Prepoznavanje redova usjeva na slici primjenom metoda globalne optimizacije

Vidović, Ivan

Doctoral thesis / Disertacija

2016

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:880047

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-17**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
ELEKTROTEHNIČKI FAKULTET OSIJEK

Doktorska disertacija

PREPOZNAVANJE REDOVA USJEVA NA SLICI PRIMJENOM METODA GLOBALNE OPTIMIZACIJE

Ivan Vidović

Osijek, 2016.

Doktorska disertacija izrađena je na Elektrotehničkom fakultetu Osijek, Sveučilišta J. J. Strossmayera u Osijeku.

Mentor: Dr. sc. Željko Hocenski, redoviti profesor

Sumentor: Dr. sc. Robert Cupec, izvanredni profesor

Disertacija ima 120 stranica.

Disertacija broj: 54

Povjerenstvo za ocjenu doktorske disertacije

- Dr. sc. Goran Martinović, redoviti profesor, predsjednik, Sveučilište J. J. Strossmayera u Osijeku, Elektrotehnički fakultet Osijek
- Dr. sc. Željko Hocenski, redoviti profesor, mentor, Sveučilište J. J. Strossmayera u Osijeku, Elektrotehnički fakultet Osijek
- Dr. sc. Ivan Petrović, redoviti profesor, član, Svučilište u Zagrebu, Fakultet elektrotehnike i računarstva u Zagrebu
- Dr. sc. Robert Cupec, izvanredni profesor, sumentor, Sveučilište J. J. Strossmayera u Osijeku, Elektrotehnički fakultet Osijek
- Dr. sc. Emmanuel Karlo Nyarko, docent, član, Sveučilište J. J. Strossmayera u Osijeku, Elektrotehnički fakultet Osijek

Povjerenstvo za obranu doktorske disertacije

- Dr. sc. Goran Martinović, redoviti profesor, predsjednik, Sveučilište J. J. Strossmayera u Osijeku, Elektrotehnički fakultet Osijek
- Dr. sc. Željko Hocenski, redoviti profesor, mentor, Sveučilište J. J. Strossmayera u Osijeku, Elektrotehnički fakultet Osijek
- Dr. sc. Ivan Petrović, redoviti profesor, član, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva u Zagrebu
- Dr. sc. Robert Cupec, izvanredni profesor, sumentor, Sveučilište J. J. Strossmayera u Osijeku, Elektrotehnički fakultet Osijek
- Dr. sc. Emmanuel Karlo Nyarko, docent, član, Sveučilište J. J. Strossmayera u Osijeku, Elektrotehnički fakultet Osijek

Datum obrane doktorske disertacije: 25.05.2016.

Zahvale

Be thankful for what you have, you'll end up having more. If you concentrate on what you don't have, you will never, ever have enough.
Oprah Winfrey

Put do stjecanja titule doktora znanosti puno je duži od trajanja poslijediplomskog studija. Počinje rođenjem, nastavlja se osnovnoškolskim i srednjoškolskim obrazovanjem te preko fakultetskog obrazovanja i spomenutog poslijediplomskog studija završava izradom i obranom doktorske disertacije. Na tom putu mnogo je lijepih trenutaka, ali i prepreka koje čovjek sam ne bi mogao savladati. Prema tome, napisati zahvalu za sve što su meni dragi ljudi učinili za mene zahtijevalo bi barem još jedan rad kao što je ova doktorska disertacija. Ipak, pokušat ću ukratko zahvaliti svima koji su na bilo koji način pomogli da dođem do ovog, za mene velikog, uspjeha.

Zahvaljujem voditelju i mentoru na poslijediplomskom studiju prof. dr. sc. Željku Hocenskom koji me svojim znanjem i iskustvom vodio tijekom studija te mi pomagao pri izradi doktorske disertacije. Osim mentora, veliku ulogu u vođenju kroz studij te u izradi disertacije imao je sumentor izv. prof. dr. sc. Robert Cupec, kojem dugujem veliku zahvalu. Svojim znanjem i savjetima uvelike je olakšao put ka stjecanju akademskog stupnja doktora znanosti.

Zahvaljujem i ostalim profesorima, asistentima, suradnicima i administrativnom osoblju Elektrotehničkog fakulteta Osijek koji su kroz znanstveno-istraživački rad ili kao podrška sudjelovali u izradi ove disertacije. Radnim kolegama iz kabineta, doc. dr. sc. Tomislavu Matiću i doc. dr. sc. Ivanu Aleksiju zahvaljujem na iznimnom razumijevanju i pomoći pri rješavanju brojnih problema s kojima se mladi doktorand susreće na svom putu. Bili su mi velika podrška pri uključivanju u radnu okolinu, znanstveno-istraživački te stručni rad.

Prof. dr. sc. Rudolfu Scitovskom također dugujem zahvalu. Kao iskusan i svjetski priznati znanstvenik, nesebično je dijelio svoje znanje i pomogao mi napraviti prve korake

u znanstveno-istraživačkom radu.

Zahvaljujem se svojoj dugogodišnjoj djevojci Barbari Andabak, koja je uvijek imala razumijevanja za moje probleme i prekovremene sate, koje sam utrošio na završetak studija i na izradu disertacije, te mi je u svemu bila i ostala velika podrška.

Posebno zahvaljujem svojoj obitelji, mami Mileni i bratu Tihomiru, koji su bili uz mene tijekom cijelog obrazovanja pa tako i tijekom poslijediplomskog studija. Njihova podrška i savijeti pomogli su mi pri rješavanju brojnih problema na koje sam nailazio. Zahvaljujem obitelji Barić, didi Blagi, baki Slavki, ujacima Vencelu i Branku te ujinama, bratićima i sestrični koji su uvijek bili tu kada sam ih trebao te su mi nesebično pomagali u svemu.

Prijateljima Krešimiru, Draganu, Josipu, Željku, Josipu, Petru, Gabrijelu, Heleni i ostalima također zahvaljujem za sve što su učinili za mene.

Na kraju, zahvaljujem se i svima onima koje nisam spomenuo u ovoj zahvali, a koji su sa mnom podijelili lijepe i one manje lijepe trenutke te se nadam da ću im moći vratiti barem dio onoga što su oni meni pružili.

Hvala vam!

Ivan

Sadržaj

Popis slika **i**

Popis tablica **iv**

Popis algoritama **v**

Popis kratica **vi**

Popis oznaka **ix**

1 Uvod **1**

2 Problem prepoznavanja redova usjeva **6**

2.1 Snimanje slike polja 7

2.2 Filtriranje i segmentacija slike 8

2.3 Prepoznavanje redova usjeva 10

2.3.1 Projekcija redova usjeva na sliku 10

2.3.2 Model ravnih redova usjeva 12

2.3.3 Model zakrivljenih redova usjeva 13

3 Dosadašnje spoznaje o problemu prepoznavanja redova usjeva **15**

3.1 Prepoznavanje vegetacije 16

3.1.1 Indeksi boje vegetacije 17

3.1.2 Metode segmentacije slike 19

3.1.3 Morfološke operacije 21

3.2 Prepoznavanje redova usjeva 24

3.2.1 Metode zasnovane na Houghovoj transformaciji 25

3.2.2 Metode zasnovane na linearnoj regresiji . . . 26
3.2.3 Metode zasnovane na akumulaciji zelenih piksela . . . 27
3.2.4 Metode zasnovane na filtriranju slike . . . 28
3.2.5 Metode zasnovane na stereoviziji . . . 29
3.2.6 Ostali pristupi rješavanju problema prepoznavanja redova usjeva . . 29
3.2.7 Predloženi pristup . . . 30

4 Primjena inkrementalnog čvrstog grupiranja podataka za prepoznavanje redova usjeva 32

4.1 Problem prepoznavanja pravaca . . . 33
4.1.1 Generiranje skupa točaka . . . 33
4.1.2 Prepoznavanje pravaca zasnovano na grupiranju podataka . . . 35
4.1.3 Prilagodba k-means algoritma . . . 36
4.1.4 Prilagodba inkrementalnih metoda . . . 37
4.2 Metoda za prepoznavanje redova usjeva . . . 38
4.2.1 Algoritam za prepoznavanje dva reda usjeva . . . 39
4.2.2 Algoritam za prepoznavanje tri reda usjeva . . . 40
4.2.3 Algoritam za prepoznavanje proizvoljnog broja redova usjeva . . . 42

5 Prepoznavanje redova usjeva zasnovano na minimizaciji globalne energije 45

5.1 Prepoznavanje vegetacije . . . 46
5.2 Prepoznavanje pravilnih uzoraka u redovima slike . . . 48
5.2.1 Kreiranje predložaka redova usjeva . . . 49
5.2.2 Računanje podudaranja redova slike s predlošcima redova usjeva . . 54
5.3 Određivanje optimalnog modela redova usjeva . . . 59

6 Evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva 66

6.1 Kriteriji za određivanje točnosti prepoznavanja redova usjeva . . . 68
6.1.1 Kriterij za određivanje točnosti prepoznavanja redova usjeva opisanih SCR modelom . . . 68
6.1.2 Kriterij za određivanje točnosti prepoznavanja redova usjeva opisanih CCR modelom . . . 70
6.2 Postupak generiranja referentnih vrijednosti redova usjeva . . . 72
6.3 Baza slika redova usjeva . . . 74

7 Eksperimentalni rezultati **77**

7.1 Metode korištene za usporedbu 78

7.1.1 Houghova transformacija 78

7.1.2 Linearna regresija s predlošcima 80

7.1.3 Houghova transformacija s predlošcima 82

7.2 Eksperimentalna evaluacija CRDI metode 83

7.2.1 Postavke pokusa 83

7.2.2 Usporedba prepoznavanja dva reda usjeva 86

7.2.3 Usporedba prepoznavanja tri reda usjeva 89

7.3 Eksperimentalna evaluacija TMGEM metode 92

7.3.1 Postavke pokusa 93

7.3.2 Usporedba prepoznavanja ravnih redova usjeva 95

7.3.3 Evaluacija prepoznavanja zakrivljenih redova usjeva 98

7.3.4 Analiza utjecaja rezolucije slike na točnost prepoznavanja redova usjeva 101

8 Zaključak **104**

Literatura **108**

Sažetak **116**

Abstract **118**

Životopis **120**

Popis slika

2.1 Ciklus automatizacije procesa poljoprivredne proizvodnje. 7

2.2 Primjer slike polja. (a) Slika snimljena kamerom u boji, (b) Slika snimljena infracrvenom kamerom (izvor: http://www.chrisupdegrave.com/infrared/). 8

2.3 Primjer segmentacije slike polja. (a) Originalna slika, (b) Segmentirana slika dobivena primjenom Otsu metode, (c) Slika dobivena računanjem ExG indeksa boje vegetacije, (d) Segmentirana slika dobivena primjenom Otsu metode na slici c). 9

2.4 Model polja. (a) Ravno polje, (b) Zakrivljeno polje. 11

2.5 Model ravnih redova usjeva. 13

2.6 Model zakrivljenih redova usjeva. 14

3.1 (a) Primjer refleksije piksela skupa K u skup $\hat{K}$, (b) Primjer translacije skupa K u skup $(K)_z$. 22

3.2 Primjeri strukturnih elemenata za morfološke operacije. 22

3.3 Primjer morfoloških operacija erozije i dilatacije. (a) Ulazna slika, (b) Strukturni element, (c) Rezultat primjene morfološke operacije erozije, (d) Rezultat primjene morfološke operacije dilatacije. 23

3.4 Primjer morfoloških operacija otvaranja i zatvaranja. (a) Ulazna slika, (b) Strukturni element, (c) Rezultat primjene morfološke operacije otvaranja, (d) Rezultat primjene morfološke operacije zatvaranja. 24

4.1 Primjer generiranja jedne točke skupa A_j korištenjem izraza (4.3). 34

4.2 Prepoznavanje pravaca primjenom IMLD metode. (a) Primjer generiranih točaka, (b) Pravci dobiveni primjenom IMLD metode. 38

4.3 Primjer rada algoritma 2. (a) Referentni redovi usjeva i generirane točke, (b) TLS pravac, (c) Pravci dobiveni primjenom `DIRECT` algoritma, (d) Pravci dobiveni nakon korekcije k-means algoritmom (algoritam 1). 40

4.4 Primjer rada algoritma 3. (a) Referentni redovi usjeva i generirane točke, (b) TLS pravac, (c) TLS pravac i pravci dobiveni primjenom `DIRECT` algoritma, (d) Pravci dobiveni nakon korekcije k-means algoritmom (algoritam 1). 41

4.5 Primjer rada algoritma 4. (a) Referentni redovi usjeva i generirane točke, (b) TLS pravac, (c) TLS pravci za lijevi i desni skup točaka iz prethodnog koraka, (d) TLS pravci za četiri podskupa iz prethodnog koraka, (e) Svi pravci koji se koriste kao početni pravci u k-means algoritmu, (f) Pravci dobiveni nakon korekcije k-means algoritmom (algoritam 1). 43

5.1 Slika redova usjeva. (a) Bez korova, (b) S puno korova. 46

5.2 Slike vegetacije dobivene računanjem ExG indeksa boje vegetacije za slike redova usjeva prikazane na slici 5.1. 47

5.3 Profili intenziteta za redove slike vegetacije označene isprekidanim linijama na slici 5.2. 49

5.4 Primjer mapiranja piksela slike na interval $[0, 1)$. 50

5.5 Srednji profil intenziteta vegetacije (histogram) i funkcija M_0 (isprekidana linija). . . . 51

5.6 Predložak redova usjeva. 54

5.7 Primjeri predložaka redova usjeva za tri kombinacije parametara c i d. (a) $c = 10$, $d = 16$, (b) $c = -10$, $d = 40$, (c) $c = 15$, $d = 100$. 55

5.8 Primjer pravokutnog impulsa. 57

5.9 Vrijednosti mjere podudaranja za retke slike vegetacije prikazane na slici 5.3. Globalni maksimumi su označeni iprekidanim kružnicama. 59

5.10 Maksimalne vrijednosti mjere podudaranja $f_{v,max}$ za sve retke slike 5.1a. 62

5.11 Utjecaj optimizacijskog postupka na prepoznavanje redova usjeva. (a) CCR model dobiven određivanjem maksimalne mjere podudaranja za svaki redak slike zasebno, (b) CCR model dobiven minimizacijom funkcije globalne energije. 64

5.12 Redovi usjeva dobiveni primjenom TMGEM metode na slikama 5.1a i 5.1b. 64

6.1 Razni položaji pravaca p_1, p_2 i p_3. 70

6.2 Oblik funkcije podudaranja s. 72

6.3 Primjer referentnih vrijednosti redova usjeva. Žuti i crveni križići označavaju točke na temelju kojih su određene referentne krivulje centralnih redova usjeva. 74

6.4 Primjeri slika iz baze slika redova usjeva. 76

7.1 Primjer Houghove transformacije. (a) Binarna slika, (b) Houghova ravnina. 79
7.2 Primjer predloška LR metode. (a) Ulazna slika redova usjeva, (b) Predložak kreiran na temelju predznanja. 82
7.3 Primjer tri pravca koji prolaze sjecištem S i točaka generiranih na temelju tih pravaca. . 84
7.4 Primjer točaka generiranih na temelju tri referentna pravca. (a) Kompletno zasijanje i manja varijanca, (b) Nekompletno zasijanje i manja varijanca, (c) Kompletno zasijanje i veća varijanca, (d) Nekompletno zasijanje i veća varijanca. 85
7.5 Primjer pokusa prepoznavanja dva reda usjeva u slučaju kompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$). (a) Generirane točke, (b) HT metoda, (c) IMLD metoda, (d) CRDI metoda. 87
7.6 Primjer pokusa prepoznavanja dva reda usjeva u slučaju nekompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$). (a) Generirane točke, (b) HT metoda, (c) IMLD metoda, (d) CRDI metoda. 88
7.7 Primjer pokusa prepoznavanja tri reda usjeva u slučaju kompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$). (a) Generirane točke, (b) HT metoda, (c) IMLD metoda, (d) CRDI metoda. 90
7.8 Primjer pokusa prepoznavanja tri reda usjeva u slučaju nekompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$). (a) Generirane točke, (b) HT metoda, (c) IMLD metoda, (d) CRDI metoda. 91
7.9 Primjeri redova usjeva dobivenih primjenom TMGEM metode na slikama redova usjeva prikazanim na slici 6.4. 92
7.10 Normalizirani kumulativni histogrami CRDA kriterija za prvi pokus. 96
7.11 Primjer redova usjeva dobivenih primjenom (a) HT metode, (b) HTT metode, (c) LR metode, (d) TMGEM metode. 97
7.12 Primjeri slika zakrivljenih redova usjeva. 98
7.13 Normalizirani kumulativni histogrami CRDA kriterija za drugi pokus. 99
7.14 Primjeri redova usjeva dobivenih primjenom TMGEM metode na slikama zakrivljenih redova usjeva prikazanim na slici 7.12. 100
7.15 Normalizirani kumulativni histogrami CRDA kriterija za treći pokus. 102

Popis tablica

6.1 Vrijednosti integralne udaljenosti za razne položaje pravaca prikazane na slici 6.1. . . . 69

7.1 Usporedba HT, IMLD i CRDI metode pri prepoznavanju dva reda usjeva uz manju varijancu ($\sigma^2 = 0.002$) 86

7.2 Usporedba HT, IMLD i CRDI metode pri prepoznavanju dva reda usjeva uz veću varijancu ($\sigma^2 = 0.02$) 87

7.3 Usporedba HT, IMLD i CRDI metode pri prepoznavanju tri reda usjeva uz manju varijancu ($\sigma^2 = 0.002$) 89

7.4 Usporedba HT, IMLD i CRDI metode pri prepoznavanju tri reda usjeva uz veću varijancu ($\sigma^2 = 0.02$) 90

7.5 Korisnički definirani parametri TMGEM metode i njihove vrijednosti. 93

7.6 Vrijednosti CRDA kriterija za prvi pokus. 95

7.7 Vremena izvođenja pojedinih koraka TMGEM metode za prvi pokus. Vremena su prikazana u ms. 97

7.8 Vrijednosti CRDA kriterija za drugi pokus. 99

7.9 Vremena izvođenja pojedinih koraka TMGEM metode za drugi pokus. Vremena su prikazana u ms. 101

7.10 Vrijednosti CRDA kriterija za treći pokus. 102

7.11 Vremena izvođenja pojedinih koraka TMGEM metode za treći pokus. Vremena su prikazana u ms. 103

Popis algoritama

1 k-means algoritam. 37

2 Algoritam CRDI metode za prepoznavanje 2 reda usjeva. 39

3 Algoritam CRDI metode za prepoznavanje 3 reda usjeva. 41

4 Algoritam CRDI metode za prepoznavanje k redova usjeva. 42

5 Podudaranje s predloškom. 56

6 Poprečna korelacija retka slike vegetacije i predloška redova usjeva. 58

7 Optimalni CCR model redova usjeva. 63

Popis kratica

CCR	model - model zakrivljenih redova usjeva; skraćenica od engleskog izraza *Curved Crop Rows*
CIVE	indeks boje vegetacije; skraćenica od engleskog izraza *Color Index of Vegetation Extraction*
COM	indeks boje vegetacije; skraćenica od engleskog izraza *Combined index*
CRBD	evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva; skraćenica od engleskog izraza *Crop Row Benchmark Dataset*
CRDA	kriterij za određivanje točnosti prepoznavanja redova usjeva opisanih CCR modelom; skraćenica od engleskog izraza *Crop Row Detection Accuracy*
CRDI	metoda za prepoznavanje redova usjeva zasnovana na IMLD metodi; skraćenica od engleskog izraza *Crop Row Detection based on Incremental method for line detection*
CRHID	kriterij za određivanje točnosti prepoznavanja redova usjeva opisanih pravcima; skraćenica od engleskog izraza *Crop Row Hausdorff Integral Distance*
`DIRECT`	metoda za globalnu optimizaciju; skraćenica od engleskog izraza *`DI`viding `RECT`angles*
ExB	indeks boje vegetacije; skraćenica od engleskog izraza *Excess Blue*
ExG	indeks boje vegetacije; skraćenica od engleskog izraza *Excess Green*

ExGR	indeks boje vegetacije; skraćenica od engleskog izraza *Excess Green minus Excess Red*
ExR	indeks boje vegetacije; skraćenica od engleskog izraza *Excess Red*
GPS	globalni sustav za pozicioniranje; skraćenica od engleskog izraza *Global Positioning System*
GPU	grafička procesorska jedinica; skraćenica od engleskog izraza *Graphics Processing Unit*
HT	Standardna Houghova transformacija
HTT	metoda za prepoznavanje redova usjeva zasnovana na Houghovoj transformaciji koja primjenjuje predloške kao LR metoda; skraćenica od engleskog izraza *Hough Transform with Templates*
IMLD	inkrementalna metoda za prepoznavanje pravaca; skraćenica od engleskog izraza *Incremental Method for Line Detection*
LR	metoda za prepoznavanje redova usjeva zasnovana na linearnoj regresiji; skraćenica od engleskog izraza *Linear Regression*
MCET	metoda segmentacije koja se zasniva na minimizacije entropije između originalne sive slike i sive slike binarizirane na dvije razine; skraćenica od engleskog izraza *Minimum Cross-Entropy Threshold*
MET	metoda segmentacije koja se zasniva na minimizacije pogreške binarizacije; skraćenica od engleskog izraza *Minimum Error Thresholding*
NDI	indeks boje vegetacije; skraćenica od engleskog izraza *Normalized Difference Index*
PGO	problem globalne optimizacije
RANSAC	metoda za određivanje parametara modela za zadani skup podataka; skraćenica od engleskog izraza *RANdom SAmple Consensus*
RMS	korjen srednje kvadratne pogreške; skraćenica od engleskog izraza *Root Mean Square*

ROI	područje interesa; skraćenica od engleskog izraza *Region Of Interes*
SCR	model - model ravnih redova usjeva; skraćenica od engleskog izraza *Straight Crop Rows*
TLS	suma najmanjih kvadrata; skraćenica od engleskog izraza *Total Least Squares*
TMGEM	metoda za prepoznavanje redova usjeva zasnovana na podudaranju s predloškom i minimizaciji globalne energije; skraćenica od engleskog izraza *Template Matching followed by Global Energy Minimization*
VEG	indeks boje vegetacije; skraćenica od engleskog izraza *Vegetative*

Popis oznaka

$\mathcal{A}$	skup točaka
a	širina pozitivnog intervala funkcije M_0
A	koeficijent jednadžbe pravca u proizvoljnom položaju
a_v	konstanta za računanje VEG indeksa boje vegetacije
$\hat{b}$	vrijednost piksela plavog kanala RGB slike normirana po svim kanalima
B_m	maksimalna vrijednost intenziteta plavog kanala RGB slike
b	širina negativnog intervala funkcije M_0
$\hat{B}$	normirana vrijednost piksela plavog kanala RGB slike
B	koeficijent jednadžbe pravca u proizvoljnom položaju
B_s	plavi kanal RGB slike
$B_v(\mathbf{x})$	minimalna vrijednost funkcije globalne energije $E_v(\mathbf{x}_0, \ldots, \mathbf{x}_{v-1}, \mathbf{x})$ za određeni $\mathbf{x}$
c	udaljenost najbližeg reda usjeva do centra slike
C	koeficijent jednadžbe pravca u proizvoljnom položaju
c^*	referentna vrijednost udaljenosti najbližeg reda usjeva do centra slike
D	funkcija troška (engl. *cost function*) koja vektorima parametara $\mathbf{x}$ s većom vrijednosti mjere podudaranja $f(\mathbf{x})$ pridružuje manje vrijednosti
d	udaljenost dvaju susjednih redova usjeva
δ	parametar Hesseovog oblika jednadžbe pravca; predstavlja udaljenost pravca od ishodišta koordinatnog sustava
$d_I(p_1, p_2)$	integralna udaljenost pravaca p_1 i p_2

D_{max}	korisnički definiran parametar; maksimalna dopuštena vrijednost funkcije troška D
d_{max}	maksimalna vrijednost parametra d
d_{min}	minimalna vrijednost parametra d
d^*	referentna vrijednost udaljenosti dvaju susjednih redova usjeva
E	funkcija globalne energije
E'	funkcija energije
F	funkcija cilja
f_{low}	prag minimalne vrijednosti mjere podudaranja
$\mathcal{F}$	funkcija cilja
$f_p(a,b)$	vrijednost normalizirane poprečne korelacije funkcije M_0 i profila $\mathbf{p}$
$f'_{p(a,b)}$	vrijednost normalizirane poprečne korelacije funkcije M_0 i profila $\mathbf{p}$; pojednostavljeni izraz
$f_{v,max}$	maksimalna vrijednost mjere podudaranja v-tog retka slike vegetacije
$f_v(\mathbf{x})$	vrijednost poprečne korelacije v-tog retka slike vegetacije i funkcije M definirane vektorom parametara $\mathbf{x}$
f_x	žarišna duljina po x osi
f_y	žarišna duljina po y osi
$\hat{g}$	vrijednost piksela zelenog kanala RGB slike normirana po svim kanalima
G_m	maksimalna vrijednost intenziteta zelenog kanala RGB slike
$\hat{G}$	normirana vrijednost piksela zelenog kanala RGB slike
G_s	zeleni kanal RGB slike
h	visina slike
$h(i)$	vrijednost histograma za i-ti intenzitet
$\mathbf{I}$	slika vegetacije
$\bar{I}_i$	srednja vrijednost intenziteta vegetacije za podskup S_i
I_s	slika sivih tonova
$I(u,v)$	intenzitet slike vegetacije na lokaciji (u,v)
$J(u,v)$	kumulativna suma retka slike vegetacije
J_{MCET}	funkcija cilja MCET metode

J_{MET}	funkcija cilja MET metode
J_o	funkcija cilja Otsu metode
K	oznaka za skup koordinata piksela pri definiciji morfoloških operacija
k	broj pravaca/redova usjeva
κ	proizvoljna pozitivna konstanta
$\hat{K}$	skup koordinata piksela dobivenih preslikavanjem koordinata piksela iz skupa K
k_p	koeficijent nagiba u eksplicitnom obliku jednadžbe pravca
$(K)_z$	skup koordinata piksela dobivenih translacijom koordinata piksela iz skupa K za vrijednost $z = (u, v)$
λ_c	korisnički definiran parametar; kontstanta penalizacije razlike parametra c za dva susjedna retka slike
λ_d	korisnički definiran parametar; kontstanta penalizacije razlike parametra d za dva susjedna retka slike
l_p	odsječak na y osi u eksplicitnom obliku jednadžbe pravca
L_v	presjek ravnine P_v i redova usjeva
M	funkcija predloška redova usjeva
m	broj točaka
M_0	funkcija koja se sastoji od tri pravokutna intervala
$M^{'}$	pravokutni impuls
μ_a	broj piksela slike koji odgovaraju pozitivnim impulsima predloška redova usjeva
μ_b	broj piksela slike koji odgovaraju negativnim impulsima predloška redova usjeva
$\mu_0(T_b)$	srednja vrijednost piksela prvog objekta; koristi se u funkciji cilja Otsu i MCET metode
$\mu_1(T_b)$	srednja vrijednost piksela drugog objekta; koristi se u funkciji cilja Otsu i MCET metode
$\mathcal{N}(0, \sigma^2)$	normalna razdioba sa srednjom vrijednošću 0 i varijancom σ^2
n_d	broj diskretnih vrijednosti parametra d
n_{oct}	broj oktava
n_{spo}	broj diskretnih vrijednosti u jednoj oktavi

$S = (x_s, y_s)$	sjecište pravaca
$\omega_0(T_b)$	vjerojatnost pojavljivanja prvog objekta; koristi se u funkciji cilja Otsu i MET metode
$\omega_1(T_b)$	vjerojatnost pojavljivanja drugog objekta; koristi se u funkciji cilja Otsu i MET metode
p	pravac u proizvoljnom položaju
$\mathcal{P}(\mathcal{A}; m, k)$	skup svih particija skupa $\mathcal{A}$ u k grupa
$\varphi_v(u)$	funkcija mapiranja piksela s lokacijom (u, v) na interval $[0, 1)$
Π	particija skupa $\mathcal{A}$
P_v	ravnina koja prolazi optičkim centrom kamere i v-tim retkom slike
$\mathbf{p}$	srednji profil intenziteta vegetacije
$\hat{r}$	vrijednost piksela crvenog kanala RGB slike normirana po svim kanalima
$\mathbb{R}$	skup realnih brojeva
ρ	parametar Hesseovog oblika jednadžbe pravca; predstavlja kut koji normala iz ishodišta na pravac zatvara s pozitivnim dijelom x-osi koordinatnog sustava
R_m	maksimalna vrijednost intenziteta crvenog kanala RGB slike
$\hat{R}$	normirana vrijednost piksela crvenog kanala RGB slike
R_s	crveni kanal RGB slike
R	pravokutnik R s granicama x_{min} i x_{max} te y_{min} i y_{max}; $R = [x_{min}, x_{max}] \times [y_{min}, y_{max}]$
sat	funkcija zasićenja
S_i	i-ti podinterval intervala $[0, 1)$
$\sigma_0(T_b)$	standardna devijacija vrijednosti piksela prvog objekta; koristi se u funkciji cilja MET metode
$\sigma_1(T_b)$	standardna devijacija vrijednosti piksela drugog objekta; koristi se u funkciji cilja MET metode
σ^2	varijanca
σ_M	standardna devijacija funkcije M_0
σ_p	standardna devijacija srednjeg profila intenzitera vegetacije $\mathbf{p}$

σ_s	korisnički definiran parametar; određuje dopuštenu toleranciju odstupanja prepoznatih redova usjeva od referentnih vrijednosti pri izračunu CRDA kriterija
T_b	prag binarizacije
$T_v(\mathbf{x})$	mapiranje vektora $\mathbf{x}$ na vektor $\mathbf{x}'$ za koji je vrijednost sume $B_v(\mathbf{x}') + V(\mathbf{x}', \mathbf{x})$ minimalna
$T(\xi, \eta)$	točka s koordinatama ξ i η
$T(x, y)$	točka s koordinatama x i y
u	koordinata stupca slike
u_c	u koordinata optičkog centra
$u_{v,k}$	horizontalna koordinata k-tog reda usjeva u v-tom retku slike
$u^*_{v,k}$	referentna vrijednost horizontalne koordinate k-tog reda usjeva u v-tom retku slike
$U_v(\mathbf{x})$	minimalna vrijednost zbroja $B_v(\mathbf{x}') + V(\mathbf{x}', \mathbf{x})$ izračunatog za sve $\mathbf{x}' \in \chi$
V	funkcija koja penalizira rezliku u parametrima $\mathbf{x}$ za dva susjedna retka slike
v	koordinata retka slike
v_0	prvi redak slike za koji su definirene referentne vrijednosti redova usjeva
v_c	v koordinata optičkog centra
w	širina slike
w_{CIVE}	konstanta koja određuje udio CIVE indeksa boje vegetacije u COM indeksu boje vegetacije
w_{ExG}	konstanta koja određuje udio ExG indeksa boje vegetacije u COM indeksu boje vegetacije
w_{ExGR}	konstanta koja određuje udio ExGR indeksa boje vegetacije u COM indeksu boje vegetacije
w_{VEG}	konstanta koja određuje udio VEG indeksa boje vegetacije u COM indeksu boje vegetacije
χ	skup diskretnih vrijednosti vektora parametara $\mathbf{x}$
$\mathbf{x}_v$	parametri CCR modela za v-ti redak slike

$\mathbf{x}_v^*$	referentne vrijednosti parametara CCR modela za v-ti redak slike
z	visina pravokutnog impulsa
z_a	amplituda pozitivnog intervala funkcije M_0
z_b	amplituda negativnog intervala funkcije M_0

1 Uvod

Automatizacija procesa poljoprivredne proizvodnje problem je koji znanstvenici istražuju dugi niz godina. Neki od prvih znanstvenih radova u ovom području pojavljuju se sredinom 80-ih godina 20. stoljeća (Gerrish et al., 1986; Reid i Searcy, 1986, 1988; Brandon et al., 1989). Procesi kao što su sjetva, gnojidba, prskanje te žetva ili branje plodova samo su neki od procesa poljoprivredne proizvodnje koji mogu biti automatizirani. Navedeni procesi su često mukotrpni i zamorni za čovjeka te iziskuju visoku preciznost i ponavljanje iste radnje nekoliko sati. Upravljanje traktorom uz istovremeno praćenje redova usjeva, ponekada je neizvediv zadatak za jednog čovjeka. Često se u prošlosti, ali i danas, može vidjeti da jedan čovjek upravlja traktorom ili drugim poljoprivrednim strojem, dok drugi čovjek sjedi na stražnjem kraju stroja i daje upute vozaču. Automatizacijom procesa poljoprivredne proizvodnje čovjeku se olakšava rad te se povećava preciznost, a time se dolazi i do veće produktivnosti. Osim toga, spomenutom automatizacijom se može postići i manje zagađivanje okoliša jer se proces prskanja zaštitnim sredstvima može preciznije obaviti te se pri tome koristi manja količina zaštitnih sredstava štetnih za okoliš.

U literaturi je moguće pronaći razne pristupe rješavanju problema automatizacije procesa u poljoprivredi. Prema preglednim radovima (Billingsley i Schoenfisch, 1995; Hague et al., 2000; Wilson, 2000; Li et al., 2009; Mousazadeh, 2013) znanstvenici su istražili mogućnost upravljanja poljoprivrednim strojevima zasnovanu na mehaničkom upravljanju, optičkom upravljanju, radio upravljanju, GPS (engl. *Global Positioning System*) upravljanju te upravljanju korištenjem računalnog vida. Zbog niske cijene kamera i razvoja brojnih algoritama u području računalnog vida, veliki broj radova zasniva se na

primjeni računalnog vida za prepoznavanje redova usjeva i automatsko upravljanje poljoprivrednim strojevima.

Prepoznavanje redova usjeva jedan je od najvažnijih koraka u postupku automatizacije procesa poljoprivredne proizvodnje. Na temelju informacije o poziciji redova usjeva, može se automatski upravljati poljoprivrednim strojem te pri tome obavljati određeni proces poljoprivredne proizvodnje (prskanje, gnojidba, žetva i sl.). Točnost prepoznavanja redova usjeva važna je zbog preciznosti obavljanja određenog procesa poljoprivredne proizvodnje, ali i zbog sprječavanja oštećivanja plodova. Tražena točnost prepoznavanja redova usjeva ovisi o željenoj primjeni, odnosno procesu poljoprivredne proizvodnje koji se automatizira. Prema navedenom, razvoj metoda za prepoznavanje redova usjeva na slici ima veliki značaj u području automatizacije procesa poljoprivredne proizvodnje.

U istraživanju provedenom u sklopu izrade ove doktorske disertacije naglasak je stavljen na razvoj metoda i algoritama za prepoznavanje redova usjeva na slici. Dosadašnjim proučavanjem literature iz područja automatizacije procesa poljoprivredne proizvodnje, odnosno prepoznavanja redova usjeva u svrhu automatizacije procesa poljoprivredne proizvodnje (poglavlje 3), uočena su brojna ograničenja postojećih metoda. Neka od ograničenja su: osjetljivost na prisutnost korova ili sjene, mogućnost prepoznavanja samo određenog (unaprijed zadanog) broja redova usjeva, mogućnost prepoznavanja redova usjeva samo za određeni raspored redova usjeva ili određenu kulturu i sl. Temeljni cilj istraživanja u sklopu ove doktorske disertacije je razviti metodu koja posjeduje sljedeća svojstva:

- robusnost s obzirom na prisutnost korova i sjene,
- mogućnost prepoznavanja redova usjeva za različite kulture,
- mogućnost prepoznavanja redova usjeva u različitim stadijima rasta kulture,
- mogućnost prepoznavanja različitog broja proizvoljno razmaknutih redova usjeva,
- mogućnost prepoznavanja ravnih i zakrivljenih redova usjeva.

Zadovoljavanjem prva četiri svojstva omogućava se široka primjena razvijene metode u rješavanju problema automatizacije procesa poljoprivredne proizvodnje. Mogućnost prepoznavanja ravnih i zakrivljenih redova usjeva predstavlja važno svojstvo metode, budući da većina pristupa predloženih u literaturi ima mogućnost prepoznavanja samo ravnih redova usjeva. Ovo svojstvo važno je zbog činjenice da su brežuljci i udubljenja česta pojava u poljima te se zbog toga ravno zasijani redovi usjeva projiciraju na sliku kao

zakrivljene linije.

Osim navedenih nedostataka metoda za prepoznavanje redova usjeva na slici, tijekom proučavanja literature uočeni su i problemi pri evaluaciji predloženih metoda. U većini slučajeva, redovi usjeva dobiveni primjenom predložene metode ocjenjuju se vizualnom analizom od strane eksperta. Ovakvim načinom evaluacije unosi se subjektivnost u postupak evaluacije jer je ekspert obično jedan od autora predložene metode. Također, vizualnom analizom prepoznatih redova usjeva ne dobiva se kvantitativna mjera odstupanja prepoznatih redova usjeva od referentnih vrijednosti. Nadalje, u području prepoznavanja redova usjeva ne postoji standardizirana baza slika redova usjeva koja bi se mogla koristiti za evaluaciju predloženih metoda. Trenutno, autori prilikom evaluacije predloženih metoda koriste vlastiti skup slika za testiranje, čime se unosi dodatna subjektivnost u postupak evaluacije. Zbog navedenih nedostataka, u sklopu ovog istraživanja cilj je razviti evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva koji bi uključivao:

- bazu slika redova usjeva,
- postupak ručnog kreiranja referentnih vrijednosti redova usjeva,
- kriterije za evaluaciju prepoznatih redova usjeva.

Razvojem spomenutog evaluacijskog okvira omogućila bi se jednostavnija, efikasnija i objektivnija evaluacija novo razvijenih metoda za prepoznavanje redova usjeva. Evaluacijom novo predloženih metoda na skupu slika iz baze slika, autorima bi se, osim objektivnosti, osigurala i jednostavnija usporedba s postojećim metodama iz literature koje su evaluirane na istom skupu slika. Korištenjem postupka za kreiranje referentnih vrijednosti redova usjeva moguće je brzo i efikasno kreirati referentne vrijednosti redova usjeva za nove slike te na taj način proširiti bazu slika redova usjeva.

Doktorska disertacija, koja je rezultat spomenutog istraživanja, organizirana je kako slijedi. Prvo poglavlje sadrži uvod u istraživanje provedeno u sklopu izrade ove doktorske disertacije. Uz motivaciju i osnovne pojmove, navedeni su ciljevi istraživanja te izvorni znanstveni doprinosi koji su ostvareni kao rezultat istraživanja.

U drugom poglavlju predstavljen je problem prepoznavanja redova usjeva na slici. Opisan je postupak automatizacije procesa poljoprivredne proizvodnje, koji je podijeljen na automatizaciju kretanja poljoprivrednog stroja te obavljanje određenog procesa poljoprivredne proizvodnje. Navedene su faze automatizacije kretanja poljoprivrednog stroja te su, uz fazu prepoznavanja redova usjeva na slici, detaljno opisane faze koje prethode fazi prepoznavanja redova usjeva. Osim navedenog, u drugom poglavlju definirane su

pretpostavke i matematički modeli redova usjeva korišteni pri razvoju metoda u kasnijim poglavljima.

Pregled dosadašnjih spoznaja iz područja prepoznavanja redova usjeva na slici napravljen je u trećem poglavlju. Prvo je napravljen pregled metoda za prepoznavanje vegetacije na slikama redova usjeva. Ove metode obično se primjenjuju u postupku predobrade slike pri rješavanju problema prepoznavanja redova usjeva. U nastavku poglavlja napravljen je pregled najvažnijih metoda za prepoznavanje redova usjeva. Metode su podijeljene u šest grupa prema pristupu koji je korišten za rješavanje navedenog problema. Konačno, u sklopu ovog poglavlja, opisan je pristup korišten pri razvoju novih metoda u sklopu ovog istraživanja.

Nova metoda za prepoznavanje pravaca u proizvoljnom položaju predložena je u četvrtom poglavlju. Predložena metoda zasniva se na inkrementalnoj metodi za traženje približno optimalne particije skupa podataka i `DIRECT` algoritmu za globalnu optimizaciju. Predložena metoda prilagođena je za rješavanje problema prepoznavanja redova usjeva. Prilagodba se sastoji od zasebnih algoritama za prepoznavanje dva i tri reda usjeva te poopćenog algoritma za prepoznavanje k redova usjeva.

U petom poglavlju predložena je nova metoda zasnovana na podudaranju s predloškom i minimizaciji funkcije globalne energije koja omogućuje prepoznavanje i zakrivljenih redova usjeva. Za razliku od metode predložene u četvrtom poglavlju i većine metoda dostupnih u literaturi, broj redova usjeva ne mora biti unaprijed poznat. Predložena metoda robusna je na prisutnost korova i sjene te omogućava prepoznavanje redova usjeva za različite kulture u različitim stadijima rasta te za različite geometrije polja. Problem prepoznavanja redova usjeva se, kao i kod metode predložene u četvrtom poglavlju, formulira kao optimizacijski problem. Optimizacijski problem je formuliran na način da se efikasno može riješiti primjenom dinamičkog programiranja, a funkcija globalne energije koja se minimizira, uz podatke sa slike, koristi predznanje o geometrijskoj strukturi redova usjeva.

Evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva opisan je u šestom poglavlju. Predloženi evaluacijski okvir sastoji se od baze slika redova usjeva, postupka generiranja referentnih vrijednosti redova usjeva te kriterija za određivanje točnosti prepoznavanja redova usjeva.

Sedmo poglavlje donosi rezultate eksperimentalne evaluacije predloženih metoda za prepoznavanje redova usjeva. Metoda predložena u četvrtom poglavlju ispitana je na umjetno generiranim skupovima podataka i uspoređena sa Standardnom Houghovom

transformacijom te s predloženom metodom za prepoznavanje pravaca u proizvoljnom položaju. Metoda predložena u petom poglavlju ispitana je na stvarnim slikama redova usjeva iz baze slika redova usjeva te je uspoređena s dvjema metodama zasnovanim na Houghovoj transformaciji i s jednom metodom zasnovanoj na linearnoj regresiji.

Zaključci dobiveni u sklopu ovog istraživanja navedeni su u osmom poglavlju. Uz to, u ovom poglavlju napravljen je osvrt na dobivene rezultate evaluacije predloženih metoda te su navedene smjernice za buduće istraživanje.

Razvojem metoda za prepoznavanje redova usjeva na slici i evaluacijskog okvira za usporedbu metoda prepoznavanja redova usjeva, u sklopu ovog istraživanja, ostvareni su sljedeći izvorni znanstveni doprinosi:

- Metoda za prepoznavanje redova usjeva zasnovana na inkrementalnoj metodi za traženje približno globalne optimalne particije skupa podataka i `DIRECT` algoritmu za globalnu optimizaciju,
- Metoda zasnovana na podudaranju s predloškom i minimizaciji globalne funkcije energije koja omogućuje prepoznavanje i zakrivljenih redova usjeva,
- Evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva koji uključuje bazu slika redova usjeva, postupak generiranja referentnih vrijednosti i kriterije za određivanje točnosti prepoznavanja redova usjeva.

2

Problem prepoznavanja redova usjeva

Prepoznavanje redova usjeva važan je korak u automatizaciji procesa poljoprivredne proizvodnje. Postupak automatizacije procesa poljoprivredne proizvodnje može se podijeliti na *i*) *automatizaciju kretanja poljoprivrednog stroja* i *ii*) *obavljanje određenog procesa poljoprivredne proizvodnje*. Ova dva procesa izvode se paralelno, odnosno poljoprivredni stroj obavlja određenu poljoprivrednu radnju (plijevljenje korova, sijanje i sl.) dok se istovremeno obavlja proces automatizacije kretanja. Proces automatizacije kretanja poljoprivrednog stroja može se podijeliti u sljedeće faze (slika 2.1): snimanje slike polja, filtriranje i segmentacija slike, prepoznavanje redova usjeva, određivanje trenutnog položaja stroja u odnosu na redove usjeva, planiranje kretanja stroja te upravljanje strojem. Ove faze izvode se ciklički pri čemu se, u jednom ciklusu automatizacije kretanja poljoprivrednog stroja, svaka od navedenih faza izvodi jednom. Prikaz jednog ciklusa automatizacije kretanja poljoprivrednog stroja prikazan je na slici 2.1. Na slici je vidljivo, ranije spomenuto paralelno izvođenje procesa automatizacije kretanja i procesa obavljanja određenog procesa poljoprivredne proizvodnje.

Budući da je naglasak istraživanja u sklopu doktorske disertacije stavljen na rješavanje problema prepoznavanja redova usjeva, u nastavku ovog poglavlja ukratko su objašnjene prve tri faze automatizacije procesa kretanja poljoprivrednog stroja. Faze koje prema slici 2.1 sljede nakon faze prepoznavanja redova usjeva (određivanje trenutnog položaja stroja u odnosu na redove usjeva, planiranje kretanja stroja te upravljanje strojem) izlaze iz okvira ovog istraživanja pa u nastavku nisu detaljnije objašnjene.

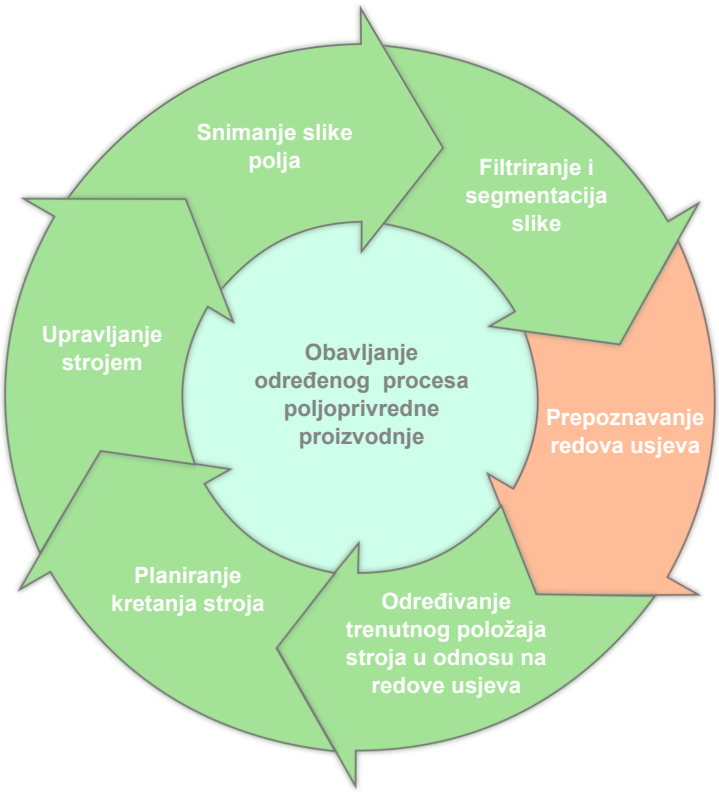

Slika 2.1: Ciklus automatizacije procesa poljoprivredne proizvodnje.

2.1 Snimanje slike polja

Snimanje slike polja, radi primjene algoritama računalnog vida za automatizaciju procesa poljoprivredne proizvodnje, prvi je, ali važan korak.

Slika polja može biti snimljena kamerom u boji, infracrvenom kamerom ili nekim od 3D senzora koji uz snimljenu sliku daje trodimenzionalnu informaciju u obliku dubinske slike. U 3D senzore spadaju senzori zasnovani na strukturiranom svjetlu (npr. Microsoft Kinect senzor) ili na mjerenju vremena putovanja svjetlosne zrake (time-of-flight kamere). Infracrvena kamera pogodna je za primjenu u automatizaciji procesa poljoprivredne proizvodnje jer biljke koje sadrže klorofil, na slici snimljenoj infracrvenom kamerom imaju svjetlije nijanse od ostatka scene (slika 2.2b). Prema tome, ukoliko je slika snimljena infracrvenom kamerom, postoji mogućnost primjene algoritama računalnog vida bez potrebe za filtriranjem ili segmentacijom ulazne slike. Podatak o udaljenosti objekata na sceni, odnosno primjena nekog od 3D senzora za snimanje slike polja može biti korisna jer se na temelju podatka o dubini (Kise et al., 2005) može odrediti visina biljaka. Na taj način može se lakše razlikovati biljke od ostatka scene (zemlje, korova, kamenja i sl.) te ujedno povećati preciznost primijenjenih metoda računalnog vida. Primjer slike polja snimljene kamerom u boji prikazan je na slici 2.2a, dok je na slici 2.2b prikazan primjer

(a) (b)

Slika 2.2: Primjer slike polja. (a) Slika snimljena kamerom u boji, (b) Slika snimljena infracrvenom kamerom (izvor: http://www.chrisupdegrave.com/infrared/).

slike polja snimljene infracrvenom kamerom.

Prilikom automatizacije procesa poljoprivredne proizvodnje potrebno je odabrati najpogodniji način snimanja slike polja. U sklopu ovog istraživanja korištena je kamera u boji, a u nekom od budućih istraživanja potrebno je istražiti mogućnost primjene metoda i algoritama predloženih u ovoj disertaciji na slikama snimljenim na druge načine.

2.2 Filtriranje i segmentacija slike

Nakon snimanja slike polja, sljedeći korak u postupku automatizacije kretanja poljoprivrednog stroja (slika 2.1) je filtriranje i segmentacija slike.

Cilj ovog koraka je primjenom raznih filtara te metoda segmentacije kreirati binarnu sliku na kojoj su usjevi/plodovi prikazani bijelom bojom, a ostalo (korov, zemlja, kamenje i sl.) crnom. Ovaj korak zapravo predstavlja korak prepoznavanja vegetacije na ulaznoj slici polja. Jedna od najčešće korištenih metoda segmentacije u području automatizacije procesa poljoprivredne proizvodnje je Otsu metoda (Otsu, 1979). Više o Otsu metodi i ostalim često korištenim metodama segmentacije može se vidjeti u poglavlju 3.1.

Na slici 2.3b prikazan je primjer segmentirane slike dobivene primjenom Otsu metode na ulaznoj slici prikazanoj na slici 2.3a. Prag binarizacije za prikazani primjer iznosi 125. Budući da se Otsu metoda primjenjuje na slici sivih tonova, ulazna slika u boji je transformirana u sliku sivih tonova (poglavlje 3.1) i na tako dobivenoj slici je primijenjena Otsu metoda. Iz prikazanog primjera može se uočiti da na segmentiranoj slici postoji puno šuma, odnosno neki dijelovi ulazne slike, koji ne pripadaju usjevima, su na segmentiranoj slici označeni bijelom bojom. Zbog toga je u većini slučajeva ulaznu sliku potrebno

filtrirati prije primjene metoda segmentacije. Osim standardnih postupaka filtriranja slike (filtar usrednjavanja, median filtar, Gaussov filtar i sl.), u području automatizacije poljoprivredne proizvodnje često se koriste indeksi boje vegetacije. Indeksi boje vegetacije služe kako bi se naglasila boja usjeva/plodova (obično zelena) u odnosu na boje ostalih elemenata na slici (zemlja, kamenje, slama i sl.). Primjer slike dobivene računanjem Excess green (ExG) indeksa (Woebbecke et al., 1995) boje vegetacije za ulaznu sliku 2.3a prikazan je na slici 2.3c. Na slici 2.3c je vidljivo da veću vrijednost intenziteta imaju oni dijelovi slike koji pripadaju usjevima na slici 2.3a. Primjenom Otsu metode na slici 2.3c dobiva se segmentirana slika 2.3d. Na prikazanoj segmentiranoj slici je vidljivo da je uklonjena većina šuma koji je postojao na slici 2.3b. U ovom primjeru prag binarizacije određen Otsu metodom iznosi 37. Detaljniji opis ExG indeksa boje vegetacije te pregled ostalih često korištenih indeksa boje vegetacije u literaturi napravljen je u poglavlju 3.1.

Filtriranje slike, s ciljem boljeg prepoznavanja vegetacije, se, osim primjene prije segmentacije slike, može napraviti i nakon nje. Na segmentiranoj slici se, uz standardne pos-

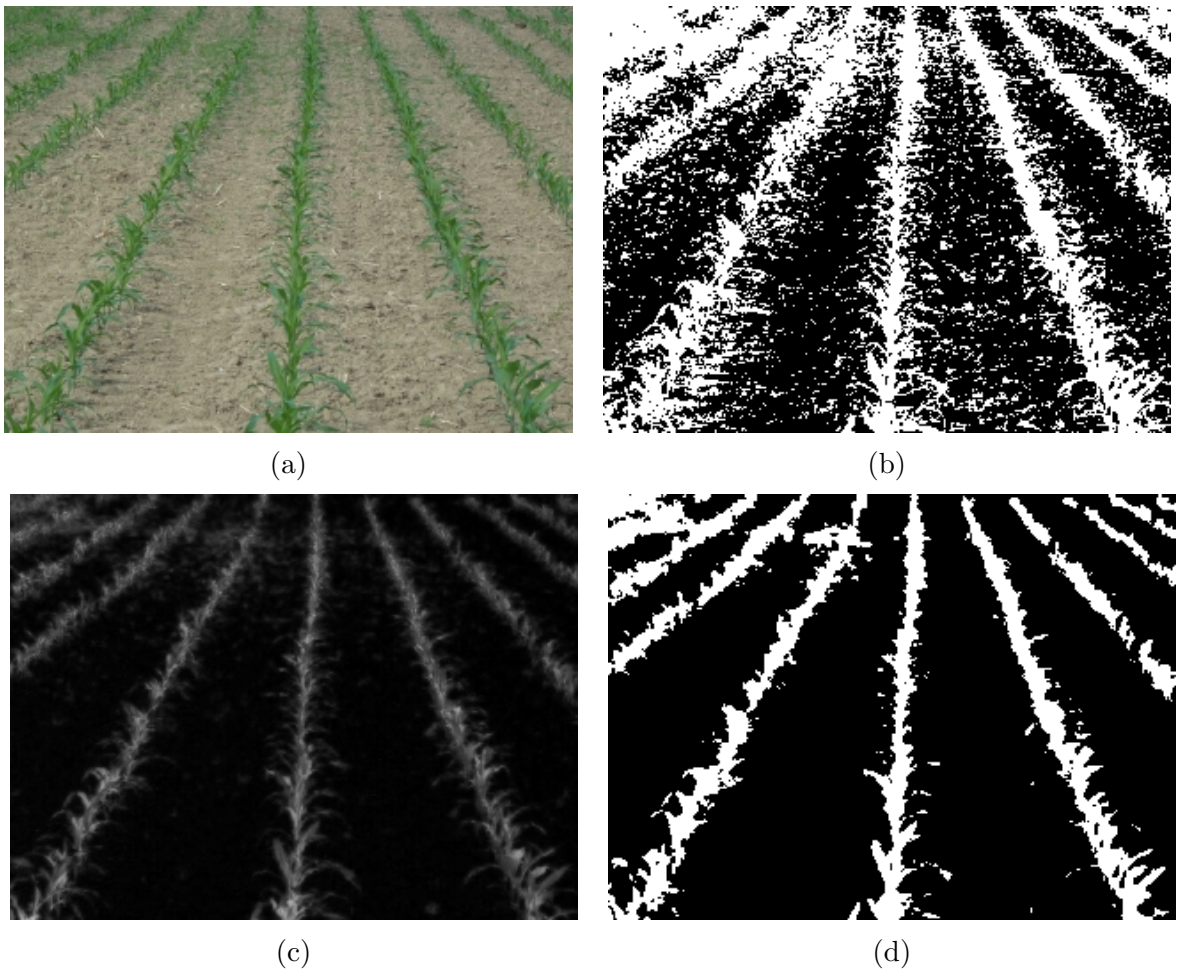

Slika 2.3: Primjer segmentacije slike polja. (a) Originalna slika, (b) Segmentirana slika dobivena primjenom Otsu metode, (c) Slika dobivena računanjem ExG indeksa boje vegetacije, (d) Segmentirana slika dobivena primjenom Otsu metode na slici c).

tupke filtriranja slike, često koriste i morfološke operacije primjenom kojih se poboljšava rezultat prepoznavanja vegetacije dobiven segmentacijom. U poglavlju 3.1 je napravljen pregled često korištenih morfoloških operacija u području primjene računalnog vida za automatizaciju procesa poljoprivredne proizvodnje.

2.3 Prepoznavanje redova usjeva

Prepoznavanje redova usjeva je korak u postupku automatizacije kretanja poljoprivrednog stroja koji slijedi nakon prepoznavanja vegetacije, odnosno nakon koraka filtriranja i segmentacije slike. Ovaj korak je važan jer se na temelju precizno prepoznatih redova usjeva može upravljati kretanjem poljoprivrednog stroja bez oštećivanja usjeva. Prepoznavanje redova usjeva predstavlja temelj za sljedeće korake koji rezultiraju automatizacijom određenog procesa poljoprivredne proizvodnje. Znanstvenici su za rješavanje problema prepoznavanja redova usjeva iskoristili razne pristupe, a pregled najznačajnijih metoda iz ovog područja napravljen je u poglavlju 3.2.

Rezultat postupka prepoznavanja redova usjeva je matematički model kojim se opisuju redovi usjeva prikazani na ulaznoj slici polja. Kao što se može vidjeti iz pregleda postojećih metoda za prepoznavanje redova usjeva na slikama (poglavlje 3.2), predložene metode imaju mogućnost detekcije samo ravnih redova usjeva koji se obično opisuju pravcima. Međutim, kao što je ranije rečeno, u istraživanju u sklopu ove doktorske disertacije razvijena je metoda koja ima mogućnost prepoznavanja zakrivljenih redova usjeva. Prema tome potrebno je, osim modela za opisivanje ravnih redova usjeva, definirati novi matematički model kojim se mogu opisati zakrivljeni redovi usjeva na slici polja.

U nastavku ovog poglavlja navedeni su uvijeti koji moraju biti zadovoljeni kako bi se paralelni jednako razmaknuti redovi usjeva projicirali na sliku kao jednako razmaknute točke te su definirana dva matematička modela: *i*) *model ravnih redova usjeva* i *ii*) *model zakrivljenih redova usjeva.*

2.3.1 Projekcija redova usjeva na sliku

Problem prepoznavanja redova usjeva se u ovom radu razmatra za one redove usjeva koji su posađeni/posijani paralelno i na konstantnom razmaku između dva susjedna reda usjeva. Na ovaj način se sadi/sije većina poljoprivrednih kultura zbog toga što su alati za obavljanje poljoprivrednih radnji (pravljenje redova, sijanje, sadnja) napravljeni da istovremeno obrade više redova i pri tome je razmak između dijelova alata konstantan. Korištenjem

takvog alata se u jednom prolasku poljem zasadi/posije 10-ak redova usjeva koji su paralelni i imaju konstantan razmak između dva susjedna reda. U svakom sljedećem prolasku čovjek koji upravlja traktorom prati redove usjeva iz prethodnog prolaska i na taj način su novi redovi usjeva zasađeni približno paralelno s redovima iz prethodnog prolaska.

Radi jednostavnosti, redovi usjeva se u ovom poglavlju promatraju kao krivulje koje leže na površini koja predstavlja polje. Većina metoda za prepoznavanje redova usjeva predloženih u literaturi koristi pretpostavku da su redovi usjeva paralelne ravne linije koje leže na ravnoj površini (slika 2.4a). Projekcija takvih paralelnih ravnih linija na sliku je niz pravaca koji imaju zajedničko sjecište (slika 2.5).

Kako bi se potvrdila prethodna tvrdnja o projekciji paralelnih redova usjeva na sliku potrebno je definirati referentni koordinatni sustav kamere postavljene iznad polja. Neka je ishodište tog referentnog koordinatnog sustava postavljeno u optičkom centru kamere, z os neka je paralelna s optičkom osi kamere, a x i y osi neka su paralelne s horizontalnim i vertikalnim rubovima matričnog osjetnika kamere. Ovako definirani referentni koordinatni sustav i pripadajuća projekcijska ravnina prikazani su na slici 2.4a.

Uz pretpostavku da je projekcija točaka na sliku definirana tzv. pinhole modelom (Wöhler, 2009), točka s koordinatama (x, y, z) u referentnom koordinatnom sustavu kamere se pojicira u točku (u, v) na slici. Pri tome su koordinate točke (u, v) definirane izrazom

$$u = f_x \frac{x}{z} + u_c, \tag{2.1}$$

$$v = f_y \frac{y}{z} + v_c, \tag{2.2}$$

gdje su f_x, f_y, u_c i v_c intrinsični parametri kamere (Wöhler, 2009). U nastavku se promatra niz jednako razmaknutih točaka koje leže na pravcu paralelnom s x osi referentnog

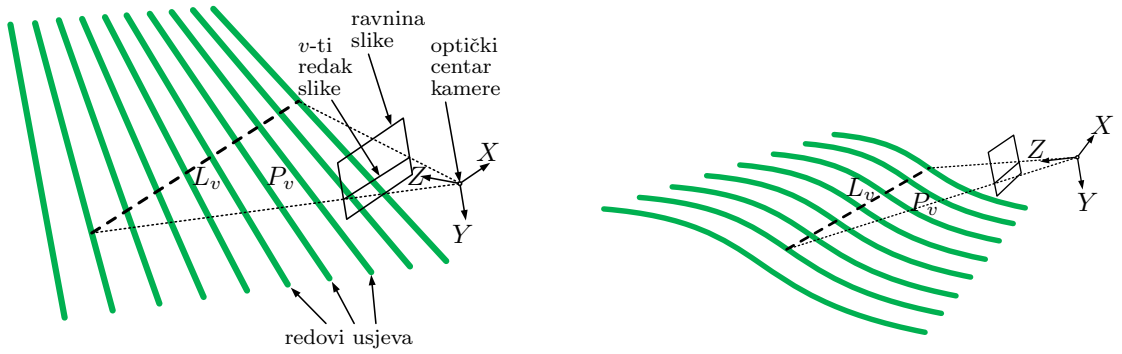

(a) (b)

Slika 2.4: Model polja. (a) Ravno polje, (b) Zakrivljeno polje.

koordinatnog sustava kamere. Prema slici 2.4a, sve točke na spomenutom pravcu imaju jednaku y i jednaku z koordinatu te se prema (2.2) projiciraju na isti redak slike. Nadalje, budući da su točke na pravcu jednako razmaknute i da imaju jednaku z koordinatu, njihove projekcije na sliku će prema (2.1) biti također jednako razmaknute. Iz navedenog primjera može se zaključiti da će se točke koje predstavljaju redove usjeva projicirati na sliku kao jednako razmaknute točke u v-tom retku slike, ukoliko je presjek ravnine P_v i redova usjeva niz jednako razmaknutih točaka koje leže na pravcu L_v paralelnom s x osi referentnog koordinatnog sustava kamere. Pri tome ravnina P_v predstavlja ravninu koja prolazi optičkim centrom kamere i v-tim retkom slike. Stoga, ako je kamera pozicionirana tako da je x os referentnog koordinatnog sustava kamere paralelna s poljem, jednako razmaknuti redovi usjeva projiciraju se u jednako razmaknute točke na slici (slika 2.5). Važno je uočiti da se objašnjeni uvjet projekcije jednako razmaknutih redova usjeva u jednako razmaknute točke na slici može primijeniti i na zakrivljeno polje prikazano na slici 2.4b. Pri tome moraju biti zadovoljeni sljedeći uvjeti: *i*) redovi usjeva su predstavljeni paralelnim jednako razmaknutim krivuljama, i *ii*) presjek ravnine P_v i polja (za određeni interval radova slike) predstavlja linije paralelne s x osi referentnog koordinatnog sustava kamere (slika 2.4b). Čak i ako ovi uvjeti nisu idealno zadovoljeni, paralelni jednako razmaknuti redovi usjeva projicirat će se u približno jednako razmaknute točke na slici, pogodne za prepoznavanje redova usjeva, što je i pokazano u poglavlju 7.

2.3.2 Model ravnih redova usjeva

Prema spoznajama stečenim kroz proučavanje literature iz područja prepoznavanja redova usjeva, dostupne metode imaju mogućnost prepoznavanja samo ravnih redova usjeva. Za opisivanje prepoznatih ravnih redova usjeva znanstvenici obično koriste pravce. Ravni red usjeva može se matematički opisati jednadžbom pravca

$$Ax + By - C = 0, \quad A^2 + B^2 = 1, \quad C \geq 0, \tag{2.3}$$

koji predstavlja centralnu liniju odgovarajućeg reda usjeva. Prema tome, model ravnih redova usjeva predstavlja skup k jednadžbi pravaca opisanih izrazom (2.3), pri čemu k predstavlja broj redova usjeva koje je potrebno prepoznati na slici polja.

Primjer ravnih redova usjeva koje je potrebno prepoznati i modela kojim se mogu opisati ovakvi redovi usjeva prikazani su na slici 2.5. Redovi usjeva su na slici 2.5 prikazani zelenom bojom, a pravci modela ravnih redova usjeva koji predstavljaju centralne linije svakog reda usjeva prikazani su sivom bojom i označeni s $p_1 \ldots p_6$. Iz slike 2.5 se može

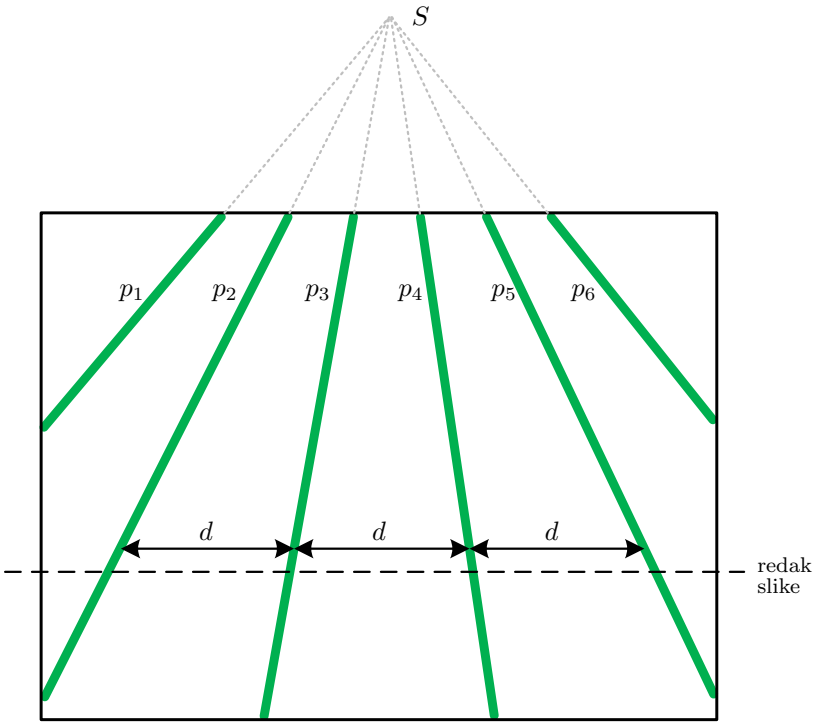

Slika 2.5: Model ravnih redova usjeva.

vidjeti da je udaljenost dvaju susjednih redova usjeva/pravaca konstantna za određeni redak slike. Također, vidljivo je da pravci $p_1 \dots p_6$ imaju zajedničko sjecište, označeno sa S. Ovakav model redova usjeva se u nastavku naziva SCR model što je skraćenica od engleskog izraza *Straight Crop Rows*.

2.3.3 Model zakrivljenih redova usjeva

Budući da je jedan od temeljnih ciljeva istraživanja provedenog u sklopu izrade ove doktorske disertacije razviti metodu koja ima mogućnost prepoznavanja zakrivljenih redova usjeva, potrebno je definirati matematički model za opisivanje zakrivljenih redova usjeva.

Analogno SCR modelu, predloženom u prethodnom poglavlju, zakrivljeni red usjeva se može matematički opisati jednadžbom polinoma n-tog stupnja. Pri tome minimalni stupanj polinoma nije jednostavno unaprijed odrediti jer ovisi o načinu zakrivljenosti reda usjeva. Zbog toga se u ovom radu predlaže novi model za opisivanje zakrivljenih redova usjeva zasnovan na opisivanju svakog retka slike polja jednim parom parametara c i d. Parametar c u predloženom modelu označava udaljenost najbližeg reda usjeva do centra slike, a parametar d označava međusobnu udaljenost dva susjedna reda usjeva. Stoga se

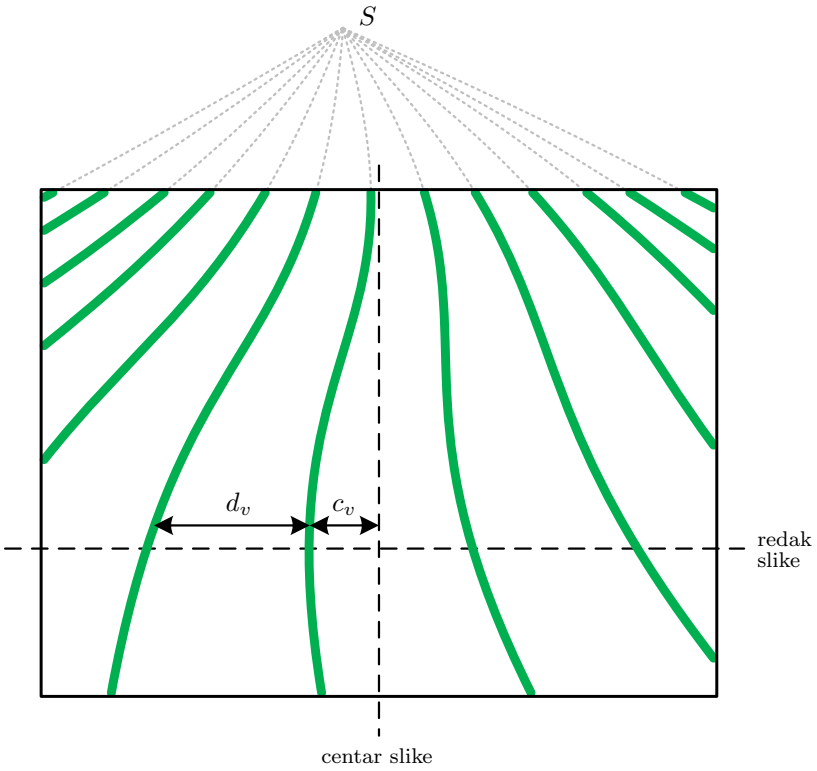

Slika 2.6: Model zakrivljenih redova usjeva.

matematički model zakrivljenih redova može opisati izrazom

$$CCR = \{\mathbf{x}_v = (c_v, d_v), \quad v = 1, \ldots, h\}, \tag{2.4}$$

gdje je h visina ulazne slike polja, a $\mathbf{x}_v$ označava par parametara c i d za v-ti redak slike. Iz izraza (2.4) može se zaključiti da predloženi model predstavlja niz parova parametara c i d za svaki redak ulazne slike polja. Ovako definirani model zakrivljenih redova usjeva se u nastavku naziva CCR model, što je skraćenica od engleskog izraza *Curved Crop Rows*. Važno je naglasiti da je predloženi CCR model redova usjeva primjenjiv i za opisivanje ravnih redova usjeva, što je objašnjeno u poglavlju 5 te pokazano u eksperimentalnoj analizi provedenoj u poglavlju 7.3.

Na slici 2.6 prikazan je primjer zakrivljenih redova usjeva te parametri c_v i d_v v-tog retka slike u predloženom CCR modelu. Redovi usjeva su na slici 2.6 prikazani zelenom bojom, a sivom bojom je prikazana projekcija nastavka redova usjeva te je pri tome vidljivo da svi redovi imaju zajedničko sjecište označeno sa S.

3

Dosadašnje spoznaje o problemu prepoznavanja redova usjeva

Problem prepoznavanja redova usjeva predstavlja temu brojnih znanstvenih radova u posljednjih 30-ak godina. Važnost ovog koraka, u procesu automatizacije kretanja poljoprivrednog stroja, naglašena je u prethodnim poglavljima, a u ovom poglavlju je napravljen pregled postojećih metoda za prepoznavanje redova usjeva.

Na slici 2.1 je vidljivo da se proces automatizacije kretanja poljoprivrednog stroja, u procesu automatizacije procesa poljoprivredne proizvodnje, sastoji od šest koraka koji se izvode ciklički. Prepoznavanje redova usjeva je, u spomenutom cikličkom procesu, treći korak, a prije njega se obavljaju korak snimanja slike polja te korak filtriranja i segmentacije slike.

Najčešći načini snimanja slike polja, za primjenu u automatizaciji procesa poljoprivredne proizvodnje, navedeni su u poglavlju 2.1. U ovom poglavlju nije napravljen poseban pregled radova prema načinu snimanja slike polja, nego je prilikom pregleda metoda iz područja prepoznavanja redova usjeva navedeno koji način snimanja slike je korišten.

Nakon snimanja slike polja, prema slici 2.1, slijedi korak filtriranja i segmentacije slike. Svrha ovog koraka je, kao što je navedeno u poglavlju 2.2, prepoznavanje vegetacije na slici redova usjeva. U sklopu ovog poglavlja napravljen je pregled najčešće korištenih pristupa u postupku prepoznavanja vegetacije.

Osim pregleda najčešće korištenih pristupa rješavanju problema prepoznavanja vegetacije, u ovom poglavlju je napravljen i pregled najznačajnijih metoda za prepoznavanje

redova usjeva. Prema dosadašnjim spoznajama, većina metoda predloženih u literaturi, ima mogućnost prepoznavanja samo ravnih redova usjeva. Zbog toga je pregled postojećih metoda napravljen samo za metode prepoznavanja ravnih redova usjeva. Pregled je podijeljen prema načinu na koji su autori riješili problem prepoznavanja redova usjeva, a način podjele je naveden u nastavku poglavlja.

3.1 Prepoznavanje vegetacije

Prepoznavanje vegetacije na slikama redova usjeva jedan je od koraka u procesu automatizacije procesa poljoprivredne proizvodnje. Ovaj korak slijedi nakon snimanja slike redova usjeva i predstavlja korak predobrade snimljene slike prije primjene metoda za prepoznavanje redova usjeva.

Cilj ovog koraka je naglasiti usjeve na slici redova usjeva. Kao rezultat ovog koraka, obično se dobiva binarna slika na kojoj su usjevi označeni bijelom, a sve ostalo (korov, zemlja i sl.) crnom bojom. Za dobivanje binarne slike koriste se metode segmentacije koje računaju prag binarizacije (engl. *threshold*), na temelju kojeg se određuje koji pikseli na slici pripadaju usjevima, a koji ne. Primjeri segmentirane binarne slike prikazani su na slici 2.3b i 2.3d.

Pri rješavanju problema prepoznavanja vegetacije, metode segmentacije se obično primjenjuju na slici sivih tonova (engl. *grayscale image*), koja se dobiva postupkom usrednjavanja vrijednosti intenziteta pojedine komponente boje piksela na RGB slici. Osim usrednjavanja, slika sivih tonova može se dobiti i primjenom drugačijih filtara na ulaznoj slici u boji. U području automatizacije procesa poljoprivredne proizvodnje, primjenom računalnog vida, često se, za dobivanje slike sivih tonova, koriste indeksi boje vegetacije. Korištenjem indeksa boje vegetacije na slici sivih tonova se naglašava određena boja piksela na ulaznoj slici u boji. Boja koja se naglašava je, u pravilu, boja usjeva koji se očekuju na slici. Primjeri slika vegetacije prikazani su na slici 2.3c u poglavlju 2.2 te na slikama 5.2a i 5.2b u poglavlju 5.1.

S ciljem poboljšavanja rezultata prepoznavanja vegetacije na slikama često se, osim indeksa boje vegetacije, primjenjuju i razni filtri kao što su filtar usrednjavanja, medijan filtar ili Gaussov filtar. Slika se može filtrirati prije primjene metoda segmentacije ili nakon nje. Nakon primjene metoda segmentacije, na dobivenoj binarnoj slici se, osim standardnih postupaka filtriranja, često koriste morfološke operacije. Primjenom morfoloških operacija, u određenim slučajevima se poboljšava rezultat prepoznavanja vegetacije dobiven

primjenom metoda segmentacije.

U ovom radu je za prepoznavanje vegetacije korišten samo ExG indeks boje vegetacije. Metoda predložena u poglavlju 5 se može primijeniti na slici sivih tonova pa je zbog toga, u postupku predobrade slike, dovoljno samo primijeniti ExG indeks boje vegetacije. Ovime je složenost predobrade značajno manja od složenosti predobrade za metode koje zahtijevaju binarnu sliku, što za sobom povlači primjenu određene metode za segmentaciju slike. Metoda predložena u poglavlju 4 zahtjeva binarnu sliku, ali je ispitana na umjetno generiranim skupovima podataka, pa stoga u ovom radu za njeno ispitivanje nije bilo potrebno primjenjivati metode za segmentaciju slike. Primjena navedene metode na stvarnim slikama izlazi iz okvira ove disertacije te predstavlja temu za buduće istraživanje.

U nastavku poglavlja napravljen je pregled najčešće korištenih indeksa boje vegetacije za kreiranje sive slike na kojoj je naglašena boja usjeva. Nakon spomenutog pregleda prikazane su često korištene metode za binarizaciju slike sivih tonova, te su objašnjene osnovne morfološke operacije.

3.1.1 Indeksi boje vegetacije

Indeksi boje vegetacije (Woebbecke et al., 1995; Ribeiro et al., 2005; Meyer i Neto, 2008; Guijarro et al., 2011; Xiang i Tian, 2011) se koriste u području automatizacije procesa poljoprivredne proizvodnje za transformaciju ulazne slike u boji u sliku sivih tonova. Na tako kreiranoj slici sivih tonova naglašeni su usjevi u odnosu na ostale elemente prikazane na slici, kao što su korov, zemlja ili kamenje. Indeksi boje vegetacije zapravo naglašavaju određenu boju na ulaznoj slici, a budući da se za određenu primjenu odabire indeks boje vegetacije koji naglašava boju očekivanih usjeva, ovim postupkom se postiže željeni efekt naglašavanja usjeva na slici.

Indeksi boje vegetacije se računaju korištenjem normiranih vrijednosti R_s, G_s i B_s kanala RGB slike. Oznake R_s, G_s i B_s označavaju crveni (engl. *red*), zeleni (engl. *green*) i plavi (engl. *blue*) kanal slike u boji. Normirane vrijednosti piksela $(\hat{r}, \hat{g}, \hat{b})$ se prema (Meyer i Neto, 2008; Gée et al., 2008) računaju na sljedeći način

$$\begin{aligned}
\hat{r}(u,v) &= \frac{\hat{R}(u,v)}{\hat{R}(u,v) + \hat{G}(u,v) + \hat{B}(u,v)}, \\
\hat{g}(u,v) &= \frac{\hat{G}(u,v)}{\hat{R}(u,v) + \hat{G}(u,v) + \hat{B}(u,v)}, \\
\hat{b}(u,v) &= \frac{\hat{B}(u,v)}{\hat{R}(u,v) + \hat{G}(u,v) + \hat{B}(u,v)}.
\end{aligned} \tag{3.1}$$

U izrazu (3.1) $\hat{R}(u,v)$, $\hat{G}(u,v)$ i $\hat{B}(u,v)$ predstavljaju normirane vrijednosti piksela (u,v) za pojedini kanal RGB slike, a određuju se prema

$$\begin{aligned} \hat{R}(u,v) &= \frac{R_s(u,v)}{R_m}, \\ \hat{G}(u,v) &= \frac{G_s(u,v)}{G_m}, \\ \hat{B}(u,v) &= \frac{B_s(u,v)}{B_m}, \end{aligned} \tag{3.2}$$

pri čemu je $R_m = G_m = B_m = 255$ za 24-bitnu RGB sliku.

U svrhu prepoznavanja redova usjeva primjenom računalnog vida, u literaturi se najčešće koriste sljedeći indeksi boje vegetacije:

- *Excess Green* (Woebbecke et al., 1995)

$$\mathrm{ExG} = 2\hat{g} - \hat{r} - \hat{b}, \tag{3.3}$$

- *Excess Red* (Meyer i Neto, 2008)

$$\mathrm{ExR} = 1.4\hat{r} - \hat{g}, \tag{3.4}$$

- *Excess Blue* (Guijarro et al., 2011)

$$\mathrm{ExR} = 1.4\hat{b} - \hat{g}, \tag{3.5}$$

- *Excess Green minus Excess Red* (Neto, 2004)

$$\mathrm{ExGR} = \mathrm{ExG} - \mathrm{ExR}, \tag{3.6}$$

- *Vegetative* (Hague et al., 2006)

$$\mathrm{VEG} = \frac{\hat{g}}{\hat{r}^{a_v}\hat{b}^{1-a_v}}, \tag{3.7}$$

  gdje je $a_v = 0.667$,

- *Color Index of Vegetation Extraction* (Kataoka et al., 2003)

$$\mathrm{CIVE} = 0.441\hat{r} - 0.811\hat{g} + 0.385\hat{b} + 18.78745, \tag{3.8}$$

- *Combined index* (Guijarro et al., 2011)

$$\text{COM} = w_{ExG}\text{ExG} + w_{ExGR}\text{ExGR} + w_{CIVE}\text{CIVE} + w_{VEG}\text{VEG}, \tag{3.9}$$

  gdje je $w_{ExG} = 0.25$, $w_{ExGR} = 0.30$, $w_{CIVE} = 0.33$ i $w_{VEG} = 0.12$.

- *Normalized Difference Index* (Pérez et al., 2000)

$$\text{NDI} = \frac{\hat{g} - \hat{r}}{\hat{g} + \hat{r}}. \tag{3.10}$$

Kao što je rečeno ranije, indeksi boje vegetacije služe kako bi se dobila slika sivih tonova na kojoj su naglašeni usjevi u odnosu na ostale elemente prikazane na slici. Stoga, indeksi boje vegetacije obično naglašavaju očekivanu boju usjeva. Međutim, na popisu često korištenih indeksa boje vegetacije nalaze se ExR i ExB indeksi koji rade suprotno od navedenog. Korištenjem ova dva indeksa boje vegetacije naglašava se crvena, odnosno plava boja na slici. Budući da su za zemlju i nebo dominantne komponente boje upravo crvena i plava, korištenjem navedena dva indeksa boje vegetacije mogu se sa slike ukloniti dijelovi koji pripadaju zemlji ili nebu, čime se postiže željeni efekt naglašavanja usjeva.

3.1.2 Metode segmentacije slike

Metode segmentacije se često koriste za rješavanje problema prepoznavanja vegetacije u području prepoznavanja redova usjeva na slici u svrhu automatizacije procesa poljoprivredne proizvodnje. Rezultat primjene metoda segmentacije je binarna slika na kojoj su usjevi prikazani bijelom, a korov, zemlja, nebo, kamenje i ostali elementi na slici, crnom bojom. Primjeri binarne slike prikazani su na slici 2.3b i 2.3d.

Metode segmentacije obično se primjenjuju na slici sivih tonova koja se najčešće dobiva usrednjavanjem vrijednosti intenziteta piksela za pojedinu komponentu boje. Kreiranje slike sivih tonova, na ovaj način, definirano je izrazom

$$I_s(u, v) = \frac{R_s(u, v) + G_s(u, v) + B_s(u, v)}{3}, \tag{3.11}$$

gdje u i v označavaju koordinate stupca, odnosno retka slike.

Najčešće korištena metoda segmentacije u području prepoznavanja redova usjeva na slici je Otsu metoda (Otsu, 1979) koja se primjenjuje na histogramu intenziteta sive slike. Metoda daje zadovoljavajuće rezultate segmentacije za slike s bimodalnim histogramom pri čemu omjer broja piksela objekta od interesa i broja piksela koji pripadaju ostatku slike ne prelazi omjer 1:100 (Kittler i Illingworth, 1986). Otsu metoda je neparametarska

metoda za globalnu binarizaciju koja određuje prag binarizacije na temelju maksimizacije međuklasne varijance ili minimizacije unutarklasne varijance. Međuklasna varijanca se definira funkcijom cilja

$$J_o(T_b) = \omega_0(T_b) \cdot \omega_1(T_b) \cdot \big[\mu_1(T_b) - \mu_0(T_b)\big]^2, \tag{3.12}$$

gdje su $\omega_0(T_b)$ i $\omega_1(T_b)$ vjerojatnosti pojavljivanja dviju klasa (objekata), a $\mu_0(T_b)$ i $\mu_1(T_b)$ srednje vrijednosti pojedine klase. Primjer binarne slike dobivene primjenom Otsu metode na slici sivih tonova, dobivenoj primjenom postupka usrednjavanja, prikazan je na slici 2.3b, dok slika 2.3d predstavlja primjer binarne slike dobivene primjenom Otsu metode na slici sivih tonova dobivenoj primjenom ExG indeksa boje vegetacije.

Druga metoda segmentacije, opisana u sklopu ovog poglavlja, je Minimum Error Thresholding (MET) metoda predložena u (Kittler i Illingworth, 1986). MET metoda se, kao i Otsu metoda, primjenjuje na histogramu intenziteta sive slike. Pretpostavka, primijenjena u MET metodi, je da histogram predstavlja kombinaciju dviju normalnih razdioba, pri čemu jedna normalna razdioba predstavlja piksele objekta, a druga piksele pozadine. Prag binarizacije se određuje na temelju minimizacije preklapanja Gaussovih funkcija kojima se opisuju dvije ranije spomenute normalne distribucije intenziteta piksela. Odgovarajuća vrijednost praga binarizacije određuje se minimizacijom funkcije cilja

$$\begin{aligned} J_{MET} = \; & 1 + 2\big[\omega_0(T_b) \cdot \log \sigma_0(T_b) + \omega_1(T_b) \cdot \log \sigma_1(T_b)\big] - \\ & -2\big[\omega_0(T_b) \cdot \log \omega_0(T_b) + \omega_1(T_b) \cdot \log \omega_1(T_b)\big], \end{aligned} \tag{3.13}$$

gdje su $\omega_0(T_b)$ i $\omega_1(T_b)$ vjerojatnosti pojavljivanja dviju klasa, a $\sigma_0(T_b)$ i $\sigma_1(T_b)$ standardne devijacije pojedine klase.

Minimum Cross-Entropy Threshold (MCET) metoda je još jedna metoda koja određuje prag binarizacije na temelju histograma intenziteta sive slike. Metoda se zasniva na računanju entropije (engl. *cross-entropy*) između originalne sive slike i sive slike binarizirane na dvije razine sive boje. Siva slika binarizirana na dvije razine sive boje sastoji se od dviju razina sive boje koje su određene računanjem srednje vrijednosti intenziteta piksela iznad i ispod praga binarizacije. Vrijednost praga binarizacije određuje se minimizacijom funkcije entropije definirane izrazom

$$\begin{aligned} J_{MCET} = \; & \sum_{i=0}^{T_b} h(i) \cdot \mu_0(T_b) \cdot \log \frac{\mu_0(T_b)}{i} + \\ & + \sum_{i=T_b+1}^{255} h(i) \cdot \mu_1(T_b) \cdot \log \frac{\mu_1(T_b)}{i}, \end{aligned} \tag{3.14}$$

gdje $h(i)$ označava vrijednost histograma i-tog intenziteta, a $\mu_0(T_b)$ i $\mu_1(T_b)$ srednju vrijednost piksela prvog i drugog objekta.

U sklopu ovog istraživanja napravljena je usporedba navedenih metoda segmentacije, a rezultati usporedbe su pokazali da se najbolji rezultati prepoznavanja vegetacije dobivaju primjenom Otsu metode. Rezultati usporedbe su objavljeni u radu (Vidović et al., 2014), a uz navedene tri metode segmentacije testirana je i dvostruka Otsu metoda segmentacije objašnjena u poglavlju 7.1.2.

Osim navedenih pristupa rješavanju problema segmentacije slike, postoje i brojni drugi jednostavniji i složeniji pristupi. Od složenijih pristupa korištene su metode čvrstog grupiranja podataka (Bossu et al., 2009), neizrazitog grupiranja podataka (Romeo et al., 2012) te umjetne neuronske mreže (Leemans i Destain, 2006).

3.1.3 Morfološke operacije

Pojam morfologija, u području obrade slike, koristi se u kontekstu pojma matematičke morfologije (engl. *mathematical morphology*) koja predstavlja alat za pronalaženje dijelova slike koji su korisni za opisivanje oblika na slici kao što su granice (engl. *boundaries*), kosturi (engl. *skeletons*) ili konveksne ljuske (engl. *convex hull*) (Gonzalez i Woods, 2006). Nadalje, morfološke operacije predstavljaju primjenu morfologije za predobradu ili postobradu slike s ciljem filtriranja, stanjivanja (engl. *thinning*) ili pročišćavanja (engl. *pruning*). U području obrade slike s ciljem prepoznavanja redova usjeva, morfološke operacije se koriste u predobradi i postobradi slike za uklanjanje dijelova binarne slike koji ne pripadaju usjevima.

Morfološke operacije definiraju se korištenjem teorije skupova pri čemu skup označava niz koordinata (u, v) svih bijelih piksela na binarnoj slici. Za definiranje morfoloških operacija važno je razumijevanje osnovnih operacija refleksije (engl. *reflection*) i translacije (engl. *translation*) koje su opisane u nastavku.

Refleksija skupa K definirana je izrazom

$$\hat{K} = \{(-u, -v), \quad \text{za sve } (u, v) \in K\}. \tag{3.15}$$

Iz izraza (3.15) se može zaključiti da operacija refleksije jedan piksel iz skupa K na lokaciji (u, v) reflektira u skup $\hat{K}$ kao piksel s lokacijom $(-u, -v)$. Refleksija cijelog skupa K se radi tako da se napravi refleksija svih elemenata skupa. Primjer refleksije skupa K u skup $\hat{K}$ prikazan je na slici 3.1a.

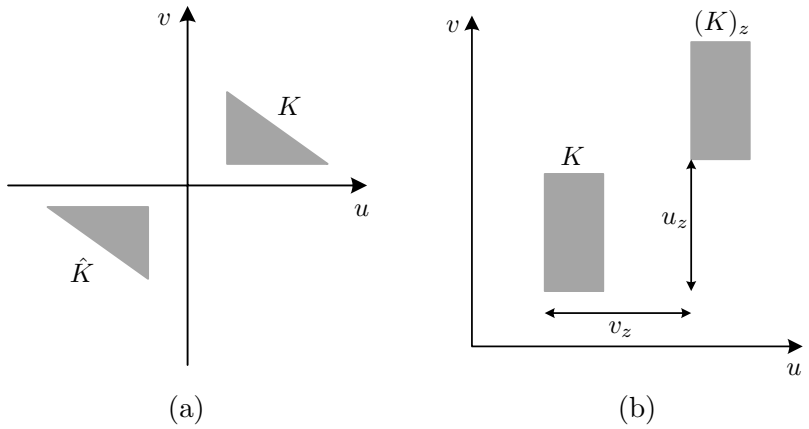

Slika 3.1: (a) Primjer refleksije piksela skupa K u skup $\hat{K}$, (b) Primjer translacije skupa K u skup $(K)_z$.

Translacija skupa K za vrijednost $z = (u_z, v_z)$ definirana je izrazom

$$(K)_z = \{(u + u_z, v + v_z), \quad \text{za sve } (u, v) \in K\} \tag{3.16}$$

Iz izraza (3.16) je vidljivo da translacija jedan piksel skupa K na lokaciji (u, v) translatira u piksel na lokaciji $(u + u_z, v + v_z)$. Cijeli skup K se translatira za vrijednost $z = (u_z, v_z)$ tako da se translatiraju svi elementi skupa. Primjer translacije skupa K u skup $(K)_z$ prikazan je na slici 3.1b.

Korištenjem strukturnog elementa (engl. *structuring element*) i operacija refleksije i translacije definiraju se morfološke operacije. Strukturni element je mali set ili dio slike koji se koristi za obavljanje morfološke operacije na slici od interesa. Primjeri strukturnih elementa prikazani su na slici 3.2, gdje crna točka označava ishodište za primjenu operacija refleksije i translacije. Ishodište kod simetričnih strukturnih elemenata je obično postavljeno u centar simetrije. Najčešće korištene morfološke operacije su erozija (engl. *erosion*), dilatacija (engl. *dilation*), otvaranje (engl. *opening*) i zatvaranje (engl. *closing*) i svaka od njih je ukratko opisana u nastavku.

Erozija skupa K strukturnim elementom K_{se} označava se $K \ominus K_{se}$, a definirana je izrazom

$$K \ominus K_{se} = \{z | (K_{se})_z \subset K\}. \tag{3.17}$$

Iz izraza (3.17) je vidljivo da erozija skupa K strukturnim elementom K_{se} predstavlja

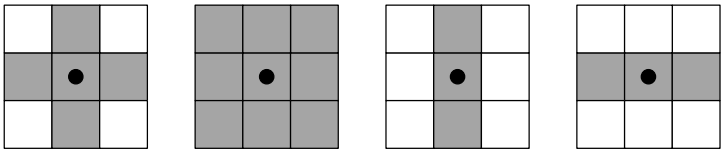

Slika 3.2: Primjeri strukturnih elemenata za morfološke operacije.

skup piksela z takvih da strukturni element K_{se}, translatiran za z, predstavlja podskup skupa K. Prema tome, može se zaključiti da se primjenom erozije na slici filtriraju oni dijelovi koji su manji od strukturnog elementa.

Dilatacija skupa K strukturnim elementom K_{se} označava se $K \oplus K_{se}$, a definirana je izrazom

$$K \oplus K_{se} = \{z|(\hat{K}_{se})_z \cap K \neq \emptyset\}. \tag{3.18}$$

Iz izraza (3.18) se može zaključiti da dilatacija skupa K strukturnim elementom K_{se} predstavlja skup piksela z takvih da strukturni element K_{se}, translatiran za z i reflektiran oko ishodišta, ima barem jedan zajednički piksel sa skupom K. Prema tome, jedna od primjena dilatacije je popunjavanje praznina unutar određenog objekta.

Morfološke operacije erozije i dilatacije su dualne te vrijede izrazi

$$(K \ominus K_{se})^c = K^c \oplus \hat{K}_{se}, \tag{3.19}$$

$$(K \oplus K_{se})^c = K^c \ominus \hat{K}_{se}. \tag{3.20}$$

Primjeri primjene operacije erozije i dilatacije na slici 3.3a prikazani su na slikama 3.3c i 3.3d. U prikazanom primjeru korišten je strukturni element sa slike 3.3b.

Operacija otvaranja primijenjena na skupu K sa strukturnim elementom K_{se} označava se $K \circ K_{se}$, a definirana je izrazom

$$K \circ K_{se} = (K \ominus K_{se}) \oplus K_{se}. \tag{3.21}$$

Iz izraza (3.21) je vidljivo da operacija otvaranja predstavlja primjenu erozije sa strukturnim elementom K_{se} nakon čega se na dobivenom skupu primjenjuje dilatacija. Primjena operacije otvaranja na slici rezultira proširivanjem malih otvora i uklanjanjem slabo povezanih piksela.

Operacija zatvaranja primijenjena na skupu K sa strukturnim elementom K_{se} označava

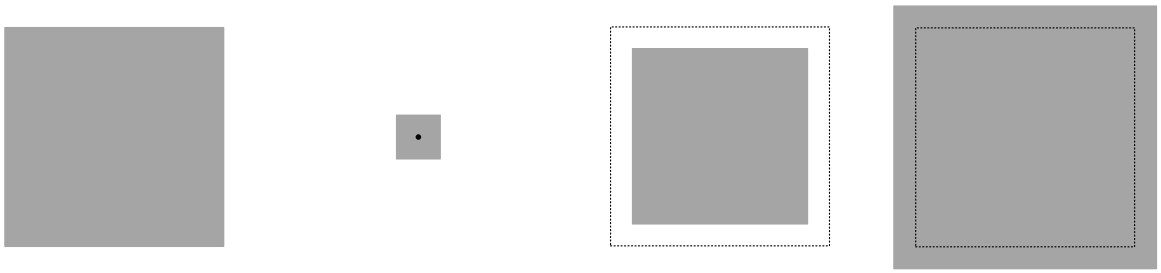

(a) (b) (c) (d)

Slika 3.3: Primjer morfoloških operacija erozije i dilatacije. (a) Ulazna slika, (b) Strukturni element, (c) Rezultat primjene morfološke operacije erozije, (d) Rezultat primjene morfološke operacije dilatacije.

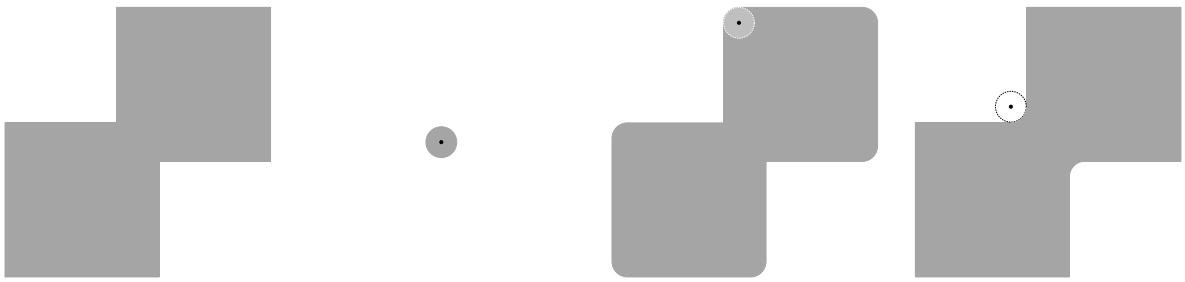

(a) (b) (c) (d)

Slika 3.4: Primjer morfoloških operacija otvaranja i zatvaranja. (a) Ulazna slika, (b) Strukturni element, (c) Rezultat primjene morfološke operacije otvaranja, (d) Rezultat primjene morfološke operacije zatvaranja.

se $K \bullet K_{se}$, a definirana je izrazom

$$K \bullet K_{se} = (K \oplus K_{se}) \ominus K_{se}. \tag{3.22}$$

Iz izraza (3.22) je vidljivo da je operacija zatvaranja slična operaciji otvaranja, samo je redoslijed primjene erozije i dilatacije obrnut. Operacija zatvaranja predstavlja primjenu dilatacije sa strukturnim elementom K_{se} nakon čega se na dobivenom skupu primjenjuje erozija. Primjenom operacije zatvaranja na slici popunjavanju se mali otvori i izolirani pikseli pozadine.

Kao što su erozija i dilatacija dualne operacije s obzirom na komplement i preslikavanje, isto vrijedi i za operacije otvaranja i zatvaranja. Navedeno se može zapisati izrazima

$$(K \bullet K_{se})^c = K^c \circ \hat{K}_{se}, \tag{3.23}$$

$$(K \circ K_{se})^c = K^c \bullet \hat{K}_{se}. \tag{3.24}$$

Primjeri djelovanja operacije otvaranja i zatvaranja na slici 3.4a sa strukturnim elementom u obliku kruga prikazanog na slici 3.4b, prikazani su na slikama 3.4c i 3.4d.

3.2 Prepoznavanje redova usjeva

Točno prepoznavanje redova usjeva na slici jedan je od glavnih preduvjeta za automatizaciju bilo kojeg procesa poljoprivredne proizvodnje. U literaturi postoje brojni različiti pristupi rješavanju spomenutog problema, a u nastavku je napravljen pregled najznačajnijih radova iz tog područja. Pregled radova je podijeljen u sljedećih šest grupa: metode zasnovane na Houghovoj transformaciji, metode zasnovane na linearnoj regresiji, metode zasnovane na akumulaciji zelenih piksela, metode zasnovane na filtriranju slike, metode zasnovane na stereoviziji i ostale pristupe.

3.2.1 Metode zasnovane na Houghovoj transformaciji

U (Marchant, 1996) predložena je metoda za prepoznavanje redova usjeva temeljena na Houghovoj transformaciji uz korištenje informacije o broju redova i njihovoj strukturi. Korištenjem spomenutog predznanja postiže se robusnost s obzirom na prisutnost korova i izostanak plodova u redovima usjeva. Glavna ideja metode je praćenje maksimuma u Houghovoj ravnini, umjesto traženja istih. Navedeno se postiže korištenjem aproksimacije koja se dobiva estimacijom na temelju vrijednosti prikupljenih od različitih senzora poljoprivrednog stroja. Predložena metoda ispitana je na redovima cvjetače, šećerne repe i široko razmaknutim dvostrukim redovima pšenice. Usporedbom s čovjekovim prepoznavanjem redova usjeva pokazano je da su pogreške metode oko 18 mm lateralnog odstupanja i 1° kutnog odstupanja. Glavni nedostatak predložene metode je potrebno poznavanje broja redova usjeva. Prepoznavanje redova zasijanja i redova cikorije korištenjem prilagođene Houghove transformacije opisano je u (Leemans i Destain, 2006). U koraku predobrade slike, redovi zasijanja su prepoznati korištenjem Gaussovog filtra i oduzimanjem slike pozadine, dok se za prepoznavanje plodova cikorije koristi umjetna neuronska mreža. Nakon predobrade, prilagođena Houghova transformacija se koristi za prepoznavanje linija. Prilagodba se sastoji od toga da se očekivana pozicija redova koristi kao ishodište Houghove ravnine. Ovime se postiže da sve linije na originalnoj slici glasaju za gotovo istu točku u Houghovoj ravnini te se na taj način olakšava problem pronalaska maksimuma u Houghovoj ravnini. Nedostatak predložene metode je što očekivana pozicija redova mora biti poznata unaprijed. U eksperimentalnoj analizi pokazano je da odstupanje prepoznatih redova usjeva od očekivanih iznosi nekoliko centimetara. Houghova transformacija za prepoznavanje redova usjeva primijenjena je i u (Bakker et al., 2008). Autori su u ovom radu testirali različite transformacije ulazne slike u sivu sliku na kojoj je naglašeno zelenilo usjeva. Nakon transformacije ulazne slike i segmentacije, slika je podijeljena na tri vertikalna segmenta na temelju poznavanja geometrije redova usjeva. Ovaj korak predstavlja ograničenje predložene metode pri primjeni na drugim redovima usjeva, osim onih koji su ispitani u radu. Vrijednosti piksela vertikalnih segmenata se zbrajaju i na novo dobivenom segmentu primjenjuje se Houghova transformacija. Budući da sumirani segment slike sadrži samo jedan red usjeva, u Houghovoj ravnini je potrebno pronaći samo jedan maksimum, a na temelju poznate geometrije redova usjeva moguće je rekonstruirati sva tri reda. Metoda je ispitana na redovima šećerne repe, a median odstupanja prepoznatih redova usjeva od očekivanih ima vrijednost između 5 i 198 mm.

Autori u radu navode da linearne strukture na površini zemlje mogu imati utjecaj na točnost prepoznavanja redova usjeva u stvarnoj primjeni. Nadalje, metoda može prepoznati samo tri reda usjeva i kamera mora biti postavljena na način da snima samo tri reda usjeva. U (Ji i Qi, 2011) predložena je modifikacija Randomizirane Houghove transformacije (Xu et al., 1990) za prepoznavanje centralne linije jednog reda usjeva. Ulazna slika je segmentirana i na segmentiranoj slici su redovi označeni provjerom povezanosti piksela sa susjednim pikselima. Filtriranjem su uklonjeni pogrešno označeni redovi nakon čega su izračunate centralne koordinate. Nakon toga, primijenjena je Randomizirana Hougova transformacija, uz korištenje informacije o gradijentu redova, čime je postignuto kraće vrijeme izvođenja i veća točnost prepoznavanja u odnosu na Standardnu Houghovu transformaciju. Houghova transformacija ili njena prilagodba korištene su za prepoznavanje redova usjeva u brojnim drugim radovima (Marchant i Brivot, 1995; Rovira-Más et al., 2005; Åstrand i Baerveldt, 2005; Ericson i Åstrand, 2009).

3.2.2 Metode zasnovane na linearnoj regresiji

U (Montalvo et al., 2012) autori su predstavili metodu za automatsko prepoznavanje redova usjeva u poljima kukuruza uz visoku prisutnost korova. Za segmentaciju slike autori su koristili ExG indeks boje vegetacije, nakon čega je primijenjena dvostruka Otsu metoda segmentacije (poglavlje 7.1.2) za razdvajanje usjeva od korova i zemlje. Nakon segmentacije slike, redovi usjeva su prepoznati korištenjem linearne regresije. Predložena metoda ima nekoliko ograničenja za stvarnu primjenu. Pretpostavlja se da je broj redova usjeva poznat, da je očekivana pozicija redova usjeva poznata te da je područje na slici koje treba pretražiti poznato. U radu su definirani posebni predlošci (engl. *templates*) koji omogućavaju primjenu linearne regresije na ograničenom skupu segmentiranih točaka. Usporedba sa Standardnom Houghovom transformacijom pokazuje bolje rezultate za predloženu metodu, a autori ističu da je glavni doprinos rada segmentacija slike korištenjem dvostruke Otsu metode segmentacije. Ova metoda korištena je u eksperimentalnoj analizi provedenoj u poglavlju 7 pa je stoga detaljnije opisana u poglavlju 7.1.2. Metoda predstavljena u (Guerrero et al., 2013) zasniva se na kombinaciji različitih indeksa boje vegetacije, Otsu metodi za binarizaciju i Theil-Sen estimatoru. Korištenjem kombinacije indeksa boje vegetacije, zelenilo usjeva i korova je naglašeno u odnosu na zemlju, kamenje i ostale elemente na slici. Otsu metoda je primijenjena na transformiranoj slici za dobivanje binarne slike. Korištenjem znanja o rasporedu redova usjeva te znanja o ekstrinsičnim i intrinsičnim parametrima kamere, dobiveni su očekivani redovi

usjeva. Očekivani redovi usjeva su korigirani primjenom Theil-Sen estimatora na podacima koji predstavljaju usjeve i korov u okolini svakog očekivanog reda usjeva. Pearsonov koeficijent momenta korelacije je također ispitan u ovom radu te je pokazano da Theil-Sen estimator ima veću točnost. Kao i metoda predstavljena u (Montalvo et al., 2012), ova metoda također ima ograničenu primjenu na prepoznavanje redova usjeva različitog rasporeda. Vremena izvođenja metode s Theil-Sen estimatorom kreću se između 9.568 i 0.03 s, ovisno o postavkama metode. Autori tvrde da je vrijeme izvođenja metode od 9.568 s prihvatljivo za rad u stvarnom vremenu.

3.2.3 Metode zasnovane na akumulaciji zelenih piksela

Metoda zasnovana na infracrvenim slikama i zbrajanju sivih piksela za prepoznavanje redova usjeva predstavljena je u (Olsen, 1995). Infracrveni filtar se koristi za izbjegavanje segmentacije slike jer su usjevi i korov svjetliji od zemlje pri valnim duljinama svjetlosti između 700 i 1400 nm (Deering, 1989). Zbrajanje sivih piksela napravljeno je za svaki stupac pravokutnog područja slike koje se analizira. Nakon toga, krivulja zbroja se aproksimira sinus funkcijom ili se filtrira nisko propusnim filtrom. Maksimumi aproksimirane sinus funkcije ili maksimumi filtrirane krivulje zbroja predstavljaju pozicije redova usjeva. Kamera je u eksperimentima postavljena u ortogonalni položaj te se na slikama ne vidi utjecaj perspektive. Metoda je jednostavna i nije osjetljiva na sjene, dok bočni vjetrovi i osvjetljenje uzrokuju pogrešku u detekciji. Kut redova usjeva veći od 15° i visoka prisutnost korova također mogu uzrokovati pogrešku. U (Romeo et al., 2012) autori su predstavili metodu za prepoznavanje redova usjeva u poljima kukuruza temeljenu na neizrazitom grupiranju podataka (engl. *fuzzy clustering*) i akumulaciji zelenih piksela. Neizrazito grupiranje primjenjuje se za određivanje praga binarizacije koji se koristi za segmentaciju usjeva i korova od ostalih elemenata na slici. Nakon segmentacije, redovi usjeva se prepoznaju traženjem maksimuma akumulacije zelenih piksela duž ravnih segmenata. Autori su koristili općenito znanje o polju kukuruza kako bi postigli nisko vrijeme izvođenja, ali glavni nedostatak metode je što broj redova usjeva mora biti poznat unaprijed. Također, metoda može prepoznati samo ravne redove usjeva i samo one redove usjeva čiji je početak na dnu slike. Metoda je uspoređena sa Standardnom Houghovom transformacijom, a mjerena je učinkovitost i vrijeme izvođenja. Različite rezolucije slike su ispitane u sklopu eksperimentalne evaluacije te je pokazano da predložena metoda daje bolje rezultate od Houghove transformacije u svim ispitanim slučajevima. U (Søgaard i Olsen, 2003) autori su predstavili metodu za prepoznavanje redova usjeva zasnovanu na

akumulaciji zelenih piksela i otežanoj linearnoj regresiji. Ulazna slika se transformira u sliku sivih tonova korištenjem ExG indeksa, nakon čega se dobivena slika podijeli na 15 horizontalnih linija. Za svaku liniju računa se zbroj intenziteta piksela po stupcima te se određuje centar gravitacije. Približna vrijednost udaljenosti između redova usjeva mora biti poznata i ona se koristi pri računanju centra gravitacije. Metoda je ispitana na polju ječma, a rezultati pokazuju da središnja točka prepoznatog reda usjeva može biti prepoznata s točnošću od $6 - 12$ mm.

3.2.4 Metode zasnovane na filtriranju slike

Početni pokušaj automatskog navođenja poljoprivrednog stroja zasnovan na računalnom vidu predstavljen je u (Tillett i Hague, 1999). Metoda se zasniva na proširenom Kalmanovom filtru i jednostavnim značajkama dobivenim na binariziranoj infracrvenoj slici. Predikcija stanja sustava se određuje korištenjem modela procesa, prethodnog stanja sustava i ulaza u Kalmanov filtar. Tako dobivena predikcija korigira se novim značajkama korištenjem metode najmanjih kvadrata. Na ispitanim slikama nije bila prisutna sjena i prema rezultatima navedenim u radu, autori tvrde da metoda nije komercijalno primjenjiva. U (Hague i Tillett, 2001) autori su proširili sustav iz ranijeg rada (Tillett i Hague, 1999) zamjenom binarizacije slike s pojasno propusnim filtriranjem infracrvene slike. Prema ponavljajućem pravilnom uzorku redova usjeva, autori su kreirali pojasno propusni filtar kojim su filtrirali osam linja na svakoj snimljenoj slici. Maksimalne vrijednosti filtriranih linija, zajedno s informacijom o kinematici traktora koriste se u proširenom Kalmanovom filtru za estimiranje pozicije poljoprivrednog stroja. Dobivene maksimalne vrijednosti postupka filtriranja se obrađuju sekvencijalno s Kalmanovim filtrom, što znači da prethodni rezultati imaju utjecaj na trenutni rezultat. Metoda je testirana na polju pšenice i prosječno odstupanje prepoznatih linija je 15.6 mm. Za razliku od ranijih radova istih autora, ova metoda nije osjetljiva na prisutnost sjene na slikama. Prilagodba ove metode za automatsko plijevljenje korova u poljima šećerne repe predstavljena je u (Tillett et al., 2002). Zbog toga što u redovima šećerne repe postoje razmaci između plodova, slika je podijeljena u osam horizontalnih grupa te se filtrirane linije unutar iste grupe spajaju. Važno je osigurati da svaka horizontalna grupa sadrži dio ploda u svakom redu usjeva. U radu (Tillett et al., 2002) predstavljena su dva različita pojasno propusna filtra. Jedan je isti kao filtar u (Hague i Tillett, 2001) i u (Tillett et al., 2002) se koristi za velike plodove, a drugi je pojednostavljena verzija tog filtra i koristi se za male usjeve. Zbog moguće upotrebe dva različita filtra, operator mora specificirati jesu li plodovi mali

ili veliki, što smanjuje automatiziranost metode. Eksperimentalni rezultati predložene metode pokazuju prosječnu grešku od 16 mm.

3.2.5 Metode zasnovane na stereoviziji

U (Kise et al., 2005) autori su predstavili metodu za prepoznavanje redova usjeva i automatsku navigaciju traktora zasnovanu na stereoviziji. Korištenjem stereo parova slika kreira se slika dubine na temelju koje se određuju 3D točke plodova. Korištenjem 3D točaka kreira se visinska mapa (engl. *elevation map*) koja se filtrira kako bi se nadomjestile točke koje nedostaju. Točke za navigaciju poljoprivrednog stroja određuju se na temelju poprečne korelacije između redaka visinske mape i predloženog modela redova usjeva. Metoda je ispitana na redovima usjeva soje s ravnim i zakrivljenim linijama, a pokazano je da je RMS (engl. *Root Mean Square*) pogreška manja od 0.05 m. Algoritam za određivanje lateralnog pomaka pri navigaciji poljoprivrednog stroja korištenjem stereovizije predložen je u (Wang et al., 2011). Značajke na zemlji se detektiraju korištenjem Harrisovog detektora uglova (engl. *Harris corner detector*), a korištenjem normalizirane poprečne korelacije se tako detektirane značajke prate na dvjema uzastopnim stereo slikama. RANSAC (Fischler i Bolles, 1981) metoda se koristi za uklanjanje odudarajućih vrijednosti, a lateralni pomak se određuje na temelju 3D koordinata točno sparenih značajki. Testiranje metode u polju pokazalo je da je pogreška u određivanju lateralnog pomaka pri praćenju ravnih linija manja od 50 mm, dok je pogreška pri praćenju zakrivljenih linija znatno veća. Nedostatak predloženog algoritma je u činjenici da se pretpostavlja da ne postoji rotacija kamere što u stvarnoj primjeni, zbog neravnina u polju, gotovo nikada nije slučaj.

3.2.6 Ostali pristupi rješavanju problema prepoznavanja redova usjeva

Autori su u (Pla et al., 1997) predstavili metodu za usmjeravanje poljoprivrednog stroja u redovima usjeva zasnovanu na građenju strukture scene korištenjem točke nestajanja (engl. *vanishing point*). Značajke se pronalaze koristeći metodu zasnovanu na pronalasku kontura. Metoda ne daje dobre rezultate u slučajevima kada je slika snimljena na kraju polja gdje je preostala duljina redova usjeva mala te kada je na slici prisutno puno korova. Nedavno, su u (Jiang et al., 2015) autori predstavili metodu za prepoznavanje redova usjeva zasnovanu na akumulaciji zelenih piksela, jednostavnoj metodi klasifikacije i linearnoj regresiji. U ovom radu se za dobivanje slike sivih tonova koristi indeks boje ve-

getacije predložen u (Burgos-Artizzu et al., 2011), a na dobivenoj sivoj slici se primjenjuje Otsu metoda za segmentaciju plodova. Centralne točke redova usjeva određuju se zbrajanjem piksela plodova u višestrukim prozorima obrade (engl. *ROI - Region Of Interest*) na binariziranoj slici. Zbrajanje se obavlja horizontalnim skeniranjem slike, a optimalne vrijednosti prethodnih centralnih točaka se koriste kao početne vrijednosti pri izračunu trenutnih centralnih točaka. Pseudo centralne točke uklanjaju se jednostavnom metodom klasifikacije, a nakon toga se primjenjuje linearna regresija. Metoda je uspoređena sa Standardnom Houghovom transformacijom, a mjeren je postotak prepoznavanja, točnost prepoznavanja i vrijeme izvođenja. Rezultati pokazuju da postotak prepoznavanja može biti i do 93%.

3.2.7 Predloženi pristup

U sklopu ovog istraživanja predložene su dvije metode za rješavanje problema prepoznavanja redova usjeva na slici. Obje metode zasnovane su na primjeni metoda globalne optimizacije, a detaljnije su opisane u nastavku.

Prva predložena metoda (poglavlje 4) zasnovana je na inkrementalnoj metodi za traženje približno optimalne particije skupa podataka i `DIRECT` algoritmu za globalnu optimizaciju. Ideja primjene inkrementalne metode slična je metodi predloženoj u (Bagirov et al., 2013) u kojoj se u svakom koraku novi centralni pravac pronalazi rješavanjem odgovarajućeg lokalno optimalnog problema. S druge strane, metoda predložena u ovom radu u svakom koraku novi centralni pravac određuje pronalaskom globalno optimalnog rješenja odgovarajućeg problema. Centralni pravci dobiveni kao rezultat globalne optimizacije se u predloženoj metodi korigiraju primjenom k-means algoritma kako bi se dobili konačni pravci koji predstavljaju centralne pravce redova usjeva. Broj redova usjeva koje je potrebno prepoznati mora biti poznat unaprijed, a omogućavanje automatskog prepoznavanja broja redova usjeva predstavlja temu za buduće istraživanje.

U poglavlju 5 predložena je metoda za prepoznavanje redova usjeva na slici zasnovana na računanju podudaranja s predloškom te minimizaciji funkcije globalne energije. Predložena metoda u koraku predobrade slike koristi ExG indeks boje vegetacije. Za razliku od metoda predloženih u (Bakker et al., 2008; Montalvo et al., 2012; Guerrero et al., 2013; Jiang et al., 2015), za prepoznavanje vegetacije se ne primjenjuje metoda segmentacije, nego se redovi usjeva prepoznaju na slici transformiranoj primjenom ExG indeksa. Nadalje, broj redova usjeva, očekivana pozicija redova usjeva, te područje na slici koje treba pretražiti ne moraju biti unaprijed poznati. Kao u radu (Hague i Til-

lett, 2001), predložena metoda koristi postupak podudaranja s predloškom. Za razliku od metode (Hague i Tillett, 2001), u ovom radu je kreiran niz filtara i filtriran je svaki redak slike. Parametri kreiranih filtara određuju se primjenom postupka učenja, odnosno optimizacijom na skupu za učenje. Optimalni CCR model redova usjeva prikazanih na slici određuje se minimiziranjem funkcije globalne energije primjenom dinamičkog programiranja. Nadalje, za razliku od svih proučenih metoda za prepoznavanje redova usjeva na slikama, predložena metoda ima mogućnost prepoznavanja i zakrivljenih redova usjeva.

Metoda za prepoznavanje redova usjeva na stereo parovima slika, predložena u (Wang et al., 2011), ispitana je na ravnim i zakrivljenim putanjama, ali autori tvrde da su potrebna dodatna poboljšanja metode u slučaju zakrivljenih putanja. Nadalje, pristup predložen u (Wang et al., 2011) je razvijen za potrebe rada u polju nakon žetve, dok je metoda predložena u sklopu ovog istraživanja namijenjena za rad u strukturiranom okruženju, kao što su redovi usjeva. Još jedna razlika između metode predložene u ovom radu i metode (Wang et al., 2011) je ta što je metoda predložena u ovom radu zasnovana na računanju podudaranja s predloškom na monokularnoj slici nakon čega se primjenjuje globalna optimizacija, dok je metoda predložena u (Wang et al., 2011) zasnovana na detekciji i praćenju značajki na stereo parovima slika.

Metoda predložena u (Kise et al., 2005) uspješno je ispitana na stereo slikama ravnih i zakrivljenih redova soje. Uz razliku u načinu snimanja slike, metoda (Kise et al., 2005) pronalazi samo jednu točku za navigaciju na snimljenom stereo paru slika, dok metoda predložena u ovom radu prepoznaje sve redove usjeva vidljive na monokularnoj slici. Model predložen u (Kise et al., 2005) je pogodan samo za polja s korisnički definiranom udaljenošću između redova usjeva, dok je metoda predložena u ovom radu pogodna za prepoznavanje redova usjeva različitih kultura, u različitim stadijima rasta te pri različitim geometrijama polja. Nadalje, budući da je metoda (Kise et al., 2005) zasnovana na visinskoj mapi, važno je da usjevi budu relativno visoki, kako bi ih metoda mogla razlikovati od neravnina u polju. S druge strane metoda predložena u ovom radu zasniva se na zelenilu usjeva, čime je omogućeno prepoznavanje redova usjeva relativno malih biljaka u ranim fazama rasta. Ideja primjene visinske mape za prepoznavanje vegetacije, iskorištena u (Kise et al., 2005), može se iskoristiti u kombinaciji s metodom predloženom u ovom radu. U tom slučaju visinska mapa bi zamijenila korak računanja ExG indeksa za transformaciju ulazne slike u sliku sivih tonova, što predstavlja zanimljivu temu za neko od budućih istraživanja.

4

Primjena inkrementalnog čvrstog grupiranja podataka za prepoznavanje redova usjeva

Kao što je rečeno u uvodu, problem prepoznavanja redova usjeva važan je korak u postupku automatizacije kretanja poljoprivrednog stroja, odnosno automatizacije procesa poljoprivredne proizvodnje. Za rješavanje spomenutog problema znanstvenici su koristili različite pristupe, a najčešći od njih prikazani su u poglavlju 3. U istraživanju provedenom u sklopu izrade ove doktorske disertacije predložena je nova metoda za prepoznavanje redova usjeva zasnovana na primjeni inkrementalnog čvrstog grupiranja podataka. Metoda je opisana u radu (Vidović i Scitovski, 2014), u kojem je prvo predložena nova efikasna metoda za prepoznavanje pravaca u proizvoljnom položaju zasnovana na inkrementalnoj metodi za traženje približno optimalne particije skupa podataka (Likas et al., 2003; Bagirov i Ugon, 2005; Scitovski i Scitovski, 2013) i `DIRECT` (engl. *DIviding RECTangles*) algoritmu (Finkel, 2003) za globalnu optimizaciju. Predložena metoda za prepoznavanje pravaca ispitana je na brojnim umjetno generiranim skupovima podataka koji simuliraju redove usjeva. Prilikom analize rezultata prepoznavanja redova usjeva (poglavlje 7.2) uočeno je da, za određene ispitane slučajeve, predložena metoda ne uspijeva dobro prepoznati referentne redove usjeva. Zbog toga je predložena metoda prilagođena za rješavanje problema prepoznavanja redova usjeva. Spomenuta prilagodba sastoji se od zasebnih algoritama za rješavanje problema prepoznavanja dva i tri reda usjeva te poopćenja navedenih algoritama za rješavanje problema prepoznavanja k redova usjeva.

Budući da je predložena metoda za prepoznavanje redova usjeva prilagodba metode

za prepoznavanje pravaca, može se zaključiti da su redovi usjeva dobiveni ovom metodom opisani pravcima. Prema tome jedna od pretpostavki koja mora biti zadovoljena, kako bi predložena metoda uspješno prepoznala redove usjeva, je da su redovi usjeva ravni, odnosno da se mogu opisati SCR modelom definiranim u poglavlju 2.3.2. Osim ove pretpostavke važno je da distribucija točaka koje predstavljaju usjeve bude takva da TLS pravac, kojim se skup podataka dijeli na dva podskupa (algoritam 2, algoritam 3, algoritam 4), bude vertikalan s određenom tolerancijom kuta. Na taj način se korištenjem TLS pravca skup podataka dijeli na lijevi i desni podskup. Ukoliko bi TLS pravac bio horizontalan, podijelio bi skup podataka na gornji i doljnji te pri tome predloženi algoritmi za prepoznavanje redova usjeva ne bi dobro prepoznali referentne redove usjeva. Nadalje, broj redova usjeva koje je potrebno prepoznati, mora biti unaprijed poznat.

U nastavku poglavlja formalno je opisan problem prepoznavanja pravaca u proizvoljnom položaju te je definiran način generiranja skupa točaka koje potječu od pravaca u proizvoljnom položaju. Spomenuti postupak generiranja točaka koristi se i u eksperimentalnoj analizi (poglavlje 7.2) za generiranje testnih skupova točaka koji simuliraju redove usjeva. Prijedlog metode za rješavanje problema prepoznavanja pravaca u proizvoljnom položaju dan je u poglavlju 4.1.4, dok je u poglavlju 4.2 navedena prilagodba spomenute metode za rješavanje problema prepoznavanja redova usjeva.

4.1 Problem prepoznavanja pravaca

Problem prepoznavanja pravaca može se promatrati na primjeru prepoznavanja proizvoljnih pravaca u ravnini od kojih je svaki definiran izrazom (2.3). Pravce je potrebno prepoznati na temelju skupa točaka $\mathcal{A}$ koje potječu od unaprijed nepoznatih pravaca. Pri tome broj pravaca koje je potrebno prepoznati može, ali ne mora biti poznat. Jedan mogući način za generiranje skupa točaka $\mathcal{A}$ opisan je u nastavku poglavlja.

4.1.1 Generiranje skupa točaka

Točke na temelju kojih je potrebno prepoznati redove usjeva mogu se dobiti postupkom opisanim u poglavlju 2.2. Budući da se u nastavku ovog poglavlja prvo razmatra problem prepoznavanja pravaca u proizvoljnom položaju, potrebno je definirati način generiranja skupa točaka $\mathcal{A}$ koje potječu od k pravaca u proizvoljnom položaju. Ovaj postupak generiranja točaka koristi se i za generiranje testnih skupova točaka korištenih u eksperimentalnoj analizi metode predložene za prepoznavanje redova usjeva (poglavlje 7).

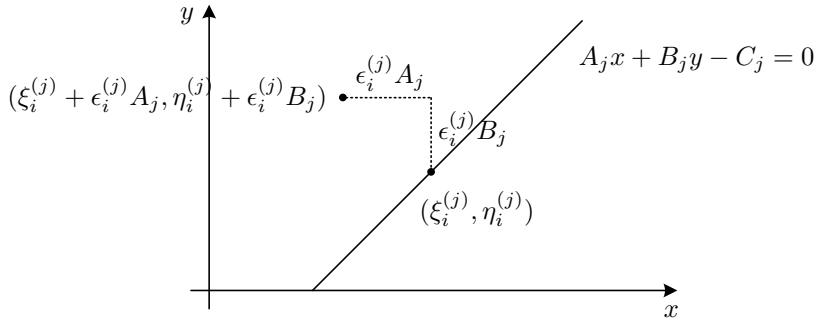

Slika 4.1: Primjer generiranja jedne točke skupa A_j korištenjem izraza (4.3).

Postupak generiranja skupa točaka opisan je u nastavku. Neka je

$$\mathcal{A} = \{T_i = (x_i, y_i) \in \mathbb{R}^2 : i \in \{1, \ldots, m\}\} \subset R \tag{4.1}$$

skup m točaka $T(x, y)$ sadržanih u pravokutniku $R = [x_{min}, x_{max}] \times [y_{min}, y_{max}]$. Točke skupa $\mathcal{A}$ generirane su na temelju k pravaca oblika

$$p_j : \quad A_j x + B_j y - C_j = 0, \quad A_j^2 + B_j^2 = 1, \quad C_j \geq 0, \qquad j \in J = \{1, \ldots, k\}. \tag{4.2}$$

Prvi korak generiranja ovakvog skupa točaka je odabir intervala $[y_{min}, y_{max}] \subset \mathbb{R}$ nakon čega se za svaki $j \in J$ definira $m_j \geq 3$ jednako razmaknutih brojeva $\eta_1, \ldots, \eta_{m_j} \in [y_{min}, y_{max}]$ i skup

$$\mathcal{A}_j = \{(\xi_i^{(j)}, \eta_i^{(j)}) + \epsilon_i^{(j)}(A_j, B_j)\} \tag{4.3}$$

gdje je

$$\xi_i^{(j)} = \tfrac{1}{A_j}(C_j - B_j \eta_i^{(j)}), \quad A_j \geq 0,$$
$$\epsilon_i^{(j)} \sim \mathcal{N}(0, \sigma^2),$$
$$i = 1, \ldots, m_j.$$

Pri tome $\mathcal{N}(0, \sigma^2)$ označava normalnu razdiobu sa srednjom vrijednošću 0 i varijancom σ^2, a $\epsilon_i^{(j)}$ predstavlja slučajan broj određen tom razdiobom. Primjer generiranja jedne točke skupa A_j na temelju izraza (4.3) prikazan je na slici 4.1. Iz prikazanog primjera i jednadžbe (4.3), može se uočiti da se za odabrani broj $\eta_i^{(j)}$ (y koordinata) izračunava vrijednost $\xi_i^{(j)}$ (x koordinata) na temelju jednadžbe pravca p_j. Konačne koordinate točke dobivaju se dodavanjem vrijednosti $\epsilon_i^{(j)} A_j$ x koordinati i vrijednosti $\epsilon_i^{(j)} B_j$ y koordinati. Skup točaka $\mathcal{A}$ se nakon toga dobiva kao unija skupova $\mathcal{A}_j$ i sastoji se od m točaka na temelju kojih je potrebno prepoznati pravce $p_1, \ldots, p_k$.

4.1.2 Prepoznavanje pravaca zasnovano na grupiranju podataka

Grupiranje podataka (engl. *clustering*) je postupak razvrstavanja podataka ulaznog skupa u više grupa pri čemu podaci unutar određene grupe trebaju biti što sličniji po nekom obilježju, a istodobno po istom obilježju što različitiji od podataka u drugim grupama. U literaturi je grupiranje podataka dobro proučen problem koji ima praktičnu primjenu u brojnim područjima kao što su medicina, biologija, ekonomija, psihologija, računarstvo i sl. te u specifičnim problemima kao što su prepoznavanje predmeta, klasifikacija teksta, istraživanje potresa, proučavanje klime i sl. (Kogan, 2007; Liao et al., 2012; Mostafa, 2013; Pintér, 2013; Reyes et al., 2013; Scitovski i Scitovski, 2013).

Problem prepoznavanja pravaca može se također promatrati kao problem grupiranja podataka (engl. *clustering problem*) (Bagirov i Ugon, 2005; Späth, 1983; Yin, 1998) skupa $\mathcal{A}$ u k nepraznih razdvojenih podskupova $\pi_1, \ldots, \pi_k$ takvih da je

$$\bigcup_{i=1}^{k} \pi_i = \mathcal{A}, \qquad \pi_r \cap \pi_s = \emptyset, \quad r \neq s, \qquad |\pi_j| \geq 1, \quad j = 1, \ldots, k. \tag{4.4}$$

Takva particija se u nastavku označava s Π, a skup svih particija skupa $\mathcal{A}$ u k grupa označava se s $\mathcal{P}(\mathcal{A}; m, k)$. Elementi particije Π u nastavku se nazivaju *klasteri*.

Ako je funkcija udaljenosti točke $T(\xi, \eta) \in \mathcal{A}$ do pravca $p_j(A_j, B_j, C_j)$ zadanog s (2.3) definirana kao ortogonalna kvadratna udaljenost (Nievergelt, 1994; Chernov, 2010)

$$d(p_j(A_j, B_j, C_j), T) = (A_j\xi + B_j\eta - C_j)^2, \tag{4.5}$$

tada se za svaki klaster $\pi_j \in \Pi$ može definirati centralni pravac $\hat{p}_j(\hat{A}_j, \hat{B}_j, \hat{C}_j)$ oblika

$$(\hat{A}_j, \hat{B}_j, \hat{C}_j) = \underset{A_j, B_j, C_j \in \mathbb{R}}{\operatorname{argmin}} \sum_{T \in \pi_j} d(p_j A_j, B_j, C_j), T). \tag{4.6}$$

Budući da se minimizacijom izraza (4.6) pronalazi pravac oblika (2.3), važno je uočiti da pri minimizaciji moraju biti zadovoljeni uvjeti $A^2 + B^2 = 1$ i $C \geq 0$. Prema (4.6) može se zaključiti da centralni pravac p_j predstavlja TLS (engl. *Total Least Square*) pravac klastera π_j.

Kvaliteta particije može se odrediti definiranjem funkcije cilja $\mathcal{F}\colon \mathcal{P}(\mathcal{A}; m, k) \to \mathbb{R}_+$, a *globalno optimalna k-particija* može se dobiti rješavanjem sljedećeg problema globalne optimizacije (PGO)

$$\Pi^* = \underset{\Pi \in \mathcal{P}(\mathcal{A}; m, k)}{\operatorname{argmin}} \mathcal{F}(\Pi), \qquad \mathcal{F}(\Pi) = \sum_{j=1}^{k} \sum_{T \in \pi_j} d(\hat{p}_j(\hat{A}_j, \hat{B}_j, \hat{C}_j), T), \tag{4.7}$$

pri čemu je centralni pravac $\hat{p}_j$ definiran s (4.6).

Obratno, primjenom principa minimalnih udaljenosti za dani set centralnih pravaca $p_1, \dots p_k$, može se odrediti particija $\Pi = \{\pi_1(p_1), \dots \pi_k(p_k)\}$ skupa $\mathcal{A}$, koja se sastoji od klastera

$$\pi_j(p_j) = \{T \in \mathcal{A} : d(p_j, T) \leq d(p_s, T),\ \forall s = 1, \dots, k\}, \qquad j = 1, \dots, k, \tag{4.8}$$

pri čemu pojedina točka skupa $\mathcal{A}$ može pripadati jednom i samo jednom klasteru. Problem traženja optimalne particije skupa $\mathcal{A}$ se tada svodi na sljedeći PGO

$$\begin{aligned} (\mathbf{A}^*, \mathbf{B}^*, \mathbf{C}^*) &= \underset{\mathbf{A},\mathbf{B},\mathbf{C} \in \mathbb{R}^k}{\operatorname{argmin}} F(\mathbf{A}, \mathbf{B}, \mathbf{C}), \\ &= \underset{\mathbf{A},\mathbf{B},\mathbf{C} \in \mathbb{R}^k}{\operatorname{argmin}} \sum_{T \in \mathcal{A}} \min_{1 \leq s \leq k} d(p_s(A_s, B_s, C_s), T), \end{aligned} \tag{4.9}$$

gdje je $F\colon \mathbb{R}^{3\times k} \to \mathbb{R}_+$ i $\mathbf{A} = (A_1, \dots, A_k)$, $\mathbf{B} = (B_1, \dots, B_k)$, $\mathbf{C} = (C_1, \dots, C_k)$. Može se pokazati da se rješenja (4.7) i (4.9) podudaraju (Scitovski i Scitovski, 2013; Späth, 1983).

Prema navedenom, problem prepoznavanja pravaca svodi se na rješavanje PGO definiranog izrazom (4.9). Funkcija cilja (4.9) je Lipschitz kontinuirana funkcija, te se za njenu minimizaciju mogu iskoristiti brojne metode dostupne u literaturi (Evtushenko, 1985; Neumaier, 2004; Floudas i Gounaris, 2009; Pintér, 2013). Jedna od najpoznatijih metoda za minimizaciju ovakvih funkcija je `DIRECT` metoda. Međutim, zbog velikog broja nezavisnih varijabli i velikog broja globalnih minimuma koje funkcija (4.9) može imati, ovakve metode nisu dovoljno efikasne. Stoga se u literaturi često koriste različita pojednostavljenja pomoću kojih se pronalazi dobra particija. U takvim slučajevima obično nije poznato koliko je dobivena particija blizu globalno optimalne particije.

4.1.3 Prilagodba k-means algoritma

Jedan od najpopularnijih algoritama za traženje lokalno optimalne particije je k-means algoritam (Kogan, 2007; Liao et al., 2012; Scitovski i Sabo, 2014; Späth, 1983; Teboulle, 2007) koji može dati prihvatljivo rješenje u slučajevima kada je početna particija dobro odabrana. U slučajevima kada početnu particiju nije moguće dobro odabrati, algoritam se pokreće više puta s nasumično odabranim početnim particijama. Prilagodba k-means algoritma (algoritam 1) za rješavanje PGO definiranog izrazom (4.9) predložena je u (Späth, 1982). Ulaz u algoritam je skup točaka $\mathcal{A}$ te k međusobno različitih početnih pravaca $p_1, \dots, p_k$. Prvi korak algoritma je određivanje k nepraznih razdvojenih klastera korištenjem principa minimalnih udaljenosti (4.8). Nakon toga se za svaki klaster

Algoritam 1 k-means algoritam.

1. Neka je $\mathcal{A} = \{T_i = (x_i, y_i) \colon i = 1, \ldots, m\}$, i neka su $p_1, \ldots, p_k$ međusobno različiti pravci;
2. Korištenjem principa minimalnih udaljenosti (4.8) odrediti k nepraznih razdvojenih klastera $\pi_1(p_1), \ldots, \pi_k(p_k)$;
3. Za svaki klaster π_j odrediti centralni pravac $\hat{p}_j$ prema (4.6);
4. **if** $\{\hat{p}_1, \ldots, \hat{p}_k\} = \{p_1, \ldots, p_k\}$ **then**
5. STOP
6. **else**
7. Postaviti $p_j := \hat{p}_j$, $j = 1, \ldots, k$ i skočiti na korak 2;
8. **end if**

računaju novi centralni pravci te se algoritam iterativno ponavlja dok god se centralni pravci mijenjaju.

4.1.4 Prilagodba inkrementalnih metoda

Druga mogućnost za rješavanje PGO definiranog izrazom (4.9) je prilagodba inkrementalnih metoda za traženje približno globalno optimalne particije (Likas et al., 2003; Bagirov i Ugon, 2005; Scitovski i Scitovski, 2013). Navedena prilagodba se u nastavku rada naziva IMLD (engl. *Incremental Method for Line Detection*) metoda.

Uz pretpostavku da je početni centralni pravac $\hat{p}_1(\hat{A}_1, \hat{B}_1, \hat{C}_1)$ proizvoljno odabran ili određen kao TLS pravac, sljedeći centralni pravac $\hat{p}_2(\hat{A}_2, \hat{B}_2, \hat{C}_2)$ određuje se rješavanjem PGO (Scitovski i Scitovski, 2013)

$$\operatorname*{argmin}_{\alpha,\beta,\gamma\in\mathbb{R}} \sum_{i=1}^{m} \min\{d(\hat{p}_1(\hat{A}_1, \hat{B}_1, \hat{C}_1), T_i), d(p(\alpha, \beta, \gamma), T_i)\},$$

$$\alpha^2 + \beta^2 = 1,\ \gamma \geq 0,$$

korištenjem `DIRECT` algoritma. Primjenom k-means algoritma (algoritam 1) s početnim centrima $(\hat{p}_1, \hat{p}_2)$ dobiva se približno globalno optimalna particija $\Pi^*\{\pi_1^*(p_1^*), \pi_2^*(p_2^*)\}$ s centralnim pravcima p_1^* i p_2^*.

Analogno, za $k-1$ poznatih centralnih pravaca $\hat{p}_1, \ldots \hat{p}_{k-1}$, sljedeći centralni pravac $\hat{p_k}(\hat{A}_k, \hat{B}_k, \hat{C}_k)$ određuje se primjenom `DIRECT` algoritma za rješavanje PGO

$$\operatorname*{argmin}_{\alpha,\beta,\gamma_2\in\mathbb{R}} \sum_{i=1}^{m} \min\{\hat{\delta}_{k-1}^i, d(p(\alpha, \beta, \gamma), T_i)\}, \tag{4.10}$$

gdje je

$$\hat{\delta}_{k-1}^i = \min\{d(\hat{p}_1, T_i), \ldots, d(\hat{p}_{k-1}, T_i)\}.$$

Primjenom k-means algoritma (algoritam 1) s početnim centralnim pravcima $(\hat{p}_1, \ldots \hat{p}_k)$

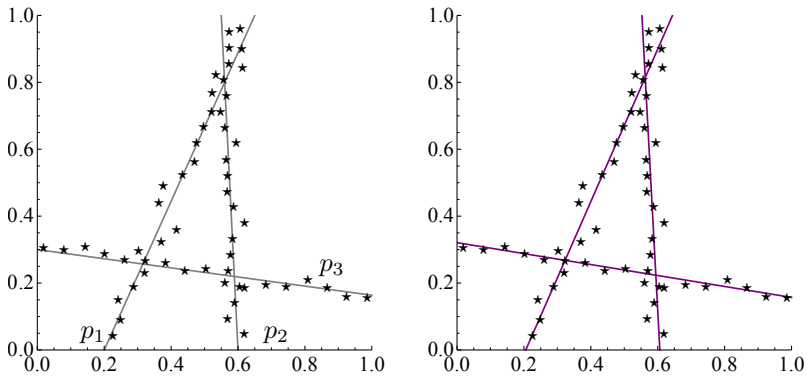

Slika 4.2: Prepoznavanje pravaca primjenom IMLD metode. (a) Primjer generiranih točaka, (b) Pravci dobiveni primjenom IMLD metode.

dobiva se približno globalno optimalna particija $\Pi^*\{\pi_1^*(p_1^*), \ldots \pi_k^*(p_k^*)\}$ s centralnim pravcima $p_1^* \ldots p_k^*$.

Važno je uočiti da predložena IMLD metoda u svakom koraku novi centralni pravac određuje pronalaskom globalno optimalnog rješenja problema (4.10) primjenom `DIRECT` algoritma za globalnu optimizaciju. Slična metoda predložena je u (Bagirov et al., 2013), ali se u toj metodi u svakom koraku novi centralni pravac pronalazi rješavanjem odgovarajućeg lokalno optimalnog problema. U tom slučaju važno je dobro odabrati početnu aproksimaciju, jer funkcija cilja može imati nekoliko lokalnih i globalnih minimuma.

Na slici 4.2 prikazan je primjer prepoznavanja pravaca predloženom IMLD metodom. Točke skupa $\mathcal{A}$, prikazane na slici 4.2a, generirane su prema postupku opisanom u poglavlju 4.1.1 na temelju pravaca $p_1\colon 0.9x - 0.4y + 0.18 = 0$, $p_2\colon x + 0.05y + 0.6 = 0$, $p_3\colon 0.135x + y + 0.3 = 0$. Pravci dobiveni primjenom IMLD metode prikazani su na slici 4.2b. Na slici se može vidjeti da IMLD metoda uspjeva prepoznati sva tri originalna pravca.

4.2 Metoda za prepoznavanje redova usjeva

Problem prepoznavanja redova usjeva predstavlja specijalan slučaj problema prepoznavanja pravaca. Formalno, problem prepoznavanja redova usjeva može se definirati na sljedeći način. Neka je skup točaka $\mathcal{A} \subset R$, $R = [x_{min}, x_{max}] \times [y_{min}, y_{max}]$ generiran na način opisan u poglavlju 4.1.1 na temelju pravaca $p_1, \ldots, p_k$ koji sijeku interval $[x_{min}, x_{max}]$ u jednako razmaknutim točkama $\nu_1, \ldots, \nu_k \in [x_{min}, x_{max}]$ i imaju zajedničko sjecište $S = (x_s, y_s)$, $x_{min} \leq x_s \leq x_{max}$, $y_s > y_{max}$ (slika 7.3). Na temelju ovako generiranog skupa točaka potrebno je prepoznati originalne pravce, koji predstavljaju centralne linije

redova usjeva, odnosno odrediti pravce SCR modela (poglavlje 2.3.2).

Kao što je navedeno u poglavlju 3, postoje različiti pristupi rješavanju problema prepoznavanja redova usjeva. Problem se može riješiti i primjenom predložene IMLD metode. Ipak, eksperimentalna analiza provedena u sklopu ove doktorske disertacije (poglavlje 7) pokazala je da IMLD metoda u određenim slučajevima ne daje zadovoljavajuće rezultate prepoznavanja redova usjeva. Stoga se u nastavku poglavlja predlaže prilagodba IMLD metode za problem prepoznavanja redova usjeva. Navedena prilagodba se u nastavku rada naziva CRDI metoda što je skraćenica od engleskog izraza *Crop Row Detection based on Incremental method for line detection*. U nastavku poglavlja navedeni su algoritmi za prepoznavanje dva i tri reda usjeva, a nakon toga je predložen poopćeni algoritam za prepoznavanje proizvoljnog, unaprijed poznatog, broja redova usjeva.

4.2.1 Algoritam za prepoznavanje dva reda usjeva

Algoritam CRDI metode za prepoznavanje dva reda usjeva (algoritam 2) zasniva se na traženju TLS pravca i primjeni k-means algoritma (algoritam 1). Ulaz u algoritam je skup točaka $\mathcal{A}$ koje potječu od dva unaprijed nepoznata pravca. Prvi korak algoritma je određivanje TLS pravca p_0 pomoću kojeg se skup $\mathcal{A}$ dijeli u dva razdvojena podskupa $\mathcal{A}_1$ i $\mathcal{A}_2$ takva da vrijedi $\mathcal{A} = \mathcal{A}_1 \cup \mathcal{A}_2$. Skup točaka se dijeli na način da se točke s jedne strane TLS pravca svrstaju u skup $\mathcal{A}_1$, a točke s druge strane pravca u skup $\mathcal{A}_2$. Nakon toga se za svaki od podskupova $\mathcal{A}_1$ i $\mathcal{A}_2$ određuje TLS pravac. Dobiveni pravci se koriste kao početni pravci u k-means algoritmu (algoritam 1) kako bi se dobili približno globalno optimalni pravci koji predstavljaju centralne linije redova usjeva. Važno je primijetiti da se pravac p_0 koristi samo za dijeljenje skupa $\mathcal{A}$ na dva podskupa i nakon toga se odbacuje.

Primjer rada algoritma 2, podijeljen u osnovne korake, vidljiv je na slici 4.3. Dva referentna reda usjeva i točke generirane na temelju tih redova usjeva prikazane su na slici 4.3a. Slika 4.3b prikazuje TLS pravac koji dijeli skup generiranih točaka na dva podskupa:

Algoritam 2 Algoritam CRDI metode za prepoznavanje 2 reda usjeva.

1. Neka je $\mathcal{A} = \{T_i = (x_i, y_i) \colon i = 1, \ldots, m\}$;
2. Za skup točaka $\mathcal{A}$ odrediti TLS pravac p_0;
3. Korištenjem pravca p_0 podijeliti skup $\mathcal{A}$ u dva razdvojena podskupa takva da je $\mathcal{A} = \mathcal{A}_1 \cup \mathcal{A}_2$;
4. **for** $j = 1, 2$ **do**
5. Za skup točaka $\mathcal{A}_j$ odrediti TLS pravac $\hat{p}_j$;
6. **end for**
7. Primijeniti k-means algoritam (algoritam 1) na skupu točaka $\mathcal{A}$ s početnim centralnim pravcima $\hat{p}_1, \hat{p}_2$

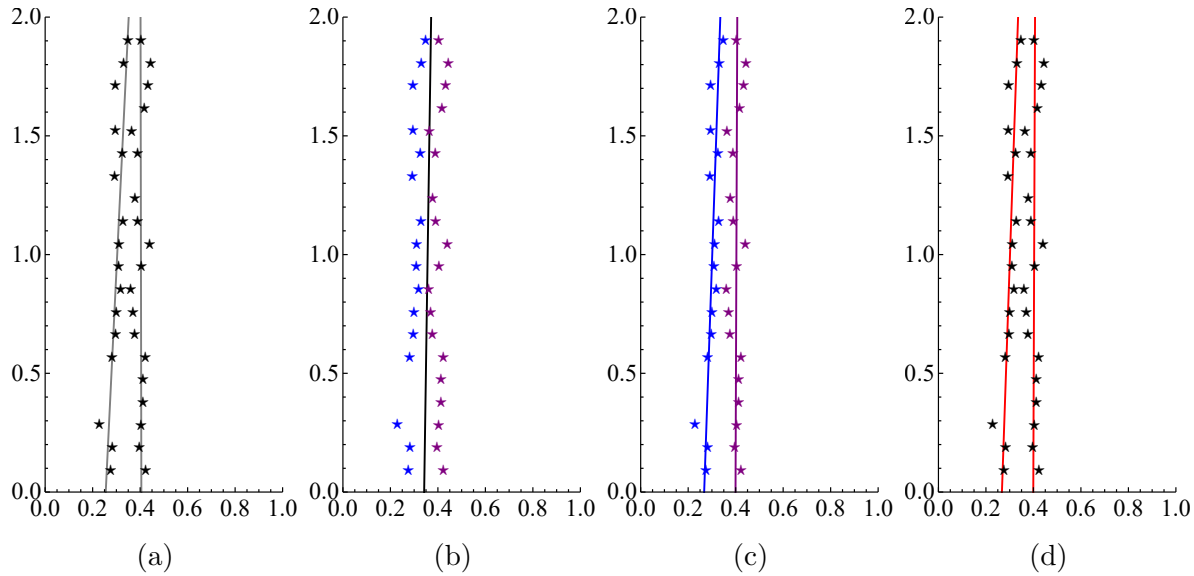

Slika 4.3: Primjer rada algoritma 2. (a) Referentni redovi usjeva i generirane točke, (b) TLS pravac, (c) Pravci dobiveni primjenom `DIRECT` algoritma, (d) Pravci dobiveni nakon korekcije k-means algoritmom (algoritam 1).

lijevi (plave zvjezdice) i desni (ljubičaste zvjezdice). Ovaj pravac se, nakon podjele ulaznog skupa točaka na dva podskupa, odbacuje te se ne koristi u daljnjim koracima algoritma. Prema algoritmu 2, za svaki od podskupova pronalazi se TLS pravac. Oba dobivena TLS pravca vidljiva su na slici 4.3c te su prikazana plavom i ljubičastom bojom, ovisno koji skup točaka predstavljaju. Nakon korekcije primjenom k-means algoritma dobivaju se konačni redovi usjeva prikazani na slici 4.3d. Iz prikazanog primjera može se vidjeti kako predloženi algoritam uspijeva prepoznati oba referentna reda usjeva. Rezultati detaljnijeg ispitivanja i usporedbe točnosti prepoznavanja dva reda usjeva predloženom metodom s drugim postojećim metodama prikazani su u poglavlju 7.2.2.

4.2.2 Algoritam za prepoznavanje tri reda usjeva

Algoritam CRDI metode za prepoznavanje tri reda usjeva (algoritam 3) zasniva se na na traženju TLS pravca, rješavanju dva PGO primjenom `DIRECT` algoritma te primjeni k-means algoritma (algoritam 1). Ulaz u algoritam je skup točaka $\mathcal{A}$ koje potječu od tri unaprijed nepoznata pravca. Prvi korak jednak je kao i kod algoritma 2, određuje se TLS pravac $\hat{p}_0$ pomoću kojeg se skup $\mathcal{A}$ dijeli u dva razdvojena podskupa $\mathcal{A}_1$ i $\mathcal{A}_2$ takva da vrijedi $\mathcal{A} = \mathcal{A}_1 \cup \mathcal{A}_2$. Za razliku od algoritma 2 gdje se pravac p_0 odbacuje, u algoritmu 3 se pravac $\hat{p}_0$ koristi kao jedan od početnih centralnih pravaca u posljednjem koraku (primjeni k-means algoritma). Nakon određivanja podskupova $\mathcal{A}_1$ i $\mathcal{A}_2$, korištenjem `DIRECT` algoritma za svaki od podskupova rješava se PGO kako bi se odredili pravci $\hat{p}_1$ i $\hat{p}_2$. Može se uočiti da se pravci $\hat{p}_1$ i $\hat{p}_2$ određuju na način da se traži takav pravac da suma odstupa-

Algoritam 3 Algoritam CRDI metode za prepoznavanje 3 reda usjeva.

1. Neka je $\mathcal{A} = \{T_i = (x_i, y_i) \colon i = 1, \ldots, m\}$;
2. Za skup točaka $\mathcal{A}$ odrediti TLS pravac $\hat{p}_0$;
3. Korištenjem pravca $\hat{p}_0$ podijeliti skup $\mathcal{A}$ u dva razdvojena podskupa takva da je $\mathcal{A} = \mathcal{A}_1 \cup \mathcal{A}_2$;
4. **for** $j = 1, 2$ **do**
5. Korištenjem `DIRECT` algoritma riješiti PGO $(\zeta_1, \zeta_2, \zeta_3) = \underset{\alpha,\beta,\gamma \in \mathbb{R}}{\operatorname{argmin}} \sum_{T \in \mathcal{A}_j} \min\{d(\hat{p}_0, T), d(p(\alpha, \beta, \gamma), T)\}$;
6. i postaviti $\hat{p}_j := p(\zeta_1, \zeta_2, \zeta_3)$
7. **end for**
8. Primijeniti k-means algoritam (algoritam 1) na skupu točaka $\mathcal{A}$ s početnim centralnim pravcima $\hat{p}_0, \hat{p}_1, \hat{p}_2$;

nja svake točaka u skupu $\mathcal{A}_j$ do njoj najbližeg pravca bude minimalna. Dobiveni pravci $\hat{p}_1$ i $\hat{p}_2$ se zajedno s pravcem $\hat{p}_0$ koriste kao početni pravci u k-means algoritmu (algoritam 1) kako bi se dobili približno globalno optimalni pravci koji predstavljaju centralne linije redova usjeva.

Slika 4.4 prikazuje primjer rada algoritma 3. Prikaz primjera podijeljen je u osnovne korake koji su prikazani na slikama 4.4b, 4.4c i 4.4d. Tri referentna reda usjeva i točke generirane na temelju tih redova vidljivi su na slici 4.4a. Slika 4.4b prikazuje TLS pravac koji dijeli ulazni skup točaka na dva podskupa: lijevi (plave zvjezdice) i desni (ljubičaste zvjezdice). Za svaki od podskupova rješava se PGO primjenom `DIRECT` algoritma te se dobivaju plavi i ljubičasti pravci prikazani na slici 4.4c. Pravci sa slike 4.4c koriste se kao početni pravci u k-means algoritmu te se dobivaju konačni pravci (redovi usjeva)

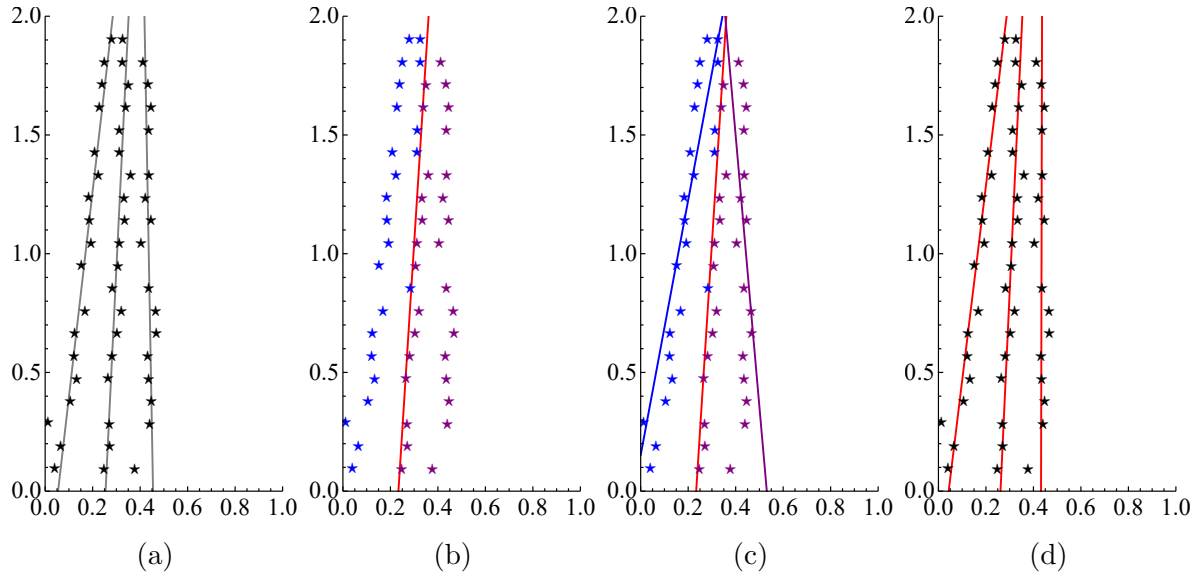

Slika 4.4: Primjer rada algoritma 3. (a) Referentni redovi usjeva i generirane točke, (b) TLS pravac, (c) TLS pravac i pravci dobiveni primjenom `DIRECT` algoritma, (d) Pravci dobiveni nakon korekcije k-means algoritmom (algoritam 1).

prikazani na slici 4.4d. Iz prikazanog primjera može se zaključiti da predloženi algoritam CRDI metode uspješno prepoznaje sva tri referentna reda usjeva. Rezultati detaljnijeg ispitivanja i usporedbe točnosti prepoznavanja tri reda usjeva predloženom metodom s drugim postojećim metodama prikazani su u poglavlju 7.2.3.

4.2.3 Algoritam za prepoznavanje proizvoljnog broja redova usjeva

Algoritam CRDI metode za prepoznavanje proizvoljnog, unaprijed poznatog, broja redova usjeva (algoritam 4) sastoji se od iterativne primjene dijelova algoritma 2 ili algoritma 3. Ulaz u algoritam je skup točaka $\mathcal{A}$ koje potječu od $k \geq 2$ unaprijed nepoznatih pravaca. Algoritam 4 se, uz inicijalizacijski dio, može podijeliti na tri dijela: *i*) *dijeljenje skupa* $\mathcal{A}_0$, *ii*) *iterativna primjena dijelova* algoritma 2 *ili* algoritma 3 i *iii*) *primjena k-means algoritma*. U inicijalizacijskom koraku se varijabla n postavi na vrijednost k (broj

Algoritam 4 Algoritam CRDI metode za prepoznavanje k redova usjeva.

1. Neka je $\mathcal{A} = \{T_i = (x_i, y_i) \colon i = 1, \ldots, m\}$; $k \geq 2$;
   $n = k$; $cnt = 0$; $\mathcal{A}_0 = \mathcal{A}$, $\bar{P} = \emptyset$; $\hat{P} = \emptyset$;
2. **while** $n > 3$ **do**
3. **for** $j = 0$ **to** $2^{cnt} - 1$ **do**
4. Za skup $\mathcal{A}_j$ odrediti TLS pravac p_j;
5. Dodati p_j u $\bar{P}$;
6. Korištenjem pravca p_j podijeliti skup $\mathcal{A}_j$ u dva razdvojena podskupa $\mathcal{B}_{2j}, \mathcal{B}_{2j+1}$;
7. **end for**
8. **if** $n \bmod 2 \neq 0$ **then**
9. Dodaj $\bar{P}$ u $\hat{P}$
10. **end if**
11. Postaviti $\bar{P} = \emptyset$; $n = \lfloor n/2 \rfloor$; $cnt = cnt + 1$;
12. **for** $j = 0$ **to** $2^{cnt} - 1$ **do**
13. $\mathcal{A}_j = \mathcal{B}_j$;
14. $\mathcal{B}_j = \emptyset$;
15. **end for**
16. **end while**
17. **for** $j = 0$ **to** $2^{cnt} - 1$ **do**
18. **if** $n == 2$ **then**
19. Primijeniti korake 2-6 algoritma 2 na skupu $\mathcal{A}_j$;
20. Dobivene pravce p_1, p_2 dodati u $\hat{P}$;
21. **end if**
22. **if** $n == 3$ **then**
23. Primijeniti korake 2-7 algoritma 3 na skupu $\mathcal{A}_j$;
24. Dobivene pravce p_0, p_1, p_2 dodati u $\hat{P}$;
25. **end if**
26. **end for**
27. Primijeniti algoritam 1 na skupu $\mathcal{A}$ s početnim centralnim pravcima $\hat{P}$;

pravaca), varijabla *cnt* se postavi na 0, točke skupa $\mathcal{A}$ kopiraju se u skup $\mathcal{A}_0$ te se skupovi P i $\hat{P}$ inicijaliziraju kao prazni skupovi. Prvi dio algoritma 4 (linije $2-16$) dijeli skup $\mathcal{A}_0$ na manje podskupove sve dok se ne dobiju podskupovi koji potječu od dva ili tri pravca. Dijeljenje skupa provodi se iterativno pomoću TLS pravca te se nakon svake podjele provjerava treba li TLS pravce zadržati ili odbaciti (linije $8-10$). Drugi dio algoritma (linije $17-26$) sastoji se od iterativne primjene dijelova algoritma 2, odnosno algoritma 3, ovisno o tome potječu li podijeljeni podskupovi iz koraka i) od 2 ili 3 originalna pravca. U trećem dijelu algoritma 4 na ulaznom skupu točaka $\mathcal{A}$ primjenjuje se k-means algoritam s početnim centralnim pravcima $\hat{P}$. Nakon primijene k-means algoritma dobiva se k približno globalno optimalnih pravaca koji predstavljaju centralne linije redova usjeva.

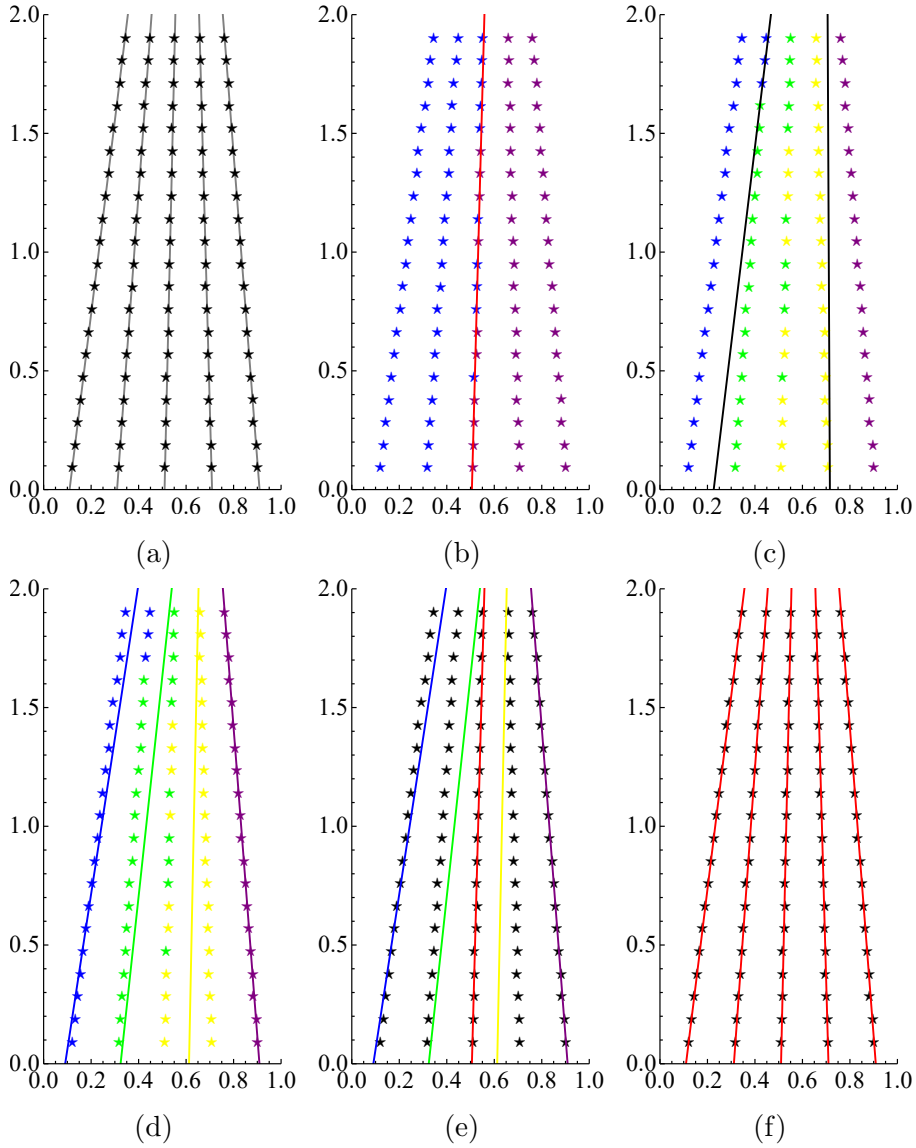

Slika 4.5: Primjer rada algoritma 4. (a) Referentni redovi usjeva i generirane točke, (b) TLS pravac, (c) TLS pravci za lijevi i desni skup točaka iz prethodnog koraka, (d) TLS pravci za četiri podskupa iz prethodnog koraka, (e) Svi pravci koji se koriste kao početni pravci u k-means algoritmu, (f) Pravci dobiveni nakon korekcije k-means algoritmom (algoritam 1).

Primjer rada algoritma 4, podijeljen u nekoliko koraka, prikazan je na slici 4.5. Slika 4.5a prikazuje pet referentnih redova usjeva te točke generirane na temelju tih redova usjeva. Prvi korak algoritma je podjela ulaznog skupa točaka na dva podskupa pomoću TLS pravca. Ovaj korak prikazan je na slici 4.5b gdje su podskupovi označeni plavim i ljubičastim zvjezdicama, a TLS pravac crvenom bojom. Prema algoritmu 4, budući da je n neparan broj, TLS pravac se sprema u skup $\hat{P}$ te se kasnije koristi kao početni pravac u k-means algoritmu. Nakon ovog koraka, vrijednost varijable n u algoritmu 4 jednaka je 2 te se zbog toga na svaki od podskupova prikazanih na slici 4.5b primjenjuje algoritam 2. Prvi korak algoritma 2 je pronalazak TLS pravca koji dijeli skup točaka na dva podsupa. TLS pravci koji dijele podskupove sa slike 4.5b prikazani su na slici 4.5c, gdje su vidljivi i novi podskupovi dobiveni podjelom korištenjem novih TLS pravaca. Za svaki od podskupova sa slike 4.5c određuje se TLS pravac, a dobiveni pravci prikazani su na slici 4.5d. Ovako određeni pravci, zajedno s TLS pravcem iz prvog koraka koriste se kao početni pravci u k-means algoritmu, a prikazani su na slici 4.5e. Nakon korekcije pravaca primjenom k-means algoritma dobivaju se konačni pravci (redovi usjeva) vidljivi na slici 4.5f. Iz ovog primjera može se zaključiti da predloženi algoritam 4 uspijeva prepoznati svih pet unaprijed nepoznatih redova usjeva.

5

Prepoznavanje redova usjeva zasnovano na minimizaciji globalne energije

CRDI metoda predložena u radu (Vidović i Scitovski, 2014) i opisana u poglavlju 4 ima mogućnost prepoznavanja samo unaprijed poznatog broja redova usjeva. Nadalje, nedostatak CRDI metode je i mogućnost detekcije samo ravnih redova usjeva. Potreba za prepoznavanjem zakrivljenih redova usjeva proizlazi iz činjenice da su brežuljci i udubljenja česta pojava u poljima pa se zbog toga paralelni, ravno zasađeni redovi usjeva projiciraju na sliku snimljenu kamerom kao zakrivljene linije (slika 2.6).

Zbog navedenih nedostataka CRDI metode, u sklopu ovog istraživanja predložena je nova metoda za prepoznavanje redova usjeva koja je opisana u nastavku ovog poglavlja, a objavljena je u radu (Vidović et al., 2016). Metoda je nazvana TMGEM metoda što je skraćenica od engleskog izraza *Template Matching followed by Global Energy Minimization*. Osim otklanjanja uočenih nedostataka CRDI metode, ciljevi postavljeni pri razvoju TMGEM metode su razviti metodu robusnu na prisutnost korova i sjene te omogućiti prepoznavanje redova usjeva za različite kulture u različitim stadijima rasta i pri različitim geometrijama polja, što su ujedno i temeljni ciljevi postavljeni u sklopu ovog istraživanja.

Osnovni princip TMGEM metode je definiranje problema prepoznavanja redova usjeva kao optimizacijskog problema koji se može efikasno riješiti primjenom dinamičkog programiranja. Funkcija energije, koja se minimizira, osim podataka sa slike koristi i predznanje o geometrijskoj strukturi redova usjeva. Mogućnost prepoznavanja ravnih i zakrivljenih redova usjeva predstavlja važno svojstvo metode budući da većina pristupa predloženih u

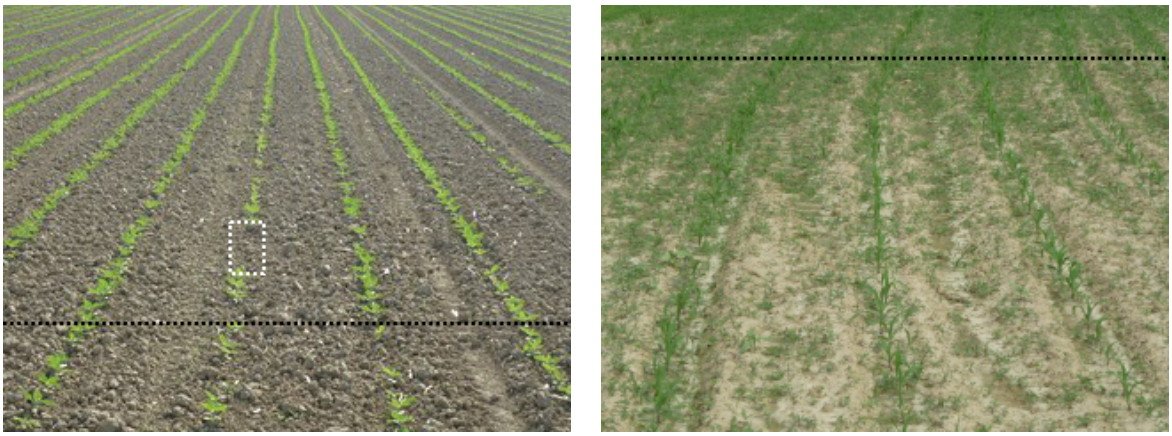

(a) (b)

Slika 5.1: Slika redova usjeva. (a) Bez korova, (b) S puno korova.

literaturi ima mogućnost prepoznavanja samo ravnih redova usjeva.

Predložena metoda sastoji se od tri koraka koji se izvode jedan iza drugog: *i*) *prepoznavanje vegetacije*, *ii*) *prepoznavanje pravilnih uzoraka*, *iii*) *određivanje optimalnih parametara modela*. U koraku prepoznavanja vegetacije, ulazna slika redova usjeva se filtrira te se dobiva nova slika koja se u nastavku naziva *slika vegetacije*. Na slici vegetacije pikseli, koji na originalnoj slici pripadaju vegetaciji, imaju veće vrijednosti intenziteta. Vrijednosti intenziteta na slici vegetacije određuju se korištenjem Excess Green indeksa boje vegetacije. Na dobivenoj slici vegetacije se u drugom koraku primjenjuje algoritam za prepoznavanje pravilnih uzoraka koji su karakteristični za redove usjeva. Spomenuti pravilni uzorci vidljivi su na slici 5.1. Svaki redak slike vegetacije uspoređuje se s nizom pravilnih uzoraka kreiranih za sve kombinacije parametara c_v i d_v CCR modela iz zadanog skupa diskretnih vrijednosti. Značenje parametara CCR modela objašnjeno je u poglavlju 2.3.3. Dobiveni rezultati podudaranja redova slike vegetacije i pravilnih uzoraka predstavljaju temelj za korak određivanja optimalnog modela. U ovom koraku cilj je pronaći optimalni CCR model redova usjeva, odnosno optimalni niz parova parametara redova usjeva (c_v, d_v) za sve redove slike vegetacije. Optimalni niz parova parametara traži se maksimiziranjem rezultata podudaranja za parove parametara u nizu, uz istovremenu minimizaciju promjene parametara za dva susjedna retka slike. U nastavku poglavlja opisani su svi navedeni koraci predložene TMGEM metode.

5.1 Prepoznavanje vegetacije

Prepoznavanje vegetacije je prvi korak predložene TMGEM metode. Za razliku od brojnih metoda predloženih u literaturi (Bakker et al., 2008; Montalvo et al., 2012; Guerrero

et al., 2013; Jiang et al., 2015) koje za prepoznavanje vegetacije koriste razne metode segmentacije, u koraku prepoznavanja vegetacije TMGEM metode ne primjenjuje se ni jedna metoda za segmentaciju slike.

Slika vegetacije se, kao što je ranije rečeno, dobiva računanjem ExG indeksa boje vegetacije. Indeksi boje vegetacije služe kako bi se naglasila boja usjeva na slici u odnosu na ostale elemente na slici (zemlja, kamenje i sl.). U slučaju ExG indeksa naglašava se zelena boja na slici pa se prema tome, na slici naglašavaju oni dijelovi koji pripadaju usjevima i korovu koji je zelene boje. Primjeri slika vegetacije dobiveni računanjem ExG indeksa boje vegetacije za slike 5.1a i 5.1b prikazani su na slikama 5.2a i 5.2b. Treba napomenuti da zbog primjene ExG indeksa TMGEM metoda daje najbolje rezultate prepoznavanja redova usjeva u slučajevima kada su usjevi zelene boje. Ukoliko usjevi, za koje je potrebno prepoznati redove usjeva, nisu zelene boje, sliku vegetacije bi bilo potrebno odrediti primjenom nekog drugog indeksa boje vegetacije ili nekog drugog načina filtriranja i segmentacije ulazne slike polja. Korov koji je u određenim slučajevima zelene boje će na slici vegetacije imati intenzitet sličan intenzitetu dijelova slike koji pripadaju usjevima. Na slici 5.2a se može vidjeti kako dijelovi slike koji pripadaju usjevima imaju znatno veći intenzitet od ostatka slike, dok je na slici 5.2b vidljivo kako korov ima gotovo jednak intenzitet kao i usjevi. TMGEM metoda je robusna na prisutnost korova tako da uspješno prepoznaje redove usjeva i za slučaj prikazan na slici 5.2b, što je pokazano na slici 5.12b i u eksperimentalnoj analizi provedenoj u poglavlju 7.3. Preduvjet koji mora biti zadovoljen kako bi TMGEM metoda bila robusna na prisutnost korova je da usjevi imaju veći intenzitet piksela na slici vegetacije od korova.

Vrijednosti intenziteta slike vegetacije se u nastavku označavaju s $I(u, v)$, gdje u i v

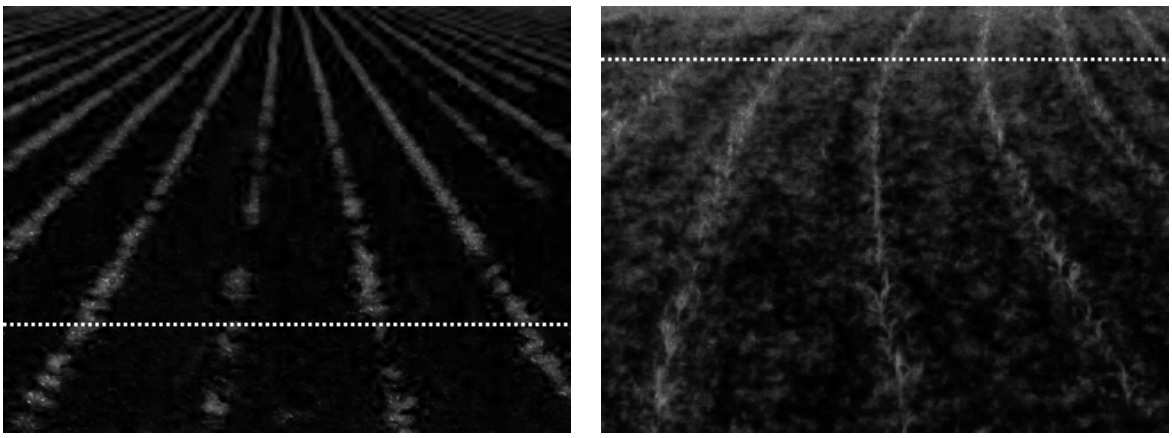

(a) (b)

Slika 5.2: Slike vegetacije dobivene računanjem ExG indeksa boje vegetacije za slike redova usjeva prikazane na slici 5.1.

predstavljaju koordinate stupca, odnosno retka na slici.

5.2 Prepoznavanje pravilnih uzoraka u redovima slike

Na slici 5.1a i 5.1b vidljivi su pravilni ponavljajući uzorci, odnosno vidljivo je da su u svakom retku slike redovi usjeva jednako razmaknuti. Kao što je objašnjeno u poglavlju 2.3.1, ukoliko je kamera pozicionirana iznad polja tako da je x os referentnog koordinatnog sustava kamere paralelna s ravninom polja, tada se paralelni jednako razmaknuti redovi usjeva projiciraju na sliku kao jednako razmaknute krivulje koje imaju zajedničko sjecište (slika 2.5 i 2.6). Pri tome svaki redak snimljene slike siječe određeni broj redova usjeva te se na taj način dobivaju ranije spomenuti pravilni uzorci.

Na slici 5.3 prikazani su profili intenziteta slike vegetacije za retke označene isprekidanim linijama na slici 5.2. Os apscisa na slici 5.3 predstavlja stupac (u) na slici vegetacije, dok os ordinata predstavlja vrijednost intenziteta slike vegetacije za piksel na lokaciji (u, v), gdje v predstavlja redak označen isprekidanom linijom na slici 5.2. Pravilan ponavljajući uzorak intervala velike i male vrijednosti intenziteta uočljiv je na slici 5.3a. Intervali velike vrijednosti intenziteta predstavljaju redove usjeva, dok intervali male vrijednosti intenziteta predstavljaju prostor između redova usjeva. Redovi usjeva na profilu intenziteta su jasno vidljivi kao vrhovi, a razlog tome je što ovaj profil odgovara retku slike prikazanom na slici 5.2a u kojem nema korova. Na slici 5.3b vidljiv je profil intenziteta slike vegetacije za redak s puno korova prikazan na slici 5.2b. Na ovom profilu se može vidjeti da prostor između redova usjeva ima znatno veću vrijednost intenziteta od intenziteta prostora između redova usjeva na profilu prikazanom na slici 5.3a. Redovi usjeva su stoga manje istaknuti, ali su i dalje uočljivi. Kao što je rečeno u prethodnom poglavlju, pretpostavka koja mora biti zadovoljena, kako bi TMGEM metoda uspješno prepoznala redove usjeva na slici, je da su redovi usjeva uočljivi kao vrhovi na profilu intenziteta slike vegetacije. Ovaj uvjet ne mora biti zadovoljen za sve retke slike vegetacije, zbog toga što TMGEM metoda pri određivanju optimalnog CCR modela koristi predznanje o geometriskoj strukturi redova usjeva, kao što je opisano u poglavlju 5.3.

Budući da je udaljenost između dva susjedna reda usjeva jednaka, udaljenost dvaju susjednih vrhova na profilu intenziteta slike vegetacije je također jednaka. Prema tome, ovakvi profili intenziteta se mogu aproksimirati periodičnom funkcijom. Aproksimacija profila intenziteta periodičnom funkcijom može se odrediti primjenom metode podudaranja s predloškom (engl. *template matching*) (Gonzalez i Woods, 2006) pri čemu se

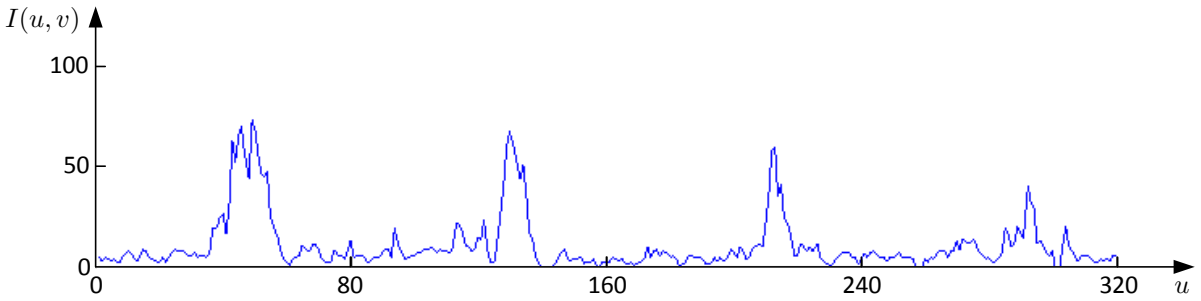

(a)

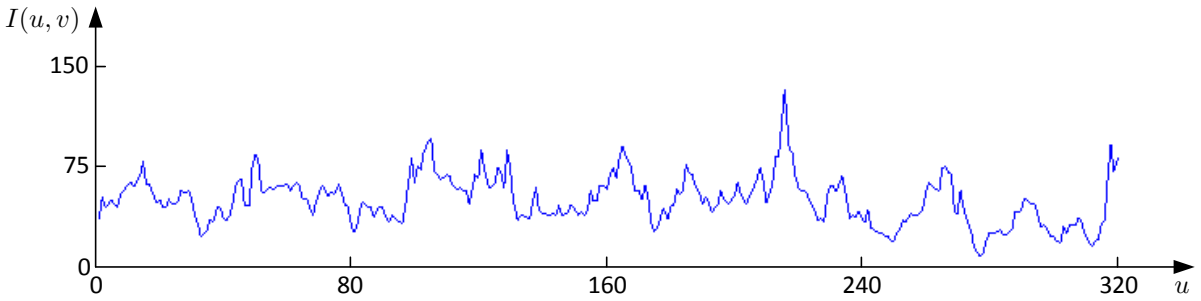

(b)

Slika 5.3: Profili intenziteta za redove slike vegetacije označene isprekidanim linijama na slici 5.2.

periodična funkcija koristi kao predložak.

U nastavku poglavlja opisan je postupak kreiranja predloška redova usjeva na temelju odabranog skupa slika redova usjeva. Nakon toga objašnjena je primjena metode podudaranja s predloškom s ciljem izračunavanja rezultata podudaranja redova slike vegetacije s predlošcima redova usjeva, što predstavlja temelj za korak određivanja optimalnog CCR modela redova usjeva.

5.2.1 Kreiranje predloška redova usjeva

Odgovarajući predložak redova usjeva stvara se na temelju srednjeg profila intenziteta vegetacije. S tim ciljem provedena je analiza profila intenziteta slika vegetacije za 56 stvarnih slika različitih poljoprivrednih kultura. Broj slika određen je odabirom 20% slika od 281 slike u bazi slika redova usjeva opisanoj u poglavlju 6.3. Na većini slika iz baze pri vrhu slike se redovi usjeva spajaju, kako se približavaju horizontu, pa nije vidljiv ranije spomenuti ponavljajući uzorak. Stoga se u analizi intenziteta profila koristi samo doljnja polovica redaka svake od 56 odabranih slika vegetacije. Skup navedenih redova slika vegetacije, koji se koristi za određivanje predloška redova usjeva, se u nastavku rada naziva *skup za učenje*.

Prvi korak analize profila intenziteta slika vegetacije, odnosno kreiranja predloška

redova usjeva, je određivanje referentnih redova usjeva. Za svaku sliku skupa za učenje ručno su kreirani referentni redovi usjeva korištenjem postupka opisanog u poglavlju 6.2. Primjer referentnih redova usjeva prikazan je na slici 6.3. Presjek redaka slike s krivuljama koje predstavljaju referentne redove usjeva je niz jednako razmaknutih točaka koje se mogu opisati parametrima c_v^* i d_v^*, odnosno mogu se opisati CCR modelom redova usjeva.

Sljedeći korak nakon određivanja referentnih redova usjeva je mapiranje svakog piksela (u, v) skupa za učenje na interval $[0, 1)$ prema poziciji piksela u odnosu na referentne redove usjeva. Pri tome 0 označava centar najbližeg reda usjeva lijevo od pozicije (u, v), a 1 označava centar prvog sljedećeg reda usjeva desno od pozicije piksela koji se mapira. Ovakvo mapiranje definirano je izrazom

$$\varphi_v(u) = \frac{u - (u_c + c_v^* + \tau d_v^*)}{d_v^*}, \tag{5.1}$$

pri čemu u_c ima vrijednost koja odgovara centru slike, a τ je najveći cijeli broj za koji vrijedi $\varphi_v(u) \geq 0$. Primjer mapiranja jednog piksela prikazan je na slici 5.4 gdje su referentni redovi usjeva označeni zelenom bojom. Na slici se može uočiti da je piksel s koordinatama (u, v) mapiran na vrijednost 0.6. Na isti način mapiraju se svi ostali pikseli. Nakon mapiranja svih piksela u skupu za učenje, interval $[0, 1)$ se dijeli na n jednakih podintervala i za svaki od podintervala se formira skup piksela S_i, $i = 1, \ldots, n$ definiran izrazom

$$S_i = \left\{ (u, v) \middle| \frac{i-1}{n} \leq \varphi_v(u) < \frac{i}{n} \right\}. \tag{5.2}$$

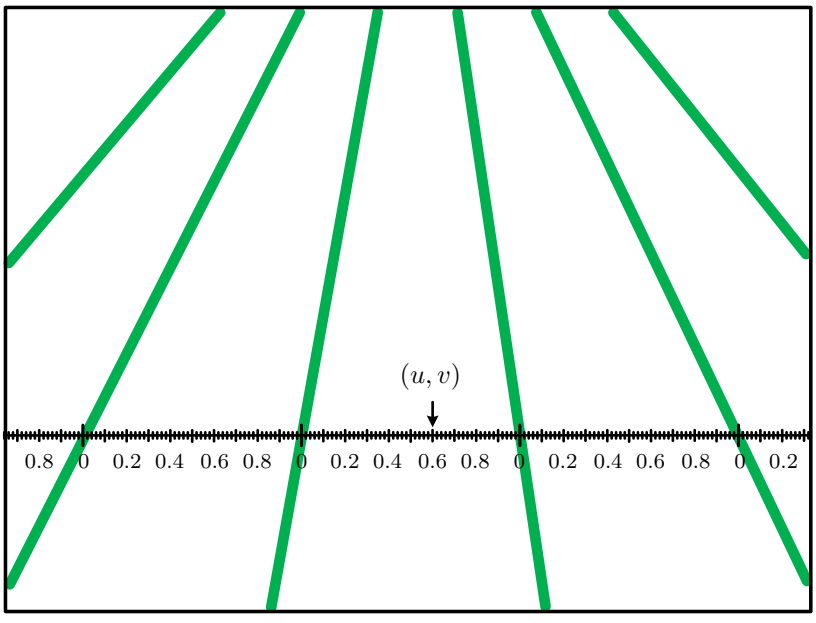

Slika 5.4: Primjer mapiranja piksela slike na interval $[0, 1)$.

Zbog razumljivosti prikaza, izraz (5.2) je definiran samo za jednu sliku, ali u postupku kreiranja predloška redova usjeva podskupovi S_i se formiraju za sve piksele u skupu za učenje.

Konačno, za svaki podskup S_i računa se srednja vrijednost intenziteta vegetacije pomoću izraza

$$\bar{I}_i = \frac{1}{|S_i|} \sum_{(u,v)\in S_i} I(u,v), \tag{5.3}$$

gdje $I(u,v)$ predstavlja vrijednost intenziteta piksela na slici vegetacije s lokacijom (u,v), a $|\cdot|$ označava broj elemenata skupa. Iz definicije izraza $\bar{I}_i$ i jednadžbi (5.1) i (5.2) može se zaključiti da vrijednosti $\bar{I}_i$ predstavlja srednju vrijednost intenziteta slike vegetacije na odgovarajućoj poziciji između dva susjedna reda usjeva. Prema tome, vektor $\mathbf{p} = [\bar{I}_1, \ldots, \bar{I}_n]$ se može smatrati *srednjim profilom intenziteta vegetacije*. Primjer takvog srednjeg profila intenziteta vegetacije prikazan je na slici 5.5.

Srednji profil intenziteta vegetacije, odnosno vektor $\mathbf{p}$, mogao bi se koristiti kao predložak redova usjeva za postupak podudaranja s predloškom zasnovan na poprečnoj korelaciji (engl. *cross-correlation*) (Gonzalez i Woods, 2006). Međutim, računanje poprečne korelacije s ovako definiranim predloškom predstavlja računski zahtjevnu operaciju. Kako bi se smanjili računski zahtjevi, dobiveni srednji profil intenziteta vegetacije aproksimira se jednostavnijom funkcijom M_0. Funkcija M_0, prikazana isprekidanom linijom na slici 5.5,

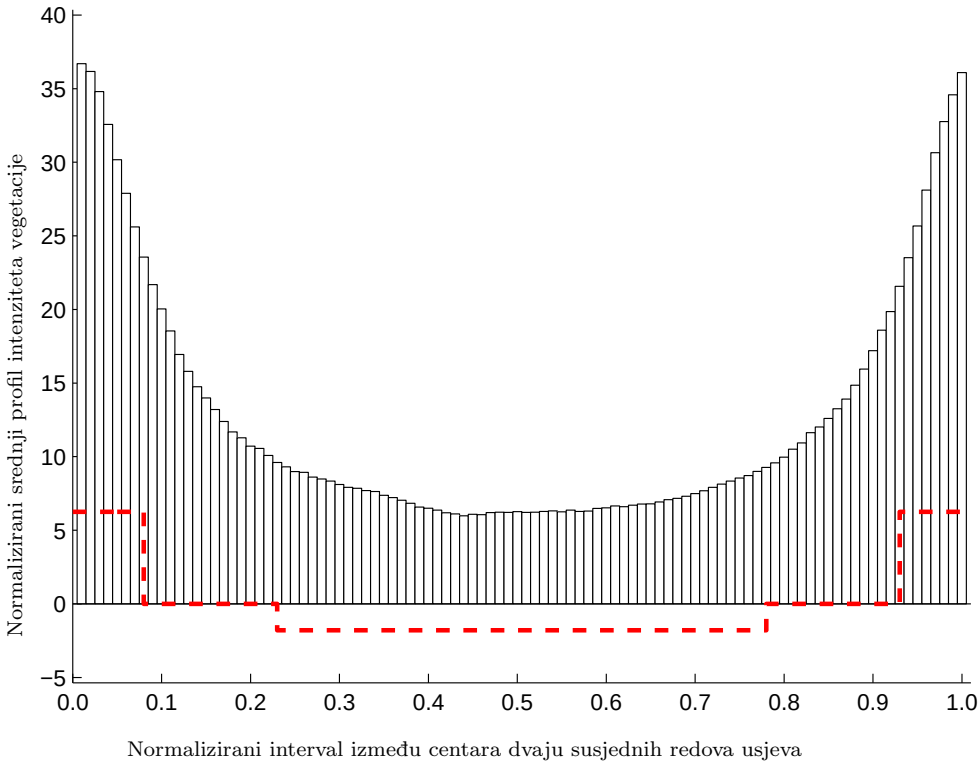

Slika 5.5: Srednji profil intenziteta vegetacije (histogram) i funkcija M_0 (isprekidana linija).

omogućava efikasan izračun poprečne korelacije primjenom kumulativne sume (engl. *cumulative sum*), što je pokazano u u nastavku poglavlja. Domena funkcije M_0 je interval $[0, 1)$, a definirana je izrazom

$$M_0(y; a, b) = \begin{cases} z_a, & \text{ako je } y \leq a/2 \ \vee \ y \geq 1 - a/2 \\ -z_b, & \text{ako je } (1-b)/2 \leq y \leq (1+b)/2 \\ 0, & \text{u suprotnom.} \end{cases} \tag{5.4}$$

Kao što se može vidjeti na slici 5.5, funkcija M_0 sastoji se od tri pravokutna intervala. Pozitivni intervali predstavljaju polovine dvaju susjednih redova usjeva, dok negativni interval predstavlja prostor između tih redova u kojem nema vegetacije ili raste nisko raslinje (korov). Širine pozitivnih i negativnih intervala definirane su parametrima a i b, a amplitude intervala parametrima z_a i z_b. Ostatak intervala $[0, 1)$, s amplitudom nula, predstavlja *granično područje* između redova usjeva i prostora niske vegetacije. U slučajevima kada je veličina biljaka relativno velika u odnosu na udaljenost između susjednih redova usjeva, granična područja mogu biti prekrivena redovima usjeva, a u slučajevima kada je veličina biljaka znatno manja, granična područja mogu biti nastavak područja niske vegetacije. Prema tome, kreirani predložak bi trebao biti pogodan za prepoznavanje redova usjeva u slučajevima različitih veličina usjeva. Srednji profil intenziteta vegetacije prikazan na slici 5.5 izračunat je za različite poljoprivredne kulture pa bi stoga predložak kreiran na temelju takvog profila trebao biti pogodan za prepoznavanje redova usjeva za različite kulture. Važno je naglasiti da, čak i ako se kreira samo za jednu kulturu, predložak treba biti pogodan za prepoznavanje različitih veličina usjeva kako bi bio primjenjiv za prepoznavanje redova usjeva u različitim stadijima rasta kulture.

U nastavku poglavlja razmatraju se parametri z_a i z_b. Ako su vrijednosti parametara z_a i z_b postavljene na

$$\begin{aligned} z_a &= \frac{\kappa}{a}, \\ z_b &= \frac{\kappa}{b}, \end{aligned} \tag{5.5}$$

gdje je κ proizvoljna pozitivna konstanta, tada funkcija M_0 na intervalu $[0, 1)$ ima srednju vrijednost nula, što je uobičajeno svojstvo predložaka korištenih u algoritmima podudaranja s predloškom.

Optimalne vrijednosti parametara a i b određuju se kao kombinacija parametara koja ima najveću vrijednost normalizirane poprečne korelacije (engl. *normalized cross-correlation*) s profilom $\mathbf{p}$. Vrijednost normalizirane poprečne korelacije računa se pomoću

izraza

$$f_p(a,b) = \frac{\sum_{i=1}^{n} M_0(i/n;a,b)\cdot \bar{I}_i}{\sigma_M \sigma_p}, \tag{5.6}$$

gdje su σ_M i σ_p standardne devijacije funkcije M_0 i profila $\mathbf{p}$. Budući da je

$$\sigma_M = \kappa\sqrt{\frac{1}{a}+\frac{1}{b}} \tag{5.7}$$

i σ_p ne ovisi o parametrima a i b, maksimizacija funkcije (5.6) ekvivalentna je maksimizaciji funkcije

$$f'_{p(a,b)} = \frac{1}{\sqrt{\frac{1}{a}+\frac{1}{b}}} \sum_{i=1}^{n} M_0(i/n;a,b)\cdot \bar{I}_i, \tag{5.8}$$

gdje je

$$z_a = \frac{1}{a},$$
$$z_b = \frac{1}{b}.$$

Maksimizacija funkcije (5.8) napravljena je računanjem vrijednosti funkcije $f'_{p(a,b)}$ za sve kombinacije parametara a i b odabrane iz intervala $[0.02, 0.98]$ s korakom 0.02. Maksimalna vrijednost funkcije (5.8) dobivena je za parametre $a = 0.16$ i $b = 0.56$. Funkcija M_0 s navedenim vrijednostima parametara a i b prikazana je na slici 5.5.

Budući da funkcija M_0 predstavlja predložak jednog reda usjeva (polovice dvaju susjednih redova usjeva i prostor između njih), repliciranjem takvog predloška može se kreirati predložak za k redova usjeva. Takav predložak je periodična funkcija pozitivnih i negativnih pravokutnih impulsa (intervala) i u nastavku rada se označava s M. Parametrizirani oblik predloška, dobiven na temelju funkcije M, može se kreirati pomicanjem funkcije M za vrijednost parametra c i skaliranjem s vrijednošću parametra d. U nastavku rada se ovakav parametrizirani predložak naziva *predložak redova usjeva*, a prikazan je na slici 5.6. Funkcija M, koja predstavlja predložak redova usjeva, definirana je sljedećim izrazima

$$M(u,\mathbf{x}) = M_0\left(\frac{u-u_c-c}{d}\right), \quad \text{za } c \le u-u_c \le c+d, \tag{5.9}$$

$$M(u,\mathbf{x}) = M(u-d,\mathbf{x}), \tag{5.10}$$

gdje $\mathbf{x} = [c,\ d]^T$ predstavlja vektor parametara objašnjenih u poglavlju 2.3.3, a u_c ima vrijednost koja odgovara središtu slike. Iz izraza (5.9) i (5.10) može se zaključiti da se za svaki par parametara c i d dobiva drugačiji predložak redova usjeva. Prema tome, kreiranjem niza predložaka, za različite parove parametara c i d, omogućeno je prepoznavanje redova usjeva različitog međusobnog razmaka za različite veličine usjeva i za različite

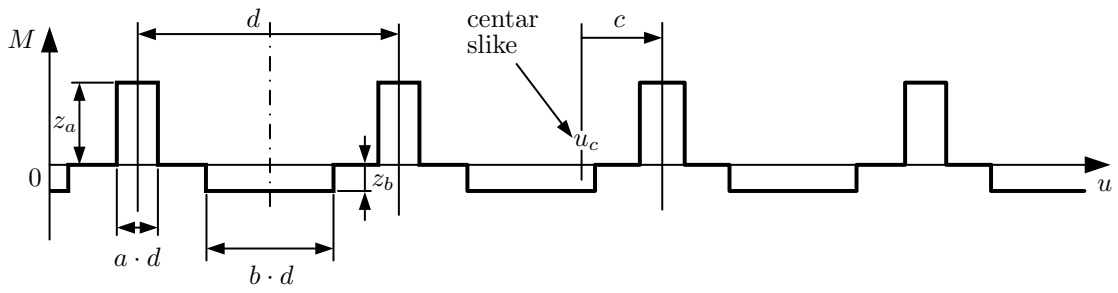

Slika 5.6: Predložak redova usjeva.

položaje redova usjeva na slici. U nastavku poglavlja objašnjen je način određivanja sličnosti predložaka redova usjeva i redaka slike vegetacije primjenom postupka podudaranja s predloškom.

5.2.2 Računanje podudaranja redova slike s predlošcima redova usjeva

Predložak, opisan funkcijom M, koja je kreirana na temelju srednjeg profila intenziteta vegetacije, predstavlja idealizirani profil intenziteta jednog retka slike vegetacije. Sličnost v-tog retka slike vegetacije i predloška redova usjeva s parametrima c i d može se odrediti računanjem poprečne korelacije

$$f_v(\mathbf{x}) = \sum_{u=0}^{w-1} I(u, v) \cdot M(u, \mathbf{x}), \tag{5.11}$$

pri čemu je w širina slike vegetacije. Vrijednost funkcije $f_v(\mathbf{x})$ predstavlja mjeru podudaranja koja se može promatrati kao vjerojatnost da v-ti redak slike vegetacije predstavlja redove usjeva opisane vektorom parametara $\mathbf{x} = [c,\ d]^T$ (poglavlje 2.3.3).

Zbog utjecaja perspektive, čak i idealno paralelni redovi usjeva se na sliku projiciraju kao linije koje imaju zajedničko sjecište (poglavlje 2.3.1) pa stoga parametri c i d imaju različite vrijednosti za različite retke slike vegetacije. Optimalni vektor parametara $\mathbf{x}$, odnosno optimalne vrijednosti parametara c_v i d_v za v-ti redak slike, mogu se odrediti računanjem vrijednosti funkcije $f_v(\mathbf{x})$ za različite vrijednosti parametara $\mathbf{x}$ te odabirom onih parametara za koje je mjera podudaranja najveća. Računanje vrijednosti funkcije (5.11) za različite vrijednosti parametara $\mathbf{x}$ predstavlja računanje poprečne korelacije između v-tog retka slike i niza predložaka redova usjeva opisanih različitim vrijednostima vektora $\mathbf{x}$. Primjeri predložaka redova usjeva za tri kombinacije vektora parametara $\mathbf{x}$ prikazani su na slici 5.7. Stvarni profil intenziteta određenog retka slike vegetacije može

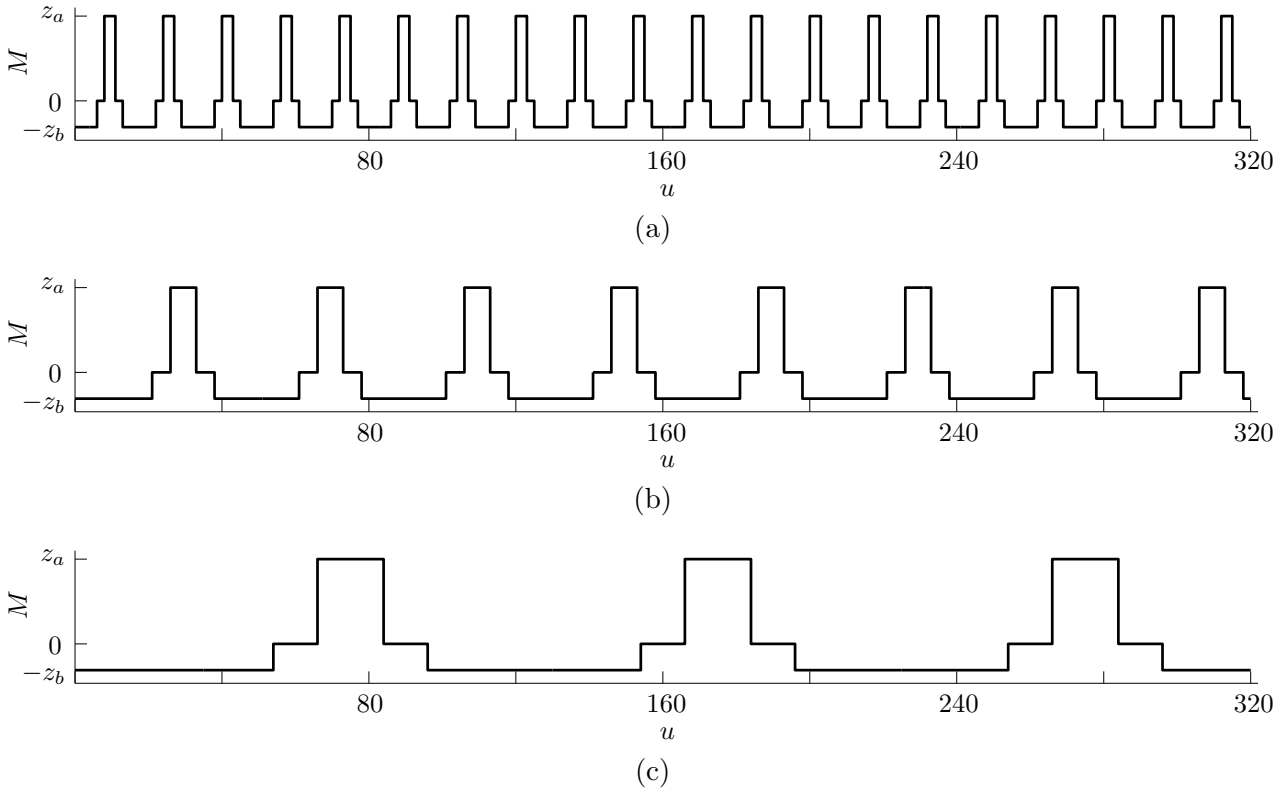

Slika 5.7: Primjeri predložaka redova usjeva za tri kombinacije parametara c i d. (a) $c = 10$, $d = 16$, (b) $c = -10$, $d = 40$, (c) $c = 15$, $d = 100$.

značajno odstupati od idealiziranog predloška redova usjeva zbog različitih veličina biljaka, nesavršenog pozicioniranja sijačice, prisutnosti korova i utjecaja svjetlosti odnosno sjene. Međutim, vektor $\mathbf{x}$ za koji je mjera podudaranja (5.11) najveća, je većinom jako sličan točnom vektoru $\mathbf{x}$, kao što je pokazano na slici 5.9 i u eksperimentima provedenim u poglavlju 7.3.

Pristup predložen u ovom radu podrazumijeva usporedbu svakog retka slike vegetacije s nizom predložaka redova usjeva M, pri čemu svaki predložak odgovara jednom vektoru $\mathbf{x}$ iz diskretnog podskupa $\chi \subset \mathbb{R}^2$. Skup χ bi trebao sadržavati sve očekivane vrijednosti parametara c i d kojima bi se omogućilo upravljanje poljoprivrednim strojem sa željenom preciznošću. Međutim, velika rezolucija skupa χ, kao i veliki raspon vrijednosti koje taj skup pokriva za rezultat ima velik broj elemenata skupa. Budući da se za svaki $\mathbf{x} \in \chi$ mora računati vrijednost izraza (5.11), računska složenost predloženog postupka povećava se s povećanjem broja elemenata skupa χ. Stoga pravilan odabir vrijednosti skupa χ ima značajan utjecaj na performanse cjelokupne TMGEM metode. U istraživanju provedenom u sklopu izrade ove doktorske disertacije, skup χ je odabran na sljedeći način. Interval $\langle d_{min}, d_{max} \rangle$ uzorkovan je uniformno u logaritamskoj skali, pri čemu svaka oktava sadrži n_{spo} diskretnih vrijednosti. Izraz oktava označava interval između vrijednosti d i $2d$.

Prema tome, diskretne vrijednosti parametra d korištene za formiranje skupa χ računaju se prema izrazu

$$d = d_{min} 2^{\frac{i}{n_{spo}}}, \tag{5.12}$$

gdje je $i = 0, 1, \ldots, n_d$, a n_d je broj diskretnih vrijednosti parametra d. Za određenu vrijednost parametra d, vrijednosti parametra c određene su uniformnim uzorkovanjem intervala $\langle -d/2, d/2 \rangle$, pri čemu razlika između dvije uzastopne vrijednosti iznosi 1 piksel.

Kao što je ranije rečeno, za određenu sliku vegetacije $\mathbf{I}$ potrebno je odrediti mjeru podudaranja $f_v(\mathbf{x})$ između svakog retka slike i niza predložaka definiranih vektorom parametara $\mathbf{x}$ iz diskretnog skupa χ. Mjere podudaranja za sliku vegetacije mogu se izračunati primjenom algoritma 5 koji je opisan u nastavku. Ulazi u algoritam 5 su slika vegetacije $\mathbf{I}$, minimalna vrijednost parametra d označena s d_{min}, broj vrijednosti parametra d po oktavi označen s n_{spo}, broj oktava n_{oct}, širine pozitivnih i negativnih impulsa funkcije M označene s a i b, širina slike w i centar retka slike u_c. U ovom radu parametar u_c postavljen je na vrijednost $w/2$. Simbol $[d/2]$ u liniji 5 označava zaokruživanje na najbliži cijeli broj u okolini vrijednosti $d/2$. Funkcija *CrossCorrelation* u liniji 7 predstavlja poprečnu korelaciju između v-tog retka slike i predloška redova usjeva definiranog vektorom parametara $\mathbf{x}$. Poprečna korelacija retka slike i predloška redova usjeva može se efikasno izračunati primjenom kumulativne sume, što je pokazano u nastavku.

Kumulativna suma retka slike vegetacije može se definirati izrazom

$$J(u, v) = \sum_{i=0}^{u} I(u, v). \tag{5.13}$$

Izraz (5.11) za određeni redak slike vegetacije i pravokutni impuls prikazan na slici 5.8, može se efikasno izračunati korištenjem kumulativne sume razmatranog retka slike vege-

Algoritam 5 Podudaranje s predloškom.

Ulaz: $\mathbf{I}, d_{min}, n_{spo}, n_{oct}, a, b, w, u_c$
Izlaz: $f_v(\mathbf{x})$, za sve $\mathbf{x} \in \chi$, $v = 0, 1, \ldots h-1$, gdje je χ definiran s $d_{min}, n_{spo}, n_{oct}$

1. $n_d = n_{spo} \cdot n_{oct} + 1$
2. **for** $v = 0$ **to** $h - 1$ **do**
3. **for** $k = 0$ **to** $n_d - 1$ **do**
4. $d = d_{min} 2^{\frac{k}{n_{spo}}}$
5. **for** $c = -[d/2]$ **to** $[d/2] - 1$ **do**
6. $\mathbf{x} = [c,\ d]^T$
7. $f_v(\mathbf{x}) = \text{CrossCorrelation}(\mathbf{I}, \mathbf{x}, v, a, b, w, u_c)$
8. **end for**
9. **end for**
10. **end for**

Slika 5.8: Primjer pravokutnog impulsa.

tacije na sljedeći način

$$\sum_{i=0}^{w-1} I(u,v) \cdot M^{'}(u) = z \cdot (J(u_2,v) - J(u_1,v)). \tag{5.14}$$

Budući da predložak redova usjeva, opisan funkcijom M, predstavlja niz pozitivnih i negativnih pravokutnih impulsa, za određeni predložak $M(u,\mathbf{x})$ mjera podudaranja (5.11) može se efikasno izračunati korištenjem konačnog broja operacija (5.14). Broj operacija iznosi približno $2w/d$, pri čemu w označava širinu slike. U predloženoj metodi, izraz (5.11) se za određeni parametar d računa za svaku vrijednost parametra c iz intervala $\langle -d/2, d/2\rangle$. Prema tome, složenost postupka podudaranja s predloškom za svaku vrijednost parametra d može se procijeniti na $O(w)$. Za svaki od h redaka slike vegetacije, u predloženoj metodi, razmatra se n_d vrijednosti parametra d. Stoga se, složenost postupka podudaranja s predloškom za cijelu sliku, može procijeniti na $O(w \cdot h \cdot n_d)$, gdje $w \cdot h$ predstavlja ukupan broj piksela na slici.

Algoritam 6 predstavlja pseudokod koji se može iskoristiti za efikasno računanje mjere podudaranja $f_v(\mathbf{x})$. U algoritmu 6 ulazi su slika vegetacije $\mathbf{I}$, vektor parametara $\mathbf{x}$, razmatrani redak slike v, parametri predloška redova usjeva a i b te širina slike w i centar redaka slike u_c, a izlaz je vrijednost mjere podudaranja $f_v(\mathbf{x})$. Parametar u_c je u ovom radu postavljen na vrijednost $w/2$. Simbol $[u]$ označava zaokruživanje na najbliži cijeli broj u okolini u, $\lceil u \rceil$ zaokruživanje na prvi veći cijeli broj od u, dok $sat(u; u_{min}, u_{max})$ označava funkciju zasićenja koja je definirana izrazom

$$sat(u; u_{min}, u_{max}) = \max\{\min\{u, u_{max}\}, u_{min}\}. \tag{5.15}$$

Kumulativna suma je u algoritmu 6 definirana izrazom

$$J(u,v) = \begin{cases} \sum_{i=0}^{u} I(u,v), & \text{ako je } u > 0 \\ 0, & \text{za } u = 0. \end{cases} \tag{5.16}$$

Algoritam 6 iterativno računa vrijednost mjere podudaranja (5.11) za predložak redova

Algoritam 6 Poprečna korelacija retka slike vegetacije i predloška redova usjeva.

Ulaz: $\mathbf{I}$, $\mathbf{x} = [c, d]^T$, v, a, b, w, u_c
Izlaz: $f_v(\mathbf{x})$

1. $u = u_c + c - \lceil \frac{u_c + c}{d} \rceil \cdot d$
2. $f_a = 0$
3. $f_b = 0$
4. $\mu_a = 0$
5. $\mu_b = 0$
6. **repeat**
7. $\quad u_{a1} = \left[u - \frac{a}{2}\right]$
8. $\quad u_{a2} = u_{a1} + a$
9. $\quad u_{b1} = \left[u + \frac{d}{2} - \frac{b}{2}\right]$
10. $\quad u_{b2} = u_{b1} + b$
11. $\quad \bar{u}_{a1} = sat(u_{a1}; 0, w)$
12. $\quad \bar{u}_{a2} = sat(u_{a2}; 0, w)$
13. $\quad \bar{u}_{b1} = sat(u_{b1}; 0, w)$
14. $\quad \bar{u}_{b2} = sat(u_{b2}; 0, w)$
15. $\quad f_a = f_a + J(\bar{u}_{a2}, v) - J(\bar{u}_{a1}, v)$
16. $\quad f_b = f_b + J(\bar{u}_{b2}, v) - J(\bar{u}_{b1}, v)$
17. $\quad \mu_a = \mu_a + \bar{u}_{a2} - \bar{u}_{a1}$
18. $\quad \mu_b = \mu_b + \bar{u}_{b2} - \bar{u}_{b1}$
19. $\quad u = u + d$
20. **until** $u - \frac{a}{2} > w$
21. $z_a = \frac{1}{\mu_a}$
22. $z_b = \frac{1}{\mu_b}$
23. $f_v(\mathbf{x}) = z_a \cdot f_a - z_b \cdot f_b$

usjeva, definiran parametrima a, b, c i d, i v-ti redak slike vegetacije. Parametar u predstavlja centar pozitivnih impulsa predloška redova usjeva. Vrijednost parametra u je u liniji 1 inicijalno postavljena na iznos koji je za d manji od centra prvog pozitivnog impulsa s lijeva te se u svakoj iteraciji povećava za vrijednost d. Algoritam završava kada vrijednost parametra u postane toliko velika da se cijeli pozitivni impuls nalazi izvan slike. Parametri μ_a i μ_b predstavljaju ukupan broj piksela slike koji odgovaraju pozitivnim, odnosno negativnim pravokutnim impulsima. Vrijednosti parametara z_a i z_b su u liniji 21 i 22 određene na način da predložak redova usjeva ima srednju vrijednost jednaku nula. Konačni rezultat mjere podudaranja u liniji 23 određen je zbrajanjem doprinosa poprečne korelacije s pozitivnim i negativnim pravokutnim impulsima.

Na slici 5.9 su prikazana dva primjera određivanja pravilnih uzoraka, odnosno najboljih parametara c i d, za retke slike vegetacije prikazane na slici 5.3. Najbolji parametri određeni su na temelju rezultata usporedbe radaka slike vegetacije prikazanih na slici 5.3 i 24832 predložaka redova usjeva. Svaki piksel na slici 5.9 predstavlja rezultat jedne usporedbe. Os apscisa na slici 5.9 predstavlja vrijednosti parametra c, a os ordinata

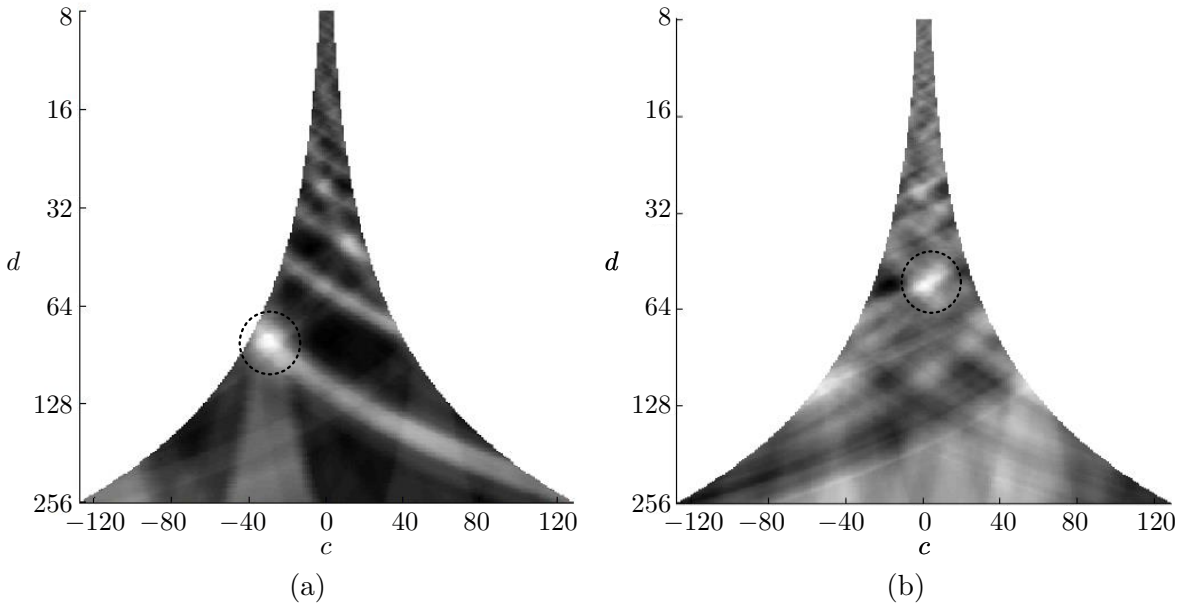

Slika 5.9: Vrijednosti mjere podudaranja za retke slike vegetacije prikazane na slici 5.3. Globalni maksimumi su označeni iprekidanim kružnicama.

vrijednosti parametra d. Prema tome, piksel s koordinatama (c, d) predstavlja rezultat usporedbe promatranog retka slike vegetacije i predloška redova usjeva definiranog parametrima c i d. Intenzitet piksela na slici odgovara vrijednosti mjere podudaranja $f_v(\mathbf{x})$ pri čemu svjetlije vrijednosti intenziteta odgovaraju većim vrijednostima $f_v(\mathbf{x})$ i obrnuto. Globalni maksimum mjere podudaranja $f_v(\mathbf{x})$, koji odgovara točnim parametrima c i d, je na slici 5.9a jasno vidljiv. Na slici 5.9b, koja predstavlja rezultate usporedbe retka slike s puno korova (slika 5.3b), postoji puno više lokalnih maksimuma i globalni maksimum nije istaknut kao na slici 5.9a. Ipak globalni maksimum, označen isprekidanom kružnicom, predstavlja točne parametre razmatranog retka slike vegetacije.

Zbog prisutnosti korova ili prekida u redovima usjeva, poput onog prikazanog bijelim isprekidanim pravokutnikom na slici 5.1a, za određene retke slike vegetacije pravilni uzorci ne mogu biti pouzdano određeni. U takvim slučajevima točno određeni parametri za ostale retke slike mogu se iskoristiti za rekonstrukciju dijelova redova usjeva koji nedostaju. Postupak, koji objedinjuje informacije dobivene na temelju primjene postupka podudaranja s predloškom na zasebne retke slike vegetacije u globalni model redova usjeva, opisan je u nastavku poglavlja.

5.3 Određivanje optimalnog modela redova usjeva

Redovi usjeva vidljivi na slici mogu se modelirati CCR modelom (poglavlje 2.3.3), odnosno nizom vektora parametara $\mathbf{x}_0, \ldots, \mathbf{x}_{h-1}$, pri čemu $\mathbf{x}_v$ predstavlja vektor parametara

za v-ti redak slike, a h ukupan broj redaka slike. U nastavku se pretpostavlja da je vrijednost mjere podudaranja $f_v(\mathbf{x})$ zadovoljavajuća mjera vjerojatnosti da određeni vektor parametara $\mathbf{x}_v$ predstavlja točnu interpretaciju v-tog retka slike vegetacije. Ukoliko se svaki redak slike vegetacije promatra zasebno, optimalni CCR model, za danu sliku, može se odrediti maksimiziranjem funkcije energije

$$E^{'}(\mathbf{x}_0, \ldots, \mathbf{x}_{h-1}) = \sum_{i=0}^{h-1} f_i(\mathbf{x}_i). \tag{5.17}$$

Funkcija energije definirana izrazom (5.17) ima maksimalnu vrijednost za niz vektora parametara $\mathbf{x}_0, \ldots, \mathbf{x}_{h-1}$, pri čemu svaki vektor parametara $\mathbf{x}_v$ predstavlja one parametre za koje je mjera podudaranja $f_v(\mathbf{x})$ maksimalna. Takav niz vektora $\mathbf{x}_v$ može se odrediti pomoću izraza

$$\mathbf{x}_v = \underset{\mathbf{x}}{\operatorname{argmax}}\, f_v(\mathbf{x}), \quad v = 0, \ldots, h-1. \tag{5.18}$$

Važno je uočiti da CCR model određen maksimiziranjem funkcije energije (5.17) nedovoljno koristi predznanje o geometrijskoj strukturi redova usjeva. Naime, na slici koja prikazuje stvarne redove usjeva, parametri c i d se, za dva susjedna retka slike, ne mijenjaju značajno. Korištenjem navedene činjenice, može se odrediti puno realističniji CCR model redova usjeva. Realistični CCR model se, u sklopu ovog istraživanja, određuje traženjem niza vektora parametara $\mathbf{x}_0, \ldots, \mathbf{x}_{h-1} \in \chi$ koji minimiziraju funkciju globalne energije

$$E_{h-1}(\mathbf{x}_0, \ldots, \mathbf{x}_{h-1}) = \sum_{i=0}^{h-1} D_i(\mathbf{x}_i) + \sum_{i=0}^{h-2} V(\mathbf{x}_i, \mathbf{x}_{i+1}), \tag{5.19}$$

gdje je $D_i(\mathbf{x}_i)$ funkcija troška (engl. *cost function*) koja vektorima parametara $\mathbf{x}$ s većom vrijednosti mjere podudaranja $f_i(\mathbf{x})$ pridružuje manje vrijednosti, a $V(\mathbf{x}, \mathbf{x}')$ je funkcija koja penalizira razliku u parametrima c i d za dva susjedna retka slike. Funkcije D i V definirane su sljedećim izrazima

$$D_v(\mathbf{x}) = \min\left(1 - \frac{f_v(\mathbf{x})}{f_{v,max}}, D_{max}\right), \tag{5.20}$$

$$V(\mathbf{x}, \mathbf{x}') = \lambda_c(c^{'} - c)^2 + \lambda_d(d^{'} - d)^2, \tag{5.21}$$

gdje je

$$f_{v,max} = \max_{\mathbf{x}} f_v(\mathbf{x}),$$

a λ_c, λ_d i D_{max} su korisnički definirani parametri. Parametri λ_c i λ_d su konstante penalizacije razlike parametara c i d za dva susjedna retka slike. Za veće vrijednosti parametara

λ_c i λ_d, razlika u parametrima se više penalizira, dok se za manje vrijednosti razlika manje penalizira, odnosno veća važnost se daje rezultatu dobivenom primjenom postupka podudaranja s predloškom. Mjera podudaranja $f_v(\mathbf{x})$, dobivena primjenom postupka podudaranja s predloškom, može u određenim slučajevima biti veća za vektor parametara $\mathbf{x}$ koji predstavlja pogrešne parametre redova usjeva od mjere podudaranja za točni vektor parametara. Tada se takvi redci slike predstavljaju krivim modelom redova usjeva, odnosno takvi redci slike se mogu smatrati odudarajućim vrijednostima (engl. *outliers*). Ovakvi slučajevi se mogu dogoditi zbog prekida u stvarnim redovima usjeva (bijeli isprekidani pravokutnik na slici 5.1a) ili zbog prisutnosti korova u prostoru između redova usjeva. Čest pristup za smanjivanje osjetljivosti metoda optimizacije na odudarajuće vrijednosti je ograničavanje funkcije troška. Stoga se, kao što je vidljivo u izrazu (5.20), za sve parametre $\mathbf{x}$ za koje vrijedi

$$1 - \frac{f_v(\mathbf{x})}{f_{v,max}} > D_{max}, \tag{5.22}$$

vrijednost $D_v(\mathbf{x})$ postavlja na D_{max}. Na taj način se u slučaju odudarajućih vrijednosti, odnosno kada je izraz (5.22) istinit za točan vektor parametara $\mathbf{x}$, odabir optimalnih vrijednosti parametara $\mathbf{x}_v$ obavlja na temelju funkcije V, što znači da se odabire vektor parametara koji je u prostoru parametara blizu vektoru parametara prethodnog retka slike.

Ukoliko u određenom retku slike nije jasno vidljiv ponavljajući uzorak karakterističan za sliku redova usjeva, tada je za taj redak maksimalna vrijednost mjere podudaranja $f_{v,max}$ jako mala. U takvim slučajevima vrijednost $D_v(\mathbf{x})$ nije relevantna za određivanje optimalnih vrijednosti parametara $\mathbf{x}$. Prema tome, ako je vrijednost $f_{v,max}$ manja od zadanog praga f_{low}, vrijednost $D_v(\mathbf{x})$ se postavlja na D_{max} za sve $\mathbf{x} \in \chi$. U eksperimentima provedenim u sklopu ovog istraživanja prag f_{low} postavljen je na ekperimentalno određenu vrijednost koja iznosi 1. Na slici 5.10 prikazan je primjer vrijednosti $f_{v,max}$ za sliku 5.1a. Iz prikazanog primjera može se uočiti da, za sliku u kojoj su redovi usjeva jasno vidljivi, vrijednost $f_{v,max}$ značajno veća od vrijednosti praga $f_{low} = 1$.

Minimizacija funkcije globalne energije (5.19) može se izvesti primjenom algoritma zasnovanog na dinamičkom programiranju, koji je opisan u radu (Felzenszwalb i Zabih, 2011). Algoritam 7 predstavlja implementaciju spomenutog algoritma za rješavanje problema traženja optimalnog CCR modela. Primjenom algoritma 7 se za zadane parametre $h, \lambda_c, \lambda_d, D_{max}$ i f_{low} određuje optimalni niz $\mathbf{x}_0, \ldots, \mathbf{x}_{h-1}$ koji minimizira funkciju glo-

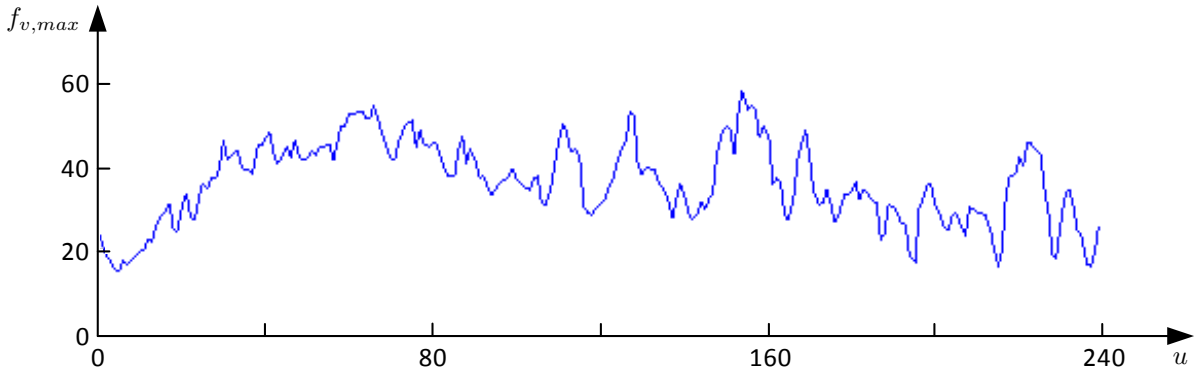

Slika 5.10: Maksimalne vrijednosti mjere podudaranja $f_{v,max}$ za sve retke slike 5.1a.

balne energije (5.19). Ulazi u algoritam su skup χ i vrijednosti mjere podudaranja $f_v(\mathbf{x})$ izračunate za svaki $\mathbf{x} \in \chi$ te ranije spomenuti parametri $h, \lambda_c, \lambda_d, D_{max}$ i f_{low}.

Algoritam 7 se sastoji od dva dijela. U prvom dijelu se, počevši od prvog retka slike, za svaki sljedeći redak određuje optimalni niz $\mathbf{x}_0, \ldots, \mathbf{x}_{v-1}$ koji minimizira funkciju globalne energije $E_v(\mathbf{x}_0, \ldots, \mathbf{x}_{v-1}, \mathbf{x})$. Takav optimalni niz koji minimizira funkciju globalne energije $E_v(\mathbf{x}_0, \ldots, \mathbf{x}_{v-1}, \mathbf{x})$ računa se za svaki $\mathbf{x} \in \chi$, a minimalna vrijednost funkcije globalne energije se za određeni $\mathbf{x}$ označava s $B_v(\mathbf{x})$. Linije $1-17$ algoritma 7 predstavljaju spomenuti prvi dio algoritma. U nastavku je ovaj dio algoritma detaljnije objašnjen. U linijama $2-8$ se za svaki $\mathbf{x} \in \chi$ računa vrijednost funkcije troška $D_v(\mathbf{x})$, dok se u liniji 9, također za svaki $\mathbf{x} \in \chi$, određuje vrijednost $B_v(\mathbf{x})$. Budući da $B_{v-1}(\mathbf{x}')$ predstavlja minimalnu vrijednost funkcije globalne energije $E_{v-1}(\mathbf{x}_0, \ldots, \mathbf{x}_{v-2}, \mathbf{x}')$ za određeni $\mathbf{x}'$, minimalna vrijednost funkcije $E_v(\mathbf{x}_0, \ldots, \mathbf{x}_{v-1}, \mathbf{x})$ za određeni $\mathbf{x}$ predstavlja sumu funkcije troška $D_v(\mathbf{x})$ i minimalne vrijednosti sume $B_{v-1}(\mathbf{x}') + V(\mathbf{x}', \mathbf{x})$ određene za sve $\mathbf{x}' \in \chi$. Minimalna vrijednost sume $B_v(\mathbf{x}') + V(\mathbf{x}', \mathbf{x})$ za v-ti redak slike je u algoritmu 7 označena s $U_v(\mathbf{x})$ (linija 13). Za proizvoljnu funkciju V, vrijednost $U_v(\mathbf{x})$ bi se odredila računanjem vrijednosti sume $B_v(\mathbf{x}') + V(\mathbf{x}', \mathbf{x})$ za sve parove $\mathbf{x}, \mathbf{x}' \in \chi$ i traženjem najmanje od tih vrijednosti. Računska složenost ovog koraka je $O(N^2)$, a budući da je to najsloženiji dio algoritma 7, ukupna složenost algoritma 7 je $O(hN^2)$. Međutim, za funkciju V oblika (5.21), minimalna vrijednosti izraza $U_v(\mathbf{x})$ može se odrediti metodom transformacije udaljenosti (engl. *distance transform method*) predložene u (Felzenszwalb i Huttenlocher, 2012) pri čemu računska složenost pretrage iznosi $O(N)$. Korištenjem metode transformacije udaljenosti ukupna složenost algoritma 7 iznosi $O(hN)$. Vektor parametara $\mathbf{x}'$, za koji je suma $B_v(\mathbf{x}') + V(\mathbf{x}', \mathbf{x})$ minimalna, se nakon pronalaska sprema u međuspremnik (linija 14). Spremanje vektora parametara $\mathbf{x}'$ je u algoritmu predstavljeno funkcijom

Algoritam 7 Optimalni CCR model redova usjeva.

Ulaz: $h, \chi, f_v(\mathbf{x})$, za svaki $v = 0, 1, \ldots h-1$, $\mathbf{x} \in \chi, f_{low}, \lambda_c, \lambda_d, D_{max}$
Izlaz: $\mathbf{x}_0, \ldots, \mathbf{x}_{h-1}$

1. **for** $v = 0$ **to** $h-1$ **do**
2. $\quad f_{v,max} = \max_{\mathbf{x}} f_v(\mathbf{x})$
3. $\quad$ **for** svaki $\mathbf{x} \in \chi$ **do**
4. $\quad\quad$ **if** $f_{v,max} \geq f_{low}$ **then**
5. $\quad\quad\quad D_v(\mathbf{x}) = \min\left(1 - \frac{f_v(\mathbf{x})}{f_{v,max}}, D_{max}\right)$
6. $\quad\quad$ **else**
7. $\quad\quad\quad D_v(\mathbf{x}) = D_{max}$
8. $\quad\quad$ **end if**
9. $\quad\quad B_v(\mathbf{x}) = \begin{cases} D_v(\mathbf{x}), & \text{ako je } v = 0 \\ D_v(\mathbf{x}) + U_{v-1}(\mathbf{x}), & \text{u suprotnom} \end{cases}$
10. $\quad$ **end for**
11. $\quad$ **if** $v < h-1$ **then**
12. $\quad\quad$ **for** svaki $\mathbf{x} \in \chi$ **do**
13. $\quad\quad\quad U_v(\mathbf{x}) = \min_{\mathbf{x}'}(B_v(\mathbf{x}') + V(\mathbf{x}', \mathbf{x}))$
14. $\quad\quad\quad T_v(\mathbf{x}) = \operatorname{argmin}_{\mathbf{x}'}(B_v(\mathbf{x}') + V(\mathbf{x}', \mathbf{x}))$
15. $\quad\quad$ **end for**
16. $\quad$ **end if**
17. **end for**
18. $\mathbf{x}_{h-1} = \operatorname{argmin}_{\mathbf{x}} B_{h-1}(\mathbf{x})$
19. **for** svaki $\mathbf{x} \in \chi$ **do**
20. $\quad \mathbf{x}_v = T_v(\mathbf{x}_{v+1})$
21. **end for**

$T_v(\mathbf{x})$ koja predstavlja mapiranje vektora $\mathbf{x}$ na vektor $\mathbf{x}'$ za koji je suma $B_v(\mathbf{x}') + V(\mathbf{x}', \mathbf{x})$ minimalna.

U drugom dijelu algoritma 7 (linije $18-21$), za svaki redak slike, počevši od posljednjeg, odabire se optimalni vektor parametara $\mathbf{x}$. Linija 18 predstavlja odabir optimalnog vektora $\mathbf{x}$ za posljednji redak slike. Za optimalni vektor $\mathbf{x}_{h-1}$ se odabire onaj vektor $\mathbf{x}$ za koji je vrijednost $B_{h-1}(\mathbf{x})$ minimalna. U linijama $19-21$ se, za svaki prethodni redak slike v, odabire vektor $\mathbf{x}_v$ koji je optimalan za vektor $\mathbf{x}_{v+1}$ određen u prethodnoj iteraciji. Vektor $\mathbf{x}_v$ predstavlja optimalnu interpretaciju v-tog retka slike, a odgovara vektoru $T_v(\mathbf{x}_{v+1})$ spremljenom u prvom dijelu algoritma (linija 14). Na kraju drugog dijela algoritma 7 određeni su optimalni vektori $\mathbf{x}_v$ za sve retke slike. Dobiveni niz vektora $\mathbf{x}_0, \ldots, \mathbf{x}_{h-1}$ predstavlja optimalni CCR model prema predloženom kriteriju.

Utjecaj predloženog optimizacijskog postupka na prepoznavanje redova usjeva prikazan je na slici 5.11. Na slici 5.11a prikazani su redovi usjeva (CCR model) dobiveni određivanjem maksimalne mjere podudaranja za svaki redak slike zasebno, dok su na slici

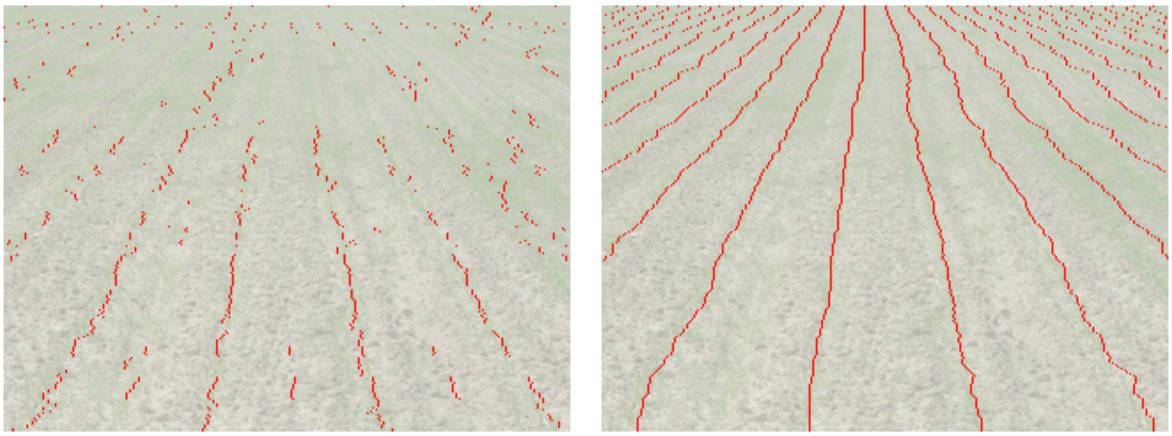

(a) (b)

Slika 5.11: Utjecaj optimizacijskog postupka na prepoznavanje redova usjeva. (a) CCR model dobiven određivanjem maksimalne mjere podudaranja za svaki redak slike zasebno, (b) CCR model dobiven minimizacijom funkcije globalne energije.

5.11b prikazani redovi usjeva dobiveni minimizacijom funkcije globalne energije. Na prikazanom primjeru vidljivo je kako su redovi usjeva dobiveni minimizacijom funkcije globalne energije puno točniji od redova usjeva dobivenih maksimizacijom mjere podudaranja za svaki redak slike zasebno.

Na slici 5.12 prikazani su redovi usjeva dobiveni primjenom TMGEM metode na slikama 5.1a i 5.1b. Na prikazanim primjerima vidljivo je da predložena TMGEM metoda uspijeva prepoznati redove usjeva za obje ispitane slike. Primjer prepoznavanja ravnih redova usjeva prikazan je na slici 5.12a. U ovom primjeru, kao što se može vidjeti na slici 5.1a, prisutnost korova je minimalna i TMGEM uspijeva dobro prepoznati sve prikazane redove usjeva. Slika 5.1b predstavlja primjer zakrivljenih redova usjeva uz visoku prisutnost korova. Na slici 5.12b je vidljivo da TMGEM metoda uspijeva točno prepoznati redove usjeva i za ovakav primjer.

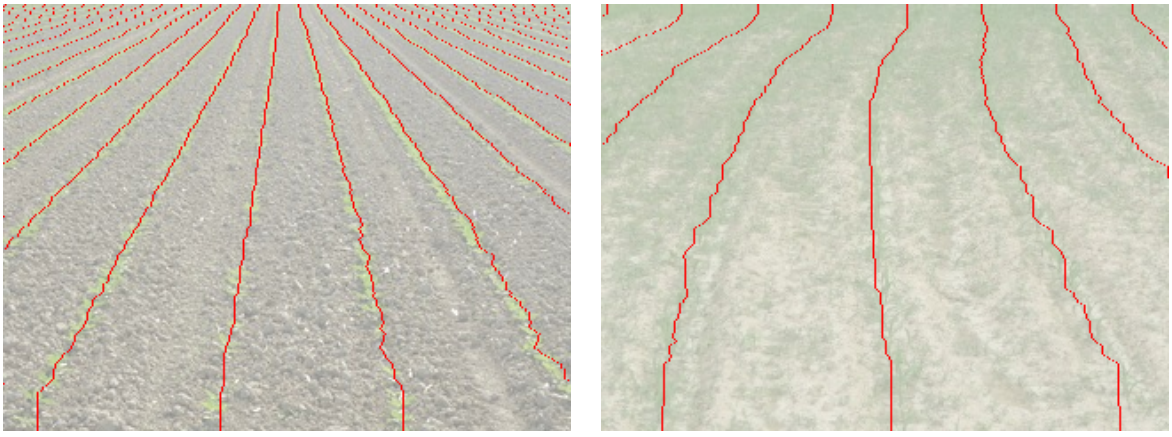

(a) (b)

Slika 5.12: Redovi usjeva dobiveni primjenom TMGEM metode na slikama 5.1a i 5.1b.

Rezultati detaljnijeg ispitivanja TMGEM metode prikazani su u poglavlju 7.3. Metoda je prvo uspoređena s postojećim metodama za prepoznavanje ravnih redova usjeva, a nakon toga je ispitana na skupu slika zakrivljenih redova usjeva. Evaluacija prepoznatih redova usjeva napravljena je korištenjem evaluacijskog okvira za usporedbu metoda prepoznavanja redova usjeva predloženog u sljedećem poglavlju.

6

Evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva

U znanstvenom području, u kojem se istražuje problem prepoznavanja redova usjeva, osim nedostataka predloženih metoda (poglavlje 3.2), uočeni su i određeni problemi pri evaluaciji predloženih metoda.

Jedan od glavnih problema je evaluacija predloženih metoda na temelju vizualne analize prepoznatih redova usjeva od strane eksperta (Pla et al., 1997; Ji i Qi, 2011; Montalvo et al., 2012; Romeo et al., 2012; Guerrero et al., 2013). Pri ovakvom načinu evaluacije, ekspert, koji je obično i jedan od autora metode, vizualnom analizom ocjenjuje jesu li redovi usjeva dobro prepoznati ili nisu. Na temelju broja slika, za koje ocijeni da su redovi usjeva dobro prepoznati, i ukupnog broja analiziranih slika, računa se postotak uspješnosti prepoznavanja redova usjeva. Iako ovakva mjera predstavlja kvantitativnu ocjenu metode, ona zapravo ne daje jasnu informaciju o tome koliko prepoznati redovi usjeva odstupaju od referentnih vrijednosti. Informacija o odstupanju prepoznatih redova usjeva je važna jer se na temelju nje može odrediti kolika će biti preciznost kretanja poljoprivrednog stroja. Na taj način može se donijeti zaključak zadovoljava li metoda za prepoznavanje redova usjeva traženu preciznost za obavljanje određenog procesa poljoprivredne proizvodnje ili ne. Preciznost je važna jer se preciznom navigacijom poljoprivrednog stroja sprječava uništavanje/oštećivanje usjeva prilikom prolaska poljoprivrednog stroja kroz redove usjeva. Nadalje, ovakav način evaluacije metoda za prepoznavanje usjeva je subjektivan, što može predstavljati veliki problem pri uspoređivanju predložene

metode s postojećim metodama iz literature.

Drugi problem koji je uočen pri evaluaciji metoda za prepoznavanje redova usjeva je nepostojanje standardizirane baze slika redova usjeva. Zbog toga, autori neke predložene metode ispituju tu metodu na svom setu slika, čime se unosi dodatna subjektivnost u postupak evaluacije. Naime, autori pri odabiru slika za ispitivanje mogu odabrati slike koje su pogodne za predloženu metodu. Postojanje standardizirane baze slika redova usjeva omogućilo bi autorima da svoju metodu testiraju na slikama iz te baze te rezultate svoje metode usporede s rezultatima postojećih metoda ostvarenim na istim slikama, čime bi se postigla veća objektivnost usporedbe različitih metoda.

Kao doprinos rješavanju navedenog problema, u sklopu ovog istraživanja predložen je novi evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva. Predloženi evaluacijski okvir uključuje bazu slika redova usjeva, postupak ručnog generiranja referentnih vrijednosti i kriterije za određivanje točnosti prepoznavanja redova usjeva. Predložena baza slika sadrži slike redova usjeva različitih kultura, u različitim stadijima rasta usjeva te uz različitu prisutnost korova i sjene. Referentne vrijednosti parametara redova usjeva predstavljaju temelj za evaluaciju prepoznatih redova usjeva primjenom određene mjere točnosti prepoznavanja redova usjeva. Postupak ručnog generiranja referentnih vrijednosti, predložen u sklopu evaluacijskog okvira, predstavlja doprinos jer znatno olakšava generiranje referentnih vrijednosti redova usjeva. Korištenjem predloženog postupka ekspert na brz i jednostavan način može generirati referentne vrijednosti redova usjeva za velik broj slika. Kriteriji za određivanje točnosti prepoznavanja redova usjeva zasnivaju se na računanju kvantitativne mjere odstupanja prepoznatih redova usjeva od referentnih vrijednosti redova usjeva. U sklopu spomenutog evaluacijskog okvira predložena su dva kriterija za određivanje točnosti prepoznavanja redova usjeva. Jedan kriterij predložen je za određivanje točnosti redova usjeva definiranih SCR modelom, a drugi za određivanje točnosti redova usjeva definiranih CCR modelom.

U nastavku poglavlja detaljno je opisan predloženi evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva. Ovaj evaluacijski okvir je u eksperimentalnoj analizi, provedenoj u poglavlju 7, korišten za određivanje točnosti prepoznavanja redova usjeva primjenom CRDI i TMGEM metoda predloženih u poglavlju 4 i 5.

6.1 Kriteriji za određivanje točnosti prepoznavanja redova usjeva

Kako bi se rezultati prepoznavanja redova usjeva dobiveni primjenom određene metode mogli kvantitativno ocijeniti, potrebno je definirati kriterij za određivanje točnosti prepoznavanja redova usjeva. Definiranje ovakvog kriterija predstavlja određivanje načina računanja mjere odstupanja prepoznatih redova usjeva od referentnih vrijednosti. Referentne vrijednosti redova usjeva, u slučaju ravnih redova usjeva, mogu biti definirane jednadžbama centralnih linija koje predstavljaju redove usjeva. U slučaju zakrivljenih redova usjeva, referentne vrijednosti mogu biti definirane kao jednadžbe polinoma višeg reda ili kao niz vektora parametara $\mathbf{x}^* = [c^*, d^*]^T$ za svaki redak slike. Efikasan postupak generiranja referentnih vrijednosti za zakrivljene redove usjeva opisan je u poglavlju 6.2. Važno je naglasiti da je spomenuti postupak moguće primijeniti i za generiranje referentnih vrijednosti za ravne redove usjeva. Računanjem mjere odstupanja prepoznatih redova usjeva od referentnih vrijednosti, postiže se objektivnija kvantitativna ocjena točnosti prepoznavanja redova usjeva od kvantitativne ocjene na temelju vizualne analize od strane eksperta.

Kao što je navedeno u poglavlju 2, u sklopu ovog rada predložena su dva modela za opisivanje prepoznatih redova usjeva. Zbog toga su predložena i dva kriterija za određivanje točnosti prepoznavanja redova usjeva. Jedan kriterij predložen je za određivanje točnosti prepoznavanja redova usjeva opisanih SCR modelom, a jedan za određivanje točnosti prepoznavanja redova usjeva opisanih CCR modelom. U nastavku poglavlja su opisana oba spomenuta kriterija.

6.1.1 Kriterij za određivanje točnosti prepoznavanja redova usjeva opisanih SCR modelom

Prilikom prepoznavanja ravnih redova usjeva, svaki red usjeva može se opisati pravcem, koji u tom slučaju predstavlja centralnu liniju tog reda usjeva. Ovakav opis redova usjeva predstavlja SCR model redova usjeva opisan u poglavlju 2.3.2. Kako bi se odredila točnost prepoznavanja redova usjeva opisanih SCR modelom, potrebno je definirati kriterij za određivanje točnosti prepoznavanja redova usjeva opisanih pravcima. Prijedlog ovakvog kriterija naveden je u nastavku.

Neka je $P = \{p_1, \ldots, p_k\}$ skup pravaca koji predstavljaju centralne linije prepoznatih redova usjeva, a $P^\star = \{p_1^\star, \ldots, p_k^\star\}$ skup referentnih pravaca (centralne linije koje opisuju

referentne redove usjeva). Točnost prepoznavanja redova usjeva se u tom slučaju može odrediti računanjem Hausdorff-ove udaljenosti skupova P i $P^\star$, definirane izrazom

$$\begin{aligned}\hat{d}_H &:= d_H(P, P^\star) \\ &= \max\{\max_r \min_s d_I(p_r, p_s^\star), \max_s \min_r d_I(p_r, p_s^\star)\}, \\ &\quad r, s \in \{1, \ldots, k\}.\end{aligned} \tag{6.1}$$

Pri tome $d_I(p_1, p_2)$ označava integralnu udaljenost između dva pravca

$$p_1 : A_1x + B_1y - C_1 = 0, \quad p_2 : A_2x + B_2y - C_2 = 0.$$

Integralna udaljenost $d_I(p_1, p_2)$ predstavlja površinu između pravaca p_1 i p_2 u području podataka određenom pravokutnikom $R = [x_{min}, x_{max}] \times [y_{min}, y_{max}]$. Vrijednost integralne udaljenosti može se izračunati pomoću izraza

$$d_I(p_1, p_2) = \int_{y_{min}}^{y_{max}} |x_2(y) - x_1(y)| dy, \tag{6.2}$$

gdje je

$$x_1(y) = \tfrac{1}{A_1}(C_1 - B_1y),$$

$$x_2(y) = \tfrac{1}{A_2}(C_2 - B_2y).$$

Izraz (6.2) može se izračunati korištenjem jednostavnijeg izraza

$$d_I(p_1, p_2) = (y_{max} - y_{min}) \left| \alpha - \tfrac{\beta^2}{2}(y_{max} + y_{min}) \right|, \tag{6.3}$$

gdje je

$$\alpha = \tfrac{C_1}{A_1} - \tfrac{C_2}{A_2},$$

$$\beta = \tfrac{B_1}{A_1} - \tfrac{B_2}{A_2}.$$

U tablici 6.1 prikazane su vrijednosti integralne udaljenosti za sve položaje pravaca prikazane na slici 6.1. Iz prikazanih vrijednosti može se uočiti da integralna udaljenost ima manje vrijednosti za pravce koji su bliži i čiji presjek zatvara manji kut. Najmanju

Slika	6.1a	6.1b	6.1c	6.1d
$d_I(p_1, p_2)$	2.43	0.33	0.82	0.76
$d_I(p_1, p_3)$	2.57	1.71	3.02	2.67
$d_I(p_2, p_3)$	0.91	1.81	2.20	1.91

Tablica 6.1: Vrijednosti integralne udaljenosti za razne položaje pravaca prikazane na slici 6.1.

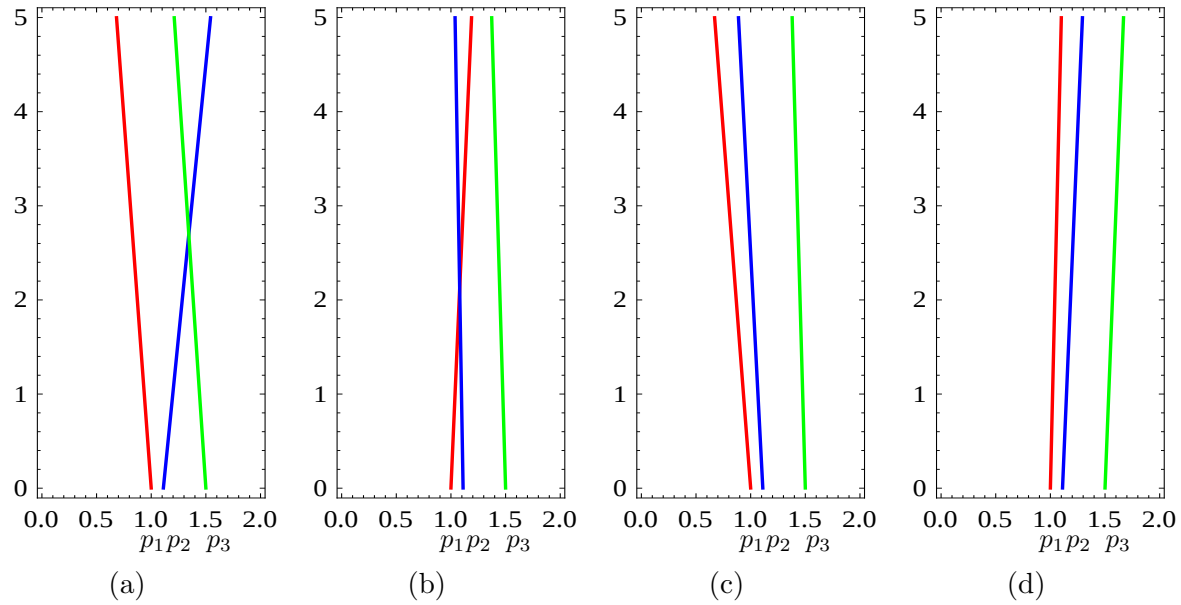

Slika 6.1: Razni položaji pravaca p_1, p_2 i p_3.

vrijednost integralna udaljenost imala bi u slučaju dva identična pravca i iznosila bi nula. Prema tome, može se zaključiti da integralna udaljenost predstavlja dobru mjeru udaljenosti, te se u nastavku koristi kao kriterij za određivanje točnosti prepoznavanja redova usjeva opisanih SCR modelom. U nastavku se ovaj kriterij naziva CRHID što je skraćenica od engleskog izraza *Crop Row Hausdorff Integral Distance*.

6.1.2 Kriterij za određivanje točnosti prepoznavanja redova usjeva opisanih CCR modelom

Kriterij definiran u prethodnom poglavlju primjenjiv je samo u slučaju ravnih redova usjeva. Budući da su brežuljci i udubljenja česta pojava u poljima, zbog čega se paralelni i ravno zasađeni redovi usjeva projiciraju kao zakrivljene linije na sliku snimljenu kamerom (poglavlje 2.3.3), potrebno je definirati novi kriterij za određivanje točnosti prepoznavanja zakrivljenih redova usjeva.

Predloženi kriterij zasniva se na usporedbi prepoznatih redova usjeva s referentnim vrijednostima redova usjeva dobivenih primjenom postupka opisanog u poglavlju 6.2. Referentne vrijednosti redova usjeva dobivene primjenom spomenutog postupka opisane su nizom parametara $\mathbf{x}_v^*$ odnosno CCR modelom redova usjeva. Kako bi se kriterij za određivanje točnosti prepoznavanja zakrivljenih redova usjeva mogao primijeniti za određivanje točnosti prepoznavanja redova usjeva koji nisu opisani CCR modelom, referentne vrijednosti redova usjeva prikazuju se u općenitijem obliku. Na temelju referentnih vrijednosti parametara c_v^* i d_v^*, određuje se niz vrijednosti $u_{v,1}^*, \ldots, u_{v,k}^*$ koje predstavljaju referentne vrijednosti horizontalnih koordinata za k susjednih redova usjeva u v-tom retku

slike. Računanjem vrijednosti $u^*_{v,1}, \ldots, u^*_{v,k}$ za svaki redak slike i prikazivanjem u obliku matrice postiže se općenitiji prikaz referentnih vrijednosti redova usjeva. Prema tome, matrica referentnih vrijednosti ima k stupaca i onoliko redaka za koliko su definirane referentne vrijednosti redova usjeva (poglavlje 6.2). U istom obliku mogu se prikazati redovi usjeva dobiveni primjenom određene metode za prepoznavanje redova usjeva. U tom slučaju, svaki redak matrice sastoji se od k vrijednosti $u_{v,1}, \ldots, u_{v,k}$ koje predstavljaju horizontalne koordinate k susjednih redova usjeva.

Na temelju usporedbe horizontalnih koordinata referentnih i prepoznatih redova usjeva može se odrediti mjera odstupanja redova usjeva, dobivenih primjenom određene metode, od referentnih vrijednosti redova usjeva. U sklopu evaluacijskog okvira za usporedbu metoda prepoznavanja redova usjeva predložen je novi kriterij za određivanje točnosti prepoznavanja redova usjeva opisanih CCR modelom, koji se zasniva na usporedbi horizontalnih koordinata. U nastavku se ovaj kriterij naziva CRDA, što je skraćenica od engleskog izraza *Crop Row Detection Accuracy*. CRDA kriterij definiran je izrazom

$$CRDA = \frac{1}{k(h - v_0)} \sum_{v=v_0}^{h-1} \sum_{i=0}^{k} s\big(u^*_{v,i}, u_{v,i}, d^*_v\big), \tag{6.4}$$

gdje je

$$s(u^*, u, d) = \max\left(1 - \left(\frac{u^* - u}{\sigma_s d}\right)^2, 0\right), \tag{6.5}$$

a $\sigma_s \in \langle 0, 1\rangle$ je korisnički definiran parametar. Varijabla v_0, u izrazu (6.4), predstavlja koordinatu prvog retka slike za koji postoji definirana referentna vrijednost redova usjeva (poglavlje 6.2).

Iz izraza (6.4) je vidljivo da se vrijednost kriterija CRDA određuje uspoređivanjem horizontalnih koordinata redova usjeva dobivenih primjenom određene metode ($u_{v,i}$) i referentnih vrijednosti horizontalnih koordinata ($u^*_{v,i}$) te računanjem prosječne vrijednosti mjere podudaranja za sve retke slike. Koordinate $u_{v,i}$ i $u^*_{v,i}$ uspoređuju se korištenjem funkcije s definirane izrazom (6.5) pri čemu mjera podudaranja ima vrijednosti u intervalu $[0, 1]$. Oblik funkcije s prikazan je na slici 6.2. U slučaju savršenog podudaranja, kada je $u_{v,i} = u^*_{v,i}$, funkcija s vraća maksimalnu vrijednost, odnosno 1. Suprotno, ukoliko je razlika vrijednosti $u_{v,i}$ i odgovarajuće referentne vrijednosti $u^*_{v,i}$ veća od $\sigma_s d$ ($|u_{v,i} - u^*_{v,i}| > \sigma_s d$), funkcija s vraća vrijednost 0. Iz navedenog i iz izraza (6.5) se može zaključiti da σ_s predstavlja korisnički definirani parametar kojim se određuje dopuštena tolerancija odstupanja prepoznatih redova usjeva od referentnih vrijednosti. Ukoliko je vrijednost parametra $\sigma_s = 0.1$, vrijednost funkcije s je veća od 0 samo ako je razlika

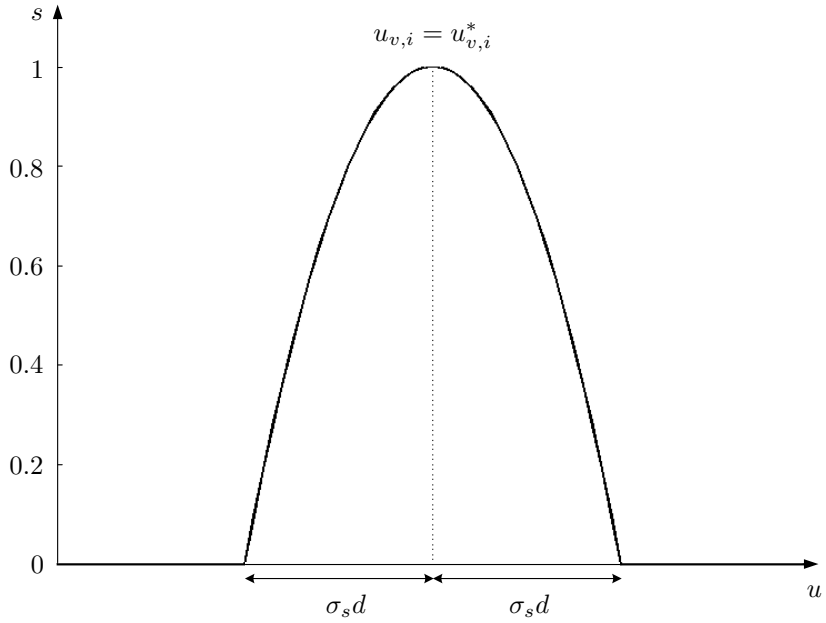

Slika 6.2: Oblik funkcije podudaranja s.

između koordinata $u_{v,i}$ i $u^*_{v,i}$ manja od 10% udaljenosti dvaju susjednih redova usjeva. Općenito, vrijednost parametra σ_s ovisi o željenoj točnosti, potrebnoj za sigurno upravljanje poljoprivrednim strojem.

6.2 Postupak generiranja referentnih vrijednosti redova usjeva

Referentne vrijednosti redova usjeva predstavljaju temelj za određivanje kvantitativne ocjene redova usjeva dobivenih primjenom određene metode. Kao što je rečeno ranije, referentne vrijednosti za ravne redove usjeva obično se definiraju u obliku jednadžbi pravaca koji predstavljaju centralne linije redova usjeva (SCR model redova usjeva). Analogno tome, u slučaju zakrivljenih redova usjeva referentne vrijednosti mogu biti definirane kao parametri polinoma višeg stupnja. Ipak, u sklopu ovog istraživanja predlaže se korištenje CCR modela za opisivanje referentnih vrijednosti zakrivljenih redova.

Postupak generiranja referentnih vrijednosti je u slučaju ravnih redova usjeva jednostavniji nego u slučaju zakrivljenih redova usjeva. Budući da se ravni redovi usjeva obično opisuju SCR modelom, odnosno pravcima, dovoljno je za svaki red usjeva definirati po dvije točke, na temelju kojih se odrede centralni pravci koji predstavljaju referentne vrijednosti redova usjeva.

Analogno postupku generiranja referentnih vrijednosti za ravne redove usjeva, u sklopu izrade evaluacijskog okvira za usporedbu metoda prepoznavanja redova usjeva, predlaže

se novi efikasan postupak za ručno generiranje referentnih vrijednosti zakrivljenih redova usjeva. S ciljem generiranja referentnih vrijednosti razvijena je aplikacija u programskom jeziku C++, a sam postupak opisan je u nastavku. Ekspert definira dvije ili više točaka koje leže na jednom redu usjeva na slici za koju se generiraju referentne vrijednosti. Nakon toga, razvijena aplikacija automatski generira glatku krivulju koja prolazi tim točkama. Isti postupak ponavlja se i za susjedni red usjeva na slici te se na taj način dobiva druga krivulja. Krivulje za ostale redove usjeva na slici rekonstruiraju se na temelju tih dviju krivulja, koje predstavljaju centralne linije dvaju susjednih redova usjeva, i na temelju činjenice da je razmak između susjednih redova usjeva u određenom retku slike konstantan.

Ovakav postupak generiranja referentnih vrijednosti redova usjeva je vrlo jednostavan i efikasan jer je za određenu sliku potrebno definirati samo nekoliko točaka. Na taj način ekspert može generirati referentne vrijednosti za velik broj slika u kratkom vremenu. Broj točaka koje je potrebno definirati za određenu sliku ovisi o zakrivljenosti redova usjeva. Kao što je ranije rečeno, za potpuno ravni red usjeva dovoljne su dvije točke, a što je zakrivljenost veća i složenija, broj točaka se povećava. Važno je naglasiti da razvijena aplikacija za generiranje referentnih vrijednosti omogućava efikasno definiranje spomenutih točaka. Nakon dodavanja određenog broja točaka i generiranja krivulja, svaku od točaka je moguće pomicati i na taj način precizno podešavati referentne vrijednosti redova usjeva. Aplikacija, u bilo kojem trenutku, omogućava i dodavanje novih točaka te uklanjanje neke od postojećih.

Na nekima od slika iz baze slika redova usjeva (poglavlje 6.3), redovi usjeva nisu vidljivi pri vrhu slike. Razlozi za to su utjecaj perspektive ili nebo koje se pojavljuje pri vrhu određenih slika. Zbog toga su referentne vrijednosti redova usjeva definirane od retka v_0 do dna slike. Prema tome, konačan rezultat predloženog postupka generiranja referentnih vrijednosti je niz referentnih vrijednosti parametara c_v^* i d_v^* za sve retke slike, počevši od v_0 do dna. Niz referentnih parametara može se prikazati u obliku niza referentnih vektora parametara $\mathbf{x}_v^*$, odnosno u obliku referentnog CCR modela.

Primjer referentnih vrijednosti za jednu sliku iz baze slika redova usjeva prikazan je na slici 6.3. Na slici 6.3 je vidljivo kako je ekspert za lijevi centralni red usjeva definirao 5 točaka (žuti križići), a za desni 3 točke (crveni križići). Na temelju tih točaka definirane su referentne krivulje za ta dva centralna reda usjeva, a na temelju njih su rekonstruirane krivulje za ostale redove usjeva na slici. Iz prikazanog primjera može se uočiti da se, korištenjem predloženog postupka za generiranja referentnih vrijednosti, referentne vrijednosti mogu definirati brzo, jednostavno i dovoljno precizno. Važno je naglasiti da se

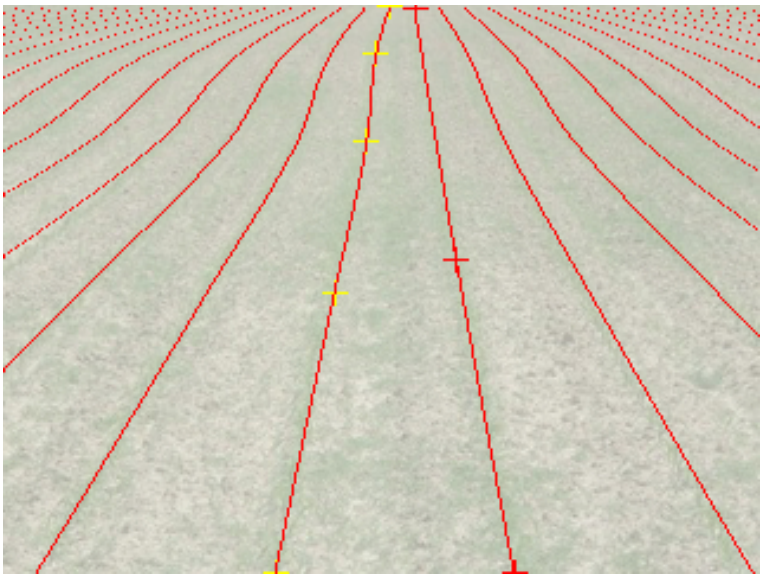

Slika 6.3: Primjer referentnih vrijednosti redova usjeva. Žuti i crveni križići označavaju točke na temelju kojih su određene referentne krivulje centralnih redova usjeva.

predloženi postupak može koristiti i za definiranje referentnih vrijednosti u slučaju ravnih redova usjeva. Pri tome je potrebno za dva susjedna reda usjeva definirati po dvije točke nakon čega aplikacija generira referentne vrijednosti u obliku CCR modela. Ukoliko je potrebno definirati referentne vrijednosti u obliku SCR modela, aplikaciju bi trebalo prilagoditi da na temelju zadane 4 točke odredi jednadžbe pravaca koje opisuju redove usjeva.

Korištenjem predloženog postupka generirane su referentne vrijednosti za sve slike iz baze slika redova usjeva, opisane u sljedećem poglavlju. Generirane referentne vrijednosti korištene su u poglavlju 7.3 pri eksperimentalnoj analizi predložene TMGEM metode.

6.3 Baza slika redova usjeva

Zbog navedenog problema nepostojanja standardizirane baze slika redova usjeva, u sklopu izrade evaluacijskog okvira za usporedbu metoda prepoznavanja redova usjeva, kreirana je baza slika redova usjeva. Ovakva baza slika omogućava znanstvenicima objektivniju i lakšu usporedbu novih metoda za prepoznavanje redova usjeva s postojećim metodama. Dosadašnjim proučavanjem literature, uočeno je da autori novo razvijene metode uspoređuju na svojim skupovima slika što dovodi u pitanje objektivnost odabira testnih slika. Korištenjem standardizirane baze slika, znanstvenici bi napravili evaluaciju nove metode na poznatom skupu slika te dobivene rezultate usporedili s već postojećim rezultatima drugih metoda na istom skupu slika. Ovime bi se postupak evaluacije novih metoda, i usporedbe s postojećim, znatno ubrzao i olakšao.

U svrhu kreiranja spomenute baze slika redova usjeva, snimljene su slike različitih poljoprivrednih kultura. Kulture koje su snimljene su kukuruz, celer, krumpir, luk, suncokret i soja. Na slikama je prisutna različita količina korova te je vidljiv različit utjecaj svjetlosti. Slike su snimane po danu pa nije korišteno dodatno osvjetljenje, a na nekim slikama je vidljiva prisutnost sjene nastale zbog raznih objekata u blizini polja. Na određenim slikama vidljivi su dijelovi travnjaka, neba ili ceste. Slike su snimljene digitalnom kamerom držanom u ruci, pa je položaj kamere u odnosu na polje varirao u određenom rasponu. Slike su snimljene u proljeće 2014. godine na raznim poljima u Slavoniji, a za snimanje je korištena Panasonic LUMIX DMC-F2 digitalna kamera. Originalna rezolucija snimljenih slika je 2560×1920, a nakon snimanja je smanjena na 320×240. Postupkom smanjenja rezolucije se smanjuje vrijeme potrebno za prepoznavanje redove usjeva, bez značajnog gubitka informacija, što je pokazano u eksperimentalnoj analizi TMGEM metode opisanoj u poglavlju 7.3.4, gdje su uspoređeni rezultati prepoznavanja redova usjeva na slikama različite rezolucije.

Kreirana baza slika sadrži 281 sliku redova usjeva te je u cijelosti dana na raspolaganje znanstvenoj zajednici[1]. Primjeri slika iz baze dani su na slici 6.4. Slike 6.4a − 6.4d prikazuju primjere slika redova usjeva na kojima su prisutni korov i sjena. Različite poljoprivredne kulture vidljive su na slikama 6.4e − 6.4h. Usjevi u različitim stadijima rasta prikazani su na slikama 6.4i − 6.4l, dok su na slikama 6.4m − 6.4p dani primjeri različite zakrivljenosti redova usjeva. Iz primjera slika prikazanih na slici 6.4 može se uočiti da kreirana baza slika sadrži raznolike primjere slika redova usjeva. Prema tome, evaluacijom metoda za prepoznavanje redova usjeva na slikama iz baze može se ispitati robusnost metode, odnosno primjenjivost na različitim poljoprivrednim kulturama te na širokom spektru uvjeta okoline, geometrije polja i načina snimanja slike.

Pri evaluaciji određene metode za prepoznavanje redova usjeva može se koristiti sve ili samo dio slika iz baze. Za potrebe ovog istraživanja baza slika je podijeljena u dva skupa, *skup za učenje* i *testni skup*. Skup za učenje, koji sadrži 56 slika (20% od ukupno 281 slike), korišten je za određivanje odgovarajućih vrijednosti parametara a i b TMGEM metode (poglavlje 5.3). Testni skup, s preostalih 225 slika, je korišten pri evaluaciji predložene TMGEM metode (poglavlje 7.3). Za potrebe usporedbe s postojećim metodama iz testnog skupa slika izdvojene su 34 slike ravnih redova usjeva, dok je preostala 191 slika korištena za evaluaciju TMGEM metode na zakrivljenim redovima usjeva.

Za svaku od slika u kreiranoj bazi slika redova usjeva određene su referentne vrijed-

[1] http://www.etfos.unios.hr/r3dvgroup/index.php?id=crd_dataset

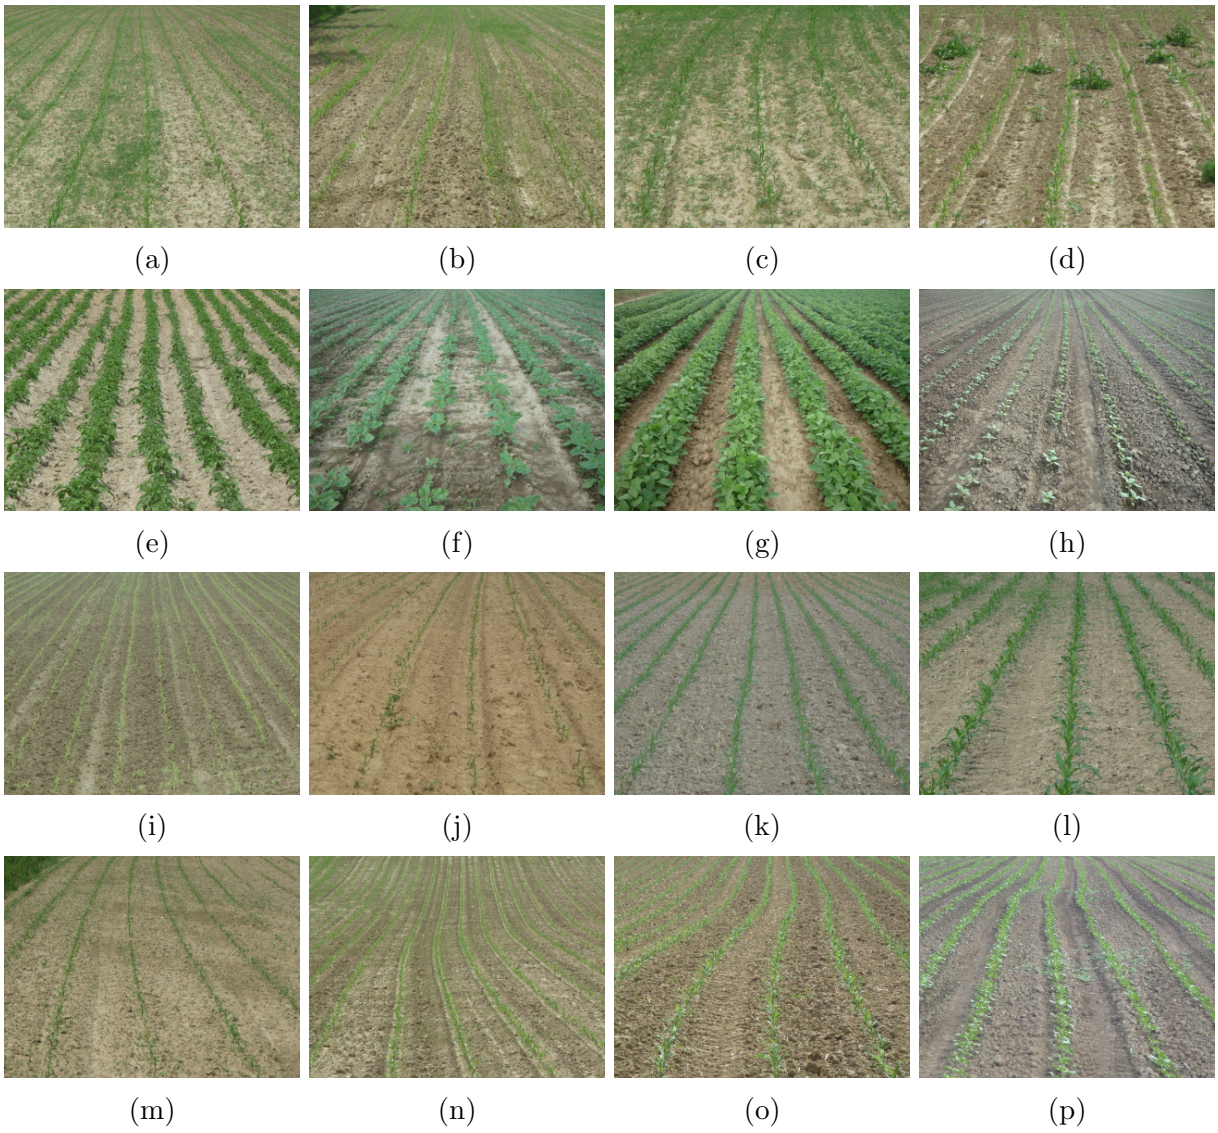

Slika 6.4: Primjeri slika iz baze slika redova usjeva.

nosti redova usjeva primjenom postupka opisanog u poglavlju 6.2. U nastavku se baza slika redova usjeva, s referentnim vrijednostima redova usjeva za sve slike, naziva CRBD, što je skraćenica od engleskog izraza *Crop Row Benchmark Dataset*. Kompletan CRBD se može pruzeti na istom linku kao i baza slika. Uz bazu slika i referentne vrijednosti redova usjeva za sve slike, CRBD sadrži i Matlab datoteke za prikaz referentnih vrijednosti redova usjeva na slici te za određivanje vrijednosti CRDA kriterija. Rezultati prepoznavanja redova usjeva primjenom TMGEM metode su također uključeni u CRBD kako bi se omogućila lakša usporedba novo razvijenih metoda s predloženom TMGEM metodom. Uz sve navedeno, CRBD sadrži i detaljne upute za korištenje.

7
Eksperimentalni rezultati

U ovom poglavlju prikazani su rezultati eksperimentalne evaluacije metoda prepoznavanja redova usjeva predloženih u sklopu ove doktorske disertacije. Eksperimentalna evaluacija podijeljena je u dva dijela: *i*) *eksperimentalna evaluacija* CRDI *metode* i *ii*) *eksperimentalna evaluacija* TMGEM *metode*.

U prvom dijelu dani su rezultati eksperimentalne evaluacije CRDI metode predložene u poglavlju 4. Predložena metoda ispitana je na umjetno generiranim skupovima podataka pri čemu je uspoređena s predloženom IMLD metodom te sa Standardnom Houghovom transformacijom. Za generiranje umjetnih skupova podataka, koji simuliraju redove usjeva, korišten je postupak opisan u poglavlju 4.1.1, dok je za mjeru točnosti prepoznavanja redova usjeva korišten CRHID kriterij predložen u poglavlju 6.1.1. Umjetni skupovi generirani su za slučaj dva i tri reda usjeva, te su pri tome simulirani utjecaj korova i neravnog zasijanja.

U drugom dijelu napravljena je eksperimentalna evaluacija TMGEM metode, predložene u poglavlju 5, na stvarnim slikama redova usjeva iz baze slika redova usjeva (poglavlje 6.3). Baza slika sadrži slike redova usjeva različitih kultura, različitih uvjeta okoline (prisutnost korova, sjene i sl.), geometrije polja i načina snimanja slike. U sklopu ovog dijela eksperimentalne evaluacije, provedena su tri pokusa. U prvom je predložena metoda ispitana na slikama ravnih redova usjeva, u drugom na slikama zakrivljenih redova usjeva, dok je u trećem analiziran utjecaj rezolucije slike na točnost prepoznavanja. Prema dosadašnjim spoznajama, većina metoda za prepoznavanje redova usjeva može prepoznati samo ravne redove usjeva. Zbog navedenog, rezultati prepoznavanja ravnih redova usjeva

dobiveni TMGEM metodom uspoređeni su s rezultatima prepoznavanja dobivenih dvjema metodama zasnovanim na Houghovoj transformaciji i jednom metodom zasnovanom na linearnoj regresiji. Ispitivanjem TMGEM metode na zakrivljenim redovima usjeva pokazana je robusnost predložene metode, odnosno mogućnost prepoznavanja i zakrivljenih redova usjeva. Točnost prepoznavanja redova usjeva, u eksperimentalnoj analizi TMGEM metode, određena je korištenjem CRDA kriterija opisanog u poglavlju 6.1.2.

U nastavku poglavlja prvo su objašnjene metode korištene za usporedbu s metodama predloženim u ovom istraživanju, a nakon toga su dani rezultati eksperimentalne analize koja je podijeljena na spomenuta dva dijela.

7.1 Metode korištene za usporedbu

Za potrebe eksperimentalne analize predloženih CRDI i TMGEM metode, napravljena je usporedba rezultata prepoznavanja redova usjeva dobivenih predloženim metodama s rezultatima prepoznavanja redova usjeva dobivenih nekim od postojećih metoda iz literature.

CRDI metoda uspoređena je sa Standardnom Houghovom transformacijom na umjetno generiranim skupovima podataka. Osim Houghove transformacije, u eksperimentalnoj analizi je, za usporedbu, korištena i IMLD metoda predložena u poglavlju 4.1.4.

TMGEM metoda je ispitana na slikama ravnih i zakrivljenih redova usjeva iz baze slika redova usjeva (poglavlje 6.3). Za usporedbu rezultata prepoznavanja ravnih redova usjeva, dobivenih TMGEM metodom, korištene su tri metode. Dvije metode su zasnovane na Standardnoj Houghovoj transformaciji, a jedna na linearnoj regresiji. Metoda zasnovana na linearnoj regresiji je metoda predložena u (Montalvo et al., 2012). Jedna od metoda zasnovanih na Houghovoj transformaciji je Standardna Houghova transformacija u svom izvornom obliku, a druga metoda je Standardna Houghova transformacija koja koristi predloške kao metoda predložena u (Montalvo et al., 2012).

U nastavku poglavlja opisane su sve tri metode korištene u eksperimentalnoj analizi za usporedbu rezultata prepoznavanja redova usjeva dobivenih primjenom CRDI i TMGEM metode.

7.1.1 Houghova transformacija

Standardna Houghova transformacija (Duda i Hart, 1972) je jedan od najčešćih pristupa rješavanju problema prepoznavanja redova usjeva (Marchant, 1996; Leemans i Destain,

2006; Bakker et al., 2008; Ji i Qi, 2011; Marchant i Brivot, 1995; Rovira-Más et al., 2005; Ericson i Åstrand, 2009).

Prepoznavanje pravaca korištenjem Houghove transformacije ostvaruje se traženjem maksimuma u Houghovoj ravnini (akumulatoru) koja predstavlja transformaciju ulazne slike. Prije primjene Houghove transformacije potrebno je napraviti binarnu sliku. Na binarnoj slici su objekti od interesa (pravci/usjevi) prikazani bijelom bojom, a sve ostalo crnom. Nakon binarizacije slike primjenjuje se Houghova transformacija, pri čemu se za svaku točku $T(x, y) \in \mathbb{R}^2$ binarne slike unosi niz glasova u Houghovu ravninu. Glasovi predstavljaju sve moguće pravce u Hesseovom obliku koji prolaze točkom T s određenom rezolucijom parametara ρ i δ. Parametri ρ i δ su parametri Hesseovog oblika jednadžbe pravca definiranog izrazom

$$x \cos \rho + y \sin \rho - \delta = 0, \tag{7.1}$$

gdje parametar ρ predstavlja kut koji normala iz ishodišta na pravac zatvara s pozitivnim dijelom x-osi koordinatnog sustava, dok parametar δ označava udaljenost pravca od ishodišta. Korištenjem ovakve transformacije, određeni pravac p u prostoru (na slici) predstavljen je točkom (ρ, δ) u Houghovoj ravnini, a jedna točka na slici predstavljena je nizom točaka u Houghovoj ravnini. Iz navedenog se može zaključiti da točke koje leže na istom pravcu na originalnoj slici povećavaju broj glasova točke (ρ, δ) u Houghovoj ravnini koja predstavlja parametre tog pravca. Na taj način se traženjem lokalnih maksimuma u Houghovoj ravnini može prepoznati najdominantnije pravce na slici.

Primjer Houghove transformacije prikazan je na slici 7.1. Na slici 7.1b prikazana je Houghova ravnina dobivena primjenom Houghove transformacije na binarnu sliku 7.1a.

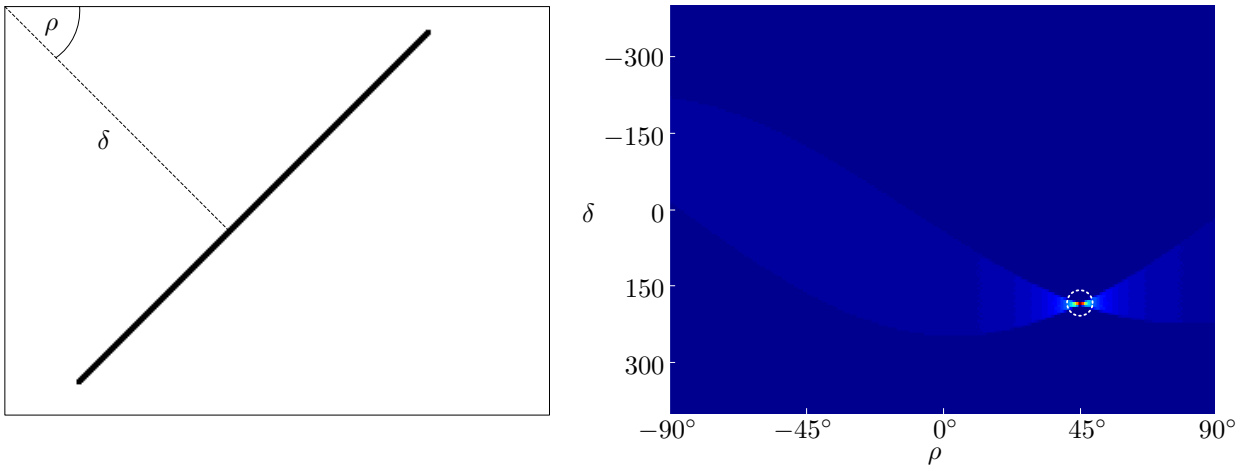

Slika 7.1: Primjer Houghove transformacije. (a) Binarna slika, (b) Houghova ravnina.

Iz prikazanog primjera može se uočiti kako sve točke koje leže na pravcu prikazanom na slici 7.1a, daju glas za točku označenu isprekidanom kružnicom na slici 7.1b. Ta točka predstavlja maksimum Houghove ravnine, odnosno parametre ρ i δ najdominantnijeg pravca originalne slike. Binarna slika 7.1a je veličine 320×240, a ishodište koordinatnog sustava pri računanju Houghove transformacije je postavljeno u lijevi gornji kut slike. Parametri ρ i δ za najdominantniji pravac, u ovom primjeru, iznose $\rho = 45°$ i $\delta = 185$.

Analogno prikazanom primjeru za prepoznavanje pravca (slika 7.1), Houghova transformacija se može primijeniti za prepoznavanje redova usjeva. U slučaju eksperimentalne analize CRDI metode (poglavlje 7.2), gdje se koriste umjetni skupovi podataka, nije potrebno raditi predobradu prije primjene Houghove transformacije, dok je u slučaju eksperimentalne analize TMGEM metode (poglavlje 7.3), gdje se koriste stvarne slike polja, potrebno napraviti predobradu, kako bi se od ulazne slike u boji dobila binarizirana slika na kojoj se primjenjuje Houghova transformacija. Binarna slika, u eksperimentalnoj analizi TMGEM metode, dobivena je primjenom dvostruke Otsu segmentacije (poglavlje 7.1.2) na sliku vegetacije koja se dobiva računanjem ExG indeksa boje vegetacije za ulaznu sliku (slika 5.2).

U nastavku se metoda za prepoznavanje redova usjeva, zasnovana na Standardnoj Houghovoj transformaciji, označava kraticom HT, a koristi se u eksperimentalnoj analizi obje predložene metode.

7.1.2 Linearna regresija s predlošcima

Drugi često korišteni pristup rješavanju problema prepoznavanja redova usjeva je primjena linearne regresije (Harrington, 2012). Kao i Houghova transformacija, linearna regresija se primjenjuje na binarnoj slici pa je u slučaju prepoznavanja redova usjeva na stvarnim slikama potrebno napraviti predobradu, odnosno binarizirati ulaznu sliku. Za skup umjetno generiranih točaka, kao ni kod Houghove transformacije, nije potrebno raditi predobradu. Primjenom linearne regresije, za određeni skup točaka se pronalazi pravac oblika

$$y = k_p x + l_p, \tag{7.2}$$

takav da je suma kvadratnih odstupanja svih točaka skupa do pravca minimalna. U izrazu (7.2) k_p predstavlja koeficijent nagiba pravca, a l_p duljinu odsječka koju pravac određuje na y osi. Suma kvadrata ortogonalnih odstupanja m točaka od pravca definiranog izrazom

(7.2) može se izračunati korištenjem izraza

$$F(k_p, l_p) = \sum_{i=0}^{m-1} \frac{(k_p x + l_p - y_i)^2}{1 + {k_p}^2}. \tag{7.3}$$

Može se uočiti da pravac određen minimizacijom izraza (7.3) predstavlja TLS pravac za razmatrani skup točaka.

Za potrebe usporedbe rezultata prepoznavanja redova usjeva primjenom predložene TMGEM metode, osim HT metode, u ovom radu se koristi i metoda zasnovana na linearnoj regresiji, predložena u (Montalvo et al., 2012). U nastavku se navedena metoda naziva LR metoda, što je skraćenica od engleskog izraza *Linear Regression*. Postupak prepoznavanja redova usjeva na slici primjenom LR metode može se podijeliti u nekoliko koraka, koji su detaljno objašnjeni u nastavku.

Prvi korak LR metode je transformacija ulazne slike primjenom ExG indeksa boje vegetacije. Ovaj korak jednak je koraku prepoznavanja vegetacije predložene TMGEM metode (poglavlje 5.1), a kao rezultat dobiva se slika vegetacije (slika 5.2). Sljedeći korak LR metode je primjena dvostruke Otsu segmentacije (engl. *Double Otsu*). Ovaj korak autori smatraju glavnim doprinosom predložene metode, a sastoji se od dvostruke primjene Otsu metode segmentacije opisane u poglavlju 3.1.2. Budući da Otsu metoda pronalazi prag binarizacije u slučaju kada je histogram slike bimodalan, prvom primjenom, u slučaju slika redova usjeva, se dobiva prag binarizacije kojim se razdvaja vegetacija (usjevi i korov) od zemlje. Nakon toga se ponovno primjenjuje Otsu metoda, ali na histogramu kreiranom od onih piksela slike koji su nakon prve binarizacije pripali vegetaciji. Autori LR metode tvrde da se drugom primjenom Otsu metode može razdvojiti usjeve od korova te na taj način postići bolje prepoznavanje redova usjeva u daljnjim koracima metode. Nakon binarizacije slike, primjenjuju se posebno kreirani predlošci kojima se olakšava prepoznavanje redova usjeva primjenom linearne regresije. Predlošci se kreiraju na temelju predznanja o broju redova usjeva, geometrijskoj strukturi redova usjeva, očekivanom položaju redova usjeva na slici te očekivanom dijelu slike koji je potrebno analizirati. U radu (Montalvo et al., 2012) su kreirana 2 ovakva predloška, za dva tipa geometrije polja. Ipak, za potrebe usporedbe LR metode s TMGEM metodom, za svaku sliku iz skupa slika za testiranje kreiran je poseban predložak. Primjer jednog takvog predloška, kreiranog za sliku 7.2a, prikazan je na slici 7.2b. Primjenom ovakvog predloška, kao maske na binarnoj slici, kreiraju se tri odvojena skupa točaka te se za svaki od skupova primjenom linearne regresije pronalazi pravac koji predstavlja centralnu liniju odgovarajućeg reda

(a) (b)

Slika 7.2: Primjer predloška LR metode. (a) Ulazna slika redova usjeva, (b) Predložak kreiran na temelju predznanja.

usjeva. Umjesto klasične linearne regresije, definirane na početku ovog poglavlja, u radu (Montalvo et al., 2012) koristi se linearna regresija kojom se minimizira suma ortogonalnih udaljenosti definirana izrazom

$$F(k_p, l_p) = \sum_{i=0}^{m-1} \frac{|k_p x + l_p - y_i|}{\sqrt{1 + {k_p}^2}}. \tag{7.4}$$

Radi jednostavnosti, u eksperimentalnoj evaluaciji TMGEM metode, implementacija LR metode napravljena je korištenjem klasične linearne regresije, odnosno minimiziran je izraz (7.3) kojim se dobiva TLS pravac. Važno je uočiti da se LR metoda može uspješno primijeniti samo na redove usjeva za koje su kreirani predlošci. Ovaj uvjet predstavlja ograničenje u stvarnoj primjeni metode jer se za primjenu na redovima usjeva drugačijeg rasporeda moraju kreirati novi predlošci.

7.1.3 Houghova transformacija s predlošcima

Treća metoda korištena u eksperimentalnoj evaluaciji TMGEM metode je Houghova transformacija s predlošcima. Ova metoda je kombinacija prethodno opisane HT i LR metode, a detaljnije je opisana u nastavku.

Budući da se metoda koristi u eksperimentalnoj analizi TMGEM metode, koja se provodi na stvarnim slikama redova usjeva, potrebno je od ulazne slike napraviti binarnu sliku. Binarizacija slike je, kao i kod LR metode, napravljena primjenom dvostruke Otsu metode na slici vegetacije. Nakon binarizacije, primjenjuju se posebno kreirani predlošci koji su jednaki predlošcima korištenim za LR metodu. Ovim korakom se izdvajaju tri skupa točaka, koji predstavljaju usjeve za tri razmatrana reda usjeva. Primjenom Stan-

dardne Houghove transformacije, odnosno HT metode, na svakom od izdvojenih skupova točaka, dobivaju se pravci koji predstavljaju centralne linije redova usjeva. Važno je uočiti da se, korištenjem predložaka, HT metodom traži samo najdominantniji pravac za svaki od izdvojenih skupova točaka. Ovime se postiže poboljšanje u odnosu na HT metodu jer se sprječava da metoda pronađe dva pravca za jedan red usjeva, a za drugi red usjeva ne pronađe niti jedan pravac. Ovakva situacija bi se dogodila kada bi dva pravca za jedan red usjeva imali više glasova u Houghovoj ravnini od pravca koji predstavlja centralnu liniju drugog reda usjeva. Međutim, korištenje predložaka omogućava primjenu metode samo na redovima usjeva za koje su kreirani predlošci, što predstavlja ograničenje u stvarnoj primjeni. U nastavku se ova metoda naziva HTT, što je kratica od engleskog izraza *Hough Transform with Templates*.

7.2 Eksperimentalna evaluacija CRDI metode

U poglavlju 4.1.4 predložena je IMLD metoda za prepoznavanje pravaca u proizvoljnom položaju. Eksperimentalnom analizom IMLD metode pokazalo se da metoda ne može s dovoljnom točnošću prepoznati redove usjeva u svim razmatranim slučajevima te je zbog toga u poglavlju 4.2 predložena prilagodba IMLD metode za problem prepoznavanja redova usjeva. Predložena prilagodba nazvana je CRDI metoda te su u poglavlju 4.2 dani algoritmi za rješavanje problema prepoznavanja 2 (algoritam 2), 3 (algoritam 3) i k (algoritam 4) redova usjeva. U ovom poglavlju predložene IMLD i CRDI metoda su uspoređene s HT metodom. Metode su uspoređene na umjetno generiranim skupovima podataka za slučaj 2 i 3 reda usjeva, a kao mjera točnosti prepoznavanja korišten je CRHID kriterij opisan u poglavlju 6.1.1. Način generiranja skupova testnih podataka, način provođenja eksperimenta, te rezultati prepoznavanja redova usjeva dani su u nastavku poglavlja.

7.2.1 Postavke pokusa

Sve ispitivane metode (IMLD, CRDI i HT) implementirane su u Matlabu. IMLD i CRDI metode implementirane su prema algoritmima danim u poglavlju 4, dok je HT metoda implementirana prema algoritmu opisanom u (Gonzalez i Woods, 2006).

U eksperimentima je korišteno osobno računalo s Intel Core i5-3350P 3.30 GHz procesorom i 8 GB RAM memorije. Na računalu je instaliran Windows 8.1 Pro 64-bit operacijski sustav te je korištena R2009a verzija Matlaba.

Metode su uspoređene na umjetno generiranim skupovima točaka koji simuliraju re-

dove usjeva (poglavlje 4.2). Postupak generiranja takvih skupova točaka objašnjen je u nastavku. Prvo se odabire sjecište pravaca $S = (x_s, y_s)$ pri čemu se koordinate sjecišta biraju u intervalu $[0, 1]$ za x_s te u intervalu $[2, 10]$ za y_s. Nakon toga odabire se k pravaca koji imaju zajedničko sjecište te interval $[0, 1]$ sijeku u jednako razmaknutim točkama $0 < \nu_1 < \nu_2 <, \ldots, \nu_k < 1$ pri čemu je

$$\nu_{j+1} - \nu_j = d < \tfrac{1}{k-1}.$$

Budući da točke $\nu_1, \ldots, \nu_k$ moraju biti jednako razmaknute (redovi usjeva su međusobno jednako udaljeni), točka ν_1 može se nasumično odabrati u intervalu $[0, 1 - (k-1)d]$, a ostale točke se onda određuju pomoću izraza

$$\nu_j = \nu_1 + (j-1)d, \quad j = 2, \ldots, k.$$

Nakon odabira točaka ν_j i k pravaca oblika (2.3) koji prolaze točkom $\{\nu_j, 0\}$ i imaju zajedničko sjecište, korištenjem postupka opisanog u poglavlju 4.1.1 za svaki pravac se generira skup točaka $\mathcal{A}_j$ koji sadrži m_j točaka. Pri tome su $\eta_1, \ldots, \eta_{m_j}$ jednako razmaknuti brojevi iz intervala $[0, 2]$. Skup točaka $\mathcal{A}$ za evaluaciju metoda se nakon generiranja skupova točaka $\mathcal{A}_j$ dobiva kao

$$\mathcal{A} = \bigcup_{j=1}^{k} \left(\mathcal{A}_j \cap [0,1] \times [0,2]\right), \quad |\mathcal{A}| = m, \tag{7.5}$$

a točke skupa $\mathcal{A}$ se, kao i u poglavlju 4.1.1, označavaju s $T_i(x_i, y_i), i = 1, \ldots, m$. Iz izraza

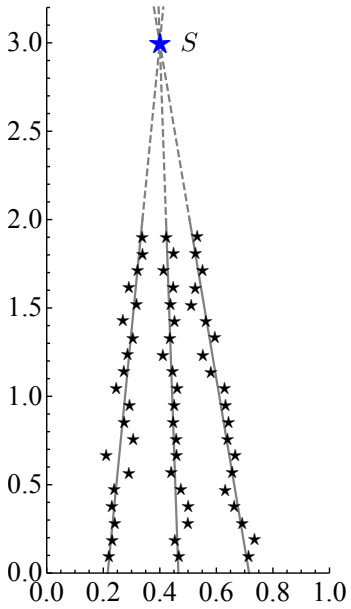

Slika 7.3: Primjer tri pravca koji prolaze sjecištem S i točaka generiranih na temelju tih pravaca.

(7.5) se može vidjeti da se skup $\mathcal{A}$ sastoji od svih točaka skupova $\mathcal{A}_j$ koje se nalaze unutar pravokutnika $[0,1] \times [0,2]$. Točke koje izlaze izvan navedenog pravokutnika se odbacuju pa stoga ukupni broj točaka u skupu $\mathcal{A}$ nije jednak $\sum_{j=1}^{k} m_j$.

Na slici 7.3 prikazana su 3 pravca koji imaju zajedničko sjecište $S = (0.4, 3)$ (plava zvjezdica) te interval $[0,1]$ sijeku u točkama 0.215, 0.465 i 0.715. Točke generirane na temelju prikazanih pravaca označene su crnim zvjezdicama.

Za potrebe eksperimentalne analize, odnosno usporedbe IMLD, CRDI i HT metoda, skup točaka $\mathcal{A}$ je generiran na četiri različita načina. Generiranjem točaka simulirano je *kompletno* i *nekompletno zasijanje* uz manju i veću varijancu. Pod pojmom kompletno zasijanje smatraju se oni redovi usjeva u kojima su svi plodovi zasijani te su iznikli. Analogno tome, pod pojmom nekompletno zasijanje smatraju se oni redovi usjeva u kojima neki plodovi nisu zasijani ili nisu iznikli. Pri generiranju skupa točaka, kompletno zasijanje je simulirano tako da svaki skup $\mathcal{A}_j$ sadrži 20 točaka, dok je nekompletno zasijanje simulirano tako da je $5 - 25\%$ nasumično odabranih točaka izbačeno iz skupa $\mathcal{A}_j$. Postotak izbačenih točaka je, pri simuliranju nekompletnog zasijanja, za svaki skup $\mathcal{A}_j$ nasumično odabran u intervalu $5 - 25\%$. Nadalje, mijenjanjem varijance pri generiranju točaka simulirano je neravno zasijanje i utjecaj korova. Ravnije zasijanje i manji utjecaj korova simuliran je postavljanjem varijance na vrijednost $\sigma^2 = 0.002$, dok je neravno zasijanje i veći utjecaj korova simuliran postavljanjem vrijednosti varijance na $\sigma^2 = 0.02$. Na slici 7.4a i 7.4b prikazane su točke koje simuliraju kompletno i nekompletno zasijanje pri manjoj varijanci ($\sigma^2 = 0.002$). Primjer točaka koje simuliraju kompletno i nekompletno

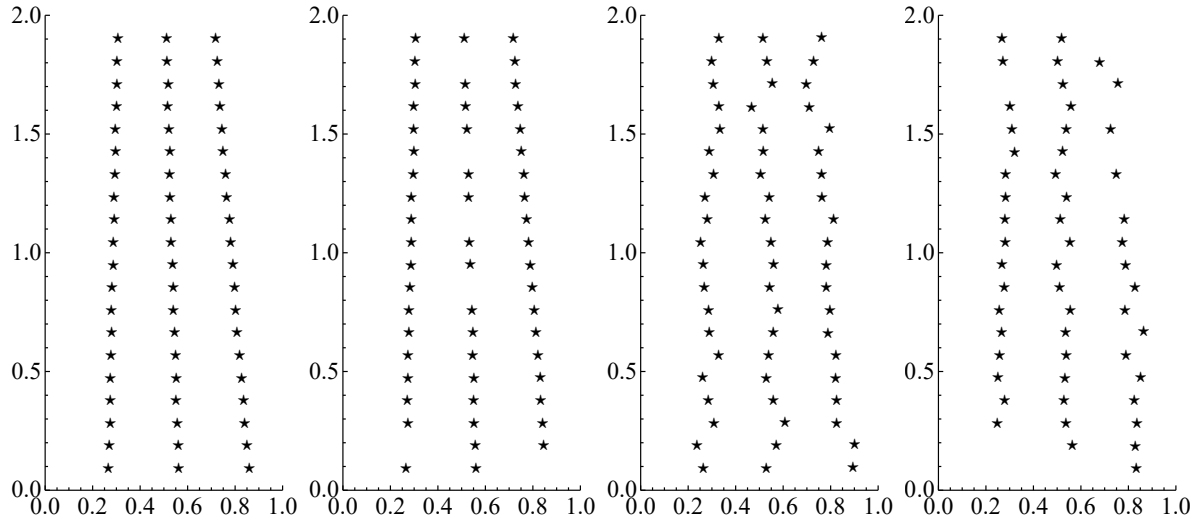

Slika 7.4: Primjer točaka generiranih na temelju tri referentna pravca. (a) Kompletno zasijanje i manja varijanca, (b) Nekompletno zasijanje i manja varijanca, (c) Kompletno zasijanje i veća varijanca, (d) Nekompletno zasijanje i veća varijanca.

zasijanje pri većoj varijanci ($\sigma^2 = 0.02$) prikazan je na slici 7.4c i 7.4d.

U nastavku poglavlja dani su rezultati usporedbe IMLD, CRDI i HT metode u slučaju prepoznavanja 2 i 3 reda usjeva. U svakom pokusu uspoređena je točnost prepoznavanja redova usjeva, određena vrijednošću CRHID kriterija, te efikasnost, određena vremenom izvođenja.

7.2.2 Usporedba prepoznavanja dva reda usjeva

Usporedba HT, IMLD i CRDI metode za prepoznavanje dva reda usjeva na umjetno generiranim skupovima točaka ponovljena je 100 puta za sve četiri kombinacije kompletnog i nekompletnog zasijanja te manje i veće varijance (poglavlje 7.2.1). Pri svakom ponavljanju pokusa generiran je novi skup točaka s $m_1 = m_2 = 20$ točaka po pravcu. Nadalje, u svakom pokusu su nasumičnim odabirom sjecišta S te nasumičnim odabirom točke ν_1 i udaljenosti pravaca d ponovno određeni referentni pravci (referentni redovi usjeva).

Rezultati prepoznavanja dva reda usjeva u slučaju manje varijance ($\sigma^2 = 0.002$) za sve tri razmatrane metode prikazani su u tablici 7.1. Brojevi u tablici predstavljaju broj pokusa u kojima je određena metoda postigla točnost prepoznavanja redova usjeva u rasponu navedenom u prvom stupcu tablice. Budući da je svaki pokus ponovljen 100 puta, ovi brojevi su jednaki postotcima. Posljednji redak tablice predstavlja prosječno vrijeme potrebno za prepoznavanje redova usjeva za svaku metodu. Kao što se može vidjeti u tablici 7.1, u slučaju kompletnog zasijanja predložena CRDI metoda uspijeva u 100% testova prepoznati redove usjeva s visokom točnošću. IMLD i HT metoda istu točnost prepoznavanja, u slučaju kompletnog zasijanja, uspijevaju postići u 75%, odnosno 60% testova, dok je u ostalim slučajevima točnost prepoznavanja lošija. Vrijeme izvođenja CRDI metode u slučaju kompletnog zasijanja iznosi 0.04 s, što je gotovo 6 puta kraće od vremena izvođenja IMLD metode i više od 30 puta kraće od vremena izvođenja HT

	Kompletno zasijanje			Nekompletno zasijanje		
Metoda	HT	IMLD	CRDI	HT	IMLD	CRDI
CRHID < 0.005	60	75	100	54	81	100
$0.005 \leq$ CRHID < 0.01	39	-	-	46	-	-
$0.01 \leq$ CRHID < 0.02	1	-	-	-	-	-
$0.02 \leq$ CRHID < 0.20	-	25	-	-	19	-
Vrijeme (s)	1.25	0.23	0.04	1.25	0.23	0.04

Tablica 7.1: Usporedba HT, IMLD i CRDI metode pri prepoznavanju dva reda usjeva uz manju varijancu ($\sigma^2 = 0.002$)

	Kompletno zasijanje			Nekompletno zasijanje		
Metoda	HT	IMLD	CRDI	HT	IMLD	CRDI
CRHID < 0.05	31	84	99	30	69	98
$0.05 <$ CRHID ≤ 0.1	12	3	1	14	4	2
$0.1 <$ CRHID ≤ 0.2	9	12	-	17	27	-
$0.2 <$ CRHID ≤ 0.5	48	1	-	39	-	-
Vrijeme (s)	1.25	0.24	0.04	1.24	0.23	0.04

Tablica 7.2: Usporedba HT, IMLD i CRDI metode pri prepoznavanju dva reda usjeva uz veću varijancu ($\sigma^2 = 0.02$)

metode. U slučaju nekompletnog zasijanja (za istu varijancu), rezultati prepoznavanja redova usjeva su slični. I u ovom slučaju CRDI metoda uspijeva u 100% testova postići visoku točnost, dok IMLD i HT metoda istu točnost postižu u 81% i 54% testova. Vremena izvođenja algoritama jednaka su kao i u slučaju kompletnog zasijanja. Iz provedenog pokusa može se zaključiti da pri prepoznavanju dva reda usjeva u slučaju relativno male varijance ($\sigma^2 = 0.002$), u svim razmatranim metodama nema značajne razlike u točnosti prepoznavanja između kompletnog i nekompletnog zasijanja.

U tablici 7.2 prikazani su rezultati prepoznavanja dva reda usjeva za sve tri razmatrane metode u slučaju veće varijance ($\sigma^2 = 0.02$). Iz tablice se može vidjeti da pri kompletnom zasijanju CRDI metoda u 99% testova uspjeva postići visoku točnost, dok IMLD i HT metoda istu točnost postižu u 84%, odnosno 31% testova. U ostalim testovima, točnost prepoznavanja redova usjeva primjenom IMLD i HT metode je lošija. U slučaju nekompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$) CRDI metoda uspijeva u 98%

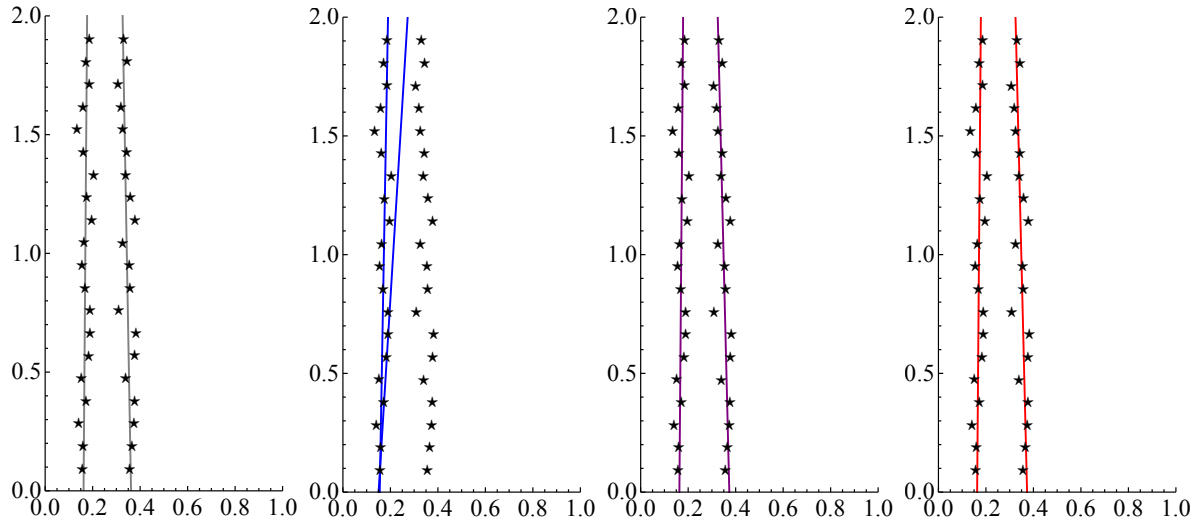

(a) (b) $CRHID = 0.26$ (c) $CRHID = 0.01$ (d) $CRHID = 0.01$

Slika 7.5: Primjer pokusa prepoznavanja dva reda usjeva u slučaju kompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$). (a) Generirane točke, (b) HT metoda, (c) IMLD metoda, (d) CRDI metoda.

testova prepoznati redove usjeva s visokom točnošću. IMLD i HT metoda istu točnost postižu u samo 69% i 30% testova, dok je u ostalim testovima točnost prepoznavanja lošija. Vremena izvođenja svih metoda podjednaka su kao u prvom pokusu pa se može zaključiti da varijanca pri generiranju točaka ne utječe na vrijeme izvođenja razmatranih metoda. Za razliku od prvog pokusa, u ovom pokusu se pokazalo da postoji razlika u točnosti prepoznavanja redova usjeva HT i IMLD metodom u slučajevima kompletnog i nekompletnog zasijanja.

Na slici 7.5 prikazan je primjer pokusa prepoznavanja dva reda usjeva u slučaju kompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$). Generirane točke i referentni redovi usjeva prikazani su na slici 7.5a, dok su redovi usjeva dobiveni primjenom HT, IMLD i CRDI metode prikazani na slikama 7.5b, 7.5c i 7.5d. Na slikama se može vidjeti kako IMLD i CRDI metoda uspjevaju dobro prepoznati oba reda usjeva, dok HT metoda uspjeva dobro prepoznati samo lijevi red usjeva. Za prikazani primjer navedene su i vrijednosti CRHID kriterija koje iznose 0.26 za HT metodu, te 0.01 za IMLD i CRDI metodu.

Primjer pokusa prepoznavanja dva reda usjeva u slučaju nekompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$) prikazan je na slici 7.6. Referentni redovi usjeva i točke generirane na temelju tih referentnih redova prikazani su na slici 7.6a. Na slikama 7.6b, 7.6c i 7.6d prikazani su redovi usjeva dobiveni primjenom HT, IMLD i CRDI metode. Iz prikazanih rezultata može se vidjeti da IMLD metoda ne uspijeva prepoznati ni jedan red usjeva, HT metoda uspijeva prepoznati desni red usjeva, dok CRDI metoda s visokom točnošću prepoznaje oba reda usjeva. Vrijednosti CRHID kriterija za prikazani primjer iznose 0.29,

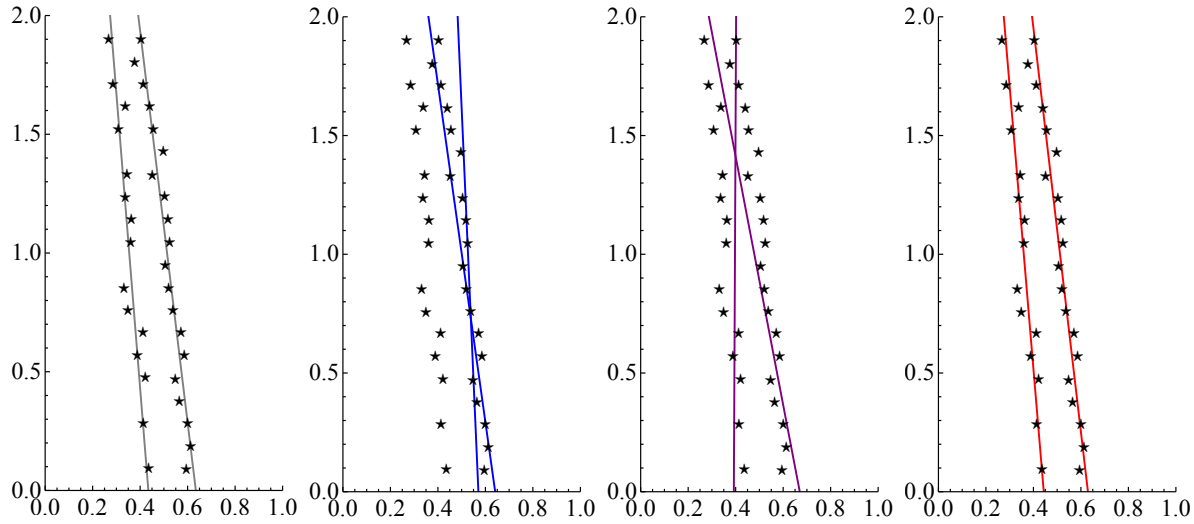

Slika 7.6: Primjer pokusa prepoznavanja dva reda usjeva u slučaju nekompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$). (a) Generirane točke, (b) HT metoda, (c) IMLD metoda, (d) CRDI metoda.

0.11 i 0.01 za HT, IMLD i CRDI metodu.

Iz provedenih pokusa te prikazanih rezultata i primjera može se zaključiti da CRDI metoda s visokom točnošću prepoznaje dva reda usjeva u slučajevima kompletnog i nekompletnog zasijanja te manje i veće varijance. Pri manjoj varijanci, nekompletno zasijanje nema utjecaj na točnost prepoznavanja redova usjeva primjenom CRDI metode, dok je utjecaj pri većoj varijanci gotovo zanemariv. U ovim pokusima je pokazana i potreba za prilagodbom IMLD metode za problem prepoznavanja redova usjeva, kao što je navedeno u poglavlju 4.2.

7.2.3 Usporedba prepoznavanja tri reda usjeva

Usporedba HT, IMLD i CRDI metode za prepoznavanje tri reda usjeva na umjetno generiranim skupovima ponovljena je, kao i u slučaju pokusa s dva reda usjeva (poglavlje 7.2.2), 100 puta za sve četiri kombinacije kompletnog i nekompletnog zasijanja te manje i veće varijance (poglavlje 7.2.1). Nadalje, jednako kao u poglavlju 7.2.2, za svako ponavljanje pokusa generirani su novi referentni redovi usjeva te novi skupovi točaka. Broj točaka po redu usjeva je u svim ponavljanjima postavljen na $m_1 = m_2 = m_3 = 20$.

U tablici 7.3 prikazani su rezultati prepoznavanja tri reda usjeva u slučaju manje varijance ($\sigma^2 = 0.002$) za sve tri razmatrane metode. Iz prikazanih rezultata može se uočiti da, u slučaju kompletnog zasijanja, HT i CRDI metoda u 100% testova postižu visoku točnost, dok IMLD metoda istu točnost postiže u 79% testova. U ostalim slučajevima točnost prepoznavanja redova usjeva primjenom IMLD metode je lošija. U slučaju nekompletnog zasijanja IMLD metoda postiže visoku točnost u samo 63% testova, dok HT i CRDI metoda i u ovom slučaju postižu visoku točnost u svih 100% testova. Vremena izvođenja metoda su slična u slučaju kompletnog i nekompletnog zasijanja. Iz prikazanih vremena može se uočiti da je vrijeme izvođenja CRDI metode nešto kraće od vremena

	Kompletno zasijanje			Nekompletno zasijanje		
Metoda	HT	IMLD	CRDI	HT	IMLD	CRDI
CRHID < 0.05	100	79	100	100	63	100
$0.05 <$ CRHID ≤ 0.1	-	6	-	-	5	-
$0.1 <$ CRHID ≤ 0.15	-	13	-	-	16	-
$0.15 <$ CRHID ≤ 0.20	-	2	-	-	16	-
Vrijeme (s)	1.25	0.45	0.37	1.25	0.44	0.36

Tablica 7.3: Usporedba HT, IMLD i CRDI metode pri prepoznavanju tri reda usjeva uz manju varijancu ($\sigma^2 = 0.002$)

	Kompletno zasijanje			Nekompletno zasijanje		
Metoda	HT	IMLD	CRDI	HT	IMLD	CRDI
CRHID < 0.05	18	74	100	8	67	98
$0.05 <$ CRHID ≤ 0.1	5	2	-	5	3	2
$0.1 <$ CRHID ≤ 0.15	2	10	-	6	11	-
$0.15 <$ CRHID ≤ 0.20	6	14	-	4	19	-
Vrijeme (s)	1.25	0.46	0.36	1.25	0.45	0.36

Tablica 7.4: Usporedba HT, IMLD i CRDI metode pri prepoznavanju tri reda usjeva uz veću varijancu ($\sigma^2 = 0.02$)

izvođenja IMLD metode te je $3 - 4$ puta kraće od vremena izvođenja HT metode.

Rezultati prepoznavanja tri reda usjeva u slučaju veće varijance ($\sigma^2 = 0.02$) za sve tri razmatrane metode prikazani su u tablici 7.4. Iz prikazanih rezultata može se uočiti da, u slučaju kompletnog zasijanja, CRDI metoda ponovno postiže visoku točnost u 100% testova, dok je postotak testova u kojima HT metoda postiže jednaku točnost prepoznavanja znatno niži u odnosu na eksperiment s manjom varijancom (tablica 7.3) i iznosi samo 18%. Jednaku točnost prepoznavanja IMLD metoda postiže u 74% testova, što je sličan rezultat kao u slučaju manje varijance. U slučaju nekompletnog zasijanja, CRDI metoda zadržava visok postotak testova (98%) u kojima postiže visoku točnost prepoznavanja redova usjeva. Postotak testova u kojima HT i IMLD metoda postižu visoku točnost opada u odnosu na slučaj s kompletnim zasijanjem i iznosi 8% i 67%. Vremena izvođenja svih razmatranih metoda, za oba pokusa prepoznavanja tri reda usjeva u slučaju veće varijance, slična su kao vremena izvođenja u pokusima prepoznavanja tri

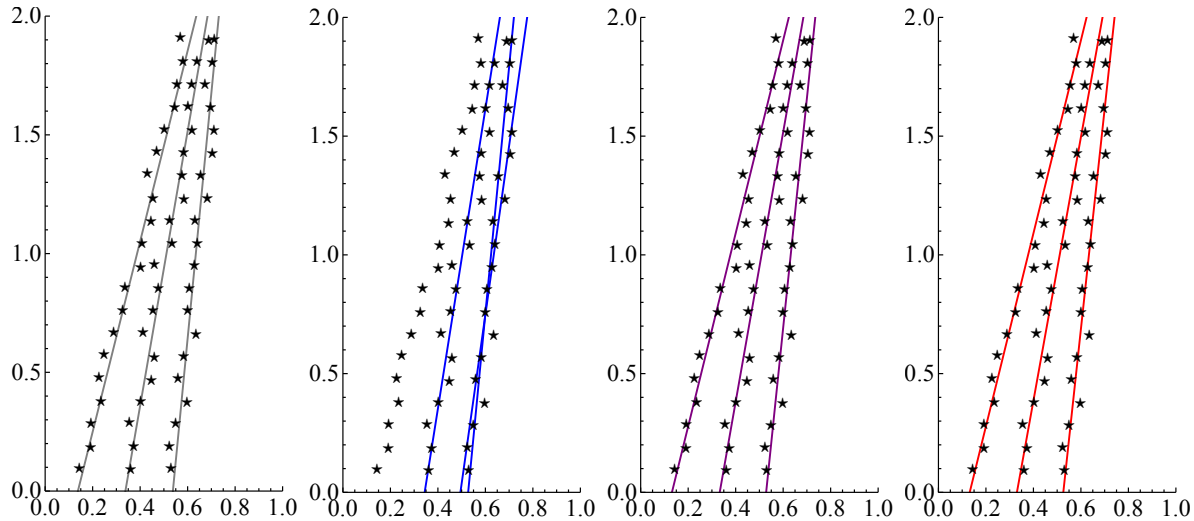

(a) (b) $CRHID = 0.23$ (c) $CRHID = 0.02$ (d) $CRHID = 0.02$

Slika 7.7: Primjer pokusa prepoznavanja tri reda usjeva u slučaju kompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$). (a) Generirane točke, (b) HT metoda, (c) IMLD metoda, (d) CRDI metoda.

reda usjeva u slučaju manje varijance.

Primjer pokusa prepoznavanja tri reda usjeva u slučaju veće varijance i kompletnog zasijanja prikazan je na slici 7.7. Na slici 7.7a prikazani su referentni redovi usjeva i generirane točke, a na slikama 7.7b, 7.7c i 7.7d prikazani su redovi usjeva dobiveni primjenom HT, IMLD i CRDI metode. Iz prikazanih slika može se vidjeti da IMLD i CRDI metoda uspjevaju dobro prepoznati sva tri reda usjeva, dok HT metoda uspjeva prepoznati samo centralni i desni red usjeva. Ispod svake od slika prikazane su vrijednosti CRHID kriterija koje iznose 0.23 za HT metodu te 0.02 za IMLD i CRDI metodu.

Na slici 7.8 prikazan je primjer pokusa prepoznavanja tri reda usjeva u slučaju veće varijance i nekompletnog zasijanja. Na slici 7.8a prikazani su referentni redovi usjeva te točke generirane na temelju tih referentnih redova. Redovi usjeva dobiveni primjenom HT, IMLD i CRDI metode prikazani su na slikama 7.8b, 7.8c i 7.8d. Na prikazanim primjerima može se vidjeti kako CRDI metoda dobro prepoznaje sva tri reda usjeva, HT metoda uspjeva prepoznati centralni i desni red usjeva, dok IMLD metoda dobro prepoznaje samo desni red usjeva. I u ovom primjeru navedene su vrijednosti CRHID kriterija koje iznose 0.30 za HT metodu, 0.14 za IMLD metodu te 0.01 za CRDI metodu.

Analiziranjem provedenih pokusa za prepoznavanje tri reda usjeva može se zaključiti da CRDI metoda s visokom točnošću prepoznaje redove usjeva u slučajevima kompletnog i nekompletnog zasijanja te manje i veće varijance. Kao i kod pokusa provedenih u poglavlju 7.2.2 i u ovom poglavlju je pokazano da ne postoji utjecaj nekompletnog zasijanja na točnost prepoznavanja redova usjeva primjenom CRDI metode pri manjoj varijanci, dok je

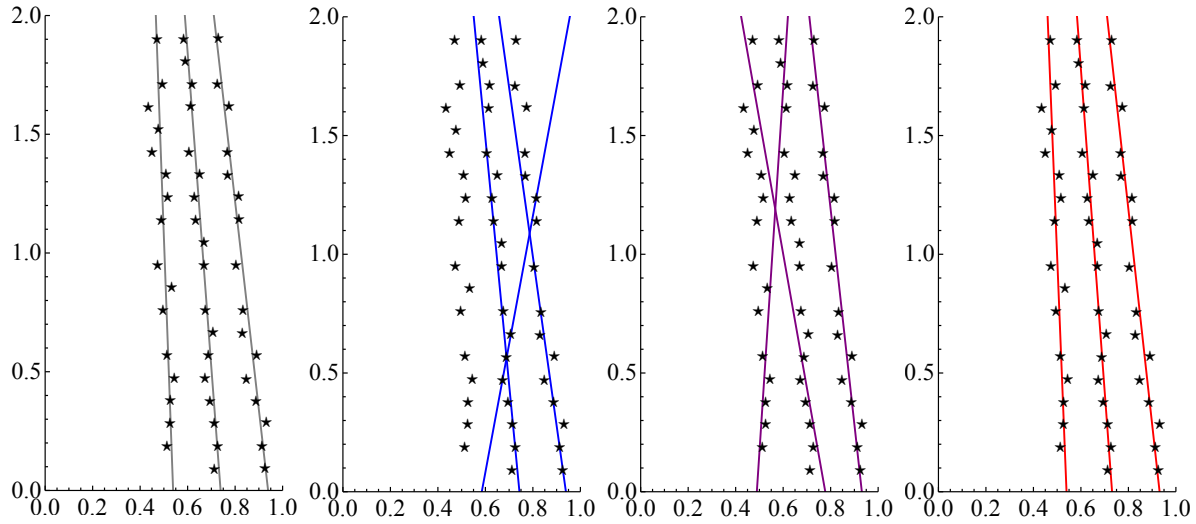

Slika 7.8: Primjer pokusa prepoznavanja tri reda usjeva u slučaju nekompletnog zasijanja i veće varijance ($\sigma^2 = 0.02$). (a) Generirane točke, (b) HT metoda, (c) IMLD metoda, (d) CRDI metoda.

utjecaj pri većoj varijanci gotovo zanemariv. Iz tablica 7.3 i 7.4 može se uočiti i da točnost prepoznavanja redova usjeva primjenom HT metode znatno opada pri povećanju varijance. Provedeni pokusi pokazuju i utjecaj nekompletnog zasijanja na točnost prepoznavanja redova usjeva primjenom IMLD pri manjoj i većoj varijanci. Točnost prepoznavanja primjenom IMLD ponovno potvrđuje potrebu za prilagodbom IMLD metode za problem prepoznavanja redova usjeva, kao što je navedeno u poglavlju 4.2.

7.3 Eksperimentalna evaluacija TMGEM metode

Predložena TMGEM metoda je eksperimentalno analizirana na stvarnim slikama redova usjeva iz baze slika redova usjeva koja je sastavni dio evaluacijskog okvira za usporedbu metoda prepoznavanja redova usjeva, predloženog u poglavlju 6. Za određivanje točnosti

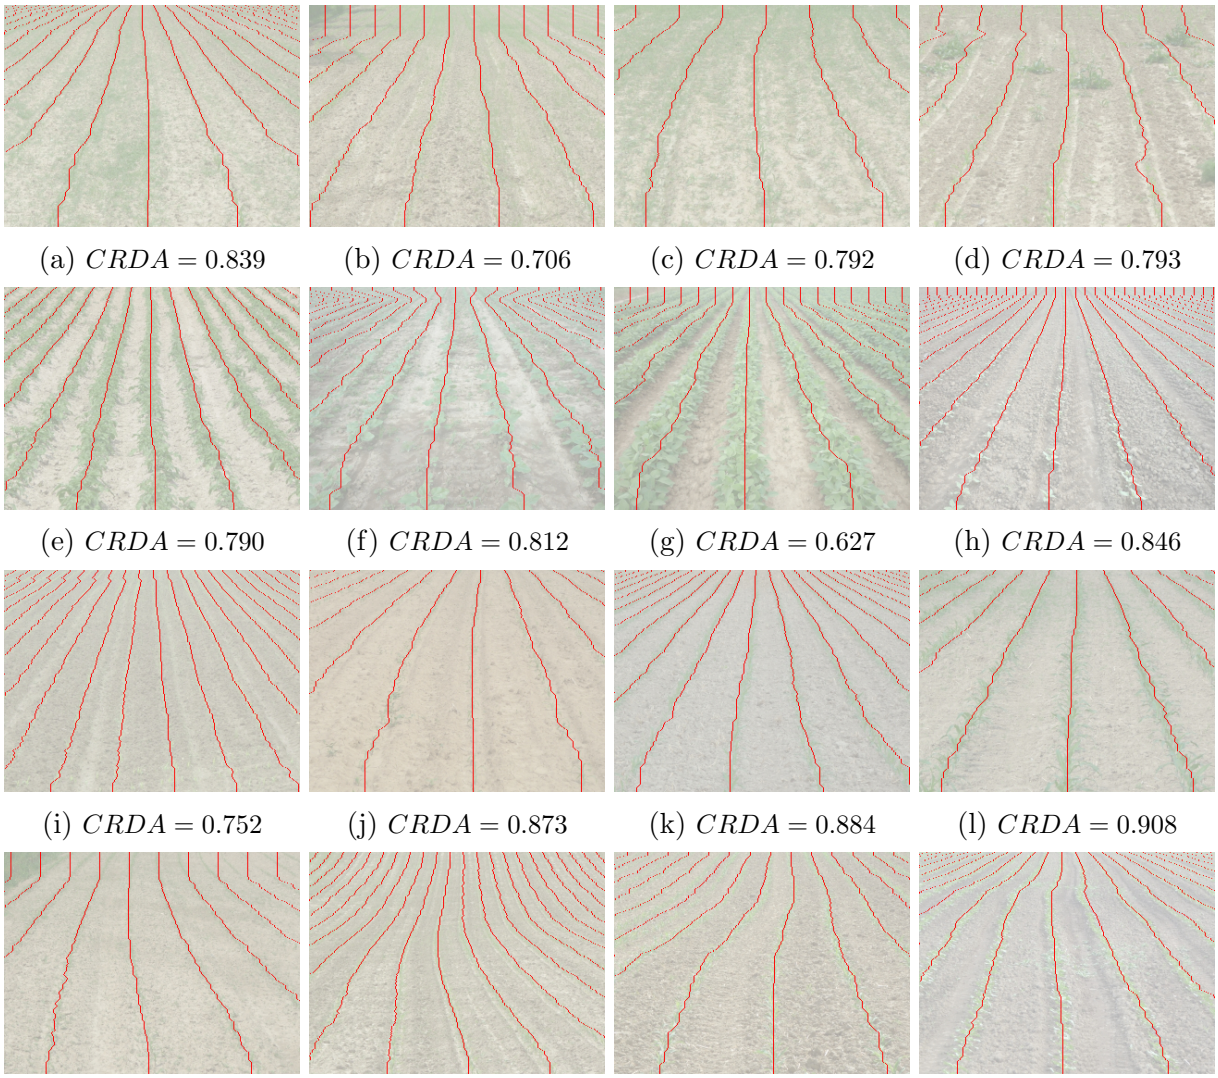

(a) $CRDA = 0.839$ (b) $CRDA = 0.706$ (c) $CRDA = 0.792$ (d) $CRDA = 0.793$

(e) $CRDA = 0.790$ (f) $CRDA = 0.812$ (g) $CRDA = 0.627$ (h) $CRDA = 0.846$

(i) $CRDA = 0.752$ (j) $CRDA = 0.873$ (k) $CRDA = 0.884$ (l) $CRDA = 0.908$

(m) $CRDA = 0.845$ (n) $CRDA = 0.755$ (o) $CRDA = 0.887$ (p) $CRDA = 0.834$

Slika 7.9: Primjeri redova usjeva dobivenih primjenom TMGEM metode na slikama redova usjeva prikazanim na slici 6.4.

prepoznatih redova usjeva korišten je CRDA kriterij, kojim se određuje mjera odstupanja prepoznatih redova usjeva od referentnih redova usjeva. Referentne vrijednosti redova usjeva su određene korištenjem postupka predloženog u poglavlju 6.2.

Rezultati prepoznavanja redova usjeva za primjere slika iz baze slika redova usjeva (slika 6.4) prikazani su na slici 7.9. Ispod svake slike prikazana je vrijednost CRDA kriterija koja je izračunata na temelju referentnih vrijednosti redova usjeva iz CRBD seta. Analiziranjem prikazanih rezultata, može se zaključiti da TMGEM metoda može točno prepoznati redove usjeva za različite kulture, različite geometrije redova usjeva te različite uvjete okoline. Kako bi se doneseni zaključak potvrdio, u sklopu ovog poglavlja napravljena je detaljnija analiza rezultata prepoznavanja redova usjeva primjenom TMGEM metode, pri čemu su za usporedbu rezultata prepoznavanja korištene HT, LR i HTT metoda.

U nastavku poglavlja detaljnije su opisane postavke provedenih pokusa, prikazani su dobiveni rezultati te su napravljene detaljne analize i zaključci koji iz njih proizlaze.

7.3.1 Postavke pokusa

Za potrebe eksperimentalne evaluacije, predložena TMGEM metoda je implementirana u programskom paketu Visual Studio, korištenjem C++ programskog jezika. Predložena metoda ima nekoliko korisnički definiranih parametara, objašnjenih u poglavlju 5. Parametri d_{min} i n_{spo} predstavljaju minimalnu vrijednost parametra d i broj uzoraka parametra d po oktavi. Pri tome, pojam oktava označava interval između vrijednosti d i $2d$. Navedeni parametri su u izrazu (5.12) korišteni za određivanje diskretnih vrijednosti parametra d. Broj oktava definiran je parametrom n_{oct}. Penalizacija promjena parametara c i d, za dva susjedna retka slike, u izrazu (5.21) određena je parametrima λ_c i λ_d. Što je vrijednost ovih parametara veća, više se penalizira promjena u parametrima i obrnuto. Parametri D_{max} i f_{low} se u izrazu (5.20) i u algoritmu 7 koriste za smanjivanje osjetljivosti metode

Parametar	Vrijednost
d_{min}	8
n_{spo}	70
n_{oct}	5
λ_c	0.5
λ_d	0.2
D_{max}	0.5
f_{low}	1

Tablica 7.5: Korisnički definirani parametri TMGEM metode i njihove vrijednosti.

optimizacije na odudarajuće vrijednosti. Vrijednosti svih navedenih parametara prikazane su u tablici 7.5 i jednake su za sve pokuse provedene u sklopu ovog istraživanja. Prikazane vrijednosti dobivene su kroz niz preliminarnih pokusa provedenih tijekom razvoja predložene TMGEM metode. Broj uzoraka po oktavi n_{spo} je postavljen na 70, što predstavlja povećanje od približno 1% između dvije susjedne vrijednosti parametra d u skupu χ. Vrijednosti parametra d podijeljene su na $n_{oct} = 5$ oktava te je početna vrijednost postavljena na $d_{min} = 8$. Prema tome, u skupu χ ima ukupno $n_d = 351$ diskretnih vrijednosti parametra d, od minimalne $d_{min} = 8$ do maksimalne $d_{max} = 256$. Parametri penalizacije λ_c i λ_d postavljeni su na vrijednost 0.5, odnosno 0.2. Vrijednost parametra D_{max} postavljena je na 0.5, a parametra f_{low} na 1.

Kao što je rečeno u uvodu ovog poglavlja, eksperimentalna evaluacija TMGEM metode napravljena je na stvarnim slikama redova usjeva iz baze slika redova usjeva (poglavlje 6.3). Osim točnosti prepoznavanja redova usjeva, određene primjenom CRDA kriterija, u svim pokusima je mjereno i vrijeme izvođenja svakog koraka TMGEM metode. U sklopu evaluacije napravljena su tri pokusa koja su detaljnije objašnjena u nastavku.

U prvom pokusu napravljena je usporedba TMGEM metode s postojećim metodama. Budući da većina metoda predloženih u literaturi ima mogućnost prepoznavanja samo ravnih redova usjeva, usporedba je napravljena na skupu slika ravnih redova usjeva. Iz baze slika su, za potrebe ovog pokusa, izdvojene 34 slike ravnih redova usjeva. Slike su izabrane iz testnog skupa slika (poglavlje 6.3) koji sadrži 225 slika. Za usporedbu su korištene HT, LR i HTT metode koje su implementirane u Matlabu. HT metoda je implementirana prema algoritmu opisanom u (Gonzalez i Woods, 2006), LR metoda prema radu (Montalvo et al., 2012), a HTT metoda prema opisu danom u poglavlju 7.1.3. Prilikom implementacije HT metode dodana su određena ograničenja, s ciljem povećanja točnosti prepoznavanja redova usjeva. Spomenuta ograničenja uključuju ograničavanje vrijednosti kuta ρ na interval $[-35°, 35°]$, ograničavanje udaljenosti pravca od ishodišta δ na interval $[100, 200]$ te ograničavanje broja linija na 4 najdominantnije. Redovi usjeva dobiveni primjenom HT, LR i HTT metode opisani su pravcima, odnosno SCR modelom, dok su redovi usjeva dobiveni primjenom TMGEM metode opisani CCR modelom redova usjeva. Kako bi se za dobivene rezultate mogla izračunati vrijednost CRDA kriterija, dobiveni redovi usjeva prikazani su u uniformnom obliku opisanom u poglavlju 6.1.2. Uniformni oblik zapravo predstavlja matricu koja za svaki redak slike sadrži horizontalne koordinate k susjednih redova usjeva. Za sve razmatrane metode, napravljena je usporedba tri reda usjeva s referentnim vrijednostima redova usjeva, odnosno parametar k u

izrazu 6.5 je postavljen na vrijednost 3. U slučajevima kada je na slici vidljivo više od tri reda usjeva, javlja se problem pri odabiru redova usjeva za usporedbu. Stoga se, pri svakoj usporedbi, referentne vrijednosti $u^*_{v,i}$ određuju za devet susjednih redova usjeva te se vrijednost CRDA kriterija računa za sve moguće trojke susjednih redova usjeva. Konačno, maksimalna CRDA vrijednost, od izračunatih sedam vrijednosti, uzima se kao konačna mjera točnosti prepoznavanja redova usjeva za određenu sliku.

U drugom pokusu je TMGEM metoda ispitana na preostalih 191 slika iz testnog skupa slika, na kojima su prikazani zakrivljeni redovi usjeva. Budući da, prema dosadašnjim spoznajama, u literaturi ne postoje metode za prepoznavanje zakrivljenih redova usjeva na 2D slici, u ovom pokusu ispitana je, između ostalog, robusnost predložene metode na zakrivljenost redova usjeva.

Treći pokus napravljen je s ciljem ispitivanja utjecaja rezolucije slike na točnost prepoznavanja redova usjeva. U ovom pokusu ispitana je samo TMGEM metoda koja je primijenjena na svih 225 slika iz testnog skupa slika. Osim slika rezolucije 320×240, koje su korištene u prva dva pokusa, u ovom pokusu su korištene i slike rezolucije 640×480.

U svim navedenim pokusima je, kao i pri eksperimentalnoj evaluaciji CRDI metode (poglavlje 7.2), korišteno osobno računalo s Intel Core i5-3350P 3.30 GHz procesorom i 8 GB RAM memorije. Na računalu je instaliran Windows 8.1 Pro 64-bit operacijski sustav te Matlab R2009a i Microsoft Visual Studio 2008 Professional Edition.

7.3.2 Usporedba prepoznavanja ravnih redova usjeva

U prvom pokusu, u sklopu eksperimentalne evaluacije TMGEM metode, napravljena je usporedba redova usjeva dobivenih primjenom predložene TMGEM metode i redova usjeva dobivenih primjenom HT, LR i HTT metode. Za usporedbu je korišten skup od 34 slike na kojima su prikazani ravni redovi usjeva.

Kvantitativna ocjena prepoznatih redova usjeva određena je korištenjem CRDA kriterija. Srednja vrijednost, medijan i standardna devijacija CRDA kriterija, za sve 4 razmatrane metode, prikazane su u tablici 7.6. Iz prikazanih rezultata može se uočiti

CRDA	HT	HTT	LR	TMGEM
Srednja vrijednost	0.572	0.622	0.679	0.737
Medijan	0.618	0.670	0.708	0.787
Std. devijacija	0.287	0.253	0.198	0.182
Poredak	4	3	2	1

Tablica 7.6: Vrijednosti CRDA kriterija za prvi pokus.

da srednja vrijednost CRDA kriterija za TMGEM metodu iznosi 0.737, dok je za ostale ispitane metode srednja vrijednost manja od 0.7. Medijan CRDA kriterija za TMGEM metodu ima vrijednost 0.787, dok za HT, HTT i LR metodu iznosi 0.618, 0.670 i 0.708. Osim najvećeg iznosa srednje vrijednosti i medijana, TMGEM metoda ima i najmanju vrijednost standardne devijacije CRDA kriterija. Standardna devijacija CRDA kriterija za TMGEM metodu iznosi 0.182, dok su za ostale ispitane metode vrijednosti standardne devijacije veće ili jednake od 0.198. Poredak u tablici 7.6 određen je uspoređivanjem srednje vrijednosti, medijana i standardne devijacije. Iz prikazanog poretka može se vidjeti da TMGEM metoda zauzima prvo mjesto, LR metoda drugo, HTT metoda treće, a HT metoda posljednje, četvrto, mjesto. Iz rezultata prikazanih u tablici 7.6 može se zaključiti da TMGEM metoda daje značajno veće vrijednosti CRDA kriterija od ostalih metoda.

Rezultati prvog pokusa prikazani su na slici 7.10 u obliku normaliziranih kumulativnih histograma (engl. *normalized cumulative histograms*). Normalizirani kumulativni histogram je način prikaza podataka pri čemu os apscisa odgovara vrijednostima mjerene varijable x, a os ordinata označava postotak mjerenja koja imaju vrijednost $\geq x$. Iz prikazanih normaliziranih kumulativnih histograma se može vidjeti da CRDA kriterij, u 95% ispitanih slika, za TMGEM metodu ima vrijednost 0.495 ili veću. Za HT, HTT i LR metodu, u 95% ispitanih slika, CRDA kriterij ima vrijednosti jednake ili veće od

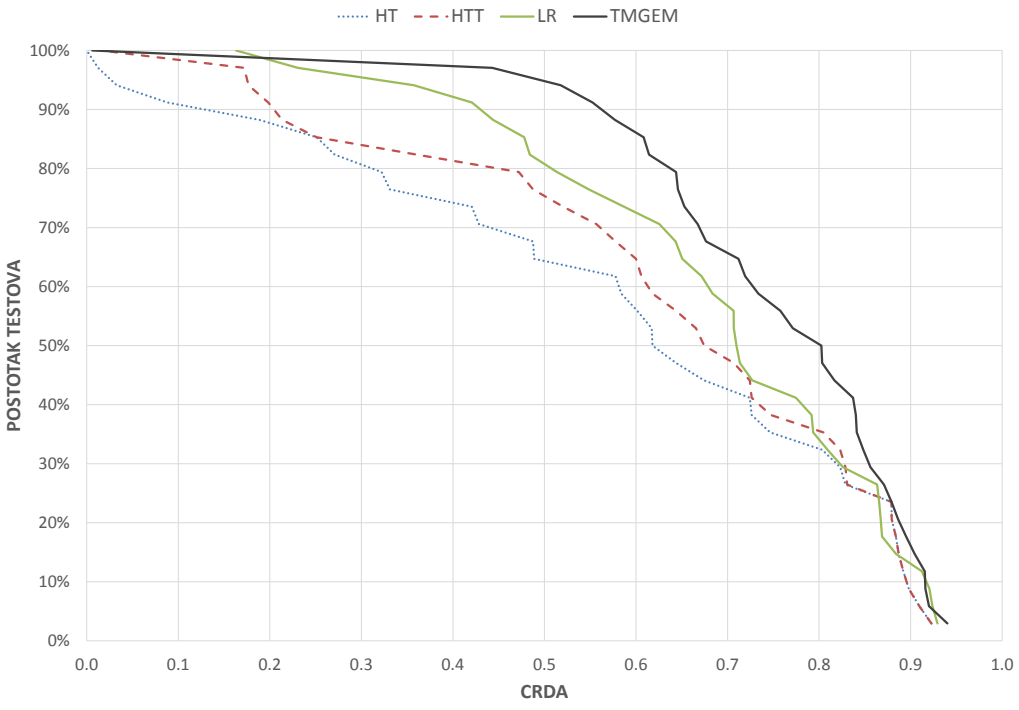

Slika 7.10: Normalizirani kumulativni histogrami CRDA kriterija za prvi pokus.

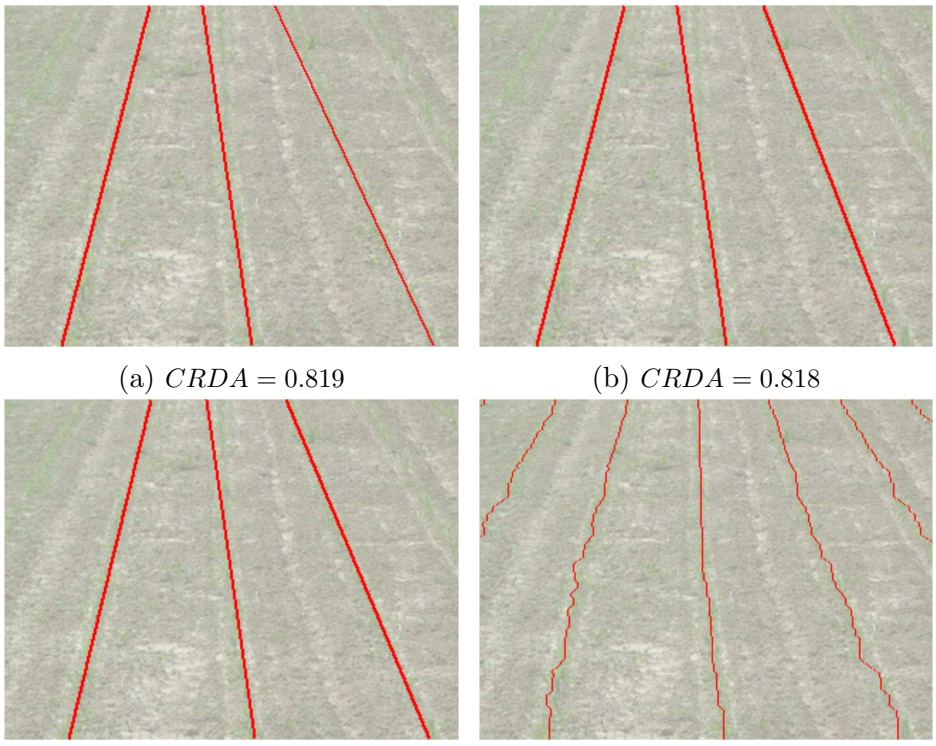

(a) $CRDA = 0.819$ (b) $CRDA = 0.818$

(c) $CRDA = 0.870$ (d) $CRDA = 0.917$

Slika 7.11: Primjer redova usjeva dobivenih primjenom (a) HT metode, (b) HTT metode, (c) LR metode, (d) TMGEM metode.

0.319, 0.175 i 0.026. Iz ovog prikaza rezultata se ponovno može zaključiti kako predložena TMGEM metoda značajno nadmašuje ostale tri razmatrane metode.

Redovi usjeva, dobiveni primjenom sve 4 razmatrane metode na jednoj testnoj slici, prikazani su na slici 7.11. Ispod svake slike prikazane su vrijednosti CRDA kriterija koje iznose 0.819, 0.818, 0.870 i 0.917 za HT, HTT, LR i TMGEM metodu. Iz prikazanih rezultata i vrijednosti CRDA kriterija, može se zaključiti da za razmatrani primjer TMGEM metoda postiže najveću točnost prepoznavanja redova usjeva.

Kao što je rečeno u poglavlju 7.3.1, svi pokusi su izvedeni na osobnom računalu s Intel Core i5-3350P 3.30 GHz procesorom i 8 GB RAM memorije. Vremena izvođenja pojedinih koraka TMGEM metode prikazana su u tablici 7.7. Koraci TMGEM metode su kreiranje slike vegetacije, računanje podudaranja s predloškom te određivanje optimal-

	Slika vegetacije			Podudaranje s predloškom			Optimizacija			Ukupno		
	min	max	avg	min	max	avg	min	max	avg	min	max	avg
Pokus 1	< 1	16	1.7	875	937	880.6	812	907	862.2	1687	1979	1744.5

Tablica 7.7: Vremena izvođenja pojedinih koraka TMGEM metode za prvi pokus. Vremena su prikazana u ms.

nog CCR modela redova usjeva. Osim vremena pojedinih koraka prikazano je i ukupno vrijeme izvođenja TMGEM metode. Za sva mjerena vremena prikazane su minimalna, maksimalna i srednja vrijednost određene za sve 34 slike. Srednja vrijednost je u tablici 7.7 označena s *avg*, što je kratica od engleskog izraza za srednju vrijednost (engl. *average*). Iz prikazanih vremena može se uočiti da korak kreiranja slike vegetacije nije računski zahtjevan korak, dok koraci računanja podudaranja s predloškom i određivanja optimalnog CCR modela traju oba oko 870 ms. Nadalje, vidljivo je da ukupno vrijeme izvođenja TMGEM metode u prvom pokusu iznosi oko 1750 ms.

7.3.3 Evaluacija prepoznavanja zakrivljenih redova usjeva

U drugom pokusu napravljena je evaluacija predložene TMGEM metode na 191 slici zakrivljenih redova usjeva. Analogno prvom pokusu, za određivanje točnosti prepoznavanja redova usjeva korišten je CRDA kriterij. Osim točnosti prepoznavanja redova usjeva, i u ovom pokusu je mjereno vrijeme izvođenja metode. Rezultati prepoznavanja zakrivljenih redova usjeva primjenom TMGEM metode nisu uspoređeni s rezultatima prepoznavanja dobivenim primjenom postojećih metoda jer, prema dosadašnjim spoznajama, metode predložene u literaturi imaju mogućnost prepoznavanja samo ravnih redova usjeva.

Primjeri slika zakrivljenih redova usjeva prikazani su na slici 7.12. Slika 7.12a prikazuje zakrivljene redove usjeva uz minimalnu prisutnost korova, dok slika 7.12b prikazuje zakrivljene redove usjeva uz veću prisutnost korova. Na slici 7.12b osim korova između redova usjeva, može se uočiti i veća količina trave u lijevom gornjem kutu slike. Također, zbog utjecaja perspektive, pri vrhu slike 7.12b nije vidljiv ponavljajući uzorak redova usjeva.

(a) (b)

Slika 7.12: Primjeri slika zakrivljenih redova usjeva.

CRDA	TMGEM
Srednja vrijednost	0.748
Medijan	0.776
Std. devijacija	0.136

Tablica 7.8: Vrijednosti CRDA kriterija za drugi pokus.

Srednja vrijednost, medijan i standardna devijacija CRDA kriterija, za sve ispitane slike, prikazane su u tablici 7.8. U tablici se može vidjeti da srednja vrijednost CRDA kriterija iznosi 0.748, medijan 0.776, a standardna devijacija 0.136. Iz prikazanih rezultata se može uočiti da je točnost prepoznavanja redova usjeva slična kao u prvom pokusu. Prema tome, može se zaključiti da je predložena TMGEM metoda robusna na zakrivljenost redova usjeva, odnosno da s visokom točnošću može prepoznati ravne i zakrivljene redove usjeva.

Normalizirani kumulativni histogrami CRDA kriterija za drugi pokus prikazani su na slici 7.13. Zbog lakše usporedbe s normaliziranim kumulativnim histogramom TMGEM metode iz prvog pokusa, na slici 7.13 su prikazana dva normalizirana kumulativna histograma. Prvi (puna linija) se odnosi na rezultate TMGEM metode na slikama ravnih redova usjeva, a drugi (isprekidana linija) na rezultate TMGEM metode na slikama zakrivljenih redova usjeva. Iz prikazanih histograma može se vidjeti da CRDA kriterij, u

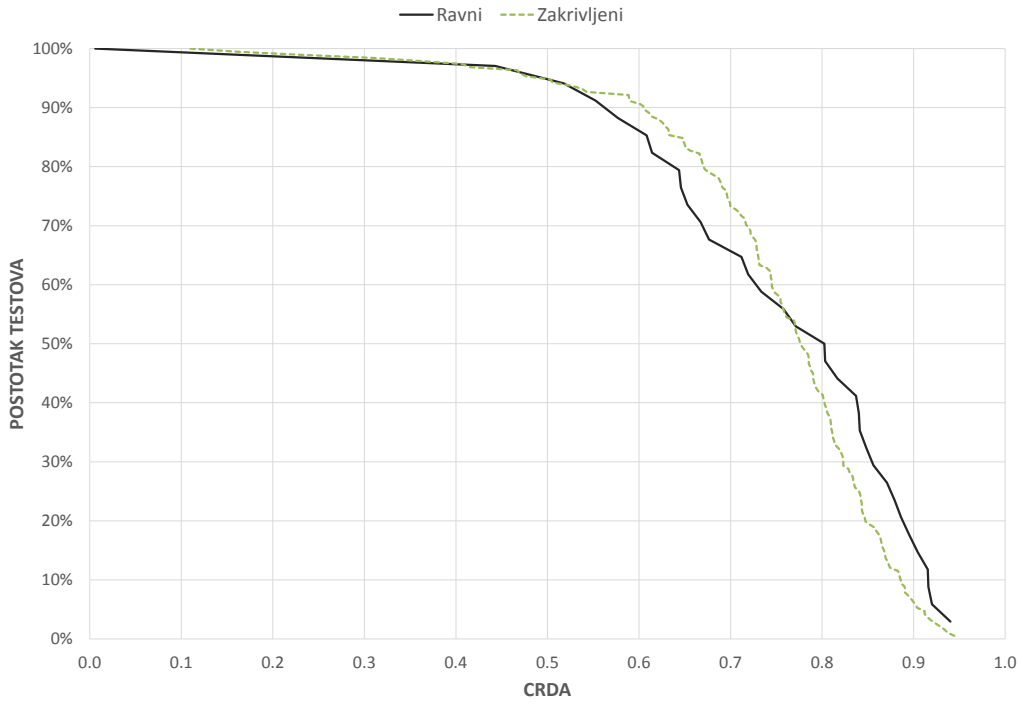

Slika 7.13: Normalizirani kumulativni histogrami CRDA kriterija za drugi pokus.

slučaju zakrivljenih redova usjeva, za 95% ispitanih slika, ima vrijednost 0.491 ili veću. U prvom pokusu CRDA kriterij je, za 95% ispitanih slika, imao vrijednost 0.495 ili veću. Ovi rezultati potvrđuju zaključak da je predložena TMGEM metoda robusna na zakrivljenost redova usjeva, odnosno da s visokom točnošću može prepoznati i ravne i zakrivljene redove usjeva.

Prepoznati redovi usjeva dobiveni primjenom TMGEM metode na primjerima zakrivljenih redova usjeva sa slike 7.12 prikazani su na slici 7.14. Ispod svake slike prikazane su vrijednosti CRDA kriterija koje iznose 0.865 i 0.816 za sliku 7.14a, odnosno 7.14b. Na slici 7.14a se može vidjeti da predložena metoda uspjeva prepoznati redove usjeva s velikom točnošću. Međutim, na slici 7.14b je vidljivo da TMGEM metoda pri vrhu slike ne uspjeva dobro prepoznati redove usjeva. Razlog tome je ranije spomenuti utjecaj perspektive zbog kojeg se pri vrhu slike ne vidi pravilni ponavljajući uzorak (slika 7.12b). Osim toga na slici 7.12b i 7.14b je u lijevom gornjem kutu vidljiva veća količina trave, što ima utjecaj na točnost prepoznavanja redova usjeva. Uklanjanjem ovakvih dijelova slike mogla bi se povećati točnost prepoznavanja, a to bi se moglo postići primjenom predobrade slike za uklanjanje većih nakupina trave. Razvoj algoritma za takvu predobradu ulazne slike redova usjeva izlazi iz okvira ovog istraživanja te predstavlja temu za buduće istraživanje.

Kao i u prethodnom, i u ovom pokusu je mjereno vrijeme izvođenja pojedinog koraka TMGEM metode. U tablici 7.9 su prikazana vremena izvođenja koraka kreiranja slike vegetacije, računanja podudaranja s predloškom, određivanja optimalnog CCR modela te ukupno vrijeme izvođenja algoritma. Za svaki korak prikazane su minimalne, maksimalne i srednje vrijednosti izmjerenog vremena za svih 191 slika. Srednja vrijednost je, kao i

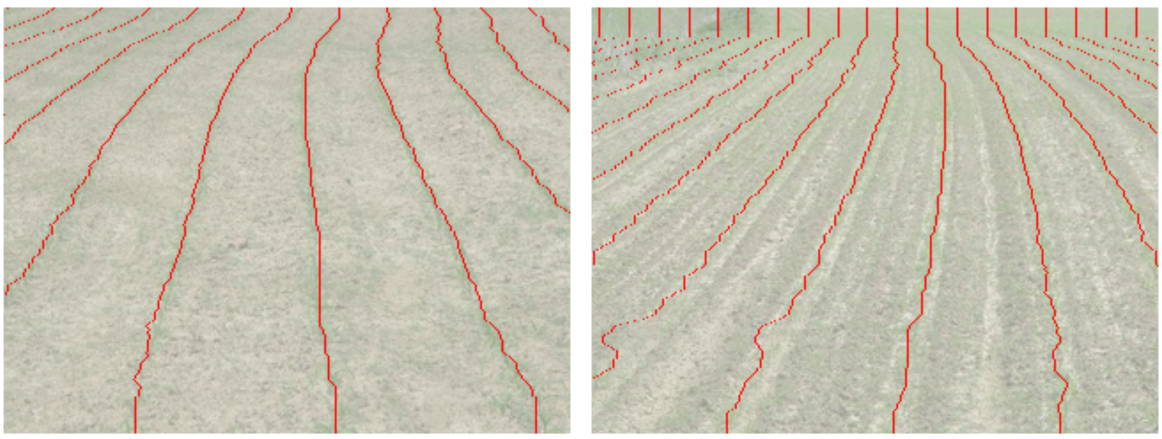

(a) $CRDA = 0.865$ (b) $CRDA = 0.816$

Slika 7.14: Primjeri redova usjeva dobivenih primjenom TMGEM metode na slikama zakrivljenih redova usjeva prikazanim na slici 7.12.

	Slika vegetacije			Podudaranje s predloškom			Optimizacija			Ukupno		
	min	max	avg	min	max	avg	min	max	avg	min	max	avg
Pokus 2	< 1	16	2.7	875	1063	880.3	812	984	867.1	1687	1953	1750.1

Tablica 7.9: Vremena izvođenja pojedinih koraka TMGEM metode za drugi pokus. Vremena su prikazana u ms.

u prvom pokusu, označena kraticom *avg*. Iz prikazanih vrijednosti se može uočiti da su vremena izvođenja slična kao u slučaju prepoznavanja ravnih redova usjeva pa se može zaključiti da zakrivljenost redova usjeva nema utjecaj na računsku složenost TMGEM metode. Korak kreiranja slike vegetacije, i u ovom pokusu, ne predstavlja računski zahtjevnu operaciju te je u prosjeku potrebno 2.7 ms za izvođenje ovog koraka. Vrijeme potrebno za računanje podudaranja s predloškom iznosi u prosjeku 880.3 ms, dok je za određivanje optimalnog CCR modela potrebno u prosjeku 867.1 ms. Srednje vrijeme potrebno za izvođenje svih koraka pri prepoznavanju zakrivljenih redova usjeva iznosi 1750.1 ms.

Trenutna implementacija predložene TMGEM metode, za prepoznavanje redova usjeva na slici veličine 320×240, traje u prosjeku oko 1.75 s. Zbog toga predložena metoda nije direktno primjenjiva za upravljanje poljoprivrednim strojem u stvarnom vremenu. Međutim, TMGEM metoda se može koristiti u kombinaciji s nekim bržim algoritmom, kao što su LR, HTT ili CRDI metoda. Pri tome bi se LR, HTT ili CRDI metoda koristile za prepoznavanje redova usjeva u stvarnom vremenu, dok bi se TMGEM metoda izvodila u paralelnoj (sporijoj) niti za periodičko kreiranje predložaka za LR, HTT ili CRDI metodu. Nadalje, dva najzahtjevnija koraka TMGEM metode (računanje podudaranja redova slike vegetacije s nizom predložaka i minimizacija funkcije globalne energije) su jako pogodne za paralelizaciju. Stoga predloženi algoritam predstavlja dobru osnovu za puno efikasniju implementaciju na paralelnim arhitekturama kao što je GPU. Paralelna implementacija na nekoj od pogodnih arhitektura izlazi iz okvira ove doktorske disertacije te predstavlja još jednu temu za buduće istraživanje.

7.3.4 Analiza utjecaja rezolucije slike na točnost prepoznavanja redova usjeva

Treći pokus, u sklopu eksperimentalne analize TMGEM metode, proveden je s ciljem utvrđivanja utjecaja rezolucije ulazne slike na točnost prepoznavanja redova usjeva. Za potrebe ovog pokusa su, osim slika s rezolucijom 320×240, korištene i slike s rezolucijom 640×480. Slike različitih rezolucija su kreirane od originalnih slika koje su snimljene u

CRDA	TMGEM	
	320×240	640×480
Srednja vrijednost	0.747	0.759
Medijan	0.776	0.789
Std. devijacija	0.144	0.139

Tablica 7.10: Vrijednosti CRDA kriterija za treći pokus.

rezoluciji 2560×1920, a za smanjivanje rezolucije je korištena kubna metoda (engl. *cubic method*) te program Light Image Resizer.

Analiza utjecaja rezolucije je napravljena određivanjem točnosti prepoznavanja redova usjeva na svih 225 slika iz testnog skupa slika. Za određivanje točnosti prepoznavanja redova usjeva je, kao i u prethodna dva pokusa, korišten CRDA kriterij. Srednja vrijednost, medijan i standardna devijacija CRDA kriterija, za obje rezolucije, prikazane su u tablici 7.10. U tablici 7.10 se može vidjeti da, za slike rezolucije 320×240, srednja vrijednost CRDA kriterija iznosi 0.747, medijan 0.776, a standardna devijacija 0.144. Za slike rezolucije 640×480 srednja vrijednost iznosi 0.759, medijan 0.789, a standardna devijacija 0.139. Analiziranjem prikazanih rezultata može se zaključiti da CRDA kriterij ima nešto veće vrijednosti u slučaju slika s rezolucijom 640×480.

Normalizirani kumulativni histogrami CRDA kriterija za ovaj pokus prikazani su na

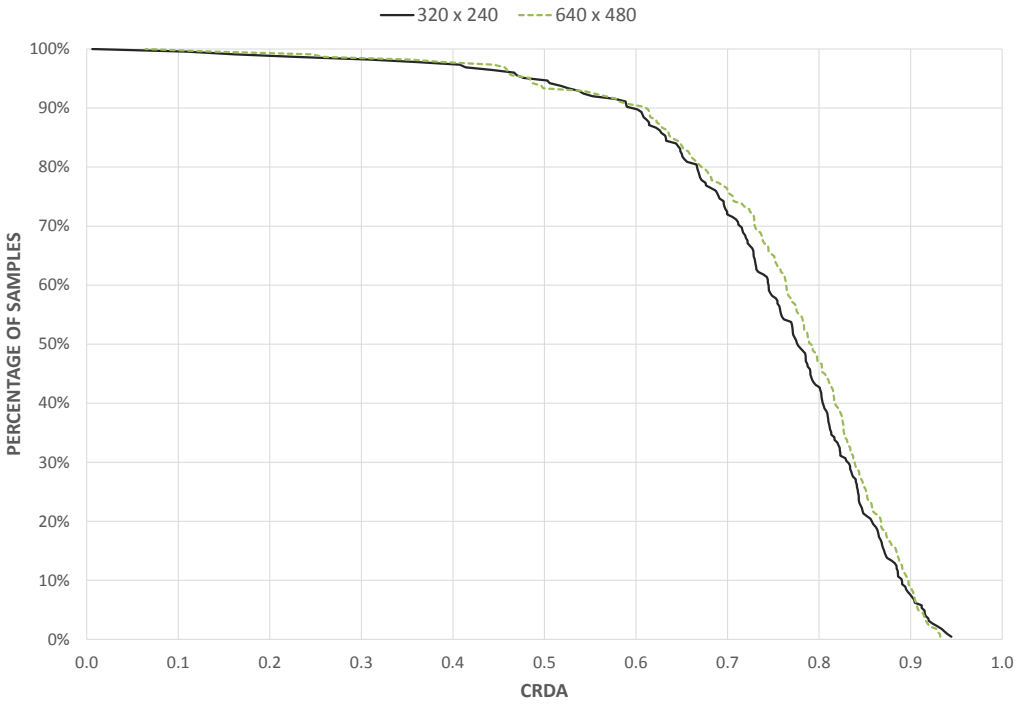

Slika 7.15: Normalizirani kumulativni histogrami CRDA kriterija za treći pokus.

	Slika vegetacije			Podudaranje s predloškom			Optimizacija			Ukupno		
	min	max	avg	min	max	avg	min	max	avg	min	max	avg
320×240	< 1	16	2.5	875	1063	880.4	812	984	866.2	1687	1953	1749.1
640×480	< 1	16	9.63	2812	2906	2827.6	1579	1859	1683.4	4422	4719	4527

Tablica 7.11: Vremena izvođenja pojedinih koraka TMGEM metode za treći pokus. Vremena su prikazana u ms.

slici 7.15. Iz prikazanih histograma može se uočiti neznatno smanjenje točnosti prepoznavanja redova usjeva koje je posljedica smanjenja rezolucije slike.

Vremena izvođenja koraka kreiranja slike vegetacije, koraka računanja podudaranja s predloškom te koraka određivanja optimalnog CCR modela, kao i ukupna vremena izvođenja TMGEM metode, za obje ispitane rezolucije slika, prikazana su u tablici 7.11. U tablici 7.11 je vidljivo da, u slučaju slika s rezolucijom 640×480, srednje vrijeme koraka kreiranja slike vegetacije iznosi 9.63 ms. Korak računanja podudaranja s predloškom ima srednje vrijeme izvođenja 2827.6 ms, a određivanje optimalnog CCR modela 1683.4 ms. Srednje ukupno vrijeme izvođenja TMGEM metode, za slike s rezolucijom 640×480, iznosi 4.57 s. Analiziranjem prikazanih rezultata može se zaključiti da je ukupno vrijeme izvođenja, za slike s rezolucijom 640×480, oko 2.5 puta duže od ukupnog vremena izvođenja metode za slike s rezolucijom 320×240. Nadalje, može se uočiti da je najveća razlika u vremenima izvođenja u koraku računanja podudaranja s predloškom, koji je računski najzahtjevniji korak predložene metode.

Prema prikazanim rezultatima utjecaja rezolucije na točnost prepoznavanja redova usjeva, može se zaključiti da bi korištenje slika većih rezolucija dodatno produžilo vrijeme izvođenja algoritma, bez značajnog povećanja točnosti prepoznavanja.

8 Zaključak

Proučavanjem literature uočeno je da postojeće metode za prepoznavanje redova usjeva na 2D slikama posjeduju brojna ograničenja pa su stoga u sklopu ovog istraživanja razvijene dvije nove metode kojima se pokušavaju otkloniti uočena ograničenja.

Prva predložena metoda opisana je u poglavlju 4, a nazvana je CRDI metoda. Metoda je zasnovana na inkrementalnoj metodi za traženje približno optimalne particije skupa podataka i `DIRECT` metodi za globalnu optimizaciju. U svakom koraku predložena metoda određuje novi centralni pravac pronalaskom globalno optimalnog rješenja odgovarajućeg optimizacijskog problema. Tako dobiveni centralni pravci korigiraju se primjenom k-means algoritma kako bi se dobili konačni pravci koji predstavljaju centralne linije redova usjeva. U poglavlju 4 predloženi su zasebni algoritmi za prepoznavanje 2 i 3 reda usjeva te poopćeni algoritam za prepoznavanje k redova usjeva. Važno je naglasiti da broj redova usjeva, koje treba prepoznati, mora biti unaprijed poznat. Nadalje, metoda ima mogućnost prepoznavanja samo ravnih redova usjeva, odnosno redova usjeva opisanih SCR modelom.

Druga predložena metoda za rješavanje problema prepoznavanja redova usjeva na slici, opisana u poglavlju 5, nazvana je TMGEM metoda. Prvi korak predložene metode je prepoznavanje vegetacije koje se obavlja primjenom ExG indeksa boje vegetacije. Na dobivenoj slici vegetacije primjenjuje se metoda podudaranja s predloškom pri čemu se svaki redak slike uspoređuje s nizom kreiranih predložaka redova usjeva. Nakon računanja mjere podudaranja između redaka slike vegetacije i niza predložaka, određuju se optimalni parametri CCR modela redova usjeva. Optimalni model dobiva se minimizacijom funk-

cije globalne energije. Funkcija globalne energije, uz podatke sa slike, koristi i prethodno znanje o geometrijskoj strukturi redova usjeva. Nadalje, optimizacijski problem je formuliran na način da se može efikasno minimizirati primjenom dinamičkog programiranja. Predložena metoda, za razliku od većine postojećih metoda, ima mogućnost prepoznavanja zakrivljenih rezova usjeva. Uz to robusna je na prisutnost korova i sjene te može prepoznati unaprijed nepoznati broj redova usjeva za različite kulture, u različitim stadijima rasta te uz različite geometrije polja.

Osim spomenutih metoda za prepoznavanje redova usjeva na slici, u sklopu ovog istraživanja predložen je i evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva. Evaluacijski okvir uključuje bazu slika redova usjeva, postupak za ručno generiranje referentnih vrijednosti redova usjeva te kriterije za određivanje točnosti prepoznavanja redova usjeva. Korištenje predloženog evaluacijskog okvira omogućava efikasniju i objektivniju evaluaciju novo razvijenih metoda za prepoznavanje redova usjeva.

CRDI metoda je, u sklopu eksperimentalne evaluacije, ispitana na umjetno generiranim skupovima podataka kojima su simulirani redovi usjeva. Prilikom generiranja skupova podataka simulirano je kompletno i nekompletno zasijanje te utjecaj korova i neravnog zasijanja. Metoda je uspoređena s predloženom IMLD metodom te s HT metodom za slučaj dva i tri reda usjeva. Prepoznati redovi usjeva evaluirani su korištenjem predloženog CRHID kriterija za određivanje točnosti prepoznavanja redova usjeva. Dobiveni rezultati, u oba pokusa prepoznavanja dva reda usjeva, pokazuju da CRDI metoda u više od 98% provedenih testova uspijeva postići visoku točnost prepoznavanja redova usjeva, dok IMLD i HT metoda istu točnost postižu u manje od 85%, odnosno 61% testova. Usporedba u slučaju tri reda usjeva pokazala je da CRDI metoda u više od 98% testova postiže visoku točnost prepoznavanja, dok IMLD istu točnost prepoznavanja postiže u manje od 80% testova. HT metoda, u slučaju manje varijance, postiže jednake rezultate kao predložena CRDI metoda, dok u slučaju veće varijance visoku točnost postiže u manje od 19% testova. Iz provedenih pokusa prepoznavanja dva i tri reda usjeva može se zaključiti da predložena CRDI metoda s visokom točnošću prepoznaje redove usjeva u slučaju male i velike varijance te kompletnog i nekompletnog zasijanja. U svim provedenim pokusima mjereno je i vrijeme izvođenja te je pokazano da su vremena izvođenja CRDI metode i do 30 puta kraća od vremena izvođenja HT metode. Prosječno vrijeme izvođenja CRDI metode u pokusima prepoznavanja dva reda usjeva iznosi 0.04 s, a u pokusima prepoznavanja tri reda usjeva 0.36 s.

Eksperimentalna evaluacija predložene TMGEM metode provedena je na testnom

skupu slika iz baze slika redova usjeva, koja je sastavni dio predloženog evaluacijskog okvira za usporedbu metoda prepoznavanja redova usjeva. Na korištenim slikama snimljeni su redovi usjeva kukuruza, celera, krumpira, luka, suncokreta i soje. Budući da većina metoda predloženih u literaturi ima mogućnost prepoznavanja samo ravnih redova usjeva, testni skup podijeljen je na dva podskupa, skup slika ravnih redova usjeva i skup slika zakrivljenih redova usjeva. Skup slika ravnih redova usjeva, koji sadrži 34 slike, korišten je za usporedbu predložene metode s postojećim metodama u literaturi. Metoda je uspoređena s HT, HTT i LR metodom, a točnost prepoznavanja redova usjeva određena je korištenjem predloženog CRDA kriterija za određivanje točnosti prepoznavanja redova usjeva. Srednja vrijednost CRDA kriterija u prvom pokusu za TMGEM metodu iznosi 0.737, dok za HT, HTT i LR metodu iznosi 0.572, 0.622 i 0.679. Analiziranjem dobivenih rezultata pokazano je da predložena TMGEM metoda, za 95% ispitanih slika, ima vrijednost CRDA kriterija 0.495 ili veću. Iz provedenog pokusa može se zaključiti da predložena TMGEM metoda s visokom točnošću prepoznaje ravne redove usjeva te da značajno nadmašuje ostale tri razmatrane metode. U drugom pokusu predložena TMGEM metoda ispitana je na skupu od 191 slike zakrivljenih redova usjeva. Srednja vrijednost CRDA kriterija u ovom pokusu iznosi 0.748, a za 95% ispitanih slika CRDA kriterij ima vrijednost 0.491 ili veću. Analiziranjem dobivenih rezultata i usporedbom s rezultatima dobivenim u prvom pokusu, može se zaključiti da je predložena TMGEM metoda robusna na zakrivljenost redova usjeva, odnosno da može s visokom točnošću prepoznati i ravne i zakrivljene redove usjeva. U oba provedena pokusa mjereno je vrijeme izvođenja pojedinih koraka TMGEM metode. Iz dobivenih vremena može se zaključiti da korak prepoznavanja vegetacije nije računski zahtjevan korak, dok koraci računanja podudaranja s predloškom i određivanja optimalnog CCR modela traju oba oko 870 ms. Ukupno vrijeme izvođenja TMGEM metode u prva dva pokusa iznosi oko 1.75 s, što predstavlja ograničenje za primjenu u stvarnom vremenu. Međutim, koraci računanja podudaranja s predloškom i određivanja optimalnog modela su pogodni za paralelizaciju, čime bi se ukupno vrijeme izvođenja znatno skratilo. Konačno, u trećem pokusu analiziran je utjecaj rezolucije slike na točnost prepoznavanja redova usjeva dobivenih primjenom TMGEM metode. U pokusu su korištene slike s rezolucijom 320×240 te 640×480. Analiziranjem dobivenih rezultata može se zaključiti da su vrijednosti CRDA kriterija neznatno veće za slike s rezolucijom 640×480, dok je ukupno vrijeme izvođenja oko 2.5 puta duže od ukupnog vremena izvođenja za slike s rezolucijom 320×240. Nadalje, može se zaključiti da je korak računanja podudaranja s predloškom računski najzahtjevniji korak predložene metode.

Budući rad mogao bi uključivati prilagodbu CRDI metode za automatsko određivanje broja redova usjeva te ispitivanje metode na stvarnim slikama redova usjeva. Automatsko određivanje broja redova usjeva moguće je napraviti definiranjem novog indeksa za određivanje kvalitete particije u slučaju kada su klasteri opisani pravcima. Slični indeksi definirani su za određivanje odgovarajućeg broja klastera u particiji u slučaju kada su klasteri opisani točkom koja predstavlja centar klastera (Vendramin et al., 2009; Halkidi et al., 2002). Definiranjem ovakvog indeksa mogao bi se odrediti optimalan broj klastera particije, odnosno broj redova usjeva koje je potrebno prepoznati ne bi morao biti unaprijed poznat. Nadalje, razvojem i primjenom algoritma za uklanjanje neželjenih dijelova na slici kao što su velike količine trave, neba ili ceste, povećala bi se točnost prepoznavanja redova usjeva primjenom TMGEM metode. Dodatno poboljšanje TMGEM metode moglo bi biti primjena metode za izglađivanje prepoznatih redova usjeva. Ovime bi se dobili redovi usjeva koji su direktno primjenjivi za kreiranje trajektorije kojom bi se kretao autonomni poljoprivredni stroj. S ciljem skraćivanja ukupnog vremena izvođenja TMGEM metode, planirana je implementacija metode na GPU. Na taj način bi se vremena izvođenja računski zahtjevnih koraka, računanja podudaranja s predloškom i određivanja optimalnog modela, znatno skratila te bi se omogućila direktna primjena TMGEM metode u stvarnom vremenu. Konačno, predložene metode bi se trebale implementirati kao dio prototipa autonomnog poljoprivrednog stroja te bi se na taj način ispitale u stvarnoj primjeni.

U sklopu ovog istraživanja razvijene su dvije metode za prepoznavanje redova usjeva na slikama te je predložen evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva. Ovime su postignuti sljedeći izvorni znanstveni doprinosi:

- Metoda za prepoznavanje redova usjeva zasnovana na inkrementalnoj metodi za traženje približno globalne optimalne particije skupa podataka i `DIRECT` algoritmu za globalnu optimizaciju,
- Metoda zasnovana na podudaranju s predloškom i minimizaciji globalne funkcije energije koja omogućuje prepoznavanje i zakrivljenih redova usjeva,
- Evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva koji uključuje bazu slika redova usjeva, postupak generiranja referentnih vrijednosti i kriterije za određivanje točnosti prepoznavanja redova usjeva.

Literatura

A. M. Bagirov i J. Ugon. An algorithm for minimizing clustering functions. *Optimization*, 54:351–368, 2005.

A. M. Bagirov, J. Ugon, i H. Mirzayeva. Nonsmooth nonconvex optimization approach to clusterwise linear regression problems. *European Journal of Operational Research*, 229 (1):132–142, 2013.

T. Bakker, H. Wouters, K. van Asselt, J. Bontsema, L. Tang, J. Müller, i G. van Straten. A vision based row detection system for sugar beet. *Computers and Electronics in Agriculture*, 60(1):87 – 95, 2008. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/j.compag.2007.07.006. URL `http://www.sciencedirect.com/science/article/pii/S0168169907001615`.

J. Billingsley i M. Schoenfisch. Vision-guidance of agricultural vehicles. *Autonomous Robots*, 2(1):65–76, 1995. ISSN 1573-7527. doi: 10.1007/BF00735439. URL `http://dx.doi.org/10.1007/BF00735439`.

J. Bossu, C. Gée, G. Jones, i F. Truchetet. Wavelet transform to discriminate between crop and weed in perspective agronomic images. *Computers and Electronics in Agriculture*, 65(1):133 – 143, 2009. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/j.compag.2008.08.004. URL `http://www.sciencedirect.com/science/article/pii/S0168169908001981`.

J. R. Brandon, S. W. Searcy, i R. J. Babowicz. Distributed control for vision based tractor guidance. In *ASAE Paper 89*, 1989.

X. P. Burgos-Artizzu, A. Ribeiro, M. Guijarro, i G. Pajares. Real-time image processing for crop/weed discrimination in maize fields. *Computers and Electronics in Agriculture*, 75(2):337 – 346, 2011. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/j.compag.2010.12.011. URL `http://www.sciencedirect.com/science/article/pii/S0168169910002620`.

N. Chernov. *Circular and linear regression: Fitting circles and lines by least squares.* CRC Press, 2010.

D. W. Deering. *Theory and Applications of Optical Remote Sensing*, chapter 2, pages 14–66. Wiley, 1989.

R. O. Duda i P. E. Hart. Use of the hough transformation to detect lines and curves in pictures. *Communications of the ACM*, 15(1):11–15, Jan. 1972. ISSN 0001-0782. doi: 10.1145/361237.361242. URL `http://dx.doi.org/10.1145/361237.361242`.

S. Ericson i B. Åstrand. A vision-guided mobile robot for precision agriculture. In *Proceedings of 7th European Conference on Precision Agriculture*, 2009.

Y. G. Evtushenko. *Numerical optimization techniques*. Springer-Verlag New York, Inc., 1985.

P. F. Felzenszwalb i D. P. Huttenlocher. Distance transforms of sampled functions. *Theory of Computing*, 8(1):415–428, 2012.

P. F. Felzenszwalb i R. Zabih. Dynamic programming and graph algorithms in computer vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(4):721–740, 2011.

D. E. Finkel. *DIRECT Optimization Algorithm User Guide*. Center for Research in Scientific Computation, North Carolina State University, 2003. URL `http://www4.ncsu.edu/~ctk/Finkel_Direct/DirectUserGuide_pdf.pdf`.

M. A. Fischler i R. C. Bolles. Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, 24(6):381–395, June 1981. ISSN 0001-0782. doi: 10.1145/358669.358692. URL `http://doi.acm.org/10.1145/358669.358692`.

C. A. Floudas i C. E. Gounaris. A review of recent advances in global optimization. *Journal of Global Optimization*, 45(1):3–38, 2009.

C. Gée, J. Bossu, G. Jones, i F. Truchetet. Crop/weed discrimination in perspective agronomic images. *Computers and Electronics in Agriculture*, 60(1):49 – 59, 2008. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/j.compag.2007.06.003. URL `http://www.sciencedirect.com/science/article/pii/S0168169907001470`.

J. B. Gerrish, G. C. Stockman, L. Mann, i G. Hu. Path-finding by image processing in agricultural field operations. In *SAE Technical Paper 861455*, 1986.

R. C. Gonzalez i R. E. Woods. *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 2006. ISBN 013168728X.

J. Guerrero, M. Guijarro, M. Montalvo, J. Romeo, L. Emmi, A. Ribeiro, i G. Pajares. Automatic expert system based on images for accuracy crop row detection in maize fields. *Expert Systems with Applications*, 40(2):656 – 664, 2013. ISSN 0957-4174. doi: http://dx.doi.org/10.1016/j.eswa.2012.07.073. URL `http://www.sciencedirect.com/science/article/pii/S0957417412009293`.

M. Guijarro, G. Pajares, I. Riomoros, P. Herrera, X. Burgos-Artizzu, i A. Ribeiro. Automatic segmentation of relevant textures in agricultural images. *Computers and Electronics in Agriculture*, 75(1):75 – 83, 2011. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/j.compag.2010.09.013. URL `http://www.sciencedirect.com/science/article/pii/S0168169910001924`.

T. Hague i N. Tillett. A bandpass filter-based approach to crop row location and tracking. *Mechatronics*, 11(1):1 – 12, 2001. ISSN 0957-4158. doi: http://dx.doi.org/10.1016/S0957-4158(00)00003-9. URL `http://www.sciencedirect.com/science/article/pii/S0957415800000039`.

T. Hague, J. Marchant, i N. Tillett. Ground based sensing systems for autonomous agricultural vehicles. *Computers and Electronics in Agriculture*, 25(1–2):11 – 28, 2000. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/S0168-1699(99)00053-8. URL `http://www.sciencedirect.com/science/article/pii/S0168169999000538`.

T. Hague, N. D. Tillett, i H. Wheeler. Automated crop and weed monitoring in widely spaced cereals. *Precision Agriculture*, 7(1):21–32, 2006. doi: 10.1007/s11119-005-6787-1. URL `http://dx.doi.org/10.1007/s11119-005-6787-1`.

M. Halkidi, Y. Batistakis, i M. Vazirgiannis. Clustering validity checking methods: Part ii. *ACM SIGMOD Record*, 31(3):19–27, Sept. 2002. ISSN 0163-5808. doi: 10.1145/601858.601862. URL `http://doi.acm.org/10.1145/601858.601862`.

P. Harrington. *Machine Learning in Action*. Manning Publications Co., Greenwich, CT, USA, 2012. ISBN 1617290181, 9781617290183.

R. Ji i L. Qi. Crop-row detection algorithm based on random hough transformation. *Mathematical and Computer Modelling*, 54(3–4):1016 – 1020, 2011. ISSN 0895-7177. doi: http://dx.doi.org/10.1016/j.mcm.2010.11.030. URL `http://www.sciencedirect.com/science/article/pii/S0895717710005212`. Mathematical and Computer Modeling in agriculture (CCTA 2010).

G. Jiang, Z. Wang, i H. Liu. Automatic detection of crop rows based on multi-ROIs. *Expert Systems with Applications*, 42(5):2429 – 2441, 2015. ISSN 0957-4174. doi: http://dx.doi.org/10.1016/j.eswa.2014.10.033. URL `http://www.sciencedirect.com/science/article/pii/S0957417414006575`.

T. Kataoka, T. Kaneko, H. Okamoto, i S. Hata. Crop growth estimation system using machine vision. In *Advanced Intelligent Mechatronics, 2003. AIM 2003. Proceedings. 2003 IEEE/ASME International Conference on*, volume 2, pages b1079–b1083 vol.2, July 2003. doi: 10.1109/AIM.2003.1225492.

M. Kise, Q. Zhang, i F. R. Más. A stereovision-based crop row detection method for tractor-automated guidance. *Biosystems Engineering*, 90(4):357 – 367, 2005. ISSN 1537-5110. doi: http://dx.doi.org/10.1016/j.biosystemseng.2004.12.008. URL `http://www.sciencedirect.com/science/article/pii/S1537511004002260`.

J. Kittler i J. Illingworth. Minimum error thresholding. *Pattern Recognition*, 19(1):41 – 47, 1986. ISSN 0031-3203. doi: http://dx.doi.org/10.1016/0031-3203(86)90030-0. URL http://www.sciencedirect.com/science/article/pii/0031320386900300.

J. Kogan. *Introduction to clustering large and high-dimensional data*. Cambridge University Press, 2007.

V. Leemans i M.-F. Destain. Line cluster detection using a variant of the hough transform for culture row localisation. *Image and Vision Computing*, 24(5):541 – 550, 2006. ISSN 0262-8856. doi: http://dx.doi.org/10.1016/j.imavis.2006.02.004. URL http://www.sciencedirect.com/science/article/pii/S0262885606000862.

M. Li, K. Imou, K. Wakabayashi, i S. Yokoyama. Review of research on agricultural vehicle autonomous guidance. *International Journal of Agricultural & Biological Engineering*, 2:1–26, 2009.

S.-H. Liao, P.-H. Chu, i P.-Y. Hsiao. Data mining techniques and applications – a decade review from 2000 to 2011. *Expert Systems with Applications*, 39(12):11303 – 11311, 2012. ISSN 0957-4174. doi: http://dx.doi.org/10.1016/j.eswa.2012.02.063. URL http://www.sciencedirect.com/science/article/pii/S0957417412003077.

A. Likas, N. Vlassis, i J. J. Verbeek. The global k-means clustering algorithm. *Pattern Recognition*, 36(2):451–461, 2003.

J. Marchant. Tracking of row structure in three crops using image analysis. *Computers and Electronics in Agriculture*, 15(2):161 – 179, 1996. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/0168-1699(96)00014-2. URL http://www.sciencedirect.com/science/article/pii/0168169996000142.

J. A. Marchant i R. Brivot. Real-time tracking of plant rows using a hough transform. *Real-Time Imaging*, 1(5):363 – 371, 1995. ISSN 1077-2014. doi: http://dx.doi.org/10.1006/rtim.1995.1036. URL http://www.sciencedirect.com/science/article/pii/S1077201485710364.

G. E. Meyer i J. C. Neto. Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture*, 63(2):282 – 293, 2008. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/j.compag.2008.03.009. URL http://www.sciencedirect.com/science/article/pii/S0168169908001063.

M. Montalvo, G. Pajares, J. Guerrero, J. Romeo, M. Guijarro, A. Ribeiro, J. Ruz, i J. Cruz. Automatic detection of crop rows in maize fields with high weeds pressure. *Expert Systems with Applications*, 39(15):11889 – 11897, 2012. ISSN 0957-4174. doi: http://dx.doi.org/10.1016/j.eswa.2012.02.117. URL http://www.sciencedirect.com/science/article/pii/S0957417412003806.

M. M. Mostafa. More than words: Social networks' text mining for consumer brand sentiments. *Expert Systems with Applications*, 40(10):4241 – 4251,

2013. ISSN 0957-4174. doi: http://dx.doi.org/10.1016/j.eswa.2013.01.019. URL http://www.sciencedirect.com/science/article/pii/S0957417413000328.

H. Mousazadeh. A technical review on navigation systems of agricultural autonomous off-road vehicles. *Journal of Terramechanics*, 50(3):211 – 232, 2013. ISSN 0022-4898. doi: http://dx.doi.org/10.1016/j.jterra.2013.03.004. URL http://www.sciencedirect.com/science/article/pii/S0022489813000220.

J. C. Neto. *A combined statistical-soft computing approach for classification and mapping weed species in minimum tillage systems*. PhD thesis, University of Nebraska, NE, 2004.

A. Neumaier. Complete search in continuous global optimization and constraint satisfaction. *Acta numerica*, 13:271–369, 2004.

Y. Nievergelt. Total least squares: State-of-the-art regression in numerical analysis. *SIAM review*, 36(2):258–264, 1994.

H. Olsen. Determination of row position in small-grain crops by analysis of video images. *Computers and Electronics in Agriculture*, 12(2):147 – 162, 1995. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/0168-1699(94)00044-Q. URL http://www.sciencedirect.com/science/article/pii/016816999400044Q.

N. Otsu. A Threshold Selection Method from Gray-level Histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1):62–66, Jan. 1979. ISSN 0018-9472. doi: 10.1109/tsmc.1979.4310076. URL http://dx.doi.org/10.1109/tsmc.1979.4310076.

J. D. Pintér. *Global optimization in action: continuous and Lipschitz optimization: algorithms, implementations and applications*, volume 6. Springer Science & Business Media, 2013.

F. Pla, J. Sanchiz, J. Marchant, i R. Brivot. Building perspective models to guide a row crop navigation vehicle. *Image and Vision Computing*, 15(6):465 – 473, 1997. ISSN 0262-8856. doi: http://dx.doi.org/10.1016/S0262-8856(96)01147-X. URL http://www.sciencedirect.com/science/article/pii/S026288569601147X.

A. Pérez, F. López, J. Benlloch, i S. Christensen. Colour and shape analysis techniques for weed detection in cereal fields. *Computers and Electronics in Agriculture*, 25(3):197 – 212, 2000. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/S0168-1699(99)00068-X. URL http://www.sciencedirect.com/science/article/pii/S016816999900068X.

J. F. Reid i S. W. Searcy. Detecting crop rows using the hough transform. In *ASAE Paper 86*, 1986.

J. F. Reid i S. W. Searcy. An algorithm for separating guidance information from row crop images. In *Transactions of the ASABE*, volume 31, 1988.

J. Reyes, A. Morales-Esteban, i F. Martínez-Álvarez. Neural networks to predict earthquakes in chile. *Applied Soft Computing*, 13(2):1314 – 1328, 2013. ISSN 1568-4946. doi: http://dx.doi.org/10.1016/j.asoc.2012.10.014. URL `http://www.sciencedirect.com/science/article/pii/S1568494612004656`.

A. Ribeiro, C. Fernandez-Quintanilla, J. Barroso, i M. C. Garcia-Alegre. Development of an image analysis system for estimation of weed pressure. In J. V. Stafford, editor, *Precision agriculture '05. Papers presented at the 5th European Conference on Precision Agriculture, Uppsala, Sweden*, 2005.

J. Romeo, G. Pajares, M. Montalvo, J. M. Guerrero, M. Guijarro, i A. Ribeiro. Crop row detection in maize fields inspired on the human visual perception. *The Scientific World Journal*, 12:10 pages, 2012. ISSN 0168-1699. doi: http://dx.doi.org/10.1100/2012/484390. URL `http://www.hindawi.com/journals/tswj/2012/484390/cta/`.

F. Rovira-Más, Q. Zhang, J. Reid, i J. Will. Hough-transform-based vision algorithm for crop row detection of an automated agricultural vehicle. *Journal of Automobile Engineering*, 219(8):999 – 1010, 2005. ISSN 09544070. URL `http://pid.sagepub.com/content/219/8/999.abstract`.

R. Scitovski i K. Sabo. Analysis of the k-means algorithm in the case of data points occurring on the border of two or more clusters. *Knowledge-Based Systems*, 57:1 – 7, 2014. ISSN 0950-7051. doi: http://dx.doi.org/10.1016/j.knosys.2013.11.010. URL `http://www.sciencedirect.com/science/article/pii/S0950705113003602`.

R. Scitovski i S. Scitovski. A fast partitioning algorithm and its application to earthquake investigation. *Computers & Geosciences*, 59:124 – 131, 2013. ISSN 0098-3004. doi: http://dx.doi.org/10.1016/j.cageo.2013.06.010. URL `http://www.sciencedirect.com/science/article/pii/S009830041300174X`.

H. Søgaard i H. Olsen. Determination of crop rows by image analysis without segmentation. *Computers and Electronics in Agriculture*, 38(2):141 – 158, 2003. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/S0168-1699(02)00140-0. URL `http://www.sciencedirect.com/science/article/pii/S0168169902001400`.

H. Späth. A fast algorithm for clusterwise linear regression. *Computing*, 29(2):175–181, 1982.

H. Späth. *Cluster-Formation und-Analyse: Theorie, FORTRAN-Programme und Beispiele*. Oldenbourg, 1983.

B. Åstrand i A.-J. Baerveldt. A vision based row-following system for agricultural field machinery. *Mechatronics*, 15(2):251 – 269, 2005. ISSN 0957-4158. doi: http://dx.doi.org/10.1016/j.mechatronics.2004.05.005. URL `http://www.sciencedirect.com/science/article/pii/S0957415804000935`.

M. Teboulle. A unified continuous optimization framework for center-based clustering methods. *The Journal of Machine Learning Research*, 8:65–102, 2007.

N. Tillett i T. Hague. Computer-vision-based hoe guidance for cereals — an initial trial. *Journal of Agricultural Engineering Research*, 74(3):225 – 236, 1999. ISSN 0021-8634. doi: http://dx.doi.org/10.1006/jaer.1999.0458. URL `http://www.sciencedirect.com/science/article/pii/S0021863499904584`.

N. Tillett, T. Hague, i S. Miles. Inter-row vision guidance for mechanical weed control in sugar beet. *Computers and Electronics in Agriculture*, 33(3):163 – 177, 2002. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/S0168-1699(02)00005-4. URL `http://www.sciencedirect.com/science/article/pii/S0168169902000054`.

L. Vendramin, R. J. G. B. Campello, i E. R. Hruschka. On the comparison of relative clustering validity criteria. In *Proceedings of the 2009 SIAM International Conference on Data Mining*, pages 733–744, 2009. doi: 10.1137/1.9781611972795.63. URL `http://epubs.siam.org/doi/abs/10.1137/1.9781611972795.63`.

I. Vidović i R. Scitovski. Center-based clustering for line detection and application to crop rows detection. *Computers and Electronics in Agriculture*, 109:212 – 220, 2014. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/j.compag.2014.10.014. URL `http://www.sciencedirect.com/science/article/pii/S0168169914002622`.

I. Vidović, T. Matić, i Željko Hocenski. Histogram based thresholding methods in crop rows detection. In D. Žagar, editor, *SIP 2014 Conference Proceedings*, 2014.

I. Vidović, R. Cupec, i Željko Hocenski. Crop row detection by global energy minimization. *Pattern Recognition*, pages –, 2016. ISSN 0031-3203. doi: http://dx.doi.org/10.1016/j.patcog.2016.01.013. URL `http://www.sciencedirect.com/science/article/pii/S0031320316000170`.

Q. Wang, Q. Zhang, F. Rovira-Más, i L. Tian. Stereovision-based lateral offset measurement for vehicle navigation in cultivated stubble fields. *Biosystems Engineering*, 109(4):258 – 265, 2011. ISSN 1537-5110. doi: http://dx.doi.org/10.1016/j.biosystemseng.2011.04.006. URL `http://www.sciencedirect.com/science/article/pii/S1537511011000705`.

J. Wilson. Guidance of agricultural vehicles — a historical perspective. *Computers and Electronics in Agriculture*, 25(1–2):3 – 9, 2000. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/S0168-1699(99)00052-6. URL `http://www.sciencedirect.com/science/article/pii/S0168169999000526`.

D. M. Woebbecke, G. E. Meyer, K. Von Bargen, i M. D. A. Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1):259–269, 1995. URL `http://cat.inist.fr/?aModele=afficheN&cpsidt=3503524`.

C. Wöhler. *3D Computer Vision: Efficient Methods and Applications (X.media.publishing)*. Springer, 1 edition, aug 2009. ISBN 3642017312. URL http://www.worldcat.org/isbn/3642017312.

H. Xiang i L. Tian. An automated stand-alone in-field remote sensing system (sirss) for in-season crop monitoring. *Computers and Electronics in Agriculture*, 78(1):1 – 8, 2011. ISSN 0168-1699. doi: http://dx.doi.org/10.1016/j.compag.2011.04.006. URL http://www.sciencedirect.com/science/article/pii/S0168169911000950.

L. Xu, E. Oja, i P. Kultanen. A new curve detection method: Randomized hough transform (rht). *Pattern Recognition Letters*, 11(5):331 – 338, 1990. ISSN 0167-8655. doi: http://dx.doi.org/10.1016/0167-8655(90)90042-Z. URL http://www.sciencedirect.com/science/article/pii/016786559090042Z.

P.-Y. Yin. Algorithms for straight line fitting using k-means. *Pattern Recognition Letters*, 19(1):31 – 41, 1998. ISSN 0167-8655. doi: http://dx.doi.org/10.1016/S0167-8655(97)00154-2. URL http://www.sciencedirect.com/science/article/pii/S0167865597001542.

Sažetak

U ovoj doktorskoj disertaciji naglasak je stavljen na razvoj metoda za prepoznavanje redova usjeva na slici. Cilj je razviti metodu koja posjeduje sljedeća svojstva: robusnost s obzirom na prisutnost korova i sjene, mogućnost prepoznavanja redova usjeva za različite kulture u različitim stadijima rasta, mogućnost prepoznavanja različitog broja proizvoljno razmaknutih redova usjeva te mogućnost prepoznavanja ravnih i zakrivljenih redova usjeva. Razvijene su dvije metode koje su nazvane CRDI metoda i TMGEM metoda. CRDI metoda zasnovana je na inkrementalnoj metodi za traženje približno optimalne particije skupa podataka te primjeni `DIRECT` algoritma za globalnu optimizaciju. Metoda je pogodna za prepoznavanje ravnih redova usjeva, pri čemu broj redova usjeva mora biti unaprijed poznat. TMGEM metoda zasnovana je računanju podudaranja s predloškom i minimizaciji funkcije globalne energije primjenom dinamičkog programiranja. Funkcija globalne energije, uz podatke sa slike, koristi i prethodno znanje o geometrijskoj strukturi redova usjeva, čime se postiže veća točnost prepoznavanja redova usjeva. Predložena metoda ima mogućnost prepoznavanja proizvoljnog broja redova usjeva za različite kulture u različitim stadijima rasta te pri različitim geometrijama polja. Nadalje, predložena TMGEM metoda robusna je na zakrivljenost redova usjeva. Osim navedenih metoda, u radu je predložen novi evaluacijski okvir za usporedbu metoda prepoznavanja redova usjeva koji uključuje bazu slika redova usjeva, postupak ručnog generiranja referentnih vrijednosti redova usjeva te kriterije za određivanje točnosti prepoznavanja redova usjeva. Na slikama u bazi snimljeni su redovi usjeva kukuruza, celera, krumpira, luka, suncokreta i soje. Korištenjem predloženog evaluacijskog okvira moguće je efikasnije i objektivnije usporediti novo razvijene metode za prepoznavanje redova usjeva s postojećim metodama. U eksperimentalnoj evaluaciji CRDI metoda je uspoređena s IMLD i HT metodom na umjetno generiranim skupovima podataka. Točnost prepoznavanja određena je primjenom CRHID kriterija, a rezultati pokazuju da CRDI metoda prepoznaje redove usjeva sa znatno većom točnošću u odnosu na ostale razmatrane metode. TMGEM metoda testirana je na 225 stvarnih slika redova usjeva iz baze slika te je uspoređena s

HT, HTT i LR metodom. Točnost prepoznavanja redova usjeva određena je korištenjem CRDA kriterija, a rezultati pokazuju da predložena metoda značajno nadmašuje ostale tri razmatrane metode pri prepoznavanju ravnih redova usjeva te je robusna na zakrivljenost redova usjeva.

Ključne riječi: automatizacija u poljoprivredi, `DIRECT`, dinamičko programiranje, inkrementalna metoda, optimizacija, podudaranje s predloškom, prepoznavanje redova usjeva, računalni vid.

Abstract

Image based crop row detection using global optimization methods

The topic of this doctoral thesis is the development of image based crop row detection methods. The main goal of the research is to develop a method which is: highly insensitive to the presence of weeds and shadows, capable of detecting crop rows of different crop types at different stages of growth, capable of detecting straight and curved crop rows and insensitive to the number and spacing of crop rows. Two methods are proposed entitled CRDI and TMGEM. CRDI method is based on incremental method of searching for an approximate globally optimal partition of a set of data points and on the `DIRECT` algorithm for global optimization. The method is capable of detecting straight crop rows, wherein the number of crop rows must be known in advance. TMGEM method is based on template matching followed by global energy minimization with dynamic programming technique. For accurate crop row detection, the global energy function combines image evidence and prior knowledge about the geometric structure of crop rows. The proposed method is insensitive to the number and spacing of crop rows and is capable of detecting crop rows of different crop types at different stages of growth. Furthermore, the proposed TMGEM method is capable of detecting curved crop rows. A new evaluation framework is proposed that consists of a crop row image database, manual ground truth image creation approach and two crop row detection performance measures. The image database includes images of different crop types including maize, celery, potato, onion, sunflower and soybean. The proposed evaluation framework enables efficient and objective comparison of new crop row detection methods with existing ones. The experimental evaluation of CRDI method includes comparison with IMLD and HT method on synthetic datasets, based on the proposed CRHID performance measure. The results show that CRDI method outperforms other considered methods. TMGEM method is evaluated on a set of 225 real-world crop row images from the image database and it is compared

with HT, HTT and LR method. The proposed CRDA measure is used as a performance measure in the comparison. The results show that TMGEM significantly outperforms the other considered methods in straight crop row detection and is capable of detecting curved crop rows.

Keywords: agricultural automation, computer vision, crop row detection, `DIRECT`, dynamic programming, incremental method, optimization, template matching.

Životopis

Ivan Vidović rođen je 16.01.1988. godine u Đakovu, gdje završava osnovnu i srednju školu. Diplomski studij računarstva završava 2011. godine na Elektrotehničkom fakultetu u Osijeku. Iste godine zaposlen je kao vanjski suradnik na Zavodu za industrijska postrojenja i automatizaciju Elektrotehničkog fakulteta, a od 2012. godine zaposlen je na istom fakultetu kao asistent. Trenutno radi na Zavodu za računalno inženjerstvo i automatiku te održava auditorne i laboratorijske vježbe iz raznih kolegija iz područja računalnog i programskog inženjerstva te automatike. Kao istraživač sudjelovao je na znanstvenom projektu MZOŠ RH "Distribuirano računalno upravljanje u transportu i industrijskim pogonima". Trenutno je suradnik i istraživač na znanstvenom projektu HRZZ-a "Napredna 3D percepcija za mobilne robotske manipulatore" te na Tetracom FP7 projektu "Prototip stanice računalnog vida za kontrolu kvalitete sirovih keramičkih pločica". Kao autor i koautor objavio je tri rada u znanstvenim časopisima CC kategorije, jedan rad u časopisu A kategorije, jedan rad u časopisu B kategorije te 5 radova u zbornicima međunarodnih konferencija. Trenutna područja istraživanja su računalni vid i razvrstavanje podataka s primjenama u poljoprivredi, prepoznavanju objekata te kontroli kvalitete keramičkih pločica.

Ivan Vidović