други карактеристики на текстурата на сликата. Имплементацијата на овој дескриптор е преземена од [104]. Оваа имплементација прави и редукција на димензионалноста на LBP дескрипторот преку користење на комбинација од неколку методи.

CLBP е составен од три дела и тоа CLBP_C, CLBP_S и CLBP_M. CLBP_S претставува обичниот LBP кој се пресметува според равенката 2.16. Кај CLBP_M дополнително се земаат предвид и интензитетите на пикселите. така се определува праг m кој е еднаков на средната вредност од сликата. Па CLBP_M се дефинира според Равенката 4.2. Во оваа равенка, c претставува интензитетот на разликата помеѓу пикселот и централниот пиксел, додека m_p претставува средна вредност од интензитетите. На крајот CLBP_C ја дава информацијата за централниот пиксел во однос на средната вредност на интензитетите на сите пиксели од сликата и се пресметува според 4.3 каде што g_c е централниот пиксел, додека c_I претставува средниот интензитет на пикселите од сликата.

$$CLBP_M_{P,R} = \sum_{p=0}^{P-1} t(m_p, c)2^p, \quad t = \begin{cases} 1, m_p \geq c \\ 0, m_p < c \end{cases} \quad (4.2)$$

$$CLBP_C_{P,R} = t(g_c, c_I) \quad (4.3)$$

После пресметката на овие вредности за секој пиксел од сликата (добивање на слики со вредности пресметани со трите оператори), се прави пресметка на хис-

Табела 4.4: Број на дескриптори и просечна прецизност при вкрстена валидација при класификација со невронски мрежи

Дескриптор	HOG	SFTA	CLBP	Контекст на форми
Должина	81	12	118	48
Прецизност (%)	61,65	49,85	75,43	20,11

тограмот. Хистограмот може да се пресмета преку спојување на трите оператори и генерирање на 3D хистограм или преку спојување на два оператори и добивање на 2D хистограм и додавање на хистограмот од третиот оператор. На ваков начин се добива хистограм на сликата од CLBP операторот, како комбинација од трите оператори CLBP_C, CLBP_S и CLBP_M.

После добивањето на четирите видови дескриптори, CLBP, HOG, SFTA и дескрипторот за контекст на форми, направена е анализа на овие дескриптори преку тренирање на модел за машинско учење со секој од нив. Пред да продолжиме понатаму, треба да се напомене дека секој од добиените дескриптори прави различна трансформација од информациите кои се содржат во сликите и со секој од користените алгоритми, како оператори, се прави некаков вид на компресија на оваа информација од матрицата, која ја претставува сликата, во вектор кој го претставува дескрипторот. Различните дескриптори даваат различна компресија, а со тоа и различна должина на векторот. Така HOG дескрипторот во овој случај дава вектор со должина 81, SFTA, вектор со должина 12, CLBP, вектор со должина 118, додека дескрипторот за контекст на форми должина 48.

За секој од дескрипторите тренирана е невронска мрежа со користење на имплементацијата во WEKA пакетот со основните параметри. Прецизноста добиена од троделната вкрстена валидација се претставена во Табела 4.4 за секој од користените пристапи.

Според добиените резултати, може да се забележи дека текстурата на листовите, најдобро ја опишува CLBP дескрипторот. Потребни се понатамошни истражувања каде што кај овие дескриптори би се направила дополнителна анализа

на важноста на атрибутите од секој од дескрипторите за добивање на комбинација од повеќе дескриптори за форма и текстура. Во овој случај, дескрипторот за контекст на форми, повеќе се задржува на контурата на листовите, а во податочното множество, голем дел од растенијата имаат многу слична форма, па заради тоа и перформансите на овој дескриптор заостануваат зад перформансите на другите дескриптори.

Сепак, перформансите на дескрипторите во комбинација со класификаторите секогаш се зависни од податоците и од дистрибуцијата на множествата. Без детална анализа на повеќе различни податочни множества и емпириско испитување на алгоритмот за пресметување на дескриптори на секое од овие множества, не можеме со голема сигурност да кажеме дека некој дескриптор има добри перформанси од друг.

Дескрипторот со најдобри перформанси во овој случај, CLBP во [102] е тестиран на две податочни множества [34] каде се дадени 24 класи на текстури и на [105] од каде се селектирани по 91 слика со агол на гледање помал од 60° од секоја од 61-та класа на текстури сликани од реални површини. Прецизноста при класификацијата на првото податочно множество со дескрипторот кој е користен и тука е преку 90% додека прецизноста на второто податочно множество е приближно иста со перформансите кои овој дескриптор ги има и на податочното множество со листовите.

Во овие примери, можеме да го согледаме основниот недостаток на алгоритмите за машинско учење. Овие алгоритми, секогаш ги градат моделите врз основа на податоците кои ги имаат на располагање за тренинг. Дескрипторите од друга страна претставуваат математичка трансформација која ги трансформира податоците од еден векторски простор во друг облик, за да се добијат што е можно поуникатни карактеристики, кои на единствен начин ќе можат да ја определат класата во која се наоѓа дадениот примерок. Алгоритмите за дескриптори, се дизајнирани од луѓе, и како такви претставуваат трансформација која што луѓето

сметаат дека би била доволно информативна и одлучувачка за да се определат соодветните класи. Од друга страна, алгоритмите за машинско учење, пробуваат да го поделат хипер-просторот на начин што би донел најмала можна грешка при поделбата на податоците од тренинг множеството. Заради самиот процес на оптимизација, односно, намалување на грешката при тренирањето, овие алгоритми се зависни од дистрибуцијата на податоците. Доколку имаме доволен број на доволно репрезентативни податоци за секоја од класите, во тој случај алгоритмите за машинско учење, функционираат добро. Доколку има шум и преклопување, во тој случај перформансите на алгоритмите за машинско учење се намалуваат.

4.5 Класификација на плевел од слики од расад на морков

Во последните неколку години, предложени се алгоритми за длабоко учење, кои истовремено ги учат односно тренираат дескрипторите и класификацијата. Овие алгоритми даваат значително подобри резултати во однос на останатите при проблемите на класификација на растителни видови според слики од нив, како и при детекција на плевел од слики со мултиспектрални камери и RGB слики при воедначено осветлување.

Во недостаток на реални податочни множества, прибрани се податоци од реални насади на морков во подоцна фаза од развојот со поголема зафатеност на површините со плевел. Дополнително, сликите имаат и дополнителни артефакти на нив како што се црева за наводнување капка по капка и други објекти. Неколку вакви примери се прикажани на Сликите 4-8, 4-9 и на 4-10. Очигледни се различните нивоа на осветлување и присуството на артефакти, како и препокривањето на плевелот со корисните расади.

Ова податочно множество е опишано во Глава 3.3. Дополнително треба да се



Слика 4-8: Пример слика од податочното множество од расад на морков (1)



Слика 4-9: Пример слика од податочното множество од расад на морков (2)



Слика 4-10: Пример слика од податочното множество од расад на морков (3)

напомене дека сликите од ова податочно множество не се едноставни за обработка, бидејќи се сликани под различно осветлување. Плевелот и расадот од морков во повеќето слики се препокриваат на повеќе места. Заради овие проблеми, пристапите опишани во претходните поглавја, каде што беа користени дескриптори на контура, неможат да се употребуваат бидејќи е потребна претходна изолација на секој лист од растенијата.

Во литературата, предложени се вакви пристапи кои успешно или делумно успешно успеваат да ги сегментираат листовите од растенијата од сликите [106, 107, 108]. Меѓутоа, овој пристап е едноставен, доколку се користат сензори за оддалеченост и RGB-D сензори кои даваат информација за интензитетот на светлината на пикселите како и за нивната длабочина. Доколку се работи за слики од камери со пониска цена, екстракцијата на површините на листовите и нивната сегментација од сликата претставува бавен процес. Дополнително, прецизноста на ваквата екстракција не овозможува добивање на доволно прецизни податоци за пресметување на дескрипторите на контура.

Проблемот на детекција на плевел во даденото множество, всушност се сведува на проблем на сегментација на плевелот од сликата. Оваа сегментација може да биде извршена директно преку директна детекција на плевелот од сликата или

може да биде извршена прво преку детекција на вегетациските површини од сликата, а потоа преку понатамошна поделба на овие површини на плевел и корисно растение.

Сегментацијата на зелените површини од сликата може да биде изведена на повеќе начини и како што веќе беше спомнато во Глава 2.1, постојат повеќе простори на бои и индекси кои може да се користат за поедноставна сегментација на растителните површини од сликите. Исто така, постојат и пристапи кои користат машинско учење, со цел сегментација на сликите од растенијата [109].

За решавање на проблемот на сегментација на растенијата од останатите површини, направен е обид со два пристапи. Едниот пристап користи ExG и ExGExR индекси и Otsu сегментација кои веќе беа опишани во Глава 2.1. Според литературата, овие индекси даваат добри резултати при сегментацијата на сликата, а поради користењето на методот за детекција на прагот Otsu, сегментацијата е и доста брза. Дополнително може да се јави потреба за морфолошки операции на сликата како отварање и затварање за да се елиминираат евентуални мали шумови и да се добијат пофини рабови на сегментите.

Бидејќи сегментацијата на вегетацијата од сликата не е едноставен проблем, во рамките на експериментите, користевме пристап за семантичка сегментација со длабоко учење - SegNet опишан во 2.5. Во рамките на истражувањето, направени се обиди со едно ниво од мрежата SegNet и со четири нивоа (Оригиналната мрежа е редуцирана за три конволуциски, три деконволуциски и по еден слој за одбирање).

Имплементацијата за длабоко учење која ја користиме е Caffe [110]. Оваа имплементација овозможува едноставна конфигурација на различни видови архитектури за длабоко учење и има едноставен интерфејс преку Python. Исто така, Caffe овозможува користење на GPU за тренирање на моделите што значајно го убрзува процесот на тренирање. Всушност, со сигурност може да се каже дека за тренирање на модели за длабоко учење поврзани со обработка на слика, мораме

Табела 4.5: Резултати од сегментација на зелени површини од слика со користење на длабоко учење и индекси на бои

Вид на сегментација	Средна прецизност
ExG и Otsu	0.974
ExGExR и Otsu	0.977
SegNet (1 со 38)	0.694
SegNet (38 со 1)	0.713

да користиме GPU бидејќи комплексноста на моделите е голема и тренирањето без паралелизација би одело многу бавно. Причината за ова е се пресметките излезите од невронските мрежи, кои се изведуваат преку множење на вектори и матрици со големи димензии.

Во недостаток на поголеми податочни множества и заради големите мемориски перформанси потребни за тренирање на модели со длабоко учење, секоја од сликите се дели на сегменти со големина 128×128 . Исто така, користиме една слика за тренинг и сите останати слики за тест во едното сценарио. додека во другото сценарио ги користиме сите освен една слика за тренинг, а останата слика за тест. Со ваквата поделба се добиваат вкупно 475 сегменти за тренинг и 18525 сегменти за тестирање во случај кога се користи една слика за тренинг, а останатите за тест, и обратно ако се користат 38 слики за тренинг, а останатата слика за тест. При тренирањето и тестирањето, избрани се само оние сегменти кои содржат по најмалку 5% пиксели кои припаѓаат на различна класа.

Резултатите добиени од сегментацијата на зелените површини е прикажана во Табела 4.5. Користена е SegNet редуцирана за еден слој како што беше погоре опишано.

Како што може да се забележи од резултатите, индексите на боја се подобри при сегментацијата на вегетацијата од сликите за разлика од длабоката невронска мрежа за сегментација за ова податочно множество. Причина е најверојатното претренирање на мрежата со карактеристиките на сликите за тренинг и недоволната можност за генерализација на мрежата. Треба да се напомене дека сликите

во мрежата се даваат такви какви што се без претходна нормализација или било каква трансформација на боите и дека сликите се со различно ниво на осветлување. Доколку користиме нормализација на сликите со помош на средната вредност и варијансата, резултатите остануваат приближно исти.

Интересен е фактот што SegNet конвергира релативно брзо при сегментацијата на растенија од земја од сликите. За конвергенција на SegNet на ова податочное множество потребни беа околу 500 итерации, после што, резултатите при тестирањето на мрежата остануваат приближно исти. Ова покажува дека SegNet прави претренирање на податоците при сегментацијата на растенијата од сликите без и со нормализација.

Истиот експеримент е направен со директна сегментација на три класи, плевел, корисно растение и земја. Во овој случај средната прецизност при класификација со една слика тренинг и сите останати тест изнесува 59.0% додека при тренинг со 38 слики а тест со 1 слика изнесува 64.1%. Според резултатите се гледа дека повторно се прави претренирање на мрежата, односно мрежата успешно се тренира на тренинг сликите каде што прецизноста при валидацијата на тренинг множеството надминува 95%, но неуспешно генерализира при сегментација на останатите слики, исто како и при сегментација на растителни површини. Дополнително при тренирање со три класи, конвергенцијата на мрежата е многу побавна и потребни се неколку илјади итерации за моделот да конвергира кон дадената прецизност.

Истите експерименти со SegNet се повторени и со трансформација на сликите во друг простор на бои пред тренирањето, бидејќи, како што веќе беше дискутирано во Глава 2.1, RGB просторот е несоодветен при математичка споредба на боите. Исто така при трансформацијата на RGB сликите во еден од другите простори на бои, осветлувањето се изведува како посебен канал и доколку е потребно, може да се нормализира или анулира. Како простори на бои кои се избрани се HSV и Lab просторите на бои. Резултатите при сегментацијата на

сликите се прикажани во табела 4.6. Резултатите се приближно исти со оние при користење на RGB слики без трансформација во HSV и Lab просторот на бои за сегментацијата на три класи. Додека за сегментацијата на растенија од земја, резултатите се полоши, што значи дека алгоритмот прави уште поголемо претренирање.

Табела 4.6: Резултати од тренирањето на модели за длабоко учење со HSV и Lab слики

Класификација	Вегетација, Земја	Плевел, Растение, Земја
SegNet (1 со 38) HSV	0.429	0.481
SegNet (1 со 38) Lab	0.534	0.521
SegNet (38 со 1) HSV	0.601	0.609
SegNet (38 со 1) Lab	0.71	0.630

Според резултатите добиени од експериментот со SegNet, можеме да заклучиме дека SegNet мрежата прави претренирање при користењето на истата за детекција на плевел или вегетација од RGB слики под различно осветлување. Дополнителни експерименти се направени со само едно ниво од SegNet мрежата (три конволуции со максимално одбирање, па три деконволуции со максимално одбирање) и се добиени слични резултати. Ваквите резултати се потврдени во литературата и кај слики од RGB со константно осветлување како и со вештачки генерирани податочни множества [79].

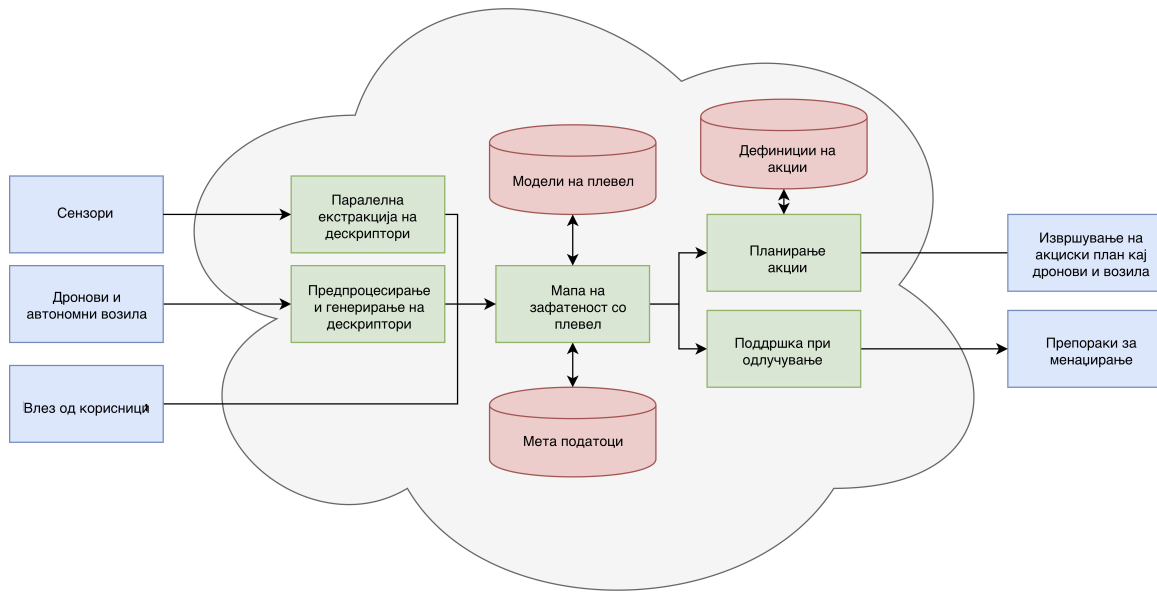
Потребни се дополнителни испитувања за да целосно се испита потенцијалот на алгоритмите за длабоко учење за сегментација на плевелот и растенијата од сликите. Исто така, можно е добивање на подобри модели доколку се користат многу поголеми податочни множества од оние кои ги имаме на располагање во рамките на оваа докторска дисертација, за да се добијат погенерални модели.

4.6 Архитектура на систем за детекција на плевел базирана на пресметки во облак

Детекцијата на плевел може да биде изведена со помош на камери, користејќи дел од предложените пристапи од литературата како и оние предложени во рамките на оваа докторска дисертација, во комбинација со други сензорски системи поставени на самите обработливи површини. Проблемот со ваквите количества податоци е тоа што нивната обработка бара компјутери со поголеми перформанси. Ова воедно ја качува и цената потребна за дизајн и имплементација на автономни или полуавтономни машини за детекција на плевел. Исто така, проблем е кога обработливите површини не се доволно големи за да се исплати купување на ваков тип на машина. Ваквиот проблем го има кај малите земјоделци како и кај оние култури кои се специфични и се садат многу малку. За таа цел во рамките на оваа докторска дисертација предлагаме архитектура на решение за систем за детекција на плевел во облак [20].

Основната архитектура на ова решение е прикажана на Слика 4-11. При автоматската детекција и отстранување на плевел, потребно е најпрво да се изврши снимање на површините и детекција на плевелот. За таа цел може да се користат информации добиени од беспилотни летала (UAV- unmanned air vehicles) како и од возила опремени со соодветни сензори од земјата (UGV - Unmanned ground vehicles). Овие сензорски податоци, во комбинација со сензорските податоци добиени од други сензори поставени во обработливите површини, како и податоците добиени од самите земјоделци, може да се користат за градење на модел, со помош на алгоритми на машинско учење, за детекција на плевел.

Податоците кои се внесени од корисникот и од сензорите понатаму се обработуваат преку алгоритми за автоматско пресметување на карактеристики и дескриптори, или може да се користат алгоритми за длабоко учење. Повеќето популарни платформи за пресметување во облак, како што се Амазон и Гугл,



Слика 4-11: Архитектура на систем за детекција на плевел во облак

веќе нудат вакви решенија за машинско учење и длабоко учење. Нивните понуди се по доста прифатливи цени и нивното користење е значајно поевтино одколку користење на сопствен хардвер за пресметување. Секако доколку се работи за повремено користење на овој систем, што одговара на сценаријата на мали земјоделци и мали површини. За големи површини, секогаш е поисплатливо да се инвестира во поквалитетна и поскапа локална опрема.

После прибирањето на податоците и нивната предобработка, се добиваат дескриптори кои може да се користат за тренирање на моделите. Моделите се тренираат и чуваат и потоа може да се користат со помош на множество од предефинирани акции на автономните возила на земјата за планирање на акциите кои овие возила треба да ги изведат за елиминација на плевелот.

Покрај за детекција и елиминација на плевел, предложената архитектура, со мали модификации, може да се користи и за други активности поврзани со земјоделието и обработката на земјата, како планирање на наводнување, планирање на третман од штетници и болести и слично. Веќе постојат решенија базирани

на облак за прецизно земјоделство. Пример решенија базирани на облак се дадени во [111] за менаџмент на работна сила, [112] за поддршка при донесување на одлуки, [113] за споделување и чување на сензорски податоци и други.

Во недостаток на податоци за специфичната сорта на растенијата и во недостаток на готови модели, предложениот систем може да добие податоци од фармерите со кои би се овозможило градење на моделите за класификација, односно, за детекција. Предлог кориснички интерфејс за ваков систем е даден на 4-12. Овој кориснички интерфејс користи алгоритам за сегментација на сликата врз основа на корисничкото обележување на земја, плевел и корисно растение. На сликата, земјата е обележана со жолто, плевелот со црвено, додека корисничкото растение е обележано со сина линија. Обичен уред кој овозможува допир на екранот би бил доволен за имплементација на ова решение, независно од платформата.

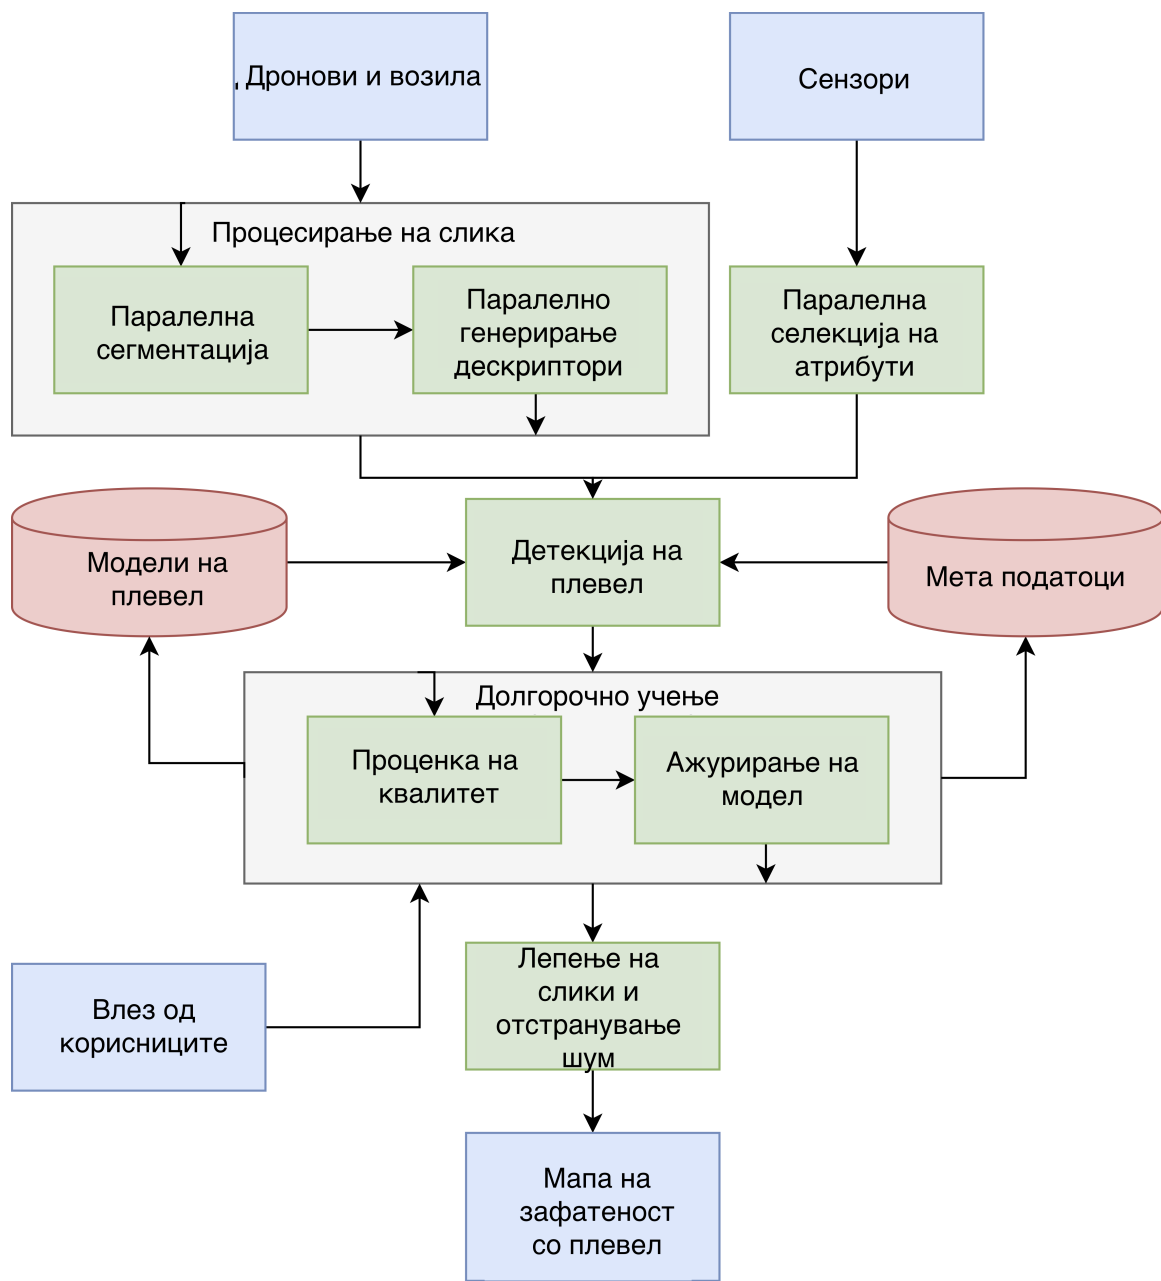
Посакуваниот излез од еден ваков систем е мапа на покриеност на земјата со плевел и со корисни растенија со цел да се изврши планирањето на акциите и да му се даде преглед на корисникот за тековната состојба на земјиштето. Предлог архитектурата за решение на овој проблем е подетално опишана во Слика 4-13. Во оваа архитектура се предлага модул за долгорочно учење кој со помош на поддршката од корисниците и од податоците, би можел континуирано да го подобрува моделот за детекција на плевел. Овој модел заедно со мета податоците кои се чуваат во системот, а кои се однесуваат, пред се, на специфичните карактеристики на растенијата на определено поднебје и специфичните услови на тоа поднебје. Модулот за чување на мета податоци, пак, овозможува споделување на локалните и глобалните карактеристики и нивно искористување при тренирањето на моделите. Целиот систем, всушност, е замислен како колаборативен систем помеѓу големите и малите фармери, со цел подобрување на детекцијата и третманот на плевелот.

Повторно, со модификации на начинот на тренирање и типот на моделите,



Слика 4-12: Кориснички интерфејс за аотирање на податоците за детекција на плевел

предложената архитектура станува генерална и може да се користи за третман на било кој друг проблем во земјоделието, како што се болестите на растенијата (детекција и третман), наводнување (детекција на влажност и дозирање на водата на соодветни места) и слично.



Слика 4-13: Архитектура за генерирање на мапи

Глава 5

Заклучок

Во рамките на оваа докторска дисертација се извршени повеќе експерименти со различни алгоритми за пресметување на дескриптори на слики, како и различни алгоритми за машинско учење.

Податочните множества во рамките на оваа докторска дисертација се снимени од обични RGB камери под различни временски услови и различно осветлување. Ова претставува дополнителен предизвик при класификацијата на растенијата.

Во случаи кога сегментацијата на растенијата е едноставна, може да се користат дескриптори на контура и текстура на листовите за класификација на растенијата на плевел и корисни растенија, меѓутоа, овој пристап во пракса е невозможен бидејќи честопати настанува препокривање на растенијата со плевелот. Во случаи кога настанува препокривање на растенијата, како во случајот со расадот на тутун и морков, можни се два пристапи. Едниот пристап е користење на лизгачки прозорец и опишување на секој сегмент кој е во прозорецот со дескриптори на текстура. Овој пристап се покажа како неуспешен. Неуспешноста на пристапот е делумно поради квалитетот на сликите од податочното множество, а делумно поради тоа што при препокривањето на расадот со плевелот, делови од текстурата на расадот се опишуваат и во сликите од плевелот поради што

настанува шум кој алгоритмите за машинско учење, а и алгоритмите за длабоко учење не можат да го анулираат и да создадат модел кој би бил употреблив за детекција на плевел. Вториос птидссп р птимрнрс кај расадот од морков, е со дирекна сегментација на растение и земја, односно на земја, плевел и корисно растение со користење на SegNet. При користењето на архитектурата SegNet, настанува претренирање на податоците, па и покрај тоа што мрежата успешно се прилагодува на податоците од тренинг множеството со прецизност поголема од 95%, нејзината можност за генерализација изоставува, па при обидот за сегментација на други слики се јавува прецизност од околу 60% што е многу малку за практична употреба. Во литературата, оваа мрежа е употребена успешно за сегментација на слики од мултиспектрални камери каде што прецизноста е во ранг од над 90% на други податочни множества. Меѓутоа, можни се упростувања и подобрувања на архитектурите за длабоко учење, кои би овозможиле подобре-на детекција на плевелот. Исто така, зголемувањето на количеството податоци, значително би ја подобрило способноста за генерализација на мрежата.

Од погоре изнесеното, можеме да заклучиме дека сегментацијата и детекцијата на плевелот од млади расади на различни растенија со користење на RGB камери и под различни временски услови е доста тешко, меѓутоа, со користење на алгоритми за процесирање на слика и машинско учење, се добиваат доста добри резултати, кои претставуваат добра појдовна точка за понатамошен развој. Со користење на мултиспектрални камери и снимање под константно осветлување, според литературата, се поедноставува детекцијата на плевел и се добиваат уште подобри резултати.

За подобрување на моделите за детекција на плевел, предложена е архитектура на пресметка и тренирање на модели за детекција на плевел во облак која би ги надминала двата основни проблеми кои се јавуваат при конвенционалните методи за детекција на плевел како и при користењето на алгоритми за длабоко учење со мало количество податоци а тоа се:

- Потребата од големи податочни множества за успешно тренирање на алгоритмите за длабоко учење и добивање на модели со поголема моќ за генерализација
- Потребата од моќни хардверски конфигурации за успешно и навремено тренирање на моделите за детекција на плевел.

Ваквата архитектура, во комбинација со алгоритмите за длабоко учење, би овозможила успешна детекција на плевел, а со тоа би овозможила изградба на генерален сензорски систем за детекција на плевел. Ваквиот систем би можел да се прилагоди на детекција на плевел за расад од било кое растение под било кои временски услови. Предложениот систем би можел да се прилагоди и за детекција на други феномени во земјоделството па и во други области каде што се јавува потреба од визуелна инспекција бидејќи предложениот кориснички интерфејс е прилагодлив на било каков влез од корисниците со многу мали модификации.

Дополнително треба да се напомене дека употребата на еден ваков систем за детекција на плевел би овозможила значајно намалување на употребата на хербициди при обработката на земјата во земјоделството, со што би се намалило дирекното загадување на корисните растенија, како и потенцијалното посредно загадување на водите и почвата. Намалената употреба на хербициди нема да влијае на приносите по единица земјина површина, но ќе влијае на намалување на трошоците за производство.

Сепак, потребно е внимателно воведување на засегнатите страни во прифаќање на новите трендови, особено на земјоделците, кои се традиционално конзервативни при воведувањето на иновации во производството. Секоја штета која би се нанела како последица на неуспешното воведување на новите технологии, во земјоделството, би можела да го чини производителот и неколку години производство за да дојде до успешно опоравување. Заради ова, земјоделците тешко ги прифаќаат новите технологии и потребни се повеќе години за адаптација, па и воведување на владини мерки и субвенции за успешно модернизирање на

производството. Дополнителен проблем се општествените предизвици при воведувањето на автоматизацијата во земјоделството предизвикани од губењето на работните места.

Хипотезата која е предложена во оваа докторска дисертација е делумно покажана, бидејќи, навистина алгоритмите за машинско учење и процесирање на слика, како и алгоритмите за длабоко учење, можат успешно да бидат применети за препознавање на растителни видови и детекција на плевел. Прецизноста на овие пристапи сеуште не доволна за сосема прецизен третман на растенијата. Со тековната развиеност на алгоритмите за машинско учење и процесирање на слика, како и на архитектурите за длабоко учење, тешко може да се изврши детекција на плевел со користење на RGB слики под варијабилни временски услови со висока прецизност. Меѓутоа, предложените пристапи се добра појдовна основа за практична реализација на систем за детекција на плевел, преку комбинирање со други техники како 3Д моделирање, користење на подвижни камери и активна перцепција. Ова ветува дека во блиска иднина, би можеле да се постигнат резултати кои би биле со задоволително ниво на прецизност и кои би биле користени во земјоделската индустрија.

Литература

- [1] D. K. Ray, N. D. Mueller, P. C. West, and J. A. Foley, “Yield trends are insufficient to double global crop production by 2050,” *PloS one*, vol. 8, no. 6, p. e66428, 2013.
- [2] P. Cosmin, “Adoption of artificial intelligence in agriculture,” *Bulletin of University of Agricultural Sciences and Veterinary Medicine Cluj-Napoca. Agriculture*, vol. 68, no. 1, 2011.
- [3] D. Schimmelpfennig *et al.*, “Farm profits and adoption of precision agriculture,” United States Department of Agriculture, Economic Research Service, Tech. Rep., 2016.
- [4] C. Ritter, D. Dicke, M. Weis, H. Oebel, H. P. Piepho, A. Büchse, and R. Gerhards, “An on-farm approach to quantify yield variation and to derive decision rules for site-specific weed management,” *Precision Agriculture*, vol. 9, no. 3, pp. 133–146, 2008. [Online]. Available: <http://dx.doi.org/10.1007/s11119-008-9061-5>
- [5] K.-H. Dammer and G. Wartenberg, “Sensor-based weed detection and application of variable herbicide rates in real time,” *Crop Protection*, vol. 26, no. 3, pp. 270 – 277, 2007, weed Science in Time of Transition. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0261219406002456>
- [6] M. Loghavi and B. B. Mackvandi, “Development of a target oriented weed control system,” *Computers and Electronics in Agriculture*, vol. 63, no. 2, pp. 112 – 118, 2008. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0168169908000471>
- [7] A. I. de Castro, M. Jurado-Expósito, J. M. Peña-Barragán, and F. López-Granados, “Airborne multi-spectral imagery for mapping cruciferous weeds in cereal and legume crops,” *Precision Agriculture*, vol. 13, no. 3, pp. 302–321, 2012. [Online]. Available: <http://dx.doi.org/10.1007/s11119-011-9247-0>
- [8] F. Castaldi, F. Pelosi, S. Pascucci, and R. Casa, “Assessing the potential of images from unmanned aerial vehicles (uav) to support herbicide patch

- spraying in maize,” *Precision Agriculture*, pp. 1–19, 2016. [Online]. Available: <http://dx.doi.org/10.1007/s11119-016-9468-3>
- [9] K.-H. Dammer, “Real-time variable-rate herbicide application for weed control in carrots,” *Weed Research*, vol. 56, no. 3, pp. 237–246, 2016. [Online]. Available: <http://dx.doi.org/10.1111/wre.12205>
- [10] T. Berge, S. Goldberg, K. Kaspersen, and J. Netland, “Towards machine vision based site-specific weed management in cereals,” *Computers and Electronics in Agriculture*, vol. 81, pp. 79 – 86, 2012. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0168169911002602>
- [11] M. Angelovski, P. Lameski, E. Zdravevski, and A. Kulakov, “Application of bci technology for color prediction using brainwaves,” *ICT Innovations 2012, Web Proceedings ISSN 1857-7288*, p. 253, 2012.
- [12] P. Lameski, D. Kulakov, E. Zdravevski, and A. Kulakov, “Tumor detection in manually selected regions of mri images,” *ICT Innovations 2014, Web Proceedings ISSN 1857-7288*, pp. 183–190, 2014.
- [13] P. Lameski, E. Zdravevski, R. Mingov, and A. Kulakov, “Comparison of local image descriptors for plant identification from leaf image,” in *Proceedings of the 2013 ICMER Conference*, 2013.
- [14] B. Dikovski, P. Lameski, E. Zdravevski, and A. Kulakov, “Structure from motion obtained from low quality images in indoor environment,” in *Proceedings of the 10th Conference for Informatics and Information Technology (CIIT 2013)*. Faculty of Computer Science and Engineering (FCSE) and Computer Society of Macedonia, 2013.
- [15] I. Dimitrovski, G. Madjarov, D. Kocev, and P. Lameski, “Maestra at lifeclef 2014 plant task: Plant identification using visual data.” in *CLEF (Working Notes)*, 2014, pp. 705–714.
- [16] P. Lameski, E. Zdravevski, and A. Kulakov, “Unsupervised weed detection in spinach seedling organic farms,” in *Proceedings of the 24th International Electrotechnical and Computer Science Conference ERK 2015*, September 2015.
- [17] P. Lameski, E. Zdravevski, A. Kulakov, and D. Gjorgjevik, “Plant images classification based on the angles between the leaf shape-contour points,” in *Proceedings of the 12th International Conference for Informatics and Information Technology (CIIT 2015)*, At Bitola, Macedonia. Faculty of Computer Science and Engineering (FCSE) and Computer Society of Macedonia, 2015.
- [18] P. Lameski, E. Zdravevski, R. Mingov, and A. Kulakov, “SVM parameter tuning with grid search and its impact on reduction of model over-fitting,” in *Rough Sets, Fuzzy Sets, Data Mining, and Granular Computing: 15th*

- International Conference, RSFDGrC 2015, Tianjin, China, November 20-23, 2015, Proceedings*, Y. Yao, Q. Hu, H. Yu, and J. W. Grzymala-Busse, Eds. Cham, Switzerland: Springer International Publishing, 2015, pp. 464–474.
- [19] P. Lameski, E. Zdravevski, and A. Kulakov, “Weed segmentation from grayscale tobacco seedling images,” in *International Conference on Robotics in Alpe-Adria Danube Region*. Springer International Publishing, 2016, pp. 252–258.
- [20] P. Lameski, E. Zdravevski, A. Kulakov, and V. Trajkovik, “Cloud based architecture for automated weed control,” in *Proceedings of the 17th IEEE International Conference on Smart Technologies IEEE EUROCON 2017*. IEEE, July 2017.
- [21] P. Lameski, E. Zdravevski, S. Koceski, A. Kulakov, and V. Trajkovik, “Suppression of intensive care unit false alarms based on the arterial blood pressure signal,” *IEEE Access*, vol. PP, no. 99, pp. 1–1, 2017.
- [22] D. Bogatinov, P. Lameski, V. Trajkovik, and K. M. Trendova, “Firearms training simulator based on low cost motion tracking sensor,” *Multimedia Tools and Applications*, vol. 76, no. 1, pp. 1403–1418, 2017.
- [23] P. Lameski, L. Pejov, L. Djinevski, D. Trajanov, and S. Filiposka, “Sampling rare events in hybrid statistical physics quantum mechanical studies of hydrophobic interactions in liquids: A gpu implementation,” in *Conference: ICT Innovations 2015, At Ohrid, Macedonia*, 2015.
- [24] E. Zdravevski, P. Lameski, V. Trajkovik, A. Kulakov, I. Chorbev, R. Goleva, N. Pombo, and N. Garcia, “Improving activity recognition accuracy in ambient assisted living systems by automated feature engineering,” *IEEE Access*, 2017.
- [25] S. Moorthy, B. Boigelot, and B. Mercatoris, “Effective segmentation of green vegetation for resource-constrained real-time applications,” in *Precision agriculture’15*. Wageningen Academic Publishers, 2015, pp. 93–98.
- [26] D. W. Deering, *Rangeland reflectance characteristics measured by aircraft and spacecraft sensors*. Deering, 1978.
- [27] D. Woebbecke, G. Meyer, K. Von Bargen, D. Mortensen *et al.*, “Color indices for weed identification under various soil, residue, and lighting conditions,” *Transactions of the ASAE-American Society of Agricultural Engineers*, vol. 38, no. 1, pp. 259–270, 1995.
- [28] G. E. Meyer and J. C. Neto, “Verification of color vegetation indices for automated crop imaging applications,” *Computers and Electronics in Agriculture*, vol. 63, no. 2, pp. 282–293, 2008.
- [29] T. Hague, N. Tillett, and H. Wheeler, “Automated crop and weed monitoring in widely spaced cereals,” *Precision Agriculture*, vol. 7, no. 1, pp. 21–32, 2006.

- [30] T. Mäenpää, *The Local binary pattern approach to texture analysis: Extensions and applications*. Oulun yliopisto, 2003.
- [31] N. Dalal and B. Triggs, “Histograms of oriented gradients for human detection,” in *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, vol. 1. IEEE, 2005, pp. 886–893.
- [32] A. F. Costa, G. Humpire-Mamani, and A. J. M. Traina, “An efficient algorithm for fractal analysis of textures,” in *Graphics, Patterns and Images (SIBGRAPI), 2012 25th SIBGRAPI Conference on*. IEEE, 2012, pp. 39–46.
- [33] M. Pietikäinen, A. Hadid, G. Zhao, and T. Ahonen, *Local binary patterns for still images*. Springer, 2011.
- [34] T. Ojala, M. Pietikainen, and T. Maenpaa, “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns,” *IEEE Transactions on pattern analysis and machine intelligence*, vol. 24, no. 7, pp. 971–987, 2002.
- [35] Z. Guo, L. Zhang, and D. Zhang, “Rotation invariant texture classification using lbp variance (lbpv) with global matching,” *Pattern recognition*, vol. 43, no. 3, pp. 706–719, 2010.
- [36] T. Ahonen, A. Hadid, and M. Pietikainen, “Face description with local binary patterns: Application to face recognition,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 28, no. 12, pp. 2037–2041, 2006.
- [37] F. Ahmed, M. H. Kabir, S. Bhuyan, H. Bari, and E. Hossain, “Automated weed classification with local pattern-based texture descriptors.” *Int. Arab J. Inf. Technol.*, vol. 11, no. 1, pp. 87–94, 2014.
- [38] X.-Y. Xiao, R. Hu, S.-W. Zhang, and X.-F. Wang, “Hog-based approach for leaf classification,” in *Advanced Intelligent Computing Theories and Applications. With Aspects of Artificial Intelligence*. Springer, 2010, pp. 149–155.
- [39] B. A. Yanikoglu, E. Aptoula, and C. Tirkaz, “Sabanci-okan system at imageclef 2012: Combining features and classifiers for plant identification.” in *CLEF (Online Working Notes/Labs/Workshop)*, 2012.
- [40] M.-K. Hu, “Visual pattern recognition by moment invariants,” *IRE transactions on information theory*, vol. 8, no. 2, pp. 179–187, 1962.
- [41] S. Conseil, S. Bourenane, and L. Martin, “Comparison of fourier descriptors and hu moments for hand posture recognition,” in *Signal Processing Conference, 2007 15th European*. IEEE, 2007, pp. 1960–1964.
- [42] S. Mouine, I. Yahiaoui, and A. Verroust-Blondet, “A shape-based approach for leaf classification using multiscaletriangular representation,” in *Proceedings of the 3rd ACM conference on International conference on multimedia retrieval*. ACM, 2013, pp. 127–134.

- [43] J. Canny, “A computational approach to edge detection,” *IEEE Transactions on pattern analysis and machine intelligence*, no. 6, pp. 679–698, 1986.
- [44] G. Csurka, C. Dance, L. Fan, J. Willamowski, and C. Bray, “Visual categorization with bags of keypoints,” in *Workshop on statistical learning in computer vision, ECCV*, vol. 1, no. 1-22. Prague, 2004, pp. 1–2.
- [45] J. A. Hartigan and M. A. Wong, “Algorithm as 136: A k-means clustering algorithm,” *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, vol. 28, no. 1, pp. 100–108, 1979.
- [46] G. Csurka and F. Perronnin, “Fisher vectors: Beyond bag-of-visual-words image representations,” in *International Conference on Computer Vision, Imaging and Computer Graphics*. Springer, 2010, pp. 28–42.
- [47] J. L. Bentley, “Multidimensional binary search trees used for associative searching,” *Communications of the ACM*, vol. 18, no. 9, pp. 509–517, 1975.
- [48] C. Silpa-Anan and R. Hartley, “Optimised kd-trees for fast image descriptor matching,” in *Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on*. IEEE, 2008, pp. 1–8.
- [49] J. Buhler, “Efficient large-scale sequence comparison by locality-sensitive hashing,” *Bioinformatics*, vol. 17, no. 5, pp. 419–428, 2001.
- [50] M. Datar, N. Immorlica, P. Indyk, and V. S. Mirrokni, “Locality-sensitive hashing scheme based on p-stable distributions,” in *Proceedings of the twentieth annual symposium on Computational geometry*. ACM, 2004, pp. 253–262.
- [51] D. G. Lowe, “Distinctive image features from scale-invariant keypoints,” *International journal of computer vision*, vol. 60, no. 2, pp. 91–110, 2004.
- [52] H. Bay, T. Tuytelaars, and L. Van Gool, “Surf: Speeded up robust features,” *Computer vision–ECCV 2006*, pp. 404–417, 2006.
- [53] E. Rosten and T. Drummond, “Machine learning for high-speed corner detection,” *Computer vision–ECCV 2006*, pp. 430–443, 2006.
- [54] S. Leutenegger, M. Chli, and R. Y. Siegwart, “Brisk: Binary robust invariant scalable keypoints,” in *Computer Vision (ICCV), 2011 IEEE International Conference on*. IEEE, 2011, pp. 2548–2555.
- [55] C. Harris and M. Stephens, “A combined corner and edge detector.” in *Alvey vision conference*, vol. 15, no. 50. Citeseer, 1988, pp. 10–5244.
- [56] M. Calonder, V. Lepetit, C. Strecha, and P. Fua, “Brief: Binary robust independent elementary features,” *Computer Vision–ECCV 2010*, pp. 778–792, 2010.

- [57] M. A. Fischler and R. C. Bolles, “Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography,” *Communications of the ACM*, vol. 24, no. 6, pp. 381–395, 1981.
- [58] K. Pearson, “Liii. on lines and planes of closest fit to systems of points in space,” *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, vol. 2, no. 11, pp. 559–572, 1901.
- [59] H. Hotelling, “Analysis of a complex of statistical variables into principal components.” *Journal of educational psychology*, vol. 24, no. 6, p. 417, 1933.
- [60] M. A. Hall, “Correlation-based feature selection for machine learning,” Ph.D. dissertation, The University of Waikato, 1999.
- [61] C. Lee and G. G. Lee, “Information gain and divergence-based feature selection for machine learning-based text categorization,” *Information processing & management*, vol. 42, no. 1, pp. 155–165, 2006.
- [62] I. Guyon and A. Elisseeff, “An introduction to variable and feature selection,” *Journal of machine learning research*, vol. 3, no. Mar, pp. 1157–1182, 2003.
- [63] R. Kohavi and G. H. John, “Wrappers for feature subset selection,” *Artificial intelligence*, vol. 97, no. 1-2, pp. 273–324, 1997.
- [64] S. Das, “Filters, wrappers and a boosting-based hybrid for feature selection,” in *ICML*, vol. 1. Citeseer, 2001, pp. 74–81.
- [65] C.-L. Huang and C.-Y. Tsai, “A hybrid softm-svr with a filter-based feature selection for stock market forecasting,” *Expert Systems with Applications*, vol. 36, no. 2, pp. 1529–1539, 2009.
- [66] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, and B. Scholkopf, “Support vector machines,” *IEEE Intelligent Systems and their Applications*, vol. 13, no. 4, pp. 18–28, 1998.
- [67] J. R. Quinlan, “Induction of decision trees,” *Machine learning*, vol. 1, no. 1, pp. 81–106, 1986.
- [68] L. Breiman, “Random forests,” *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [69] P. Geurts, D. Ernst, and L. Wehenkel, “Extremely randomized trees,” *Machine learning*, vol. 63, no. 1, pp. 3–42, 2006.
- [70] T. Cover and P. Hart, “Nearest neighbor pattern classification,” *IEEE transactions on information theory*, vol. 13, no. 1, pp. 21–27, 1967.
- [71] J. C. Bezdek, R. Ehrlich, and W. Full, “Fcm: The fuzzy c-means clustering algorithm,” *Computers & Geosciences*, vol. 10, no. 2-3, pp. 191–203, 1984.

- [72] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [73] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in *Advances in neural information processing systems*, 2012, pp. 1097–1105.
- [74] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, “Going deeper with convolutions,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015, pp. 1–9.
- [75] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *arXiv preprint arXiv:1409.1556*, 2014.
- [76] H. Goëau, P. Bonnet, and A. Joly, “Plant identification in an open-world (lifeclef 2016),” *CLEF working notes*, vol. 2016, 2016.
- [77] Y.-H. Wu, L. Shang, Z.-K. Huang, G. Wang, and X.-P. Zhang, “Convolutional neural network application on leaf classification,” in *International Conference on Intelligent Computing*. Springer, 2016, pp. 12–17.
- [78] S. Choi, “Plant identification with deep convolutional neural network: Snumedinfo at lifeclef plant identification task 2015.” in *CLEF (Working Notes)*, 2015.
- [79] C. Potena, A. Pretto, and D. Nardi, “Fast and accurate crop and weed identification with summarized train sets for precision agriculture,” in *IAS*. IAS, 2016.
- [80] M. Dyrmann, H. Karstoft, and H. S. Midtiby, “Plant species classification using deep convolutional neural network,” *Biosystems Engineering*, vol. 151, pp. 72–80, 2016.
- [81] P. Christiansen, L. N. Nielsen, K. A. Steen, R. N. Jørgensen, and H. Karstoft, “Deepanomaly: Combining background subtraction and deep learning for detecting obstacles and anomalies in an agricultural field,” *Sensors*, vol. 16, no. 11, p. 1904, 2016.
- [82] C. McCool, T. Perez, and B. Upcroft, “Mixtures of lightweight deep convolutional neural networks: Applied to agricultural robotics,” *IEEE Robotics and Automation Letters*, vol. 2, no. 3, pp. 1344–1351, 2017.
- [83] V. Badrinarayanan, A. Kendall, and R. Cipolla, “Segnet: A deep convolutional encoder-decoder architecture for image segmentation,” *arXiv preprint arXiv:1511.00561*, 2015.

- [84] Convolution arithmetic. [Online]. Available: https://github.com/vdumoulin/conv_arithmetic
- [85] M. Di Cicco, C. Potena, G. Grisetti, and A. Pretto, “Automatic model based dataset generation for fast and accurate crop and weeds detection,” *arXiv preprint arXiv:1612.03019*, 2016.
- [86] C. Mallah, J. Cope, and J. Orwell, “Plant leaf classification using probabilistic integration of shape, texture and margin features,” *Signal Processing, Pattern Recognition and Applications*, vol. 5, p. 1, 2013.
- [87] S. Haug and J. Ostermann, “A crop/weed field image dataset for the evaluation of computer vision based precision agriculture tasks,” in *Computer Vision - ECCV 2014 Workshops*, 2015, pp. 105–116. [Online]. Available: http://dx.doi.org/10.1007/978-3-319-16220-1_8
- [88] S. Suzuki *et al.*, “Topological structural analysis of digitized binary images by border following,” *Computer vision, graphics, and image processing*, vol. 30, no. 1, pp. 32–46, 1985.
- [89] R. Hu, M. Barnard, and J. Collomosse, “Gradient field descriptor for sketch based retrieval and localization,” in *Image Processing (ICIP), 2010 17th IEEE International Conference on*. IEEE, 2010, pp. 1025–1028.
- [90] A. Chalechale, G. Naghdy, and A. Mertins, “Sketch-based image matching using angular partitioning,” *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, vol. 35, no. 1, pp. 28–41, 2005.
- [91] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I. H. Witten, “The weka data mining software: an update,” *ACM SIGKDD explorations newsletter*, vol. 11, no. 1, pp. 10–18, 2009.
- [92] C. J. Burges, “A tutorial on support vector machines for pattern recognition,” *Data mining and knowledge discovery*, vol. 2, no. 2, pp. 121–167, 1998.
- [93] K. Filiposki, M. Peshevski, D. Živković, and B. Filiposki, “State of tobacco production in the republic of macedonia,” *Proceedings: International scientific Symposium of agriculture "Agrosym Jahorina*, pp. 618–624, 2011.
- [94] M. Boullé, “Tagging fireworkers activities from body sensors under distribution drift,” in *Computer Science and Information Systems (FedCSIS), 2015 Federated Conference on*. IEEE, 2015, pp. 389–396.
- [95] J. Sivic, A. Zisserman *et al.*, “Video google: A text retrieval approach to object matching in videos.” in *iccv*, vol. 2, no. 1470, 2003, pp. 1470–1477.
- [96] J. Ramos *et al.*, “Using tf-idf to determine word relevance in document queries,” in *Proceedings of the first instructional conference on machine learning*, 2003.

- [97] T. Fawcett, “An introduction to roc analysis,” *Pattern recognition letters*, vol. 27, no. 8, pp. 861–874, 2006.
- [98] J. Hanley and B. McNeal, “A simple generalization of the area under the roc curve to multiple class classification problems,” *Radiology*, vol. 143, pp. 29–36, 1982.
- [99] H. Goëau, A. Joly, P. Bonnet, S. Selmi, J.-F. Molino, D. Barthélémy, and N. Boujemaa, “Lifeclef plant identification task 2014,” in *CLEF2014 Working Notes. Working Notes for CLEF 2014 Conference, Sheffield, UK, September 15-18, 2014*. CEUR-WS, 2014, pp. 598–615.
- [100] Chinese leaf dataset. [Online]. Available: <http://www.intelengine.cn/English/dataset/>
- [101] S. Belongie, J. Malik, and J. Puzicha, “Shape matching and object recognition using shape contexts,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 24, no. 4, pp. 509–522, 2002.
- [102] Z. Guo, L. Zhang, and D. Zhang, “A completed modeling of local binary pattern operator for texture classification,” *IEEE Transactions on Image Processing*, vol. 19, no. 6, pp. 1657–1663, 2010.
- [103] Y. Guo, G. Zhao, and M. Pietikäinen, “Discriminative features for texture description,” *Pattern Recognition*, vol. 45, no. 10, pp. 3834–3843, 2012.
- [104] (2012) Implementation of clbp - lbpmatlab. [Online]. Available: <http://www.cse.oulu.fi/CMV/Downloads/LBPMatlab>
- [105] K. J. Dana, B. Van Ginneken, S. K. Nayar, and J. J. Koenderink, “Reflectance and texture of real-world surfaces,” *ACM Transactions On Graphics (TOG)*, vol. 18, no. 1, pp. 1–34, 1999.
- [106] J.-M. Pape and C. Klukas, “3-d histogram-based segmentation and leaf detection for rosette plants,” in *European Conference on Computer Vision*. Springer, 2014, pp. 61–74.
- [107] G. Alenya, B. Dellen, S. Foix, and C. Torras, “Robotized plant probing: Leaf segmentation utilizing time-of-flight data,” *IEEE Robotics & Automation Magazine*, vol. 20, no. 3, pp. 50–59, 2013.
- [108] G. Cerutti, L. Tougne, A. Vacavant, and D. Coquin, “A parametric active polygon for leaf segmentation and shape estimation,” *Advances in Visual Computing*, pp. 202–213, 2011.
- [109] F. De Smedt, I. Billiauws, and T. Goedemé, “Neural networks and low-cost optical filters for plant segmentation,” *International Journal of Computer Information Systems and Industrial Management Applications (IJCISIM)*, vol. 3, p. 4, 2011.

-
- [110] Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama, and T. Darrell, “Caffe: Convolutional architecture for fast feature embedding,” in *Proceedings of the 22nd ACM international conference on Multimedia*. ACM, 2014, pp. 675–678.
- [111] L. Tan, R. Haley, R. Wortman, Y. Ampatzidis, and M. Whiting, “An integrated cloud-based platform for labor monitoring and data analysis in precision agriculture,” in *2013 IEEE 14th International Conference on Information Reuse Integration (IRI)*, Aug 2013, pp. 349–356.
- [112] L. Tan, “Cloud-based decision support and automation for precision agriculture in orchards,” *IFAC-PapersOnLine*, vol. 49, no. 16, pp. 330 – 335, 2016, 5th {IFAC} Conference on Sensing, Control and Automation Technologies for Agriculture {AGRICONTROL} 2016Seattle, WA, USA, 14–17 August 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S240589631631624X>
- [113] L. Zhou, N. Chen, Z. Chen, and C. Xing, “Roscc: An efficient remote sensing observation-sharing method based on cloud computing for soil moisture mapping in precision agriculture,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 9, no. 12, pp. 5588–5598, Dec 2016.