

Univerza v Ljubljani
Fakulteta za računalništvo in informatiko

Ana Šimec

**Ocenjevanje relativne zmogljivosti
algoritmov za odkrivanje robov**

DIPLOMSKA NALOGA
NA UNIVERZITETNEM ŠTUDIJU

prof. dr. Franc Jager
MENTOR

Ljubljana, 2014

© 2014, Univerza v Ljubljani, Fakulteta za računalništvo in informatiko

Rezultati diplomskega dela so intelektualna lastnina Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavljanje ali izkoriščanje rezultatov diplomskega dela je potrebno pisno soglasje Fakultete za računalništvo in informatiko ter mentorja.¹

¹V dogovorju z mentorjem lahko kandidat diplomskega dela s pripadajočo izvorno kodo izda tudi pod katero izmed alternativnih licenc, ki ponuja določen del pravic vsem: npr. Creative Commons, GNU GPL.



Št. naloge: 01975 / 2013
Datum: 5.12.2013

Univerza v Ljubljani, Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Kandidat: **ANA ŠIMEC**

Naslov: **OCENJEVANJE RELATIVNE ZMOGLJIVOSTI ALGORITMOV ZA
ODKRIVANJE ROBOV
ASSESSING RELATIVE PERFORMANCE OF EDGE DETECTION
ALGORITHMS**

Vrsta naloge: DIPLOMSKO DELO UNIVERZITETNEGA ŠTUDIJA

Tematika naloge:

Implementirajte in primerjajte zmogljivost Cannyevega in Marr-Hildrethovega detektorja za odkrivanje robov. V ta namen izberite množico reprezentativnih tomografskih (CT) in magnetnoresonančnih (MRI) medicinskih posnetkov iz podatkovne baze CTMRI DB, generirajte referenčne slike in razvijte nove metrike za ocenjevanje relativne zmogljivosti algoritmov. Rezultate detekcije primerjajte kvalitativno na podlagi subjektivne ocene in kvantitativno z uporabo razvitih metrik.

Mentor:

prof. dr. Franc Jager

Dekan:

prof. dr. Nikolaj Zimic



IZJAVA O AVTORSTVU DIPLOMSKEGA DELA

Spodaj podpisana izjavljam, da sem avtorica dela, da slednje ne vsebuje materiala, ki bi ga kdorkoli predhodno že objavil ali oddal v obravnavo za pridobitev naziva na univerzi ali drugem visokošolskem zavodu, razen v primerih kjer so navedeni viri.

S svojim podpisom zagotavljam, da:

- sem delo izdelala samostojno pod mentorstvom prof. dr. Franca Jagra,
- so elektronska oblika dela, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko in
- soglašam z javno objavo elektronske oblike dela v zbirki "Dela FRI".

— Ana Šimec, Ljubljana, februar 2014.

Iskrena hvala profesorju dr. Francu Jagru za pomoč, usmerjanje
ter ves vložen čas, ki ga je namenil tej diplomski nalogi.
Hvala vsem bližnjim za spodbudo in potrpežljivost.

Procrastination is the thief of time.

- Edward Young

KAZALO

Povzetek	xvii
1 Uvod	1
1.1 Motivacija	1
1.2 Namen dela	3
1.3 Medicinske slike	4
1.3.1 Računalniška tomografija (CT)	4
1.3.2 Magnetna resonanca (MRI)	5
1.3.3 Podatkovna baza slik CTMRI	6
2 Metode	7
2.1 Izbor in kategorizacija testnih podatkov	7
2.2 Razvojno okolje	8
2.3 Odkrivanje robov	9
2.3.1 Kaj je rob?	9
2.3.2 Uporaba odvoda	11
2.3.3 Marr-Hildrethov detektor	13
2.3.4 Cannyjev detektor	16
2.4 Parametri	23
2.4.1 Avtomatizacija parametra prag	23
2.4.2 Omejitev parametra σ	23
2.5 Kompozicija referenčne slike	26
2.5.1 Korespondenčna slika	26
2.5.2 Obstoječa metoda	29
2.5.3 Predlagana metoda	33
2.6 Metrike zmogljivosti	34

2.6.1	Obstoječe metrike	34
2.6.2	Izpeljava novih metrik	36
2.6.3	Relativna občutljivost in relativna pozitivna napovedljivost detektorja	39
2.6.4	Presežek detektorja	41
2.6.5	Stopnja ujemanja	42
3	Rezultati	43
3.1	Grafični uporabniški vmesnik	43
3.1.1	GUI - detekcija	43
3.1.2	GUI - korespondenčna slika	46
3.2	Vizualna primerjava	46
3.3	Uporabljene referenčne slike	55
3.4	Uporaba in evaluacija razvitih metrik nad testno množico slik	60
4	Razprava	71
4.1	Možnosti za nadaljnje delo	71
4.2	Sklep	72
	Literatura	73
A	Testna množica CT in MRI slik ter pripadajoče referenčne slike	75
B	Rezultati evaluacije metrik nad rezultati detekcije.	89

SLIKE

1.1	Primer medicinskih slik glave z vidnim možganskim tumorjem.	2
a	MRI posnetek glave (stranski pogled). Vir:[10]	2
b	CT posnetek glave (pogled od zgoraj). Vir:[9]	2
1.2	Običajna rentgenska slika prsnega koša.	4
1.3	Rezultat CT slikanja - posnetek glave v različnih plasteh.	5
2.1	Model "stopnice" in "nagiba" ter pripadajoča profila intenziteta.	9
a	Stopnica.	9
b	Nagib.	9
2.2	Model "vrha" ter pripadajoč profil intenzitete.	10
2.3	CT posnetek z vsebovanimi osnovnimi modeli robov. Vir: [5]	10
2.4	Sivinska slika, njen profil intenzitete v horizontalni smeri (nagib) ter pripadajoča prvi in drugi odvod.	11
2.5	Vpliv šuma na profil intenzitete slike ter na njegov 1. in 2. odvod. Vir: [4]	12
2.6	Negativ LoG funkcije prikazan kot slika.	14
2.7	Negativ LoG funkcije.	14
a	Negativ LoG funkcije v 3-D. Vir: [5].	14
b	Prečni prerez negativa LoG funkcije. Vir: [5].	14
2.8	Negativ LoG funkcije prikazan kot slika.	14
2.9	Prvi korak Marr-Hildreth detektorja.	15
a	Originalna slika.	15
b	Rezultat filtriranja.	15
2.10	Rezultat iskanja prehodov skozi nič.	15

2.11	Glajenje slike z gaussovim filtrom	17
a	Originalna slika.	17
b	Slika po koraku glajenja.	17
2.12	Sobelova operatorja za računanje odvoda slike v x in y smeri	18
a	Operator za računanje horizontalnih sprememb v intenziteti.	18
b	Operator za računanje vertikalnih sprememb v intenziteti.	18
2.13	Amplituda in smer odvoda slike	18
a	Slika amplitud odvoda.	18
b	Slika smeri odvoda.	18
2.14	Območja kotov normal robov za preslikavo v 4 različne osnovne smeri. Vir: [5]	19
2.15	Preslikava kota normale v osnovno smer.	19
2.16	Pretvorba gradientnih vektorjev v 4 osnovne smeri.	20
a	Gradientni vektorji CT slike pred pretvorbo.	20
b	Gradientni vektorji CT slike po pretvorbi.	20
2.17	Pregledovanje 3x3 okolice točke.	20
2.18	Slika po uporabi metode izločanja neizrazitih pikslov.	21
2.19	Rezultat koraka histereznega upragovanja.	22
a	Slika po upragovanju.	22
b	Slika po postopku tanjšanja robov.	22
2.20	Rezultat detekcije robov z robnimi vrednostmi σ na CT posnetku.	24
a	Rezultat detekcije robov s Cannyjevim algoritmom na CT posnetku s σ_{min}	24
b	Rezultat detekcije robov s Cannyjevim algoritmom na CT posnetku s σ_{max}	24
c	Rezultat detekcije robov z Marr-Hildrethovim algoritmom na CT posnetku s σ_{min}	24
d	Rezultat detekcije robov z Marr-Hildrethovim algoritmom na CT posnetku s σ_{max}	24
2.21	Rezultat detekcije robov z robnimi vrednostmi σ na MRI posnetku.	25
a	Rezultat detekcije robov s Cannyjevim algoritmom na MRI posnetku s σ_{min}	25

b	Rezultat detekcije robov s Cannyjevim algoritmom na MRI posnetku s σ_{max}	25
c	Rezultat detekcije robov z Marr-Hildrethovim algoritmom na MRI posnetku s σ_{min}	25
d	Rezultat detekcije robov z Marr-Hildrethovim algoritmom na MRI posnetku s σ_{max}	25
2.22	Histograma korespondenčnih slik.	27
a	Histogram korespondenčne slike 2.23a.	27
b	Histogram korespondenčne slike 2.23b.	27
2.23	Primer korespondenčnih slik.	28
a	Primer korespondenčne slike za Cannyjev detektor.	28
b	Primer korespondenčne slike za Marr-Hildrethov detektor.	28
2.24	Primer upragovanih korespondenčnih slik MRI posnetka pri uporabi različnih korespondenčnih pragov.	29
a	Upragovana korespondenčna slika s 25% korespondenco.	29
b	Upragovana korespondenčna slika s 75% korespondenco.	29
2.25	Primer KP-ROC krivulje za MRI posnetek pri uporabi Marr-Hildrethovega detektorja.	32
2.26	Primer S-ROC krivulje za CT posnetek pri uporabi Marr-Hildrethovega detektorja.	34
2.27	Standardna zmogljivostna matrika.	35
2.28	Splošna shema ujemanja robnih točk dveh detektorjev.	37
2.29	Shema ujemanja robnih točk za primer Cannyjevega in Marr-Hildrethovega detektorja.	37
2.30	Shema ujemanja robnih točk z vidika Cannyjevega detektorja - referenčni detektor je Marr-Hildrethov.	38
2.31	Shema ujemanja robnih točk z vidika Marr-Hildrethovega detektorja - referenčni detektor je Cannyjev.	38
2.32	Zmogljivostni matriki za dva primera primerjave detektorjev.	39
a	Zmogljivostni matriki za primer, ko je referenčni detektor Marr-Hildrethov.	39
b	Zmogljivostni matriki za primer, ko je referenčni detektor Cannyjev.	39
2.33	Nove zmogljivostne matrike.	40

3.1	Grafični uporabniški vmesnik za detekcijo robov - izbrana slika in rezultat detekcije na podlagi vnešenih vrednosti parametra σ	44
3.2	Slika z dodanim Gaussovimi šumom z varianco $\sigma^2 = 0.2$	44
3.3	Izboljšanje kontrasta slike s pomočjo postopka izravnave histograma.	45
a	Originalna slika in pripadajoči histogram.	45
b	Rezultat po postopku izravnave histograma.	45
3.4	Grafični uporabniški vmesnik za kompozicijo korespondenčne slike in iskanje najboljše vrednosti parametra σ	46
3.5	Primerjava števila odkritih robov - Cannyjev algoritem (a,c,e) in Marr-Hildrethov algoritem (b,d,f), $\sigma_C = \sigma_M = 1.7$. CT posnetki 3, 9 in 10.	47
a	47
b	47
c	47
d	47
e	47
f	47
3.6	Del slike z zrnatostjo in odkriti robovi - posnetek št. 9; $\sigma_C = \sigma_M = 2.6$	48
a	Originalna slika.	48
b	Cannyjev algoritem.	48
c	Marr-Hildrethov algoritem.	48
3.7	Odkriti robovi dela slike pri povečevanju σ nad vrednost 5 - posnetek št. 9.	49
a	Cannyjev detektor - $\sigma_C = \{5, 6, 8\}$	49
b	Marr-Hildrethov detektor - $\sigma_M = \{5, 6, 8\}$	49
3.8	Del slike s kontrastnimi deli telesa in najdeni robovi - posnetek št. 10; $\sigma_C = \sigma_M = 2.3$	50
a	Originalna slika.	50
b	Cannyjev algoritem.	50
c	Marr-Hildrethov algoritem.	50
3.9	Del slike s kontrastnimi deli telesa in najdeni robovi - posnetek št. 7; $\sigma_C = \sigma_M = 2.3$	52
a	Originalna slika.	52
b	Cannyjev algoritem.	52
c	Marr-Hildrethov algoritem.	52

3.10	Izsek MRI posnetka in najdeni robovi - posnetek št. 11 in 12; $\sigma_C = \sigma_M = 2.5$.	53
a	Originalna slika.	53
b	Cannyjev detektor.	53
c	Marr-Hildrethov detektor.	53
d	Originalna slika.	53
e	Cannyjev detektor.	53
f	Marr-Hildrethov detektor.	53
3.11	Primerjava referenčnih slik, pridobljenih z uporabo obeh metod - posnetek št. 6.	56
a	Originalna slika.	56
b	Referenčna slika po 1. metodi.	56
c	Referenčna slika po 2. metodi.	56
3.12	Primerjava referenčnih slik, pridobljenih z uporabo obeh metod - posnetek št. 9.	57
a	Originalna slika.	57
b	Referenčna slika po 1. metodi.	57
c	Referenčna slika po 2. metodi.	57
3.13	Primerjava referenčnih slik, pridobljenih z uporabo obeh metod - posnetek št. 2.	58
a	Originalna slika.	58
b	Referenčna slika po 1. metodi.	58
c	Referenčna slika po 2. metodi.	58
3.14	Primerjava referenčnih slik, pridobljenih z uporabo obeh metod - posnetek št. 5.	59
a	Originalna slika.	59
b	Referenčna slika po 1. metodi.	59
c	Referenčna slika po 2. metodi.	59
3.15	Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 2 - CT).	61
3.16	Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 2 - CT).	62
3.17	Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 2 - CT).	64

a	Vrednosti stopnje ujemanja predstavljene s 3D mrežo.	64
b	Vrednosti stopnje ujemanja predstavljene s 3D mrežo - tloris.	64
3.18	Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (povprečje vseh CT posnetkov).	65
3.19	Rezultat uporabe metrik - referenca je Cannyjev detektor (povprečje vseh CT posnetkov).	66
3.20	Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (povprečje vseh CT posnetkov.)	67
a	Vrednosti stopnje ujemanja predstavljene s 3D mrežo.	67
b	Vrednosti stopnje ujemanja predstavljene s 3D mrežo - tloris.	67
3.21	Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 11 - MRI).	68
3.22	Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 11 - MRI).	69
3.23	Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 11 - MRI.)	70
a	Vrednosti stopnje ujemanja predstavljene s 3D mrežo.	70
b	Vrednosti stopnje ujemanja predstavljene s 3D mrežo - tloris.	70

TABELE

2.1	Testna množica posnetkov.	8
2.2	Uporabljen obseg parametra σ	24
2.3	Uporabljene vrednosti parametra σ	27
2.4	Definicija vrednosti $TP_{D_j EGT}$, $FP_{D_j EGT}$, $TN_{D_j EGT}$ in $FN_{D_j EGT}$	33
3.1	Rezultati obstoječe in lastne metode za iskanje optimalne vrednosti parametra σ ter z njo referenčne slike.	55

POJMOVNIK

CT	računalniška tomografija (<i>angl. computed tomography</i>)
MRI	magnetna resonanca (<i>angl. magnetic resonance imaging</i>)
MIC	področje, ki se ukvarja z obdelavo medicinskih slik (<i>angl. medical image computing</i>)
RTG slika	rentgenska slika
LoG	Laplace Gaussa (<i>angl. Laplacian of Gaussian</i>)
TP	vsota pravih pozitivnih odločitev (<i>angl. true positive</i>)
FP	vsota nepravilnih pozitivnih odločitev (<i>angl. false positive</i>)
TN	vsota pravih negativnih odločitev (<i>angl. true negative</i>)
FN	vsota nepravilnih negativnih odločitev (<i>angl. false negative</i>)
ROC	karakteristika sprejemnika (<i>angl. receiver operating characteristic</i>)
GUI	grafični uporabniški vmesnik (<i>angl. graphical user interface</i>)

POVZETEK

Na področju obdelave medicinskih slik v zadnjem času narašča potreba po avtomatskih postopkih za obdelavo vizualnih posnetkov. Segmentacija slik s pomočjo odkrivanja robov predstavlja eno izmed glavnih uporabljenih tehnik analize in ima lahko pomembno vlogo v medicinski diagnostiki, raziskavah in pri načrtovanju terapije. Postopki za odkrivanje robov morajo biti karseda zanesljivi in natančni. To predstavlja težavo, saj so medicinske slike v veliki meri nejasne in vsebujejo šum, kar otežuje dobro detekcijo resničnih kontur objektov.

V tej diplomski nalogi smo primerjali dva algoritma za detekcijo robov, Cannyjev in Marr-Hildrethov detektor, ki temeljita na uporabi prvega in drugege odvoda slike. Naša prva naloga je bila implementacija algoritmov, nato pa smo ju med seboj primerjali v smislu zmogljivosti.

Testno množico je sestavljal izbor posnetkov računalniške tomografije (CT) in magnetne resonance (MRI), ki so del podatkovne baze CTMRI DB. Za primerjavo zmogljivosti obeh detektorjev smo uporabili kvalitativni in kvantitativni pristop. Najprej smo rezultate detekcije primerjali vizualno, na podlagi subjektivne ocene o prisotnosti robov. Kvantitativna primerjava je obsegala generiranje referenčne slike, ki smo jo nato primerjali z rezultati detekcije. V ta namen smo razvili postopek za generiranje referenčne slike in zasnovali nove metrike zmogljivosti za primerjavo dveh detektorjev. Razvite metrike zmogljivosti je možno posplošiti na poljubno število detektorjev za odkrivanje robov in odpirajo nove možnosti na področju vrednotenja zmogljivosti algoritmov.

Ključne besede

Medicinske slike, detekcija robov, Cannyev detektor, Marr-Hildrethov detektor, metrike zmogljivosti, vrednotenje zmogljivosti.

ABSTRACT

In the field of medical imaging there is a growing need for automatic procedures for processing visual recordings. Image segmentation based on edge detection represents one of the mainly used techniques of analysis and has an important role in medical diagnostics, researches and in treatment planning. Edge detection procedures must be as reliable and accurate as possible. This represents a problem since medical images are mostly unclear and contain noise which causes difficulties in detecting true contours of objects. In this thesis we compared two edge detection algorithms, the Canny edge detector and the Marr-Hildreth edge detector, which are based on the use of the first and second derivative. Our first task was to implement the algorithms, then we compared them in the sense of performance.

The testing dataset was composed from computed tomography (CT) and magnetic resonance imaging (MRI) images that are a part of the CTMRI DB database. We used qualitative and quantitative approach to compare the performance of both detectors. First we compared detection results visually, based on a subjective assessment of the presence of the edges. Quantitative comparison consisted of generating a reference image which was then compared to the detection results. For this purpose we developed a procedure for reference image generation and established new performance metrics for comparison of performance of two detectors. The developed performance metrics can be generalized to any number of edge detectors and offer new opportunities in the field of algorithm performance evaluation.

Key words

Medical images, edge detection, Canny edge detector, Marr-Hildreth edge detector, performance metrics, performance evaluation.

1 Uvod


1.1 Motivacija

Detekcija kontur predstavlja enega izmed osnovnih korakov pri procesiranju slik. Robovi tipično označujejo meje in so tako uporabni za segmentacijo ter prepoznavanje objektov na slikah. Njihova detekcija bistveno zmanjša količino podatkov - izloči neuporabne informacije, pri tem pa ohrani pomembne strukturne lastnosti slike [7].

Veliko zanimanje za računalniško odkrivanje robov se v zadnjem času kaže tudi v medicini, na področju obdelave medicinskih slik (*Medical Image Computing - MIC*). Področje se ukvarja z razvijanjem računalniških in matematičnih metod za reševanje problemov, povezanih z medicinskimi slikami, ter njihovo uporabo v biomedicinskih raziskavah in klinični oskrbi. S porastom uporabe *računalniške tomografije* (CT) in *magnetne resonance* (MRI) je namreč postalo skoraj nujno, da si radiolog pri postavljanju diagnoze in načrtovanju zdravljenja pomaga tudi z računalniškimi programi za analizo medicinskih slik, ki mu lahko z avtomatizacijo specifičnih radioloških opravil olajšajo delo.

Glavna naloga MIC aplikacij je ekstrakcija klinično relevantnih informacij in znanja iz slik [8]. Pri tem pomemben postopek predstavlja *segmentacija*, ki sliko razdeli na različne regije, eden od načinov za doseganje tega cilja pa vključuje tudi identifikacijo in lokalizacijo ostrih intenzitetnih sprememb v sliki - *robov*.

Na spodnji sliki 1.1 sta prikazana primera dveh vrst medicinskih slik - MRI posnetek (1.1a) in CT posnetek(1.1b) glave - na katerih je dobro viden možganski tumor.



(a) MRI posnetek glave (stranski pogled). (b) CT posnetek glave (pogled od zgoraj).

Vir:[10]

Vir:[9]

Slika 1.1: Primer medicinskih slik glave z vidnim možganskim tumorjem.

Iskanje posameznih objektov (organov,kosti) na sliki bi lahko bila v tem primeru ključnega pomena, zato je potrebno zagotoviti postopke, ki bodo problem detekcije rešili čim pravilneje - razmejitev med posameznimi objekti mora biti karseda zanesljiva.

Nekaj primerov uporabe segmentacije slik v medicini:

- Preučevanje anatomske strukture
- Identifikacija regij kot so tumorji,lezije in druge anomalije
- Merjenje velikosti tkiv - npr. za ugotavljanje rasti tumorja (oz. njegovo zmanjšanje po uporabi določene terapije zdravljenja)
- 3D računalniška rekonstrukcija delov telesa, ...

Kot je razvidno iz naštetega, je avtomatska segmentacija (in z njo detekcija kontur v sliki) lahko uporaben diagnostični pripomoček, pomembno vlogo pa igra tudi pri načrtovanju ustreznega zdravljenja ter v medicinskih raziskavah [13]. Količina slikovnih podatkov se povečuje, zato so avtomatizirani postopki za njihovo obdelavo nujni. Iz informacij, ki jih izluščijo lahko nato s pomočjo podatkovnega rudarjenja pridemo do novih pomembnih medicinskih znanj.

1.2 Namen dela

Diplomska naloga se osredotoča na *odkrivanje robov*, ki predstavlja enega od pogosto uporabljenih pristopov k segmentaciji slik. Odločili smo se za obravnavo dveh že poznanih algoritmov - *Cannyjevega* in *Marr-Hildrethovega* detektorja.

Zanimalo nas je, kako se detektorja obnašata, ko ju uporabimo na netipičnih slikah - medicinskih posnetkih delov človeškega telesa. Telo sestavljajo različne vrste tkiv, kar se močno odraža v nehomogeni teksturi medicinske slike. Prav tako posnetki pogosto vsebujejo precej šuma, ki otežuje pravilno odkrivanje robov.

Odločili smo se, da ne uporabimo že obstoječih implementacij detektorjev kontur, temveč algoritma razvijemo samostojno in tako izboljšamo razumevanje njunega delovanja. Hkrati si s tem zagotovimo popoln nadzor nad potekom detekcije in zmožnost vpogleda v vmesne korake. V koraku primerjave detektorjev smo želeli spreminjati le en parameter, zato smo se odločili, da drug parameter avtomatsko določamo znotraj algoritmov. Pri tem je bil cilj, da je odkrivanje robov karseda optimalno.

Rezultate smo najprej proučili s *kvalitativnega* vidika - zanimalo nas je, kako dobri so najdeni robovi, če jih primerjamo s subjektivno človeško oceno glede prisotnosti izrazitih robov. Prav tako smo želeli preveriti, kako se algoritma razlikujeta v detekciji, če primerjamo enega z drugim - kateri od obeh je bolj robusten/občutljiv, kateri parametri dajo pri posameznem detektorju najboljše rezultate ter ali je kakšna povezava med kvaliteto detekcije in vrsto objektov na sliki.

Zatem smo oba algoritma primerjali še *kvantitativno*. Poleg že obstoječih standardnih metrik smo postavili še nekatere *nove metrike*, ki odpirajo dodatne možnosti za splošno primerjavo različnih detektorjev.

1.3 Medicinske slike

Pridobivanje slik človeškega telesa z uporabo magnetne resonance in računalniške tomografije, je ena najbolj razširjenih radiografskih tehnik za postavljanje diagnoze, načrtovanje zdravljenja ter za potrebe znanstvenih raziskav [13]. Postopka se med sabo razlikujeta, zato se za uporabo enega ali drugega odloča glede na tip želenih preiskav.

1.3.1 Računalniška tomografija (CT)

Pri računalniški tomografiji gre za računalniško podprto rentgensko preiskavo. Postopek slikanja deluje na osnovi rentgenskih žarkov, ki jih v snopu oddaja rentgenska cev v CT napravi. Žarki nato potujejo skozi telo, kjer jih do določene mere absorbirajo tkiva in organi. Različno prepustnost zaznajo detektorji, ki na nasprotni strani merijo oslabitev žarkov pri njihovem izhodu iz telesa. Na podoben način je producirana tudi običajna rentgenska (RTG) slika. Na njej so gostejša tkiva (npr. kosti) svetlejša, tista manj prepustna (npr. pljuča, ki so polna zraka) pa sive barve. Primer take slike prikazuje slika 1.2.




Slika 1.2: Običajna rentgenska slika prsnega koša.

Iz slike je razvidno, da ima uporaba običajnega rentgena številne omejitve. Predvsem pri preslikavi v 2D ravnino pride do izgube pomembnih 3D informacij - posamezni organi med sabo niso tako dobro ločeni, ni prave predstave o njihovi velikosti ter poziciji (brez

znanja anatomije bi težje razbrali, kaj je spredaj in kaj zadaj)...

CT slikanje te težave odpravlja, saj s pomočjo vrtljivega vira rentgenskih žarkov zajame večje število slik iz več različnih kotov. Podatki so nato poslani računalniku, ki iz posameznih posnetkov rekonstruira prečni presek slikanega dela telesa. Za vsako rotacijo vira rentgenskih žarkov tako dobimo sliko ene izmed plasti (slika 1.3).



Slika 1.3: Rezultat CT slikanja - posnetek glave v različnih plasteh.

1.3.2 Magnetna resonanca (MRI)

Magnetna resonanca (MRI) je metoda slikanja človeškega telesa, ki z razliko od CT tehnike ne uporablja rentgenskega sevanja. Slike so pridobljene z napravo, ki deluje na podlagi močnega magnetnega polja. S pomočjo radiofrekvenčnih valov vzbuja vodikove atome v človeškem telesu (v večjih koncentracijah prisotnih v vodi in maščobi), pri čemer se sprošča energija. Naprava meri signal iz posameznih atomov, računalnik pa jih nato s posebnimi algoritmi pretvori v sliko prereзов notranjosti telesa.

V primerjavi z računalniško tomografijo, pri slikanju z magnetno resonanco ni prisotnega sevanja, saj signal prihaja iz notranjosti telesa iz posameznih tkiv. Dodatna prednost

postopka je tudi v tem, da je lahko slika zajeta v poljubni ravnini, pri tem pa pacienta ni potrebno premikati. Oba postopka slikanja lahko za izboljšavo kontrasta uporabljata posebna kontrastna sredstva, ki se vbrizgajo v žile, vendar lahko ta pri računalniški tomografiji vsebujejo jod, kar za določene paciente ni primerno. Iz tega razloga so MRI slike v večini primerov boljše za opazovanje mehkega tkiva, medtem ko so CT posnetki zelo dobri za prikazovanje kosti. Postopek magnetne resonance od pacienta zahteva dolgotrajno mirovanje znotraj naprave, zato je iz tega vidika primernejša računalniška tomografija, ki traja manj časa, prav tako pa je cenejša.

1.3.3 Podatkovna baza slik CTMRI

Slike, ki so bile uporabljene kot testna množica podatkov, so del podatkovne baze tomografskih in magnetnoresonančnih slik (CTMRIDB) Laboratorija za biomedicinske računalniške sisteme in oslikave (Laboratory for Biomedical Computer Systems and Imaging - LBCSI), ki se sproti dopolnjuje s strani različnih sodelavcev. Trenutno vsebuje medicinske slike 11 pacientov, od tega 11335 posnetkov nastalih z računalniško tomografijo ter 907 posnetkov z magnetno resonanco.

Slike so sivinske in v večini primerov velikosti 512×512 pikslov. Pri tistih, ki so bile pridobljene z magnetno resonanco, je moč opaziti večje podrobnosti, prav tako so posamezne skupine tkiv s prostim očesom lažje razločljive. V slikah računalniške tomografije so dobro vidne kosti, ki izstopajo z močno belo barvo. Šum je prisoten v obeh vrstah posnetkov, kar je posledica tehnologije za njihov zajem ter človeškega faktorja - predvsem pri slikanju z magnetno resonanco, ki je dolgotrajnejši postopek, lahko premikanje pacienta močno poslabša končno kvaliteto slike.

2 Metode

2.1 Izbor in kategorizacija testnih podatkov

Prvi korak praktičnega dela diplomske naloge je bil izbor reprezentativnih podatkov za analizo in testiranje ter njihova razvrstitev v skupine. Kot opisano v poglavju 1.3.3, smo imeli na voljo slike znotraj CTMRI DB. Želeli smo, da bi testne slike pokrivala obe področji medicinskih posnetkov (računalniško tomografijo in magnetno resonanco) ter da bi predstavljale različne dele telesa. Izbrali smo čimbolj razločne posnetke, ki smo jih znali približno interpretirati in so tako omogočali neko vizualno oceno robov.

Končna selekcija je dala naslednjo množico testnih posnetkov:

- 3 MRI posnetki
 - 3 posnetki glave
- 10 CT posnetkov:
 - 3 posnetki glave
 - 7 posnetkov prsne in trebušne votline (notranjih organov)

V spodnji tabeli (2.1) je seznam uporabljenih testnih posnetkov. Pripisana so pripadajoča imena, vrste posnetkov, vsebina slike ter pogled (ravnina zajema).

Vrsta	Št.	Ime	Del telesa	Pogled
CT	1	rec0.png	glava	spredaj
	2	rec2.png	glava	zgoraj
	3	rec3.png	glava	s strani
	4	rec4.png	trebušna votlina	spredaj
	5	rec5.png	prsni koš	s strani
	6	rec6.png	trebušna votlina	zgoraj
	7	rec7.png	trebušna votlina	spredaj
	8	rec8.png	trebušna votlina	s strani
	9	rec9.png	prsni koš	spredaj
	10	rec10.png	prsni koš	s strani
MRI	11	rec1a.png	glava	s strani
	12	rec2a.png	glava	zgoraj
	13	rec3a.png	glava	spredaj

Tabela 2.1: Testna množica posnetkov.

2.2 Razvojno okolje

Odločili smo se, da za razvoj detektorjev in grafično predstavitev končnih rezultatov uporabimo okolje *Matlab*. Ta je prilagojen matričnemu računanju in tako zelo primerno za programiranje algoritmov, namenjenih za obdelavo in analizo slik. Prav tako ima Matlab že številne vgrajene funkcije za numerično računanje, kar lahko zelo olajša delo. Dodatna prednost je enostavna sintaksa in uporaba ter veliko možnosti za grafični prikaz podatkov. Kot koristno se je izkazalo tudi posebno okolje za razvoj lastnih grafičnih uporabniških vmesnikov.


2.3 Odkrivanje robov

2.3.1 Kaj je rob?

Robovi so ena najbolj običajnih lokalnih značilk slike. V splošnem predstavljajo *mejo* med različnimi teksturami slike, kar pogosto pomeni tudi mejo med posameznimi objekti. Na področju računalniškega vida so definirani kot *znatne lokalne spremembe v intenziteti* slike [6]. V njej torej nakazujejo prisotnost visokih frekvenc. Iz tega razloga je odkrivanje kontur v slikah, ki vsebujejo šum, težavno, saj tudi ta vsebuje visoke frekvence.


V splošnem lahko rob predstavimo z modeli, ki prikazujejo različne prehode sivinskih nivojev v sliki. Idealen rob je "stopnica" (*angl. step*), kjer se opazna sprememba v intenziteti zgodi v koraku *enega* piksla. Primer takega modela prikazuje slika 2.1a. Idealni robovi se pojavljajo predvsem v slikah, ki so računalniško generirane (npr. na področju modeliranja in animacije), medtem ko so v praksi vsaj nekoliko zamegljeni.

To je v večji meri posledica omejitev v mehanizmih za fokusiranje in elektronskih komponentah sistemov za zajem slike. Takim robom je bližji intenzitetni profil "nagib" (*angl. ramp*), kot prikazano na sliki 2.1b. Velika intenzitetna sprememba v tem primeru ni takojšnja, temveč se pojavi postopoma. To nakazuje naklon nagiba, ki je obratno sorazmeren stopnji zabrisanosti roba - večji kot je naklon, manjša je stopnja zabrisanosti in bolj se rob približuje idealnemu modelu stopnice [5, 6].




Slika 2.1: Model "stopnice" in "nagiba" ter pripadajoča profila intenziteta.

Del slik so velikokrat tudi črte. Za primere takih robov se uporablja model "vrh" (*angl. roof*). Njegov profil intenzitete (slika 2.2) nakazuje, da se intenziteta v nekem trenutku začne opazno spreminjati, nato pa se kmalu povrne v prvotno vrednost. Do takojšnje spremembe v intenziteti ponavadi ne pride, saj so črte v slikah ponavadi vsaj rahlo zabrisane. Model vrh je torej določen s širino in ostrino črte na sliki [5, 6].



Slika 2.2: Model "vrha" ter pripadajoč profil intenzitete.


Slike ponavadi vsebujejo več vrst robov. Šum in zabrisanost sicer povzročita odstopanja od posameznih oblik, vendar so osnovne karakteristike vseeno lahko zelo podobne [5]. Na sliki 2.3 je CT posnetek glave, v katerem so označeni robovi, ki zelo spominjajo na opisane modele robov.



Slika 2.3: CT posnetek z vsebovanimi osnovnimi modeli robov. Vir: [5]

2.3.2 Uporaba odvoda

Ker gre pri robovih za opazne lokalne spremembe v intenziteti, veliko metod za njihovo odkrivanje bazira na *odvodih*.



Slika 2.4: Sivinska slika, njen profil intenzitete v horizontalni smeri (nagib) ter pripadajoča prvi in drugi odvod.

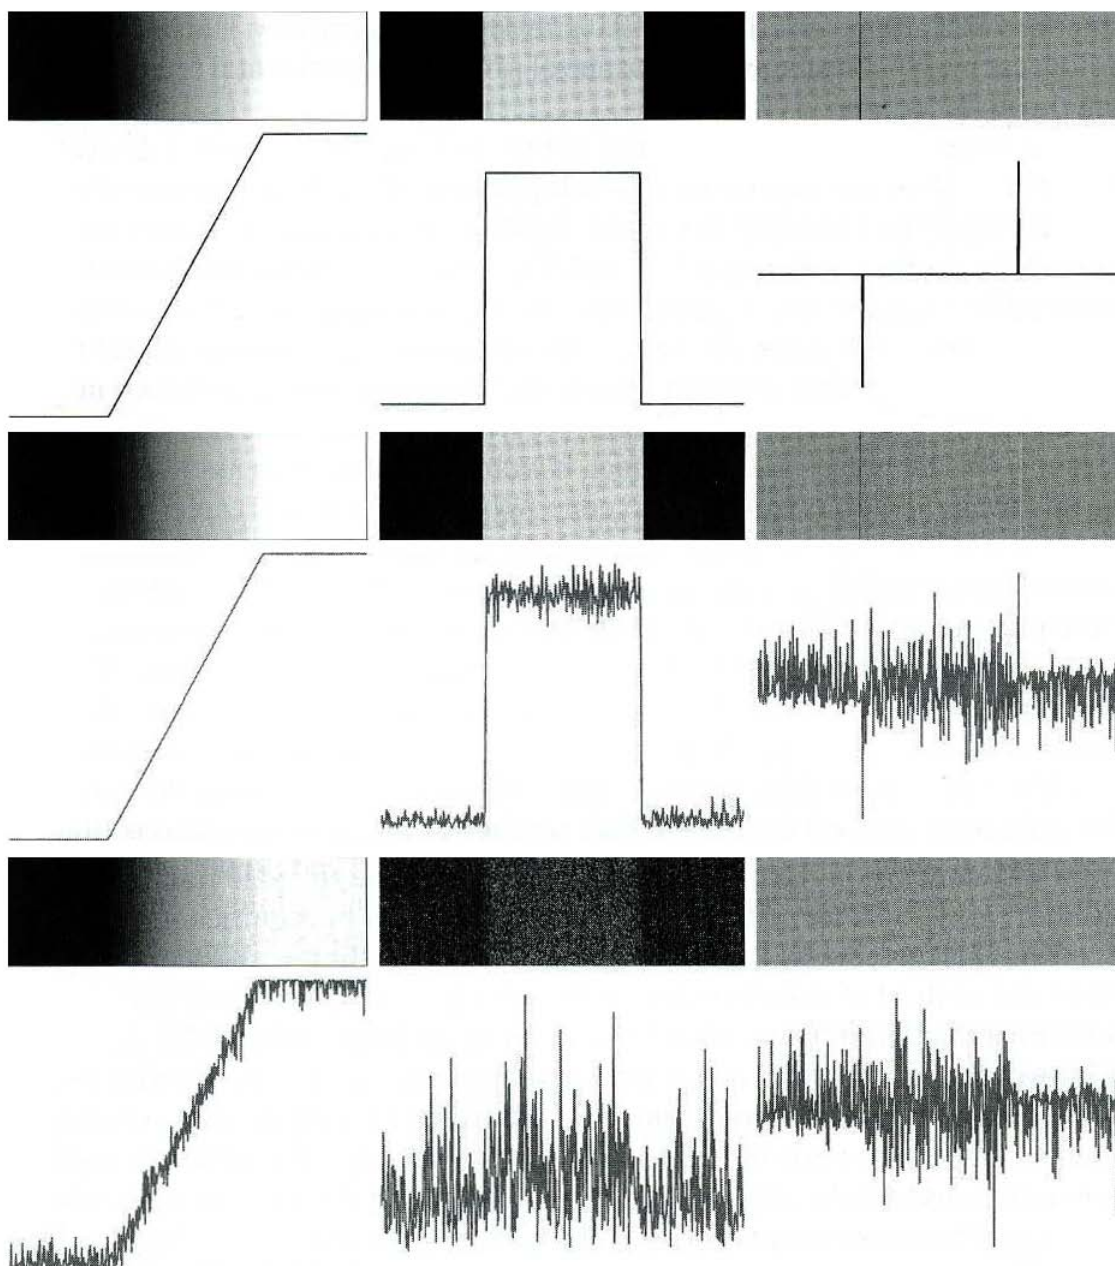
Iz slike 2.4 je razvidno, da postane prvi odvod ob nastopu nagiba *pozitiven*, v območju konstantne intenzitete pa je enak *nič*.

Drugi odvod ima *pozitivno* vrednost na začetku nagiba in *negativno* na njenem koncu. V točkah konstantne intenzitete in v tistih vzdolž nagiba je enak *nič*. Presečišče osi z intenziteto 0 in črto, ki povezuje oba ekstrema drugega odvoda (na sliki označena s sivo črtkano črto), je točka *prehod skozi nič* (angl. *zero crossing*). Ta je tako lahko uporabna za določanje sredine debelejših robov.

Za preverjanje prisotnosti roba je torej primerna *amplituda* prvega in drugega odvoda ter *sprememba v predznaku* drugega odvoda.

Slaba stran uporabe odvodov je v tem, da so zelo občutljivi na motnje. Že majhna prisotnost šuma lahko pokvari lastnosti, ki

bi bile sicer uporabne za odkrivanje robov. To lepo ponazarja slika 2.5. Na njej so v prvem stolpcu sivinske slike z robom nagib in pripadajoči profili intenzitete. Slikama v drugi in tretji vrsti je dodan Gauss-ov šum s standardno deviacijo $\sigma = 0.1$ in $\sigma = 10$. Drugi stolpec predstavlja prvi odvod slik, tretji pa drugi odvod. Jasno je razvidno, da že majhna prisotnost šuma povzroči, da sta odvoda (še posebej drugi) precej popačena glede na zgoraj opisane idealne primere. Pri večjem šumu (tretja vrsta) je sprememba še bolj očitna. Za uspešno odkrivanje robov je zato potrebno pred uporabo odvodov sliko najprej zgladiti in tako prisoten šum do določene mere odstraniti.



Slika 2.5: Vpliv šuma na profil intenzitete slike ter na njegov 1. in 2. odvod. Vir: [4]

2.3.3 Marr-Hildrethov detektor

V začetku je odkrivanje robov v slikah potekalo v obliki enostavnega filtriranja z eno ali več maskami, pri čemer niso bile upoštevane posebne karakteristike robov ali vsebovanost šuma v slikah. Prvo naprednejšo tehniko sta razvila David Marr in Ellen Hildreth (1980). Trdila sta, da spremembe v intenziteti *niso* neodvisne od velikosti slike, zato detekcija robov zahteva operatorje različnih velikosti. Predlagala sta uporabo 1. in 2. odvoda, kjer se nenadne spremembe v intenziteti odražajo v poudarjenih vrhovih oz. prehodih skozi 0. Operator za odkrivanje robov bi moral zadoščati dvema ključnima lastnostima:

1. mora biti *diferencialni operator*, torej zmožen izračuna aproksimacije odvoda v vsaki točki slike,
2. mora biti *sposoben prilagajanja glede na željeno velikost* (veliki operatorji lahko detektirajo zabrisane robove, medtem ko lahko majhni operatorji odkrijejo ostre in fine detajle) [5].

LoG funkcija

Po mnenju D. Marr-a in E.Hildreth je najbolj zadovoljiv operator, ki ustreza zgoraj naštetim pogojem, filter $\nabla^2 G$, kjer ∇^2 predstavlja *Laplace-ov operator*, G pa 2-D *Gauss-ovo funkcijo* s standardno deviacijo σ :

$$\nabla^2 = \frac{\delta^2}{\delta x^2} + \frac{\delta^2}{\delta y^2}, \quad (2.1)$$


$$G(x, y) = e^{-\frac{x^2+y^2}{2\sigma^2}}. \quad (2.2)$$

Izraz za $\nabla^2 G$ imenujemo *Laplace Gauss-a* oz. *LoG funkcija*.

$$\nabla^2 G(x, y) = \left[\frac{x^2 + y^2 - 2\sigma^2}{\sigma^4} \right] e^{-\frac{x^2+y^2}{2\sigma^2}}. \quad (2.3)$$

Na sliki je negativ funkcije *LoG* v treh oblikah:

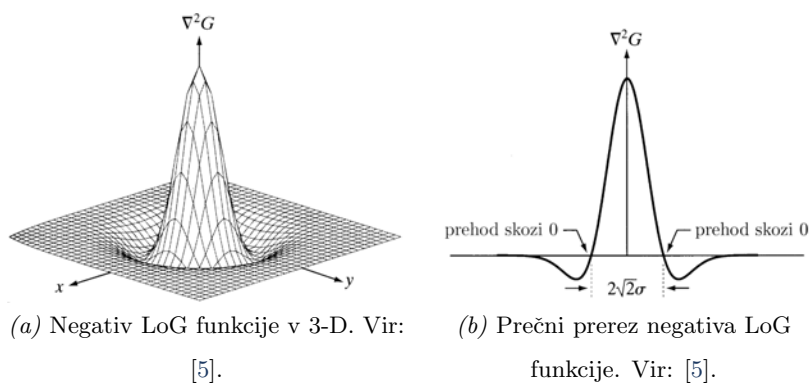
- v 3-D
- prečni prerez v 2-D ravnini
- prikazan kot slika



Slika 2.6: Negativ LoG funkcije prikazan kot slika.

Kot je razvidno iz formule 2.3, pride do prehoda skozi 0 v $x^2 + y^2 = 2\sigma^2$, kar definira krog v centru slike z radijem $\sqrt{2}\sigma$ (lepo vidno na sliki 2.6). Zaradi značilne oblike (slika 2.7a), je funkcija LoG velikokrat imenovana operator *Mehiški klobuk* (angl. *Mexican hat*). Maska, ki bi aproksimirala funkcijo LoG, mora zajeti lastnosti te oblike - potrebuje pozitiven centralni del, obkrožen z regijo negativnih vrednosti, ki se z oddaljenostjo od centra večajo, ter zunanji del, kjer so vrednosti maske

enake nič. Koefficienti maske se morajo sešteti v nič, kar zadosti pogoju, da je odziv maske enak nič v območjih konstantne intenzitete slike [5]. Primer take maske je prikazan na sliki 2.8.




Slika 2.7: Negativ LoG funkcije.

0	0	-1	0	0
0	-1	-2	-1	0
-1	-2	16	-2	-1
0	-1	-2	-1	0
0	0	-1	0	0

Slika 2.8: Negativ LoG funkcije prikazan kot slika.

Gauss-ov del operatorja sliko zgladi in tako zmanjša intenzitetne strukture (tudi šum), manjše kot σ . Drugi del operatorja je ∇^2 , ki ima lastnosti 2.odvoda in detektira spremembe v intenziteti. V primerjavi s 1.odvodom, je njegova prednost v tem, da je *izotropičen* - invarianten za rotacijo. Njegov odziv na spremembe v inteziteti je torej enak v katerikoli smeri maske.

V naši implementaciji smo uporabili že vgrajeno funkcijo *fspecial*, ki na podlagi σ in velikosti okna kreira ustrezno $n \times n$ LoG masko. Okno mora biti dovolj veliko, da zajame vse lastnosti LoG funkcije. Približno 99.7% površine pod Gaussovo funkcijo leži med $\pm 3\sigma$ od središča. Pravilo je, da za n vzamemo najmanjše liho celo število večje ali enako 6σ [5]. Slika 2.9 prikazuje primer filtriranja z LoG filtrom.




(a) Originalna slika.

(b) Rezultat filtriranja.

Slika 2.9: Prvi korak Marr-Hildreth detektorja.

Prehodi skozi nič



Slika 2.10: Rezultat iskanja prehodov skozi nič.

Naslednji korak Marr-Hildrethovega postopka je iskanje točk, kjer pride do spremembe vrednosti drugega odvoda iz pozitivne v negativno in obratno. V algoritmu opazujemo 3×3 okolico posameznega piksla slike, ki smo jo dobili po filtriranju z LoG filtrom in preverimo, kje se predznaka *vsaj dveh* nasprotnih si sosedov razlikujeta. Dodaten pogoj, ki odloči ali je tak piksel del roba je, da mora biti absolutna razlika njunih vrednosti večja od praga T . Več o izboru parametrov je napisano v poglavju 2.4. Slika 2.10 prikazuje rezultat končnega koraka Marr-Hildreth detektorja.

2.3.4 Cannyjev detektor

Cannyjev algoritem (John F. Canny, 1983) predstavlja enega standardnih postopkov za odkrivanje kontur v slikah. Pri njegovem razvoju je avtor poskušal zadostiti naslednjim trem kriterijem:

1. Majhna stopnja napake. Verjetnost pravilno odkritih robov mora biti čimvečja, medtem ko mora biti verjetnost nepravilne detekcija čimmanjša (minimizirano razmerje signal/šum).
2. Dobra lokalizacija. Robne točke morajo biti čimbližje dejanskim robovom v sliki
3. Enotočkovni odziv. Algoritem mora vrniti samo eno eno točko za vsako dejansko robno točko - število lokalnih maksimumov v okolici resničnega roba mora biti minimalno. Detektor torej ne sme odkriti več robnih pikslov, kjer je v resnici del roba le en [1].

Pri implementaciji smo sledili opisu algoritma v [5], ki odkrivanje robov razdeli v 4 osnovne korake:

1. Glajenje z Gaussovim filtrom (odstranjevanje šuma)
2. Izračun amplitude in smeri gradienta slike
3. Uporaba metode "nonmaxima suppression" nad gradientno sliko
4. Dvojno upragovanje za določitev robnih točk in povezovanje robov

Glajenje slike

Pri razvijanju detektorja je Canny ugotovil, da je težko najti zaprto rešitev, ki bi ustrezala vsem zastavljenim pogojem. Izkazalo se je, da je za *aproksimacijo* optimalnega detektorja stopnice dober *prvi odvod Gausa* [5].

$$\frac{d}{dx} e^{-\frac{x^2}{2\sigma^2}} = \frac{-x}{\sigma^2} e^{-\frac{x^2}{2\sigma^2}}. \quad (2.4)$$

To lahko aproksimiramo z dvema korakoma - najprej zgladimo sliko z Gaussovim filtrom, nato pa izračunamo odvod dobljenega rezultata. V naši implementaciji smo uporabili že vgrajeno funkcijo *fspecial*, ki na podlagi podane σ in *velikosti okna* kreira ustrezen filter.


Zglajeno sliko dobimo tako, da naredimo konvolucijo slike $f(x,y)$ in dobljenega filtra $G(x,y)$:

$$f_s(x,y) = G(x,y) \star f(x,y). \quad (2.5)$$

Pri tem je σ parameter algoritma in določa tudi velikost okna. Po smernicah za Marr-Hildrethov detektor (glej podpoglavje 2.3.3) se zanj tudi tukaj uporabi vrednost 6σ . Rezultat prvega koraka prikazuje slika 2.11



(a) Originalna slika.



(b) Slika po koraku glajenja.

Slika 2.11: Glajenje slike z gaussovim filtrom

Izračun amplitude in smeri gradienta

Za ta korak najprej izračunamo odvod slike v x in y smeri - dobimo g_x in g_y . To naredimo z uporabo *Sobelovih operatorjev* (slika 2.12), tako da naredimo konvolucijo slike z danimi maskami.

-1	0	1
-2	0	2
-1	0	1

(a) Operator za računanje horizontalnih sprememb v intenziteti.

-1	-2	-1
0	0	0
1	2	1

(b) Operator za računanje vertikalnih sprememb v intenziteti.

Slika 2.12: Sobelova operatorja za računanje odvoda slike v x in y smeri

Nato uporabimo formuli za izračun amplitude ($M(x, y)$) in smeri ($\alpha(x, y)$) odvodov:

$$M(x, y) = \sqrt{g_x^2 + g_y^2}, \quad (2.6)$$

$$\alpha(x, y) = \tan^{-1} \left[\frac{g_x}{g_y} \right]. \quad (2.7)$$

Primer rezultata je prikazan na sliki 2.13



(a) Slika amplitude odvoda.



(b) Slika smeri odvoda.

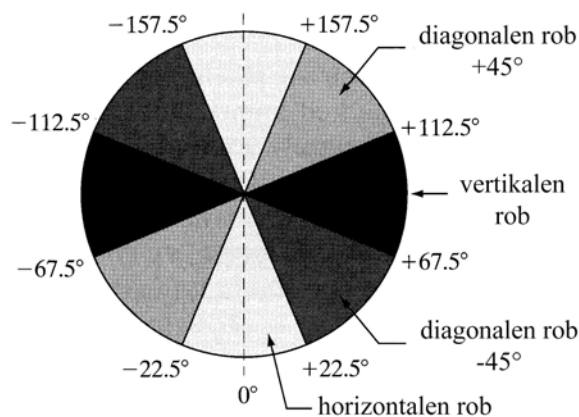
Slika 2.13: Amplituda in smer odvoda slike

Odstranjevanje točk, ki niso lokalni maksimumi

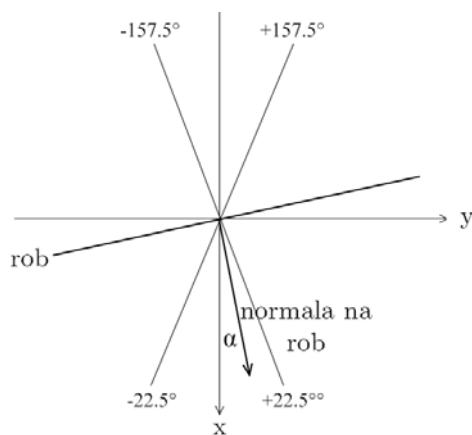
Po 2.koraku Cannyjevega algoritma se na uporabljeni sliki že vidijo posamezne konture - izstopajo s svetlo barvo, kar kaže na visoko amplitudo M . Te konture so v tej fazi še debele, kar je posledica uporabe 1. odvoda. Naslednji korak je namenjen temu, da v sliki ohranimo le posamezne lokalne maksimume, medtem ko široke grebene okoli njih odstranimo. V našem algoritmu uporabimo metodo izločanja neizrazitih pikselov (*angl. nonmaxima suppression*).

Pristop zahteva uporabo matrike α , pridobljeno v prejšnjem koraku. Le-ta vsebuje smeri odvoda oz. gradientne vektorje, ki kažejo v smeri normale na rob v posameznem pikslu. V vsaki točki slike je torej potrebno pregledati oba sosedaj vzdolž normale in najti lokalne maksimume.

Ker pri tem opazujemo le 3×3 regijo piksla, je potrebno kvantizirati smeri v 4 osnovne orientacije: horizontalno, vertikalno, $+45^\circ$ (desna diagonala) in -45° (leva diagonala).




Slika 2.14: Območja kotov normal robov za preslikavo v 4 različne osnovne smeri. Vir: [5]



Slika 2.15: Preslikava kota normale v osnovno smer.

To preslikavo ilustrira slika 2.14. Krožnica je razdeljena na 4 različna barvna območja. Kotom znotraj posameznih območij določimo pripadajočo osnovno smer. Teoretičen primer je prikazan na sliki 2.15, kjer bi bila kotu normale pripisana vertikalna usmerjenost - gre za približno horizontalen rob.

Na sliki 2.16 je prikazana uporaba opisane pretvorbe gradientnih vektorjev v 4 osnovne smeri na CT sliki. Za lažje razločanje med različnimi vrednostmi je uporabljena kontrastna barvna lestvica. Slika 2.16a je izris vrednosti gradientnih vektorjev pred, slika 2.16b pa po njihovi pretvorbi v 4 osnovne smeri. Tako je v rezultatu jasno vidno, da so vodoravne linije v oranžni barvi, diagonalne v rumeni in rdeči, navpične pa v turkizni barvi.

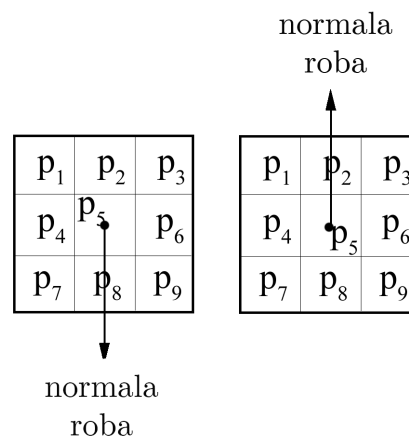


(a) Gradientni vektorji CT slike pred pretvorbo.


(b) Gradientni vektorji CT slike po pretvorbi.

Slika 2.16: Pretvorba gradientnih vektorjev v 4 osnovne smeri.

Ko dobimo novo orientacijo gradientnega vektorja v posameznem pikslu slike, lahko vrednost njegove amplitude iz matrike M primerjamo z vrednostima njegovih dveh sosedov vzdolž normale. V primeru na sliki opazujemo točko p_5 , katere gradientni vektor ima navpično usmeritev. Zaradi tega preverimo njegovega zgornjega in spodnjega soseda - če je vrednost amplitude v p_5 večja ali enaka vrednosti v p_2 ali v p_8 , potem p_5 ohranimo med množico potencialnih robnih točk, sicer ga zadušimo.



Slika 2.17: Pregledovanje 3x3 okolice točke.



Slika 2.18: Slika po uporabi metode izločanja neizrazitih pikslov.

Primer rezultata po koraku metode izločanja neizrazitih pikslov je na sliki 2.18. Ta že dobro poudari obstoječe konture v CT sliki, vendar še vedno vsebuje tudi napačne robne točke. Prav tako so nekateri robovi debelejši od 1 piksla, kar je nezaželena lastnost. To je posledica tega, da imajo nekateri sosednji piksli vzdolž normal na robove enake vrednosti in so tako vsi ohranjeni v množici potencialnih robnih točk. Zato so potrebni še nadaljnji koraki obdelave.

Histerezo upravljanje

Zadnji korak je *upravljanje*, kjer dobimo binarizirano sliko robnih in nerobnih točk. Namenjen je zmanjšanju števila napačnih robnih točk v sliki. V nekaterih postopkih se v ta namen uporablja en prag. Tako lahko pride do situacije, ko je prag prenizek in dobimo veliko napačno pozitivnih izbir (*angl. false positives - FP*) ali pa previsok, ko izločimo preveč veljavnih robnih točk - napačno negativne izbire (*angl. false negatives - FN*). Cannyjev algoritem poskuša situacijo izboljšati z uporabo *dveh* pragov - nizkega T_l ter visokega T_h , pri čemer je Canny predlagal, da je $T_h = 2(3)T_l$. [5]. V našem algoritmu smo uporabili razmerje *1:3*.

Najprej iz rezultata prejšnjega koraka (množica točk I_{nms}) kreiramo dve novi množici - I_{nh} in I_{nl} :

$$I_{nh}(x, y) = I_{nms}(x, y) \geq T_h, \quad (2.8)$$

$$I_{nl}(x, y) = I_{nms}(x, y) \geq T_l. \quad (2.9)$$

V I_{nh} so torej pozitivne vrednosti tam, kjer so vrednosti točk v I_{nms} višje kot visoki prag, v I_{nl} pa morajo presegati nizki prag. Sicer jih postavimo na nič in so tako označene kot nerobne točke. V I_{nl} so vsebovane tudi vse točke iz I_{nh} , zato jih odstranimo:


$$I_{nl}(x, y) = I_{nl}(x, y) - I_{nh}(x, y). \quad (2.10)$$

Tako dobimo *dve* ločeni množici, pri čemer so piksli v I_{nh} obravnavani kot "močni" in jih označimo kot že veljavne robne točke - dobijo vrednost ena. Tipično imajo taki robovi vrzeli, ki jih tvorijo točke iz I_{nl} . Zato so te označene kot 'šibke' in predstavljajo kandidate za robne točk. V nadaljni obravnavi pregledamo vse močne piksele in njihovo okolico 8 sosedov:

- Če je kateri od sosedov piksel iz I_{nl} (in je torej povezan z I_{nh}), le-tega označimo kot robno točko - vrednost v točki postavimo na 1.
- Sicer ga zavržemo kot kandidata za rob - vrednost v točki postavimo na 0.

Ta del postopka povezovanja močnih in šibkih robov je bil sicer najprej implementiran rekurzivno do določenega nivoja, vendar smo na koncu odločili za uporabo prvega nivoja, torej algoritem obravnava le neposrednih 8 sosedov robne točke, naprej pa več ne pregleduje.

Rezultat zadnjega koraka je binarizirana slika, ki prikazuje odkrite robove (slika 2.19a). Ta še vedno vsebuje nekatere debelejšje konture, ki so kot že rečeno posledica postopka izločanja neizrazitih pikselov. Da dosežemo debelino enega piksla, v našem algoritmu uporabimo že vgrajeno funkcijo Matlab-a *bwmorph*, ki stanjša robove v binariziranih slikah s pomočjo morfoloških operatorjev. Končni rezultat prikazuje slika 2.19b.



(a) Slika po upravljanju.

(b) Slika po postopku tanjšanja robov.

Slika 2.19: Rezultat koraka histereznega upravljanja.

2.4 Parametri

Oba algoritma za delovanje zahtevata po dva parametra. Prvi je standardna deviacija σ in se nanaša na stopnjo glajenja slike. Drugi je prag T , ki je potreben v postopku določanja robnih točk. Odločili smo se, da izbiro praga T avtomatiziramo in bo tako spremenljivka v koraku primerjave le σ . Želeli smo, da bi bil določeni prag tak, da bi dal z vidika človeške subjektivne ocene glede prisotnosti izrazitih robov čim boljše rezultate.

2.4.1 Avtomatizacija parametra prag

Marr-Hildreth

Pri preizkušanju različnih načinov avtomatskega določanja praga se je izkazalo, da dobre rezultate da *standardna deviacija absolutnih pozitivnih* vrednosti slike, ki je rezultat koraka filtriranja z LoG filtrom. Ničelnih vrednosti ne upoštevamo, ker predstavljajo (črno) ozadje slike in se ne nanašajo na del, ki nas zanima - človeško telo.

Canny

Kot opisano v podpoglavju 2.3.4 Cannyjev detektor uporablja v koraku histereznega upravljanja dva praga - T_l in T_h . Ker sta med sabo odvisna, en avtomatsko določa tudi drugega. Po Cannyjevih priporočilih smo v implementaciji uporabili razmerje 1:3. Višji prag je določen kot *povprečna vrednost vseh pozitivnih* vrednosti v sliki po koraku izločanja točk, ki niso lokalni maksimumi. Kot v primeru Marr-Hildrethovega detektorja tudi tukaj ničelnih vrednosti ne upoštevamo, saj bi te prag pokvarile. Nato izračunamo nižji prag po formuli $T_l = \frac{T_h}{3}$.

2.4.2 Omejitev parametra σ

Parameter σ je bil sicer v postopku primerjanja spremenljivka, a ga je bilo potrebno omejiti. Določiti smo morali, kakšen obseg vrednosti bo σ zavzemala. Pri tem smo uporabili kvalitativen pristop. Postopka detekcije smo preizkušali pri različnih σ in preverili, do katere vrednosti so končni rezultati še sprejemljivi. Za CT posnetke je bil določeni obseg σ nekoliko drugačen kot v primeru MRI posnetkov.

Najmanjša velikost maske za Gauss-ovo filtriranje, ki je še uporabna, je 3×3 . Tako določa tudi najmanjšo vrednost σ , ki je najmanj 0.5. V primeru Marr-Hildrethovega postopka je najmanjša σ višja, saj zelo nizka vrednost σ ne daje dobrih rezultatov.


V tabeli 2.2 so napisane dobljene vrednosti σ za oba detektorja in obe vrsti medicinskih slik. Primeri rezultatov pri uporabi takih vrednosti so prikazani na slikah 2.20 in 2.21.

	CT		MRI	
	σ_{min}	σ_{max}	σ_{min}	σ_{max}
Canny	0.5	5	0.5	3.9
Marr-Hildreth	1.1	5	1.9	4


Tabela 2.2: Uporabljen obseg parametra σ




(a) Rezultat detekcije robov s Cannyjevim algoritmom na CT posnetku s σ_{min} .



(b) Rezultat detekcije robov s Cannyjevim algoritmom na CT posnetku s σ_{max} .




(c) Rezultat detekcije robov z Marr-Hildrethovim algoritmom na CT posnetku s σ_{min}



(d) Rezultat detekcije robov z Marr-Hildrethovim algoritmom na CT posnetku s σ_{max}


Slika 2.20: Rezultat detekcije robov z robnimi vrednostmi σ na CT posnetku.




(a) Rezultat detekcije robov s Cannyjevim algoritmom na MRI posnetku s σ_{min} .



(b) Rezultat detekcije robov s Cannyjevim algoritmom na MRI posnetku s σ_{max} .



(c) Rezultat detekcije robov z Marr-Hildrethovim algoritmom na MRI posnetku s σ_{min}



(d) Rezultat detekcije robov z Marr-Hildrethovim algoritmom na MRI posnetku s σ_{max}

Slika 2.21: Rezultat detekcije robov z robnimi vrednostmi σ na MRI posnetku.

2.5 Kompozicija referenčne slike

Naš končni cilj je bil primerjati detektorja med sabo. Poleg subjektivne kvalitativne primerjave slik robov, ki jih data kot rezultat, smo želeli izvesti tudi kvantitativno primerjavo. V številnih drugih podobnih raziskavah ([3, 11, 12]) so za to imeli *referenčno sliko*, na kateri so bili označeni pravilni robovi. Za oceno delovanja detektorjev je bilo nato potrebno primerjati dobljene rezultate detekcije z dano referenčno sliko. V našem primeru take ocene robov nismo imeli, zato smo se odločili, da bosta detektorja referenca drug drugemu. V ta namen smo želeli konstruirati lastne referenčne slike za vsak implementirani detektor. Nato bi dobljeno referenco primerjali z rezultati drugega detektorja pri različnih vrednostih parametra σ .

Najprej smo se odločili konstruirati korespondenčne slike (podpoglavje 2.5.1), ki bi odražale *pogostost* (lahko bi rekli tudi *zanesljivost*) robov, ki jih posamezen detektor odkrije. V množici vrednosti parametra σ bi nato izbrali tisto, ki da pri detekciji najbolj zanesljive robove. Tako bi dobili referenčno sliko za nadaljni korak primerjave obeh detektorjev.

2.5.1 Korespondenčna slika

Korespondenčna slika je slika, ki prikazuje, kolikokrat so bili posamezni piksli pri več različnih detekcijah določeni kot del roba. Intenziteta piksla torej pomeni njegovo pogostost v celotni množici rezultatov.


V našem primeru smo iskali korespondenčne slike testnih posnetkov za vsakega od detektorjev posebej. Za to smo potrebovali nabor detektiranih robov za obe vrsti detektorjev pri različnih vrednostih parametra σ . Razpon parametra smo že izbrali (podpoglavje 2.4), določiti pa smo morali še korak spreminjanja $\Delta\sigma$. To smo naredili kvalitativno in sicer smo ga izbrali tako, da so bile razlike med rezultati dobljenimi s σ in $\sigma + \Delta\sigma$ še dovolj razločne. Pri tem se je korak razlikoval glede na vrsto testnih posnetkov ter glede na uporabljeni detektor. Tabela 2.3 je posodobljena tabela s strani 24 - vsebuje še vrednosti $\Delta\sigma$.

	CT			MRI		
	σ_{min}	σ_{max}	$\Delta\sigma$	σ_{min}	σ_{max}	$\Delta\sigma$
Canny	0.5	5	0.3	0.5	3.9	0.2
Marr-Hildreth	1.1	5	0.3	1.9	4	0.15

Tabela 2.3: Uporabljene vrednosti parametra σ


Z uporabo N različnih vrednosti parametra σ dobimo N različnih rezultatov detekcije $D_j (j = 1, \dots, N)$. Če bi jih zložili enega na drugega, bi dobili korespondenčno sliko. Konstruiramo jo torej z enostavnim seštevanjem istoležnih pikslov vseh dobljenih rezultatov. Ker so rezultati binarni, pove intenziteta posameznega piksla korespondenčne slike, kolikokrat je bil ta izbran kot robna točka.

Primeri korespondenčnih slik sta prikazana na sliki 2.22 in 2.23 na naslednji strani. Na slikah 2.22a in 2.22b sta pripadajoča histograma korespondenčnih slik. V njih so zaradi preglednosti izvzeti piksli, v katerih je intenziteta enaka nič - v njih robne točke niso bile nikoli odkrite.




(a) Histogram korespondenčne slike 2.23a. (b) Histogram korespondenčne slike 2.23b.

Slika 2.22: Histograma korespondenčnih slik.



(a) Primer korespondenčne slike za
Cannyjev detektor.



(b) Primer korespondenčne slike za
Marr-Hildrethov detektor.


Slika 2.23: Primer korespondenčnih slik.

Za korespondenčno sliko smo uporabili N rezultatov detekcije, zato ima N "korespondenčnih nivojev". Barvna lestvica na desni strani korespondenčnih slik prikazuje v katero barvo se preslika posamezni korespondenčni nivo. Pogostost neke robne točke se torej odraža v svetli barvi in v visokem korespondenčnem nivoju. Iz primerov korespondenčnih slik in histogramov je razvidno, da je pikslov, ki bi imeli najvišji korespondenčni nivo, zelo malo. Na drugi strani je veliko takih, ki se pojavijo le v eni ali dveh rezultatih detekcije. Prav tako je moč opaziti, da Marr-Hildrethov detektor v primerjavi s Cannyjevim detektorjem odkrije precej več robnih točk.

Naša naslednja naloga je bila, da na podlagi korespondenčne slike pridobimo referenčno sliko za posamezni detektor ter vrednost parametra σ , ki bi tej referenčni sliki najbolj ustrezala.

2.5.2 Obstoječa metoda

Pri določanju referenčne slike smo se delno oprli na metodo za objektivno vrednotenje odkrivanja robov in izbora parametrov detektorja ([14]). Odločili smo se, da jo implementiramo in preizkusimo na naših testnih slikah.



(a) Upragovana korespondenčna slika s 25% korespondenco.

(b) Upragovana korespondenčna slika s 75% korespondenco.

Slika 2.24: Primer upragovanih korespondenčnih slik MRI posnetka pri uporabi različnih korespondenčnih pragov.

Prvi del metode zajema že opisano kompozicijo korespondenčne slike, ki je podlaga

za naslednji korak. Ta za določitev najbolj ugodnega korespondenčnega nivoja uporablja "ROC" (*Receiver Operating Characteristic*) analizo. Tak korespondenčni nivo naj bi zagotavljal dober kompromis med informacijo in šumom v rezultatu detekcije.

Korespondenčni prag (*KP*) naj bo vrednost korespondenčnega nivoja, ki točke korespondenčne slike loči v 2 skupini - tiste z višjo ali enako vrednostjo kot *KP* ter tiste z manjšo vrednostjo. *KP* apliciramo na vseh N korespondenčnih nivojih. Na vsakem nivoju i tako dobimo točke, ki imajo višjo ali enako vrednost kot *KP* - take točke označimo kot *robne* (dobijo vrednost 1), medtem ko so ostale *nerobne* (dobijo vrednost 0). Rezultat je potencialna referenčna slika za vsak nivo i (PGT_i). Slika 2.24 prikazuje primera PGT_i za *KP* vrednost $i = \frac{N}{4} + 1$ (25% korespondenca) in $i = \frac{3*N}{4} + 1$ (75% korespondenca). Naslednji korak je primerjava posamezne PGT_i s celotnim naborom rezultatov detekcije D_j . Po smernicah statistične teorije odločanja so v članku definirane 4 različne verjetnosti:

$$\begin{aligned}\overline{TP}_{PGT_i} &= \frac{1}{N} \sum_{j=1}^N TP_{PGT_i, D_j} \\ &= \frac{1}{N} \sum_{j=1}^N \left(\frac{1}{K * L} \sum_{k=1}^K \sum_{l=1}^L PGT_{i_1} \cap D_{j_1} \right)\end{aligned}\quad (2.11)$$

$$\begin{aligned}\overline{FP}_{PGT_i} &= \frac{1}{N} \sum_{j=1}^N FP_{PGT_i, D_j} \\ &= \frac{1}{N} \sum_{j=1}^N \left(\frac{1}{K * L} \sum_{k=1}^K \sum_{l=1}^L PGT_{i_1} \cap D_{j_1} \right)\end{aligned}\quad (2.12)$$

$$\begin{aligned}\overline{TN}_{PGT_i} &= \frac{1}{N} \sum_{j=1}^N TN_{PGT_i, D_j} \\ &= \frac{1}{N} \sum_{j=1}^N \left(\frac{1}{K * L} \sum_{k=1}^K \sum_{l=1}^L PGT_{i_0} \cap D_{j_0} \right)\end{aligned}\quad (2.13)$$

$$\begin{aligned}\overline{FN}_{PGT_i} &= \frac{1}{N} \sum_{j=1}^N FN_{PGT_i, D_j} \\ &= \frac{1}{N} \sum_{j=1}^N \left(\frac{1}{K * L} \sum_{k=1}^K \sum_{l=1}^L PGT_{i_0} \cap D_{j_1} \right)\end{aligned}\quad (2.14)$$

Pri tem K in L predstavljata dimenzijo slike, PGT_{i_1} in PGT_{i_0} pa so piksli v PGT_i , označeni kot robne točke in nerobne točke. Podobno pomenita oznaki D_{j_1} in D_{j_0} .

S pomočjo teh vrednosti lahko nato izračunamo koordinate točk KP-ROC krivulje. Te točke odražajo povprečno ujemanja med PGT_i in rezultati detekcije D_j . Prva koordinata je povprečna stopnja pozitivnih izbir (*angl. average TP rate - TPR*) druga koordinata pa povprečna stopnja negativnih izbir (*angl. average FP rate - FPR*). Vrednost TPR oz. občutljivost (*angl sensitivity*) je definirana kot:

$$TPR_{PGT_i} = \frac{\overline{TP}_{PGT_i}}{P}, \quad (2.15)$$

kjer je *prevalenca* P povprečno relativno število robov v rezultatih detekcije:

$$P = \overline{TP}_{PGT_i} + \overline{FN}_{PGT_i}. \quad (2.16)$$


Vrednost FPR oz. 1-specifičnost (*angl. specificity*) je definirana kot:

$$FPR_{PGT_i} = \frac{\overline{FP}_{PGT_i}}{1 - P}, \quad (2.17)$$

$$1 - P = \overline{FP}_{PGT_i} + \overline{TN}_{PGT_i}. \quad (2.18)$$

KP-ROC krivuljo torej tvorijo točke $(TPR_{PGT_i}, FPR_{PGT_i})$. Z manjšanjem KP nivoja i se TPR_{PGT_i} in FPR_{PGT_i} (ter z njima občutljivost in 1-specifičnost) povečujeta. Tako KP-ROC krivulja monotonno narašča. Primer prikazuje graf na sliki 2.25. Posamezna točka krivulje je označena s številko KP, pri katerem je bila tvorjena obravnavana PGT_i .

Iz dobljenega grafa smo želeli razbrati najboljši KP. Ta določa PGT, ki da najboljše ujemanje glede na celotni nabor rezultatov detekcije. V našem primeru smo kriterij "diagnostične črte" (*angl. diagnosis line*). Po temu kriteriju najboljši KP določa točko v ravnini KP-ROC, ki je najbližje idealni točki $(0,1)$. V ta namen najprej definiramo diagnostično črto, ki povezuje točki (P,P) in $(0,1)$.



Slika 2.25: Primer KP-ROC krivulje za MRI posnetek pri uporabi Marr-Hildreth-ovega detektorja.

Najboljši KP dobimo tam, kjer diagnostična črta seka KP-ROC krivuljo, oz. v točki, ki je najbližje temu preseku. V primeru na sliki 2.25 je KP enak 4, torej je najboljši PGT korespondenčna slika s pribl. 30% korespondenco. Na enak način smo izračunali KP za oba detektorja in pri vseh testnih slikah - rezultati so prikazani pod poglavjem 3.3 v tabeli 3.1.

Naslednji korak metode je izbira končne referenčne slike iz celotnega nabora rezultatov detekcije. Naj bo EGT slika robov PGT, ki jo določa izračunani KP. Iščemo tisti rezultat detekcije D_j , ki daje najboljše ujemanje z EGT. Ujemanje izračunamo podobno kot smo to storili v prejšnjem koraku - s pomočjo nove ROC krivulje S-ROC in kriterija diagnostične črte. Vrednosti TPR_{D_j} in FPR_{D_j} dobimo na enak način kot v enačbah 2.15 in 2.17, le da tokrat uporabimo vrednosti $TP_{D_j EGT}$, $FP_{D_j EGT}$, $TN_{D_j EGT}$ in $FN_{D_j EGT}$. Definicija teh vrednosti je v tabeli 2.4.

Notacija	Opis
$TP_{D_j EGT}$	Robne točke v D_j , ki se ujemaajo z robnimi točkami v EGT .
$FP_{D_j EGT}$	Robne točke v D_j , ki se ne ujemaajo z robnimi točkami v EGT .
$TN_{D_j EGT}$	Točke v D_j , ki niso robne in se ujemaajo s točkami v EGT , ki prav tako niso robne.
$FN_{D_j EGT}$	Točke v D_j , ki niso robne a se ujemaajo z robnimi točkami v EGT .

Tabela 2.4: Definicija vrednosti $TP_{D_j EGT}$, $FP_{D_j EGT}$, $TN_{D_j EGT}$ in $FN_{D_j EGT}$.

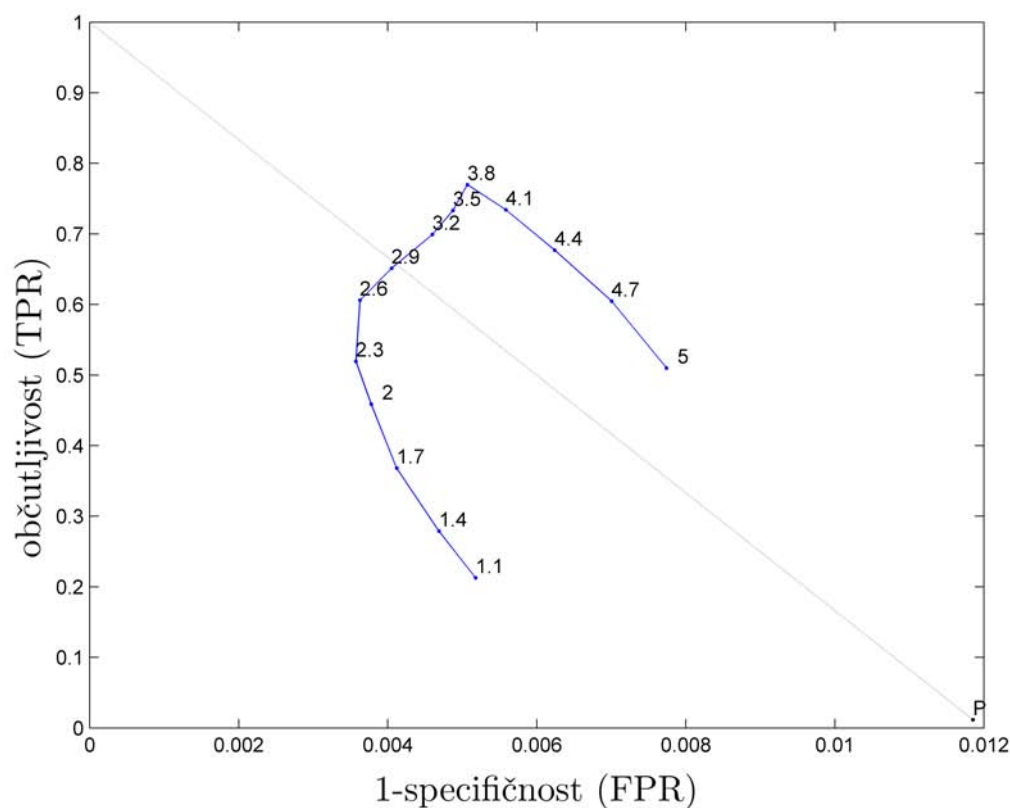
S-ROC krivuljo tvorijo točke (TPR_{D_j}, FPR_{D_j}) in odražajo ujemanje med posameznim rezultatom detekcije D_j in EGT. Primer prikazuje slika 2.26. Posamezna točka krivulje je označena z vrednostjo parametra σ , ki je dala obravnavani rezultat detekcije D_j . S pomočjo diagnostične črte lahko razberemo, da se EGT najboljše ujema z rezultatom detekcija pri uporabi $\sigma = 2.9$. Opisano metodo izbora najustreznejše vrednosti parametra *sigma* iz dane množice smo uporabili na vseh testnih posnetkih. Uporaba izračunanih vrednosti parametra, daje kot rezultat slike robov, ki so lahko referenca v koraku primerjave detektorjev. Dobljeni rezultati so prikazani pod poglavjem 3.3.

2.5.3 Predlagana metoda

Zgoraj opisana metoda ima nekaj slabosti, saj je iz časovnega vidika zamudna. Zato smo se odločili, da postavimo in preizkusimo lastno metodo, ki je enostavnejša, a učinkovita. Nato smo želeli primerjati referenčne slike, ki jih data obe metodi kot rezultat, in se nato odločiti, katere uporabiti v nadaljnjem koraku primerjave detektorjev.

Prvi del naše metode je enak kot v 2.5.2 - konstrukcija korespondenčne slike detektiranih robov. Nato prag KP določimo statično - vedno je enak 50%. To vrednost smo dobili empirično - pri preizkušanju različnih pragov se je izkazalo, da daje 50% korespondenca vizualno dobre rezultate. Tako dobimo nov EGT. Tega nato primerjamo s posameznim rezultatom detekcije D_j . Najboljši D_j je tisti, ki ima v primerjavi s številom vseh robov v EGT največ skupnih, torej da najvišjo vrednost:

$$\frac{|D_j \cap EGT|}{|EGT|}. \quad (2.19)$$



Slika 2.26: Primer S-ROC krivulje za CT posnetek pri uporabi Marr-Hildreth-ovega detektorja.

2.6 Metrike zmogljivosti

Za kvantitativno analizo obeh obravnavanih detektorjev smo potrebovali metrike, ki bi na nek način ocenile rezultate detekcije. Pri tem smo izhajali iz standardnih metrik, iz njih pa smo izpeljali tudi nekatere nove.

2.6.1 Obstoječe metrike

Za ocenjevanje uspešnosti sistemov za detekcijo in klasifikacijo so v uporabi standardne metrike. Te temeljijo na primerjavi rezultatov detekcije z resnično referenco, na podlagi katere lahko dobimo informacijo o pravilnosti/nepravilnosti odločitev detektorja. Za predstavitev števila pravilnih oz. nepravilnih detekcij se uporablja posebna zmogljivostna matrika - prikazuje jo slika 2.27. Pri detekciji gre v bistvu za binarno klasifikacijo - ali

je prišlo do detekcije ali ne. Tako dobimo pozitivno ali pa negativno odločitev. V tabeli 2.27 oznaka P pomeni pozitivno odločitev s strani obravnavanega detektorja, medtem ko N pomeni negativno odločitev, torej zavrnitev dogodka. Podobno p na strani reference pomeni pomeni pozitiven primer, n pa negativnega. Pri klasifikaciji vsakega primera so možni *štirje* različni izidi:

- primer, ki je pozitiven in je kot tak tudi klasificiran - *pravilna pozitivna odločitev* ali *tp* (*angl. true positive*),
- primer, ki je pozitiven a je bil klasificiran kot negativen - *nepravilna negativna odločitev* ali *fn* (*angl. false negative*),
- primer, ki je negativen in je bil kot tak tudi klasificiran - *pravilna negativna odločitev* ali *tn* (*angl. true negative*),
- primer, ki je negativen a je bil klasificiran kot pozitiven - *nepravilna pozitivna odločitev* ali *fp* (*angl. false positive*).

V zmogljivostni matriki je vsota posameznih vrst dogodkov - TP , FN , TN in FP . Pravilne odločitve detektorja torej ležijo na glavni diagonali matrike, medtem ko ostali elementi predstavljajo negativne odločitve.

		Detektor	
		P	N
Referenca	p	TP	FN
	n	FP	TN

Slika 2.27: Standardna zmogljivostna matrika.

Razmerja med posameznimi vsotami dogodkov nam dajo metrike, s katerimi lahko analiziramo uspešnost delovanja detektorja. Pogosto uporabljena metrika je *občutljivost* (*angl. sensitivity - Se*), ki je definirana kot razmerje med pravilno detektiranimi dogodki in vsemi resničnimi dogodki:

$$Se = \frac{TP}{TP + FN}. \quad (2.20)$$

Vrednost *Se* predstavlja verjetnost, da je dogodek, ki je bil s strani detektorja označen kot pozitiven, tudi v resnici pozitiven. Občutljivost se torej navezuje na sposobnost detektorja da odkrije pozitivne dogodke. Večja ko je občutljivost,

Naslednja uporabna metrika je *specifičnost* (*angl. specificity - Sp*), ki je definirana kot razmerje med pravilnimi negativnimi odločitvami detektorja in vsemi dejanskimi negativnimi dogodki:

$$Sp = \frac{TN}{TN + FP}. \quad (2.21)$$

Vrednost *Sp* predstavlja verjetnost, da je dogodek, ki je bil s strani detektorja označen kot negativen, tudi v resnici negativen. Specifičnost se torej navezuje na sposobnost detektorja, da zavrne negativne dogodke.

Metrika *pozitivna napovedljivost* (*angl. positive predictivity - +P*) je definirana kot razmerje med pravilno detektiranimi dogodki ter številom vseh dogodkov, ki jih je detektor označil kot pozitivne:

$$+P = \frac{TP}{TP + FP}. \quad (2.22)$$


Vrednost *+P* torej pokaže, do kake mere lahko zaupamo detektorju, ko gre za napovedovanje pozitivnih dogodkov [2].

2.6.2 Izpeljava novih metrik

Sedaj opisane metrike prenesemo na naš problem. Pozitivni dogodki so v tem primeru odkriti robovi (piksli z vrednostjo 1), negativni pa točke, ki niso bile izbrane kot robne (piksli z vrednostjo 0). Referenčne slike so kar optimalni rezultati detekcije (poglavje 2.5). Ker detektorja primerjamo enega z drugim imamo dva možna primera:


- referenčna slika je rezultat Cannyjevega detektorja,
- referenčna slika je rezultat Marr-Hildrethovega detektorja.

Shema na sliki 2.28 je splošni prikaz primerjave robnih točk, odkritih s strani dveh detektorjev - detektorja št. 1 (D_1) in detektorja št. 2 (D_2). Obarvano področje nad črto predstavlja množico robnih točk, ki jih je odkril D_1 , spodnje pa množico robnih točk, ki jih je odkril D_2 . Na sredini je področje, kjer se rezultati obeh detektorjev pokrivajo - odkrite so bile enake robne točke. Opazujemo, do kolikšne mere se robne točke ujemajo. Ker nas zanima kako podobna sta si v rezultatih detektorja, želimo izpeljati take metrike, ki bodo to podobnost čimbolje odražale.



Slika 2.28: Splošna shema ujemanja robnih točk dveh detektorjev.

Zgornjo shemo prenesemo na primerjavo Cannyjevega in Marr-Hildrethovega detektorja. Detektor št. 1 s sheme naj bo v našem primeru Cannyjev detektor (C), detektor št.2 pa Marr-Hildrethov detektor (M). Dobimo novo shemo - slika 2.29.




Slika 2.29: Shema ujemanja robnih točk za primer Cannyjevega in Marr-Hildrethovega detektorja.

Vzemimo primer, ko je referenčni detektor Marr-Hildrethov algoritem. Detektirane robne točke lahko preslikamo v skupine dogodkov, ki opisujejo uspešnost detekcije s strani Cannyjevega algoritma (slika 2.30):


- presek detektiranih robnih točk $\rightarrow TP = C \cap M$,
- točke odkrite s Cannyjevim detektorjem, a zavržene s strani Marr-Hildrethovega detektorja $\rightarrow FP_C = C - (C \cap M) = (C \cup M) - M$,
- točke odkrite z Marr-Hildrethovim detektorjem, a zavržene s strani Cannyjevega detektorja $\rightarrow FN_C = M - (C \cap M) = (C \cup M) - C$.

Novo shemo ujemanja robnih točk prikazuje slika 2.30.



Slika 2.30: Shema ujemanja robnih točk z vidika Cannyjevega detektorja - referenčni detektor je Marr-Hildrethov.

Če vzamemo nasprotno situacijo, kjer je referenčni Cannyjev detektor, dobimo shemo na sliki 2.31.



Slika 2.31: Shema ujemanja robnih točk z vidika Marr-Hildrethovega detektorja - referenčni detektor je Cannyjev.

Odločili smo se, da dogodke TN pustimo nedefinirane in pri analizi upoštevamo le množico detektiranih robnih točk. Tako za oba primera primerjave dobimo novi zmogljivostni matriki, kjer sta polji za TN prazni - slika 2.32.

		Canny	
		P	N
Marr-Hildreth	p	TP	FN _C
	n	FP _C	

		Marr-Hildreth	
		P	N
Canny	p	TP	FN _M
	n	FP _M	

(a) Zmogljivostni matriki za primer, ko je referenčni detektor Marr-Hildrethov. (b) Zmogljivostni matriki za primer, ko je referenčni detektor Cannyjev.

Slika 2.32: Zmogljivostni matriki za dva primera primerjave detektorjev.

2.6.3 Relativna občutljivost in relativna pozitivna napovedljivost detektorja

Sedaj smo lahko v luči klasičnih metrik zmogljivosti izpeljali nove. Zopet smo upoštevali oba možna primera pri izboru reference:

1. Referenca je Marr-Hildrethov detektor

Kako dobro Cannyjev detektor odkrije tisto, kar bi odkril Marr-Hildrethov detektor? To lahko opišemo s pomočjo relativne občutljivosti (Se) oz. relative pozitivne napovedljivosti ($+P$):

$$Se_C = \frac{TP}{TP + FN_C}, \quad (2.23)$$

$$+P_C = \frac{TP}{TP + FP_C}. \quad (2.24)$$

2. Referenca je Cannyjev detektor

Kako dobro Marr-Hildrethov detektor odkrije tisto, kar bi odkril Cannyjev detektor? Relativna občutljivost in relativna pozitivna napovedljivost sta definirani podobno kot zgoraj:

$$Se_M = \frac{TP}{TP + FN_M}, \quad (2.25)$$

$$+P_M = \frac{TP}{TP + FP_M}. \quad (2.26)$$

Iz diagramov 2.30 in 2.31 je razvidno, da velja $FP_C = FN_M$ ter $FN_C = FP_M$, zato:

$$Se_C = \frac{TP}{TP + FN_C} = \frac{TP}{TP + FP_M} = +P_M, \quad (2.27)$$

$$+P_C = \frac{TP}{TP + FP_C} = \frac{TP}{TP + FN_M} = Se_M. \quad (2.28)$$

Če se znova osredotočimo na shemo 2.29, vidimo, da lahko vse možne kombinacije (ne)ujemanja preslikamo v štiri razširjene zmogljivostne matrice - slika 2.33. Matriki zgoraj prikazujeta primer, ko je referenčni detektor Marr-Hildrethov in situacijo opazujemo s stališča Cannyjevega detektorja. Nasprotno matriki spodaj prikazujeta primer, ko je referenčni detektor Cannyjev in situacijo opazujemo s stališča Marr-Hildrethovega detektorja.

		Canny				Canny	
Marr-Hilredth		$C \cap M$	$M - (C \cap M)$			TP	FN_C
		$C - (C \cap M)$	$C \cup M$			FP_C	$FP_C + TP + FN_C$
		Marr-Hilredth				Marr-Hilredth	
Canny		$C \cap M$	$(C \cup M) - M$			TP	FN_M
		$(C \cup M) - C$	$C \cup M$			FP_M	$FP_M + TP + FN_M$

Slika 2.33: Nove zmogljivostne matrice.

Sedaj smo lahko iz matrike razbrali nova razmerja med posameznimi polji in v nadaljevanju oblikovali naslednje metrike.

2.6.4 Presežek detektorja

Prvo izpeljano metriko smo poimenovali *presežek* (*angl. surplus*). Glede na to, s kakšnega vidika gledamo na primerjavo detektorjev, ločimo presežek s strani Cannyjevega detektorja ter presežek s strani Marr-Hildrethovega detektorja:

$$Srp_C = \frac{(C \cup M) - M}{C \cap M}, \quad (2.29)$$

oz. ker $(C \cup M) - M = C - (C \cap M)$,

$$Srp_C = \frac{C - (C \cap M)}{C \cap M}. \quad (2.30)$$

Podobno velja za primer Marr-Hildretha:

$$Srp_M = \frac{(C \cup M) - C}{C \cap M}, \quad (2.31)$$

oz.

$$Srp_M = \frac{M - (C \cap M)}{C \cap M}. \quad (2.32)$$

Metrika odvečnosti je bila postavljena z vidika *podobnosti* detektorjev. Če bi želeli, da bi bili rezultati čim bolj podobni, vsako odkrito robno točko, ki ni del preseka rezultatov obeh detekcij, pojmuje kot *odvečno* oz. kot *presežek*. Naš cilj je torej, da bi bila vrednost Srp čim manjša. Če formulo za presežek izpeljemo naprej, dobimo povezavo z metriko relativne občutljivosti. To si pogledjmo na primeru Cannyjevega detektorja:

$$Srp_C = \frac{C - (C \cap M)}{C \cap M} = \frac{C}{C \cap M} - 1 = \frac{1}{Se_C} - 1 = \frac{1 - Se_C}{Se_C}, \quad (2.33)$$

če upoštevamo enačbo 2.27 pa

$$Srp_C = \frac{1 - +P_M}{+P_M}. \quad (2.34)$$

Analogno za Cannyjev detektor velja:

$$Srp_M = \frac{M - (C \cap M)}{C \cap M} = \frac{1 - Se_M}{Se_M}, \quad (2.35)$$

oziroma

$$Srp_M = \frac{1 - +P_C}{+P_C}. \quad (2.36)$$

2.6.5 Stopnja ujemanja

Tretja postavljena metrika je *stopnja ujemanja* (*angl. match rate*). Tudi v tem primeru smo na primerjanje detektorjev gledali z vidika podobnosti. Opazujemo razmerje med številom ujemaajočih se robnih točk ter številom vseh odkritih robnih točk:

$$Mtr = \frac{C \cap M}{C \cup M}. \quad (2.37)$$

V tem primeru ni važno ali gledamo z vidika enega ali drugega detektorja, saj nas zanima le kako podobno sta detektirala robne točke. Večja kot je vrednost stopnje ujemanja, bolj podobni so si rezultati detekcije.

Potek izpeljave metrik je bil sicer opisan na primeru Cannyjevega in Marr-Hildrethovega algoritma, vendar bi jih v splošnem lahko uporabili pri analizi katerihkoli dveh detektorjev. Prav tako ponujajo možnost razširitve na poljubno število primerjanih detektorjev.

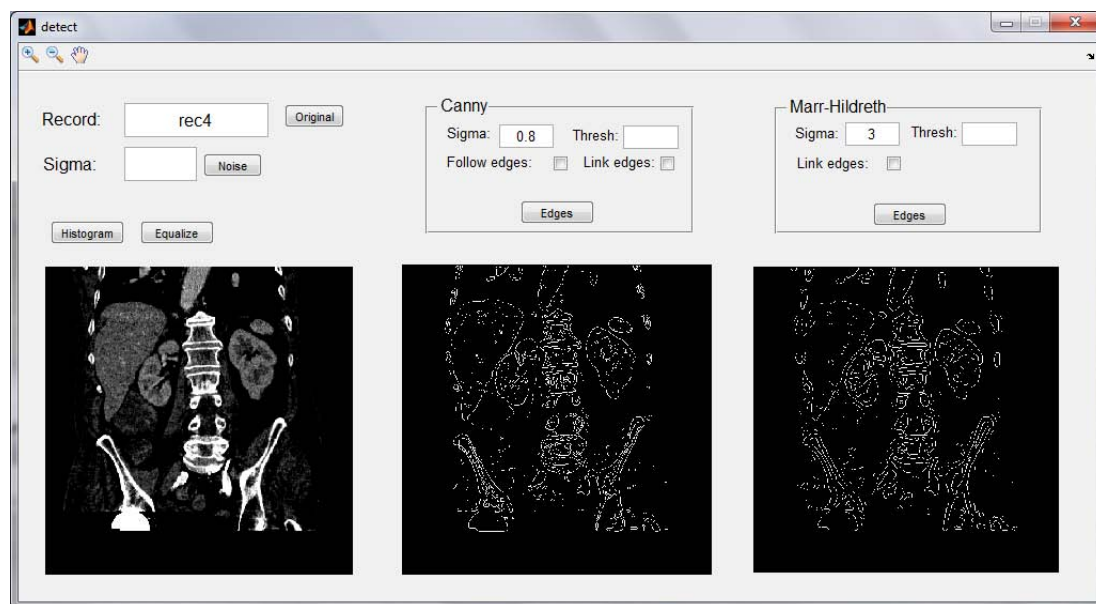
3 Rezultati

3.1 Grafični uporabniški vmesnik

Za lažje delo z rezultati in njihovo vizualno primerjavo smo tekom razvoja algoritmov za detekcijo in drugih metod razvili dva enostavna grafična uporabniška vmesnika (*angl. Graphical User Interface - GUI*). Nekatere implementirane funkcionalnosti sicer za pridobitev končnih rezultatov niso bile uporabljene, vendar odpirajo možnosti za nadaljno bolj podrobno obravnavo detektorjev.

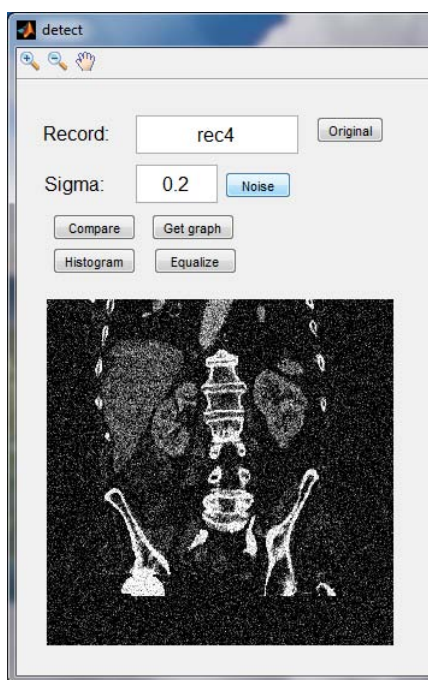
3.1.1 GUI - detekcija

Prvi grafični uporabniški vmesnik (slika 3.1) omogoča odpiranje testnih slik, ki se (v kolikor obstajajo) prikažejo na zaslonu. Naložena slika se lahko nato uporabi za detekcijo robov z izbranim algoritmom. Pri tem vpišemo poljubno vrednost parametra σ . Prav tako vmesnik omogoča še vklop nekaterih dodatnih korakov detekcije (sledenje robov, zapolnitev vrzeli). Naše končne slike detektiranih robov so rezultat najbolj osnovnih verzij algoritmov, torej brez vključenih dodatnih postopkov detekcije.



Slika 3.1: Grafični uporabniški vmesnik za detekcijo robov - izbrana slika in rezultat detekcije na podlagi vnešenih vrednosti parametra σ .

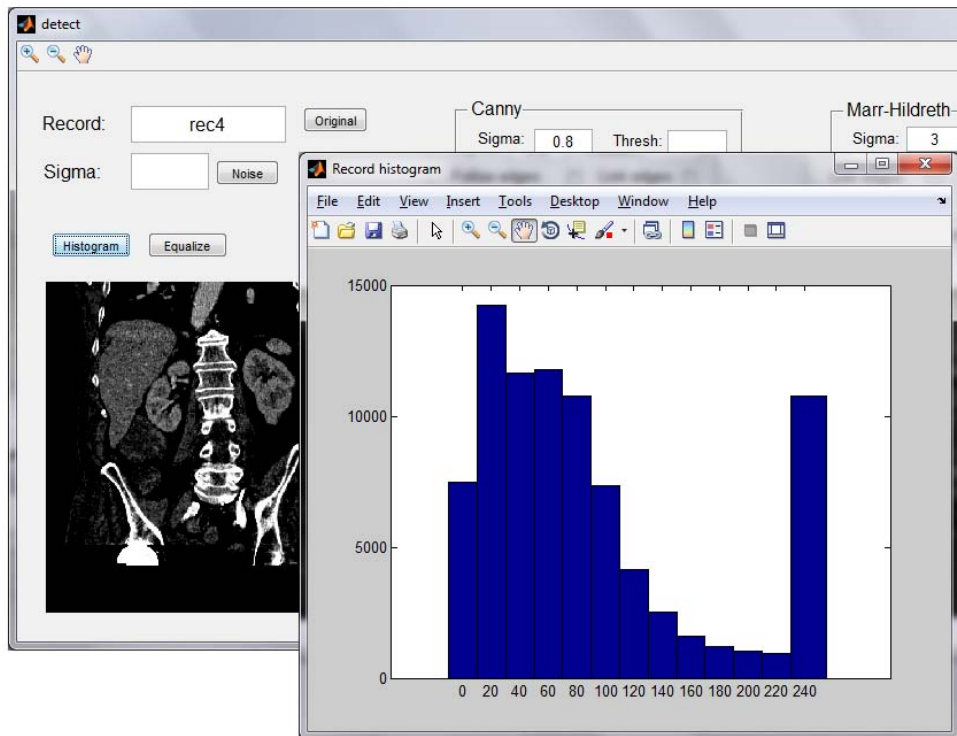
Vmesnik omogoča podrobnejši pregled slike s pomočjo orodij (levo zgoraj) za povečavo in spreminjanje trenutnega pogleda.



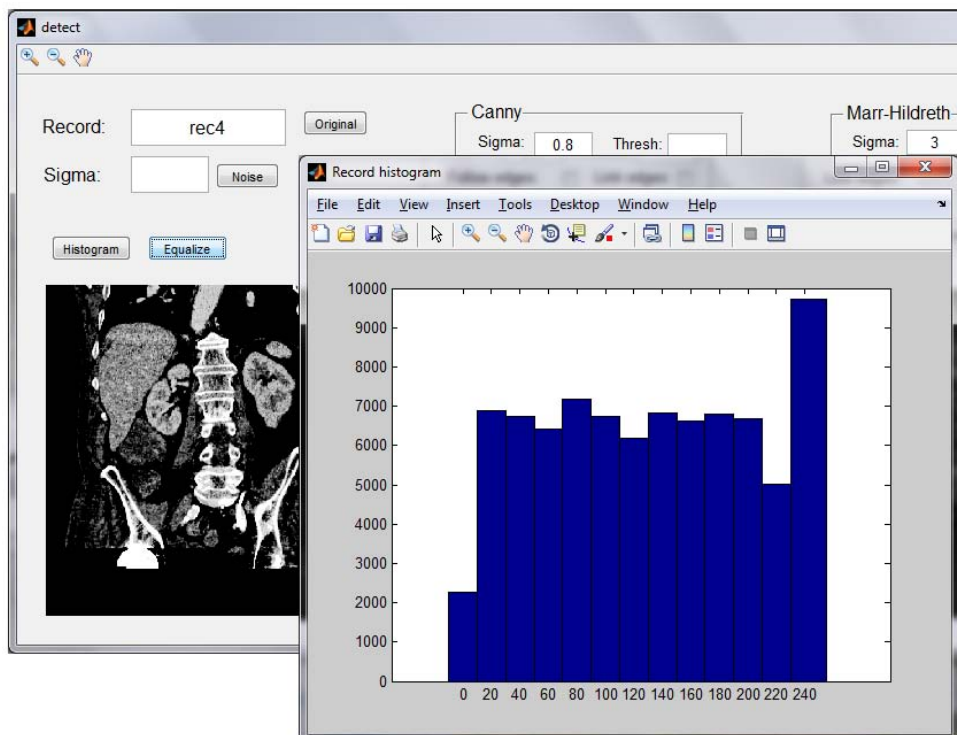
Slika 3.2: Slika z dodanim Gaussovim šumom z varianco $\sigma^2 = 0.2$.

Naslednja funkcionalnost, ki je bila implementirana, je prikaz histograma slike ter njegova izravnava. Izravnava omogoča izboljšanje kontrasta slike. Primer uporabe prikazujeta sliki 3.3a in 3.3b.

Funkcionalnost, ki omogoča nadaljno obravnavo detektorjev, je dodajanje Gaussovega šuma sliki. Tako bi lahko oba postopka primerjali tudi s stališča odpornosti na dodatne motnje. Videli bi lahko, kako šum vpliva na odkrivanje robov ter kakšna količina šuma še da smiselne rezultate. Primer uporabe prikazuje slika 3.2.



(a) Originalna slika in pripadajoči histogram.



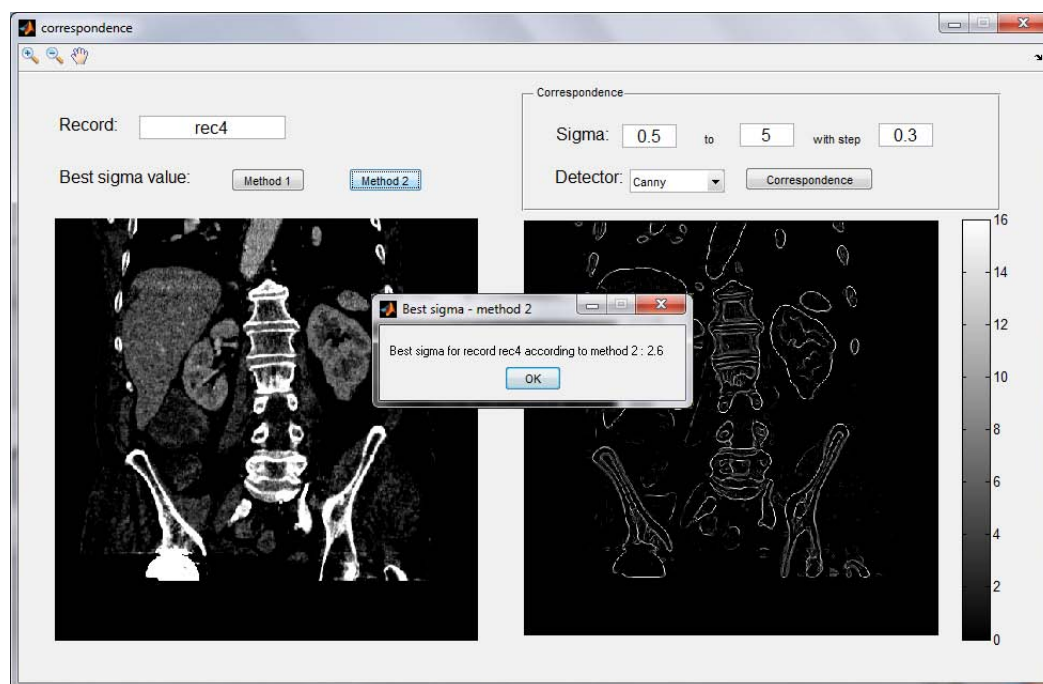
(b) Rezultat po postopku izravnave histograma.

Slika 3.3: Izboljšanje kontrasta slike s pomočjo postopka izravnave histograma.

3.1.2 GUI - korespondenčna slika

Drugi GUI je bil razvit za enostavnejšo uporabe funkcije za kompozicijo korespondenčne slike ter iskanje najustrežnejše vrednosti parametra σ in z njo referenčne slike. Vmesnik najprej zahteva vnos imena testnega posnetka. Nato na podlagi izbranega detektorja, vnešenega obsega parametra σ ter koraka $\Delta\sigma$ konstruira korespondenčno sliko.

Pod razdelkom *Best sigma value* lahko s pritiskom na gumb *Method 1* ali *Method 2* pridobimo podatek o najustrežnejši vrednosti parametra σ glede na metodo št.1 (2.5.2) ali metodo št.2 (2.5.3). Primer uporabe prikazuje slika 3.4.



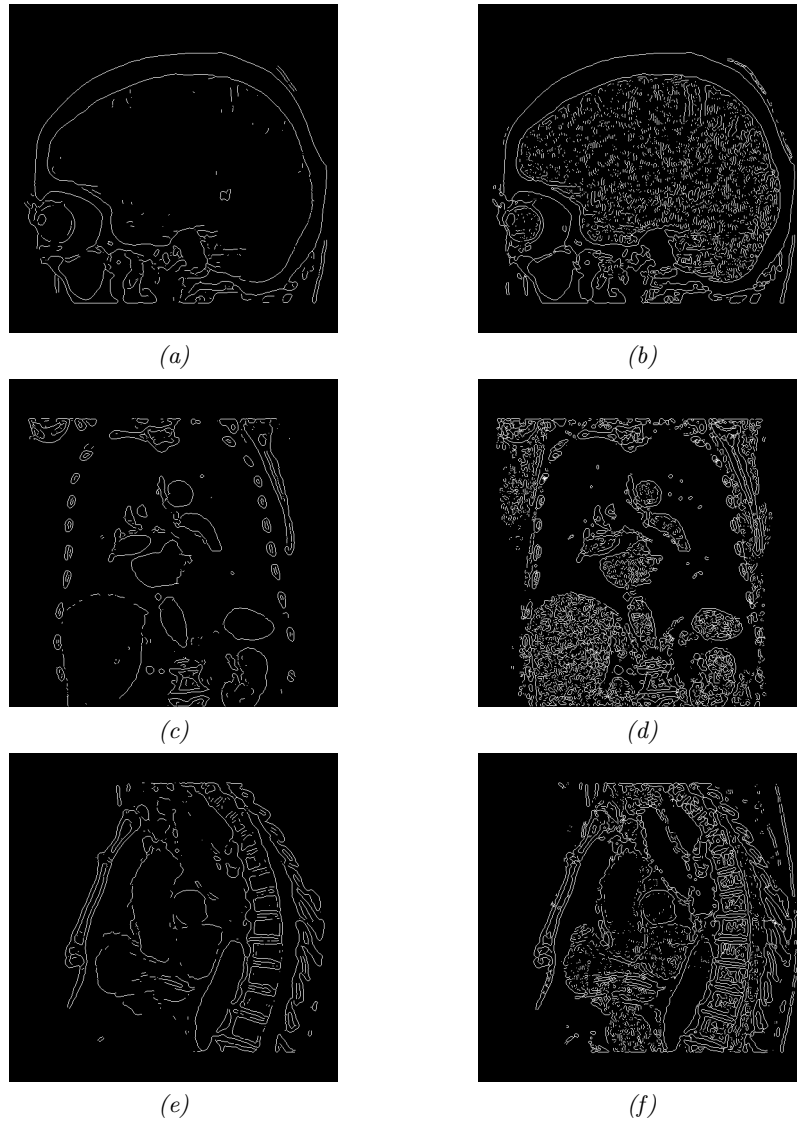
Slika 3.4: Grafični uporabniški vmesnik za kompozicijo korespondenčne slike in iskanje najboljše vrednosti parametra σ .

3.2 Vizualna primerjava

V praksi stremimo k temu, da bi se računalniška detekcija čimbolj približala človeški subjektivni predstavi o tem, kje v sliki se nahaja rob. Vizualna ocena je bila prisotna že v fazi razvoja obeh detektorjev, ko smo preverjali delovanje algoritmov, v fazi primerjave rezultatov pa je bila logični prvi korak.

Število detektiranih robov

Prva stvar, ki jo opazimo ob pregledu rezultatov, je, da Marr-Hildrethov detektor predvsem pri manjših vrednostih parametra σ odkrije veliko večje število robov. Za primer si oglejmo rezultate detekcije na CT posnetkih - slika 3.5. Na levi so rezultati Cannyjevega algoritma, na desni pa detekcije Marr-Hildrethovega algoritma.



Slika 3.5: Primerjava števila odkritih robov - Cannyjev algoritem (a,c,e) in Marr-Hildrethov algoritem (b,d,f), $\sigma_C = \sigma_M = 1.7$. CT posnetki 3, 9 in 10.

Cannyjev algoritem je z vidika števila odkritih robov bolj konsistenten in jih v povprečju odkrije manj. Že pri majhni vrednosti σ proizvede dobre robove, s povečevanjem parametra σ do "idealne" vrednosti pa odstrani odvečne robne točke, ki so ponavadi posledica šumnate teksture delov slike. Marr-Hildrethov detektor z majhno vrednostjo σ sicer odkrije glavne konture, vendar je bolj občutljiv na zrnato teksturo v sliki, ki je pogosta v primeru medicinskih posnetkov. To lepo prikazuje slika 3.6.



(a) Originalna slika.



(b) Cannyjev algoritem.



(c) Marr-Hildrethov algoritem.

Slika 3.6: Del slike z zrnato teksturo in odkriti robovi - posnetek št. 9; $\sigma_C = \sigma_M = 2.6$.

S povečevanjem vrednosti σ nad območje "idealnih" vrednosti se število robov najprej zmanjšuje. Nato začne Cannyjev algoritem producirati nepredvidljive robne točke. Na drugi strani Marr-Hildrethov algoritem še naprej odkriva vedno manj robov, ki pa so vedno bolj zaokroženi. To je posledica močnega glajenja slike, zato smo morali določiti obseg uporabljenih vrednosti σ (poglavje 2.4). Primer odkrivanja robov pri povečevanju parametra *sigma* nad vrednost 5 je na sliki 3.7.


(a) Cannyjev detektor - $\sigma_C = \{5, 6, 8\}$.(b) Marr-Hildrethov detektor - $\sigma_M = \{5, 6, 8\}$.

Slika 3.7: Odkriti robovi dela slike pri povečevanju σ nad vrednost 5 - posnetek št. 9.


Robovi, ki jih odkrije Marr-Hildrethov algoritem so vijugasti in v veliko primerih tvorijo sklenjene oblike tudi tam, kjer jih ne bi pričakovali. Ta negativna lastnost detektorja je delno izboljšana z uporabo praga. Če prag ne bi bil uveden, bi bili vsi robovi sklenjenih oblik.

Obroba tkiv

Glavno merilo pri ocenjevanju rezultatov je bilo, kako dobro detektorja odkrijeta konture delov telesa. Izkazalo se je, da so izrazito kontrastni deli slike v večini primerov obrobljeni. Predvsem to velja za kosti, ki izstopajo z intenzivno belo barvo. Dober primer je posnetek št. 10. Na sliki je izsek posnetka ter rezultat detekcije z obema detektorjema pri uporabi parametra $\sigma = 2.3$. Rezultat je prikazan na dva načina - kot samostojna slika robnih točk ter kot prekrivne robne točke na originalni sliki. Robne točke, ki jih je odkril Cannyjev algoritem so prikazane v rdeči barvi, tiste, ki jih je odkril Marr-Hildrethov algoritem, pa v zeleni barvi.



(a) Originalna slika.



(b) Cannyjev algoritem.




(c) Marr-Hildrethov algoritem.



Slika 3.8: Del slike s kontrastnimi deli telesa in najdeni robovi - posnetek št. 10;

$$\sigma_C = \sigma_M = 2.3.$$

Kot je razvidno iz primera, oba detektorja večinoma dobro obrobita glavne organe, saj so na posnetku kontrastni. Nekoliko slabše je detektirana meja med njimi, kar je posledica podobne barve in teksture ter zabrisanih prehodov. Močno izstopajo konture kosti, predvsem prsnice, ki je s strani obeh detektorjev v celoti obrobljena. Cannyjev algoritem izpusti nekatere podrobnosti, s tem pa tudi šumne točke, ki jih na drugi strani Marr-Hildrethov algoritem upošteva kot robne. Razlog za to je uporaba drugega odvoda, ki ima močen odziv na fine detajle, tudi šum. Pri iskanju robov na medicinskih posnetkih pride ta lastnost močno do izraza, saj je površina organov ponavadi prikazana z zrnato teksturo. Na takih področjih so kot robne točke določene tako obrobe organov kot tudi deli njihove površine. Iz tega vidika je Marr-Hildrethov algoritem bolj občutljiv, Cannyjev pa bolj robusten. Po drugi strani je ta občutljivost lahko prednost, saj se algoritem odzove tudi na območjih, kjer so organi predstavljeni z zelo majhnim kontrastom. To lahko opazimo na prejšnji sliki 3.8. Okrogel del organa na spodnjem delu posnetka je Cannyjev algoritem v celoti izpustil, medtem ko je Marr-Hildrethov algoritem označil nekaj robnih točk. Na zelo šumnih slikah se to vseeno izkaže za slabost, saj v končnem rezultatu detekcije težko ločimo, katere robne točke so posledica šuma, katere pa resnične obrobe organa. Tak primer je predstavljen na sliki 3.9 na strani 52. Gre za posnetek trebušne votline, kjer je vidnih več organov, vendar jih je velik del šumnatih in z zelo slabim kontrastom. Posledično Cannyjev algoritem odkrije obrobe najbolj izstopajočih delov in nekaj robnih točk šumnatih organov. Rezultat Marr-Hildrethovega algoritma je cela množica robnih točk, izmed katerih komaj razberemo relevantne obrise nekaterih organov.



(a) Originalna slika.



(b) Cannyjev algoritem.



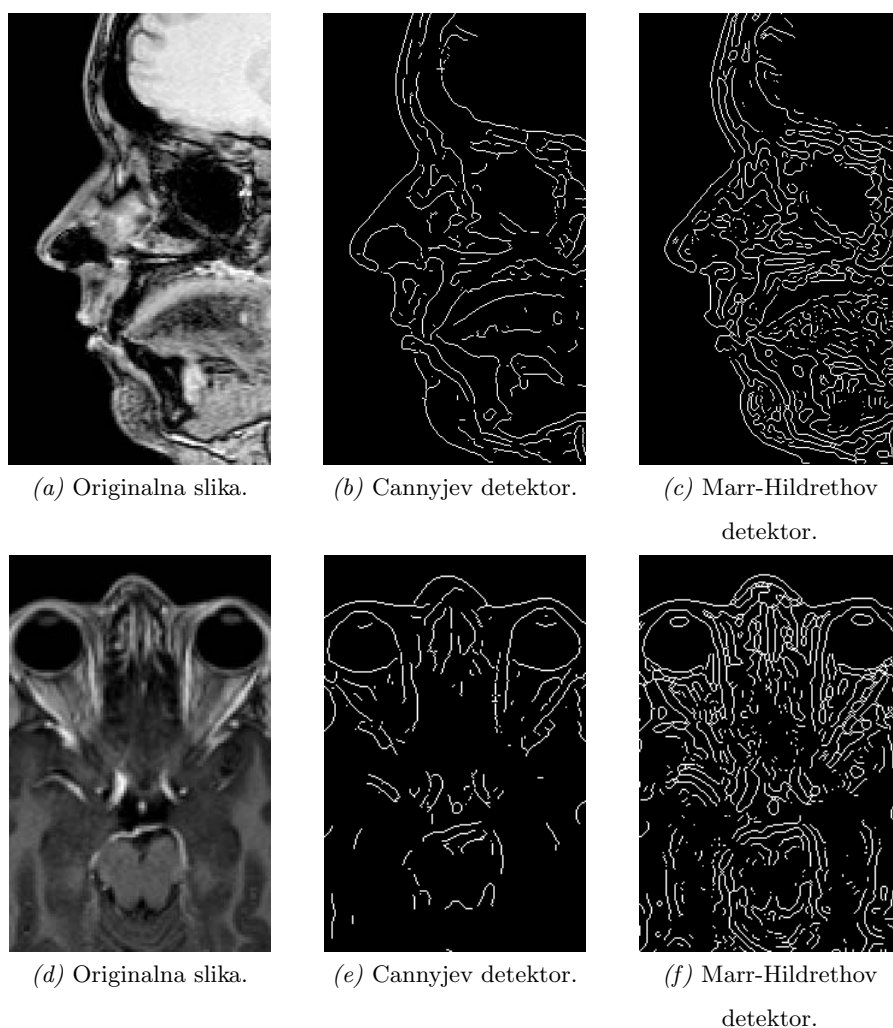
(c) Marr-Hildrethov algoritem.

Slika 3.9: Del slike s kontrastnimi deli telesa in najdeni robovi - posnetek št. 7;

$$\sigma_C = \sigma_M = 2.3.$$

MRI posnetki

V splošnem detekcija robov na posnetkih, pridobljenih z magnetno resonanco, prinaša podobne rezultate kot na CT posnetkih. Razlika je predvsem v številu odkritih robov, ki jih je v primeru MRI posnetkov več. MRI posnetki so bolj jasni in omogočajo dobro razlikovanje med mehko tkivnimi strukturami. Zaradi velikih podrobnosti v sliki je tako veliko več potencialnih robnih točk. Primer je na sliki 3.10, kjer sta prikazana izseka MRI posnetkov z najdenimi robovi.



Slika 3.10: Izsek MRI posnetka in najdeni robovi - posnetek št. 11 in 12;

$$\sigma_C = \sigma_M = 2.5.$$

Ponovno pride do izraza občutljivost Marr-Hildrethovega detektorja na detajle in šum. Oba algoritma sicer odkrijeta najbolj izstopajoče obrobe, vendar je Cannyjev rezultat, ki ne vsebuje šumnih podrobnosti, veliko bolj pregleden. Če si poskusimo zamisliti, kje na originalni sliki bi sami označili obrobe, se Cannyjeve robne točke tej oceni najbolj približajo.

Mehka tkiva in nekontrastni prehodi med njimi tudi v primeru MRI posnetkov predstavljajo težavo. Predvsem je to razvidno iz slik spodaj, kjer je na posnetku del možganov. Potencialno uporabnost detektorjev za pomoč pri odkrivanju abnormalnih tkiv znotraj telesa lahko tako na tej točki ovržemo. Za kvalitetnejše odkrivanje robov bi se morali poslužiti še kakšnega drugega postopka, morda tudi v kombinaciji z obravnavanima algoritmoma.

3.3 Uporabljene referenčne slike

Tabela 3.1 prikazuje rezultate obeh metod za kompozicijo referenčne slike, opisanih v poglavjih 2.5.2 in 2.5.3. V njej vidimo dobljene korespondenčne pragove KP ter vrednosti parametra σ , ki dajo referenčno sliko. Vrednost KP je podana tudi v % - glede na maksimalno število korespondenčnih nivojev korespondenčne slike. Na podlagi dobljenih vrednosti KP so bile nato izračunane optimalne vrednosti parametra σ .

Posnetek			Canny						Marr-Hildreth					
			Metoda 1			Metoda 2			Metoda 1			Metoda 2		
Vrsta	Št.	Ime	KP	KP [%]	σ	KP	KP [%]	σ	KP	KP [%]	σ	KP	KP [%]	σ
CT	1	rec1	4	26%	1.1	8	50%	2.6	4	30%	2.9	7	50%	2.9
	2	rec2	5	33%	1.7	8	50%	2.6	4	30%	2.6	7	50%	2.9
	3	rec3	5	33%	1.4	8	50%	2.6	4	30%	2.6	7	50%	2.9
	4	rec4	5	33%	1.4	8	50%	2.6	4	30%	2.6	7	50%	2.9
	5	rec5	5	33%	1.7	8	50%	2.6	4	30%	2.6	7	50%	2.9
	6	rec6	5	33%	4.1	8	50%	2.6	3	23%	2	7	50%	2.9
	7	rec7	5	33%	1.7	8	50%	2.6	4	30%	2.9	7	50%	2.9
	8	rec8	5	33%	2.9	8	50%	2.6	4	30%	2.6	7	50%	2.9
	9	rec9	5	33%	1.4	8	50%	2.9	4	30%	2.6	7	50%	2.9
	10	rec10	5	33%	1.4	8	50%	2.6	4	30%	2.6	7	50%	3.2
MRI	11	rec1a	6	35%	1.3	9	50%	2.1	5	36%	2.35	7.5	50%	2.8
	12	rec2a	7	41%	2.5	9	50%	2.1	5	36%	2.65	7.5	50%	2.8
	13	rec3a	6	35%	1.5	9	50%	2.1	6	43%	2.25	7.5	50%	2.8

Tabela 3.1: Rezultati obstoječe in lastne metode za iskanje optimalne vrednosti parametra σ ter z njo referenčne slike.

Če primerjamo rezultate obeh metod, opazimo, da so končne vrednosti σ v stolpcih za Marr-Hildrethov detektor precej bolj podobne kot tiste v stolpcih za Canny-jev detektor. Sicer se parameter σ v primeru naše lastne metode giblje okoli vrednosti 2.6-2.9, medtem ko so vrednosti v primeru obstoječe metode načeloma nekoliko nižje. Prav tako je tam nižji prag KP, ki znaša okoli 30%.

V nadaljevanju je za primerjavo prikazanih nekaj končnih referenčnih slik, pridobljenih z obema metodama.



(a) Originalna slika.



(b) Referenčna slika po 1. metodi.




(c) Referenčna slika po 2. metodi.

Slika 3.11: Primerjava referenčnih slik, pridobljenih z uporabo obeh metod - posnetek št. 6.


Na sliki 3.11 je prikazan originalni CT posnetek trebušne votline (pogled zgoraj) ter referenčni sliki za Marr-Hildrethov detektor, pridobljeni s koraki 1. metode ($\sigma = 2$) in 2. metode ($\sigma = 2.9$).



(a) Originalna slika.



(b) Referenčna slika po 1. metodi.




(c) Referenčna slika po 2. metodi.

Slika 3.12: Primerjava referenčnih slik, pridobljenih z uporabo obeh metod - posnetek št. 9.

Na sliki 3.12 je prikazan originalni CT posnetek trebušne votline (pogled spredaj) ter referenčni sliki za Cannyjev detektor, pridobljeni s koraki 1. metode ($\sigma = 1.4$) in 2. metode ($\sigma = 2.9$).



(a) Originalna slika.



(b) Referenčna slika po 1. metodi.




(c) Referenčna slika po 2. metodi.

Slika 3.13: Primerjava referenčnih slik, pridobljenih z uporabo obeh metod - posnetek št. 2.


Na sliki 3.13 je prikazan originalni CT posnetek glave (pogled od zgoraj) ter referenčni sliki za Marr-Hildrethov detektor, pridobljeni s koraki 1. metode ($\sigma = 2.6$) in 2. metode ($\sigma = 2.9$).



(a) Originalna slika.



(b) Referenčna slika po 1. metodi.



(c) Referenčna slika po 2. metodi.

Slika 3.14: Primerjava referenčnih slik, pridobljenih z uporabo obeh metod - posnetek št. 5.

Na sliki 3.14 je prikazan originalni CT prsnega koša (pogled s strani) ter referenčni sliki za Cannyjev detektor, pridobljeni s koraki 1. metode ($\sigma = 1.7$) in 2. metode ($\sigma = 2.6$).

Če subjektivno ocenimo referenčne slike, lahko trdimo, da so rezultati 2. metode v primeru Marr-Hildrethovega detektorja nekoliko boljši, kot če uporabimo 1. metodo. Predvsem je na referenčni sliki manj nepotrebnih (šumnih) detajlov. V primeru Cannyjevega detektorja se 1. metoda izkaže za nekoliko boljšo, a so referenčne slike pridobljene z 2. metodo še vedno sprejemljive. Iz nje so izločene nekatere podrobnosti, a s stališča detekcije glavnih kontur, so rezultati obetavni. Odločili smo se, da v postopku primerjave uporabimo za referenčne slike rezultate naše lastne metode. Vse uporabljene referenčne slike je možno videti v prilogi A.

3.4 Uporaba in evaluacija razvitih metrik nad testno množico slik

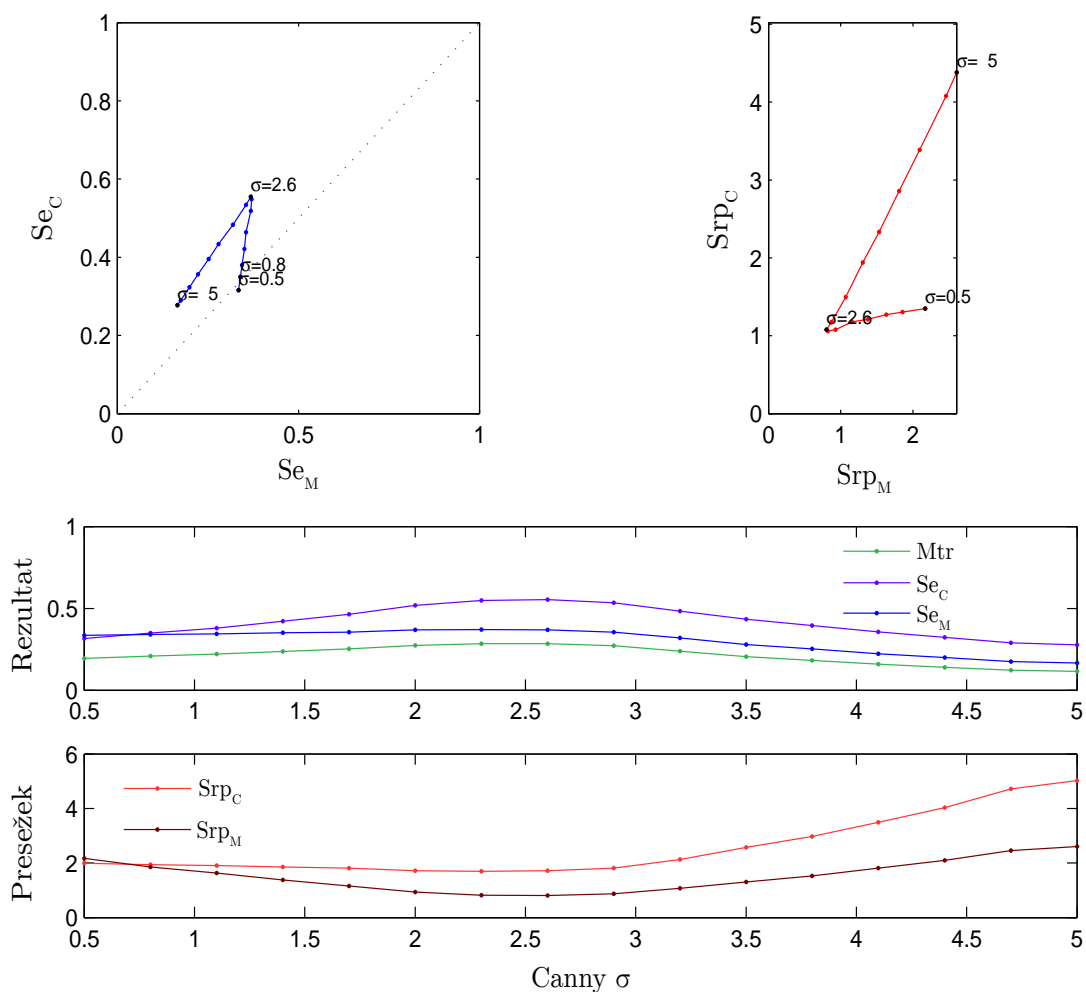
Po pridobitvi referenčne slike danega CT/MRI posnetka za oba uporabljena detektorja smo lahko izvedli kvantitativno primerjavo. Pri tem smo uporabili razvite metrike (poglavje 2.6). Najprej smo vzeli referenčno sliko Marr-Hildrethovega detektorja ter dobljene robne točke primerjali s posameznimi rezultati, ki jih je dal Canny-jev detektor pri celotni množici uporabljenih vrednosti σ . Vzemimo za primer CT posnetek št. 2:

- referenčna slika: rezultat detekcije z Marr-Hildrethovim detektorjem pri vrednosti $\sigma_M = 2.9$,
- slike, s katerimi primerjamo referenčno: rezultati detekcije s Canny-jevim detektorjem pri vrednostih $\sigma_C = \{0.5, 0.8, 1.1, \dots, 5\}$.

Pri primerjavi smo računali vrednosti za relativno občutljivost (Se) in presežek (Srp) z vidika obeh detektorjev ter stopnjo ujemanja (Mtr). Zaradi lažje analize smo se odločili, da rezultate prikažemo grafično - primer prikazuje slika 3.15.

Levo zgoraj je prikazan graf relativne občutljivosti Cannyjevega detektorja v odvisnosti od Marr-Hildrethovega detektorja. Nekatere točke so dodatno označene z vrednostmi σ , ki jih je v postopku detekcije uporabil Cannyjev detektor. Označene so tam, kjer ima σ začetno ali končno vrednost (na sliki 0.5 in 5), ter na vrhu krivulje (na sliki 2.6) - v tisti točki je vsota obeh občutljivosti največja. Prav tako je označena točka, ki je najbližje črtkani diagonali, ki gre iz točke (0,0) v (1,1). Na sliki je to točka, kjer ima σ vrednost 0.8. Tam sta si vrednosti občutljivosti obeh detektorjev najbolj podobni. V teoriji bi si želeli, da je ta točka čim bližje točki (1,1).

Podobno je desno zgoraj prikazan presežek. Poleg začetne in končne vrednosti parametra σ je označena še točka, kjer se krivulja obrne. Tam je točka, kjer je bil skupni presežek obeh detektorjev najmanjši. V teoriji zato stremimo k temu, da bi bila ta točka karseda blizu točki (0,0) in bi bil presežek minimalen. To bi kazalo na veliko podobnost rezultatov detekcije.

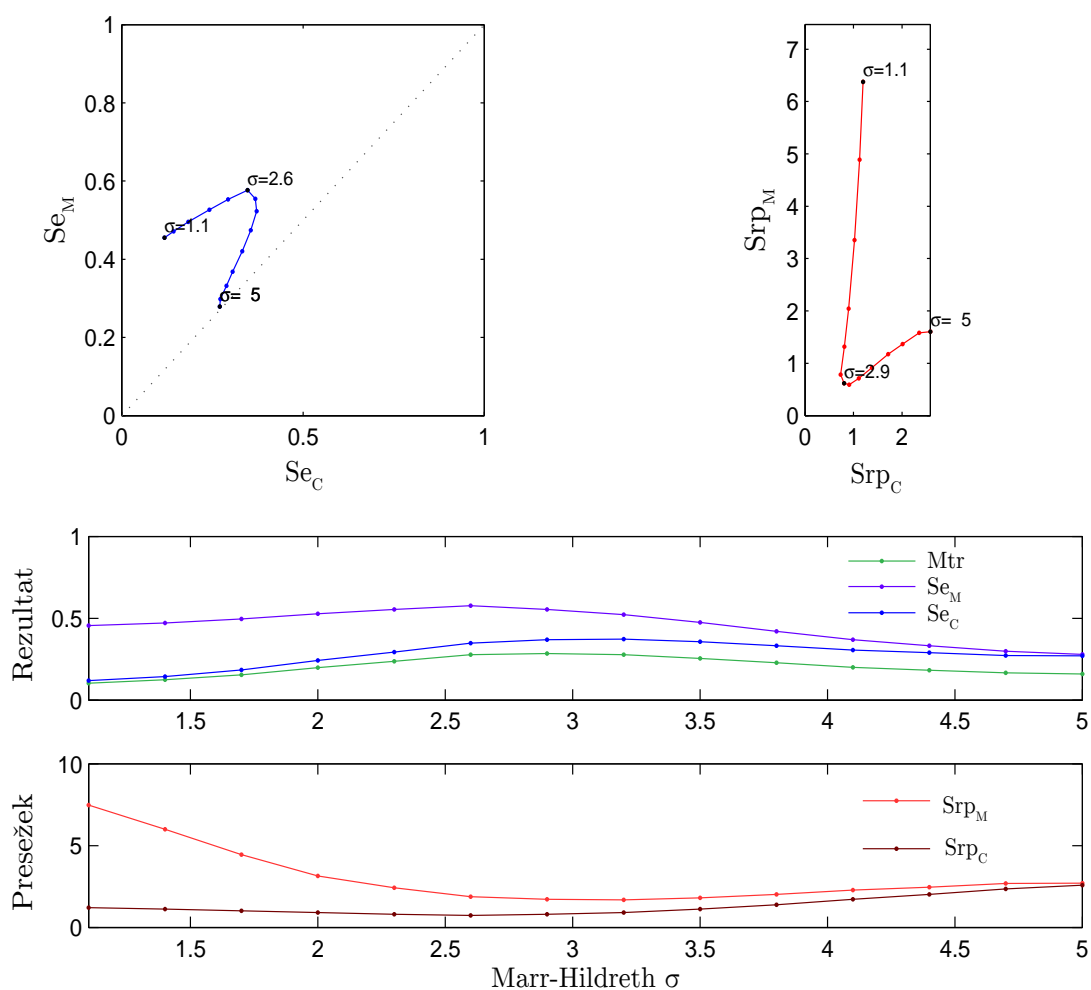


Slika 3.15: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 2 - CT).

Spodnja dva grafa prikazujeta rezultate (relativno občutljivost z vidika obeh detektorjev ter stopnjo ujemanja) v odvisnosti od spreminjanja parametra σ znotraj Cannyjevega algoritma.

Nato smo vzeli še referenčno sliko Cannyjevega detektorja in jo podobno kot zgoraj primerjali primerjali z naborom rezultatov slik, ki jih je dal Marr-Hildrethov detektor. Ponovno za primer vzemimo CT posnetek št. 2:

- referenčna slika: rezultat detekcije s Cannyjevim detektorjem pri vrednosti $\sigma_C = 2.6$,
- slike, s katerimi primerjamo referenčno: rezultati detekcije z Marr-Hildrethovim detektorjem pri vrednostih $\sigma =_M \{1.1, 1.4, 1.7, \dots, 5\}$.




Slika 3.16: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 2 - CT).

Obe sliki lahko sedaj primerjamo. Hitro vidimo, da so krivulje grafov zelo podobnih oblik, ter da so med seboj odvisne. Ko naraščata relativni občutljivosti detektorjev, narašča tudi stopnja ujemanja, obratno pa je s presežkom, ki pri tem pada. Tam, kjer sta občutljivosti najvišji, je tudi najvišja stopnja ujemanja in hkrati najmanjši presežek detektorjev. Z vidika podobnosti je torej to območje najbolj idealno. V našem primeru posnetka št. 2 je to tam, kjer je vrednost σ enaka 2.6 do 2.9. To potrjujeta tudi zgornja dva grafa na slikah, kjer je sprememba trenda občutljivosti in presežka še bolj opazna. V enakem območju sta tudi obe referenčni sliki detektorjev, torej sta si algoritma najbolj podobna pri vrednostih σ , ki dajejo (glede na našo metodo) najboljše rezultate.


Če bolj podrobno pogledamo še same vrednosti izračunanih metrik, vidimo, da je relativna občutljivost detektorjev precej nizka. Nikjer ne presega vrednosti 0.6 in je v povprečju enaka 0.4. Tudi stopnja ujemanja je nizka in se giblje okoli vrednosti 0.3. To se odraža tudi v presežku obeh detektorjev. Ta se v začetku manjša, dokler ne pride do območja največje podobnosti, nato pa se začne vztrajno povečevati. Na drugi sliki (3.15), ko je referenčni Cannyjev detektor, je dobro opazno, da so začetne vrednosti σ problematične, saj odkrije algoritem (pre)veliko število robov - zato velik presežek.

Zatem smo izračunali stopnjo ujemanja med *vsemi* kombinacijami rezultatov obeh detektorjev, torej za vse kombinacije parov med vrednostmi σ_C in σ_M . V primeru CT slik smo torej uporabili kombinacije (σ_C, σ_M) pri $\sigma_C = \{0.5, 0.8, 1.1, \dots, 5\}$ in $\sigma_M = \{1.1, 1.4, 1.7, \dots, 5\}$. Primer prikazuje 3D mreža na sliki 3.17 na naslednji strani.

Ordinatsna in abscisna os predstavljata vrednosti σ_M in σ_C , aplikatsna os pa vrednosti stopnje ujemanja. Višina točke v mreži torej odraža, kako dobro se ujema rezultati, detektirani s Cannyjevim detektorjem pri σ_C , ter rezultati, detektirani z Marr-Hildrethovim detektorjem pri σ_M . To je za lažjo analizo grafa še dodatno poudarjeno z barvno lestvico modra-zelena-rdeča (v Matlabu t.i. 'jet' barvna lestvica). Modra barva predstavlja nizko stopnjo ujemanja, medtem ko pomeni rdeča barva visoko stopnjo ujemanja in večjo podobnost v detekciji. Oblika mreže je simetrična in nakazuje, da daje detekcije s podobno vrednostjo σ podobne rezultate. Če pogledamo tloris mreže na spodnji sliki, se vrednosti stopnje ujemanja z oddaljevanjem od diagonale manjšajo - prehajanje v modro barvo. Enako je razvidno tudi iz naklona mreže na zgornji sliki. To je razumljivo, saj ima v obeh algoritmih ta parameter vlogo glajenja slike, oba postopka pa temeljita na uporabi odvodov. Vrh mreže se približno ujema z območjem, ki smo ga določili pri analizi slik 3.16 in 3.15.



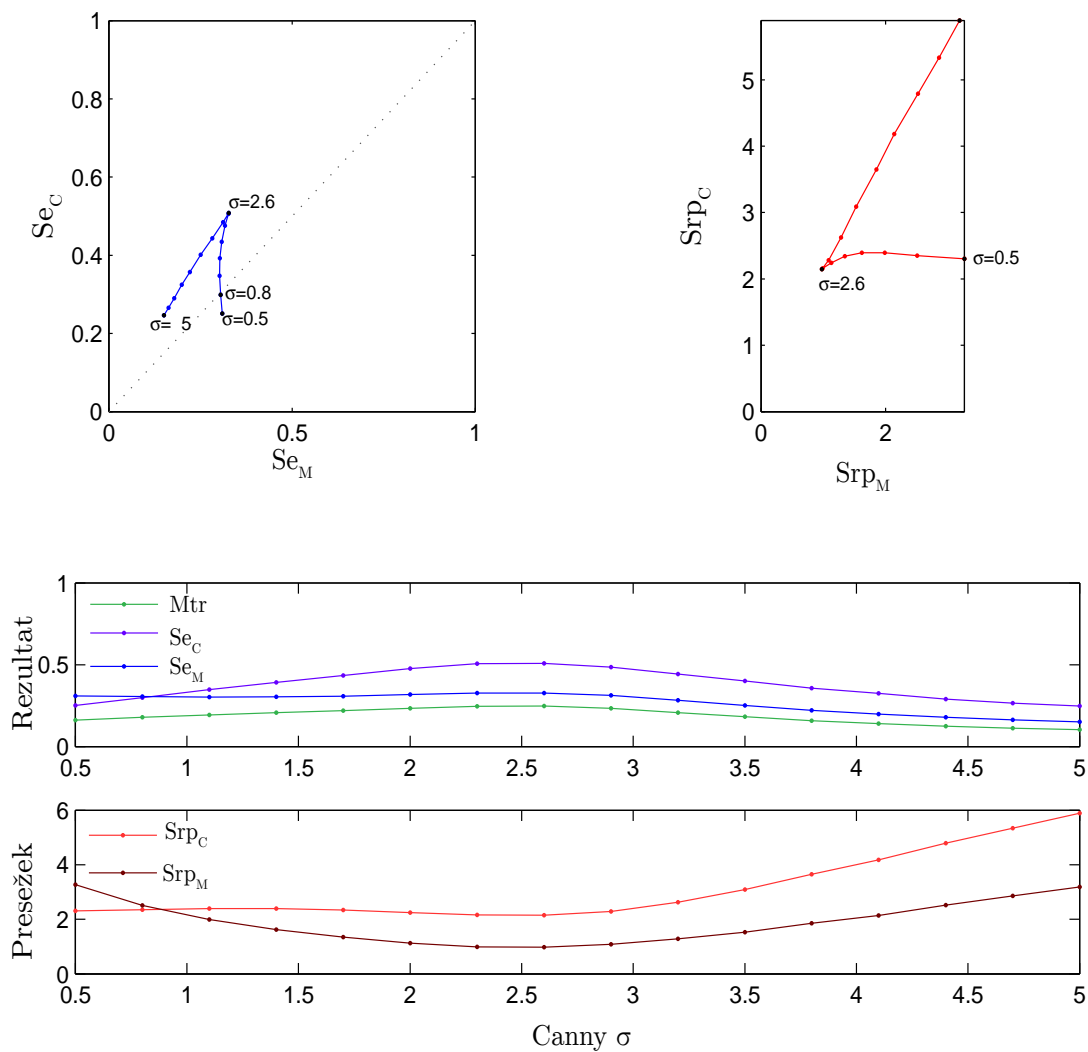
(a) Vrednosti stopnje ujemanja predstavljene s 3D mrežo.



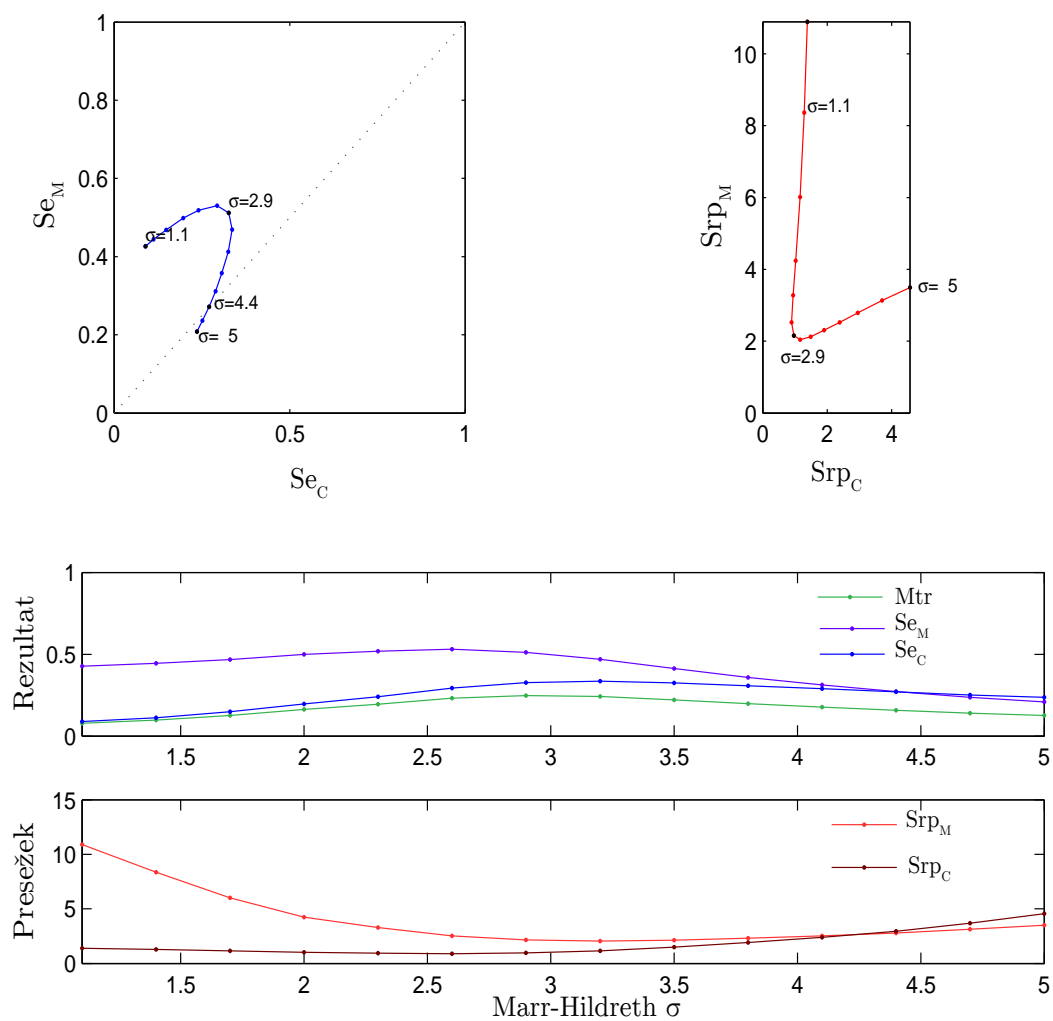
(b) Vrednosti stopnje ujemanja predstavljene s 3D mrežo - tloris.

Slika 3.17: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 2 - CT).


Pri analizi grafov relativne občutljivosti, presežka in stopnje ujemanja za vse posnetke se je izkazalo, da so rezultati pri isti vrsti posnetkov zelo podobni. Zato smo jih povprečili in prikazali na skupnih grafi - slike 3.18, 3.19 in 3.20.




Slika 3.18: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (povprečje vseh CT posnetkov).



Slika 3.19: Rezultat uporabe metrik - referenca je Cannyjev detektor (povprečje vseh CT posnetkov).



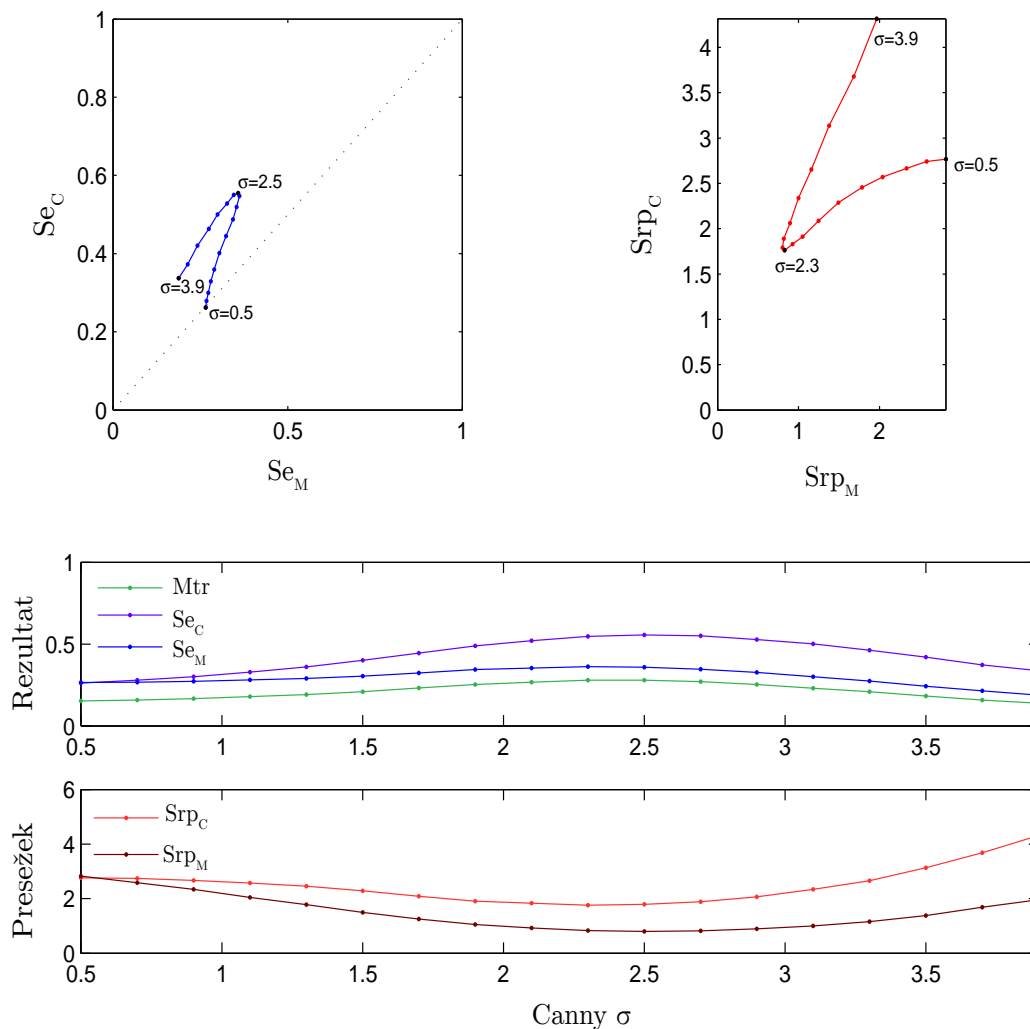
(a) Vrednosti stopnje ujemanja predstavljene s 3D mrežo.



(b) Vrednosti stopnje ujemanja predstavljene s 3D mrežo - tloris.

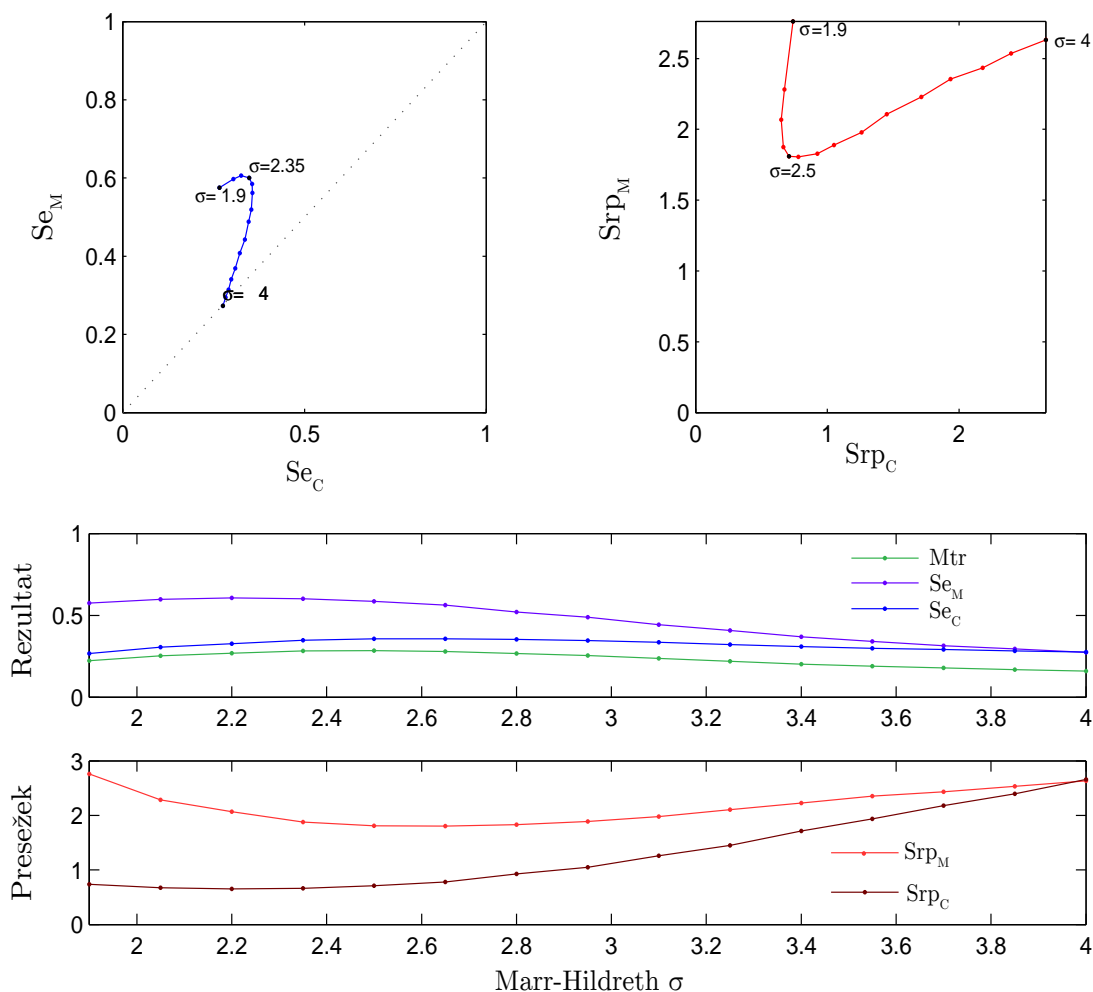
Slika 3.20: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (povprečje vseh CT posnetkov.)

Poglejmo si še primer uporabe metrik nad rezultati detekcije pri MRI posnetkih. Dobljene grafe prikazujejo slike 3.21, 3.22 in 3.23.



Slika 3.21: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 11 - MRI).


Tudi v primeru MRI posnetkov vidimo, da so izračunane vrednosti podobne tistim pri CT posnetkih. Na podoben izid analize nakazujejo že oblike krivulj. Relativna občutljivost redko preseže vrednost 0.5 in se pretežno giblje okoli vrednosti 0.3 do 0.4. Tudi dobljeni presežki so v podobnem obsegu kot v primeru CT slik. Stopnja ujemanja je v večini primerov 25%. Glede na uporabljene referenčne slike se za vrednosti parametra σ , ki dajo najbolj podobne rezultate, izkaže območje med 2.3 in 2.6.




Slika 3.22: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 11 - MRI).

Slika stopnje ujemanja med vsemi kombinacijami rezultatov obeh detektorjev prikazuje 3D mreža na sliki 3.23a. Uporabljeni so bili pari parametrov (σ_C, σ_M) za $\sigma_C = \{0.5, 0.7, 0.9, \dots, 3.5\}$ in $\sigma_M = \{1.9, 2.05, 2.2, \dots, 4\}$. Mreža na sliki 3.23 nakazuje, da dajo podobne vrednosti parametra σ višjo stopnjo ujemanja - na diagonali je temnordeče območje. Od 3D mreže za primer CT slik se razlikuje predvsem v tem, da ni izrazitega vrha, ki bi označeval največjo podobnost v detekciji. Največja stopnja ujemanja v mreži je sicer podobna kot v primeru CT posnetkov in doseže vrednost okoli 0.25.

Preostale grafe primerjav je možno videti v prilogi B, kjer so združeni rezultati evaluacije metrik nad vsemi testnimi posnetki.



(a) Vrednosti stopnje ujemanja predstavljene s 3D mrežo.



(b) Vrednosti stopnje ujemanja predstavljene s 3D mrežo - tloris.

Slika 3.23: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 11 - MRI.)

4 Razprava

4.1 Možnosti za nadaljne delo

Pri obravnavi Cannyjevega in Marr-Hildrethovega detektorja smo se morali znotraj diplomskega dela omejiti, toda področje je široko in odprte so številne možnosti za nadaljno raziskovanje. Eno izmed njih ponuja že naša implementacija, ki omogoča nekatere dodatne funkcije pri odkrivanju robov (sledenje robovom, zapolnitev vrzeli), ki niso bile vključene v končnem koraku primerjave. Prav tako bi lahko kot spreminjajoči se parameter poleg parametra σ uvedli še parameter prag, kar bi nekoliko zapletlo iskanje dobre referenčne slike, vendar bi bili rezultati detekcije z vidika kvalitete bolj optimizirani. Kot že omenjeno v poglavju 3.1 bi lahko opazovali tudi vpliv šuma na delovanje obeh detektorjev. Tako bi lahko analizirali, kako hitro se slabša detekcija, če so v posnetkih prisotne dodatne motnje, kateri detektor je manj občutljiv na njih, pri kakšni količini šuma še dobimo sprejemljive rezultate ... Naslednjo nadgradnjo bi bilo možno narediti znotraj grafičnega uporabniškega vmesnika. Trenutno razviti GUI je precej preprost, zato bi ga bilo smiselno dopolniti, da bi omogočal rokovanje s celotnim procesom primerjave detektorjev.

Če gledamo z vidika dobre detekcije robov v medicinskih posnetkih, smo med raziskovanjem prišli do zaključka, da obravnavana detektorja data relativno dobre rezultate, a ne idealnih. Zelo dobro se odzivata na kosti v sliki, medtem ko odkrivanje robov mehkih tkiv predstavlja težavo. Za dobro detekcijo kontur vseh pomembnih segmentov človeškega telesa bi morda Cannyjev in Marr-Hildrethov algoritem lahko uporabili v kombinaciji s še kakšnim drugim detekcijskim postopkom.

Metrike, ki smo jih izpeljali v fazi primerjave detektorjev, ponujajo nove možnosti na področju ocenjevanja zmogljivosti klasifikatorjev. Sicer so bile razvite za potrebe primerjave dveh detektorjev a so razširljive in bi jih v splošnem lahko uporabili pri večjem številu detektorjev ter za različne vrste problemov.

4.2 Sklep

V diplomskem delu smo primerjali dva izmed najbolj pogosto uporabljenih postopkov za odkrivanje kontur v slikah. Lahko trdimo, da dajeta detektorja obetavne rezultate tudi, ko ju uporabimo na medicinskih slikah. Ker gre za občutljivo področje, kjer se zahteva čimvečja natančnost in zanesljivost rezultatov, stremimo k temu, da bi bil postopek detekcije še izboljššan. Sicer lahko z vidika subjektivne ocene zaključimo, da so Cannyjevi rezultati detekcije nekoliko boljši in bolj blizu našim predstavam.

Poleg implementacije detektorjev in vizualne primerjave rezultatov nam je uspelo razviti dober postopek za avtomatično iskanje referenčne slike in ustreznih parametrov detekcije. Uporaben je v primeru, da v koraku primerjave nimamo ustrezne referenčne slike z označenimi pravilnimi robovi.

Prav tako smo postavili nove metrike zmogljivosti in tako posegli tudi v obravnavo širšega področja primerjave klasifikatorjev.

LITERATURA

- [1] John F. Canny. Finding edges and lines in images. Technical report AI-TR-720, MIT, june 1983.
- [2] James P. Egan. *Signal Detection Theory and ROC Analysis*. Academic Press, New York, 1975.
- [3] Ines A. Gasparotto-Boaventura and Adilson Gonzaga. Method to evaluate the performance of edge detector. *Proceedings of the The Brazilian Symposium on Computer Graphics and Image Processing*, 2009.
- [4] Rafael C. Gonzales and Richard E. Woods. *Digital Image Processing*. Pearson Education, New Jersey, second edition, 2002.
- [5] Rafael C. Gonzales and Richard E. Woods. *Digital Image Processing*. Pearson Education, New Jersey, third edition, 2008.
- [6] Ramesh Jain, Rangachar Kasturi, and Brian G. Schunck. *Machine vision*. McGraw-Hil Higher Educationl, 1995.
- [7] Mamta Juneja and Parvinder S. Sandhu. Automated medical image segmentation techniques. *International Journal of Computer Theory and Engineering*, 1(5):25–34, 2009.
- [8] Ron Kikinis. Medical image computing for translational biomedical research. In Hans-Peter Meinzer, Thomas Martin Deserno, Heinz Handels, and Thomas Toxdorff, editors, *Bildverarbeitung für die Medizin 2013*, Informatik aktuell, pages 1–1. Springer Berlin Heidelberg, 2013.


- [9] ksu-parasitology labarotory. Update on upton's cancer, November 2013. <https://www.ksu.edu/parasitology/cancer.html>.
- [10] News Medical. What is a brain tumor?, November 2013. <http://www.news-medical.net/health/What-is-a-Brain-Tumor.aspx>.
- [11] Miho Ohsaki, Takahiro Sugiyama, and Hideaki Ohno. Evaluation of edge detection methods through psychological tests - is the detected edge really desirable for humans? *Systems, Man, and Cybernetics, 2000 IEEE International Conference*, 1:671 – 677, 2000.
- [12] Ramón Román-Roldá, Juan F. Gómez-Lopera, Chakir Atae-Allah, José Martínez-Aroza, and Pedro L. Luque-Escamilla. A measure of quality for evaluating methods of segmentation and edge detection. *Pattern Recognition*, 34:969–980, 2001.
- [13] Neeraj Sharma and Lalit M. Aggarwal. A classified and comparative study of edge detection algorithms. *Journal of Medical Physics*, 35(1):3–14, 2010.
- [14] Yitzhak Yitzhaky and Eli Peli. A method for objective edge detection evaluation and detector parameter selection. *Pattern Analysis and Machine Intelligence*, 25(8):1027–1033, 2003.

A Testna množica CT in MRI slik ter pripadajoče referenčne slike


Posnetek št. 1



(a)



(b)




(c)

Slika A.1: CT posnetek glave - pogled spredaj. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c).

Vrednost parametra $\sigma_C = 2.6$, $\sigma_M = 2.9$.

Posnetek št. 2




Slika A.2: CT posnetek glave - pogled s strani. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c).

Vrednost parametra $\sigma_C = 2.6$, $\sigma_M = 2.9$.


Posnetek št. 3



(a)



(b)




(c)

Slika A.3: CT posnetek glave - pogled s strani. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c).

Vrednost parametra $\sigma_C = 2.6$, $\sigma_M = 2.9$.

Posnetek št. 4



(a)




(b)

(c)


Slika A.4: CT posnetek trebušne votline - pogled spredaj. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c). Vrednost parametra $\sigma_C = 2.6$, $\sigma_M = 2.9$.

Posnetek št. 5




Slika A.5: CT posnetek prnsega koša - pogled s strani. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c). Vrednost parametra $\sigma_C = 2.6$, $\sigma_M = 2.9$.

Posnetek št. 6



(a)




(b)

(c)

Slika A.6: CT posnetek trebušne votline - pogled zgoraj. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c). Vrednost parametra $\sigma_C = 2.6$, $\sigma_M = 2.9$.

Posnetek št. 7



(a)




(b)




(c)

Slika A.7: CT posnetek trebušne votline - pogled spredaj. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c). Vrednost parametra $\sigma_C = 2.6$, $\sigma_M = 2.9$.

Posnetek št. 8



(a)




(b)


(c)

Slika A.8: CT posnetek trebušne votline - pogled s strani. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c). Vrednost parametra $\sigma_C = 2.6$, $\sigma_M = 2.9$.


Posnetek št. 9



(a)




(b)




(c)

Slika A.9: CT posnetek prsnega koša - pogled spredaj. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c). Vrednost parametra $\sigma_C = 2.9$, $\sigma_M = 2.9$.

Posnetek št. 10



(a)




(b)

(c)

Slika A.10: CT posnetek prsnega koša - pogled s strani. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c). Vrednost parametra $\sigma_C = 2.6$, $\sigma_M = 3.2$.


Posnetek št. 11




Slika A.11: MRI posnetek glave - pogled s strani. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c).

Vrednost parametra $\sigma_C = 2.1$, $\sigma_M = 2.8$.

Posnetek št. 12



(a)






(b)

(c)

Slika A.12: MRI posnetek glave - pogled zgoraj. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c).

Vrednost parametra $\sigma_C = 2.1$, $\sigma_M = 2.8$.

Posnetek št. 13

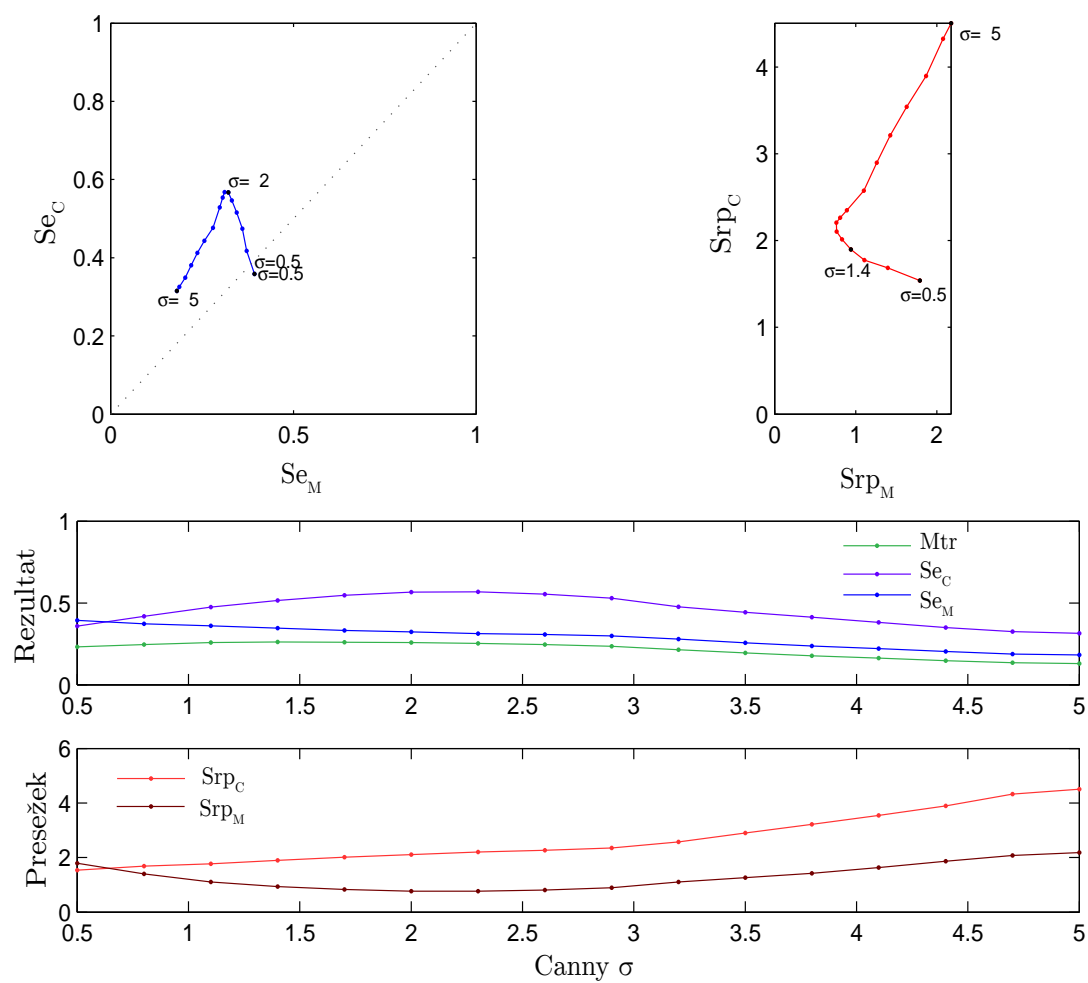
*(a)**(b)**(c)*

Slika A.13: MRI posnetek glave - pogled spredaj. Originalna slika (a) ter referenčni sliki pri uporabi Canny-jevega detektorja (b) in Marr-Hildreth-ovega detektorja (c).

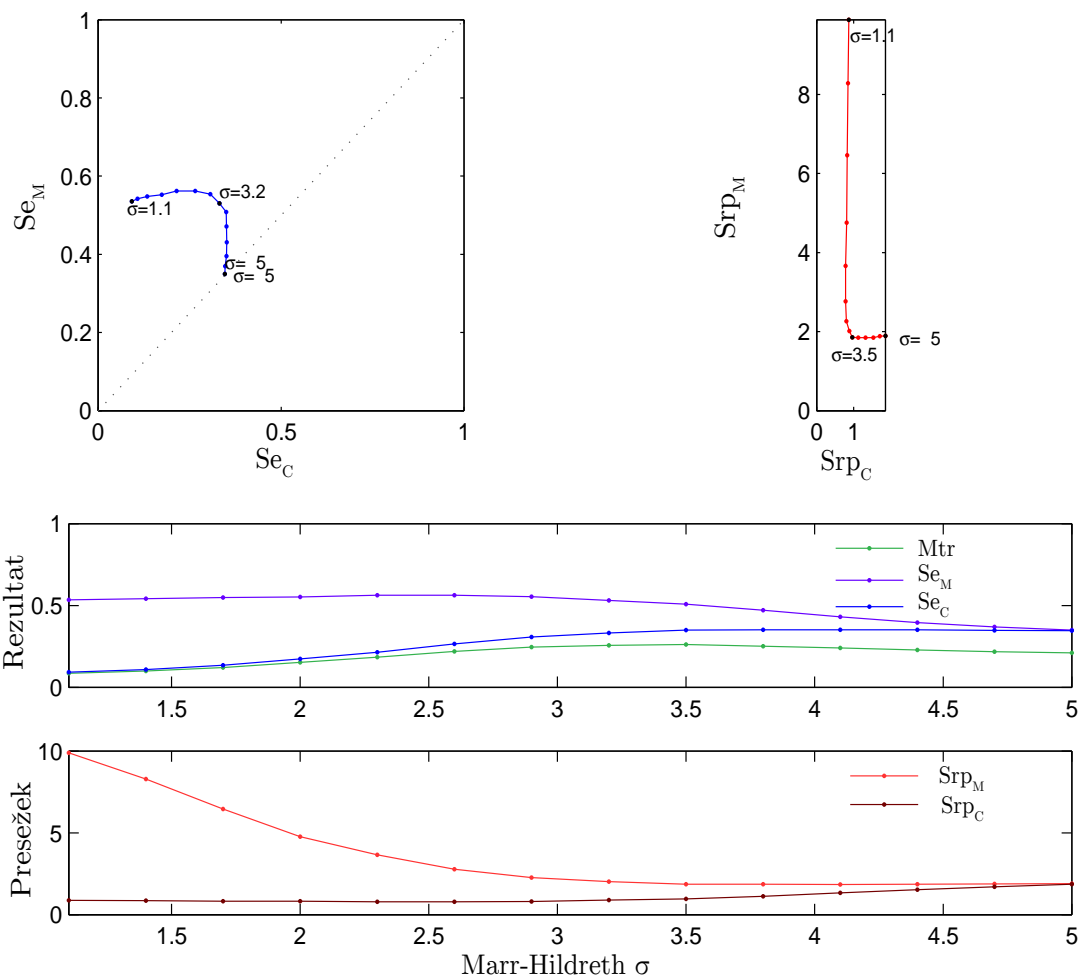
Vrednost parametra $\sigma_C = 2.1$, $\sigma_M = 2.8$.

B Rezultati evaluacije metrik nad rezultati detekcije.



Posnetek št. 1



Slika B.1: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 1 - CT).

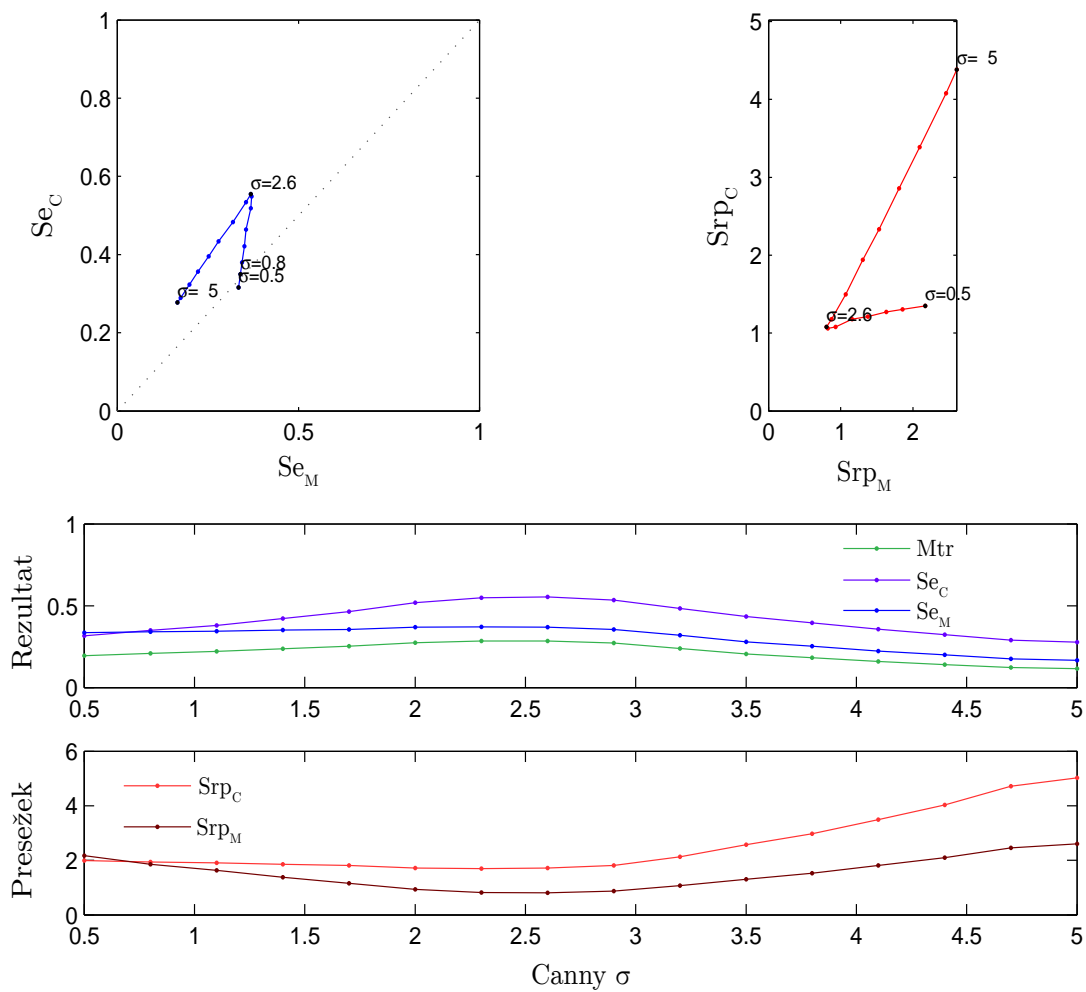


Slika B.2: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 1 - CT).

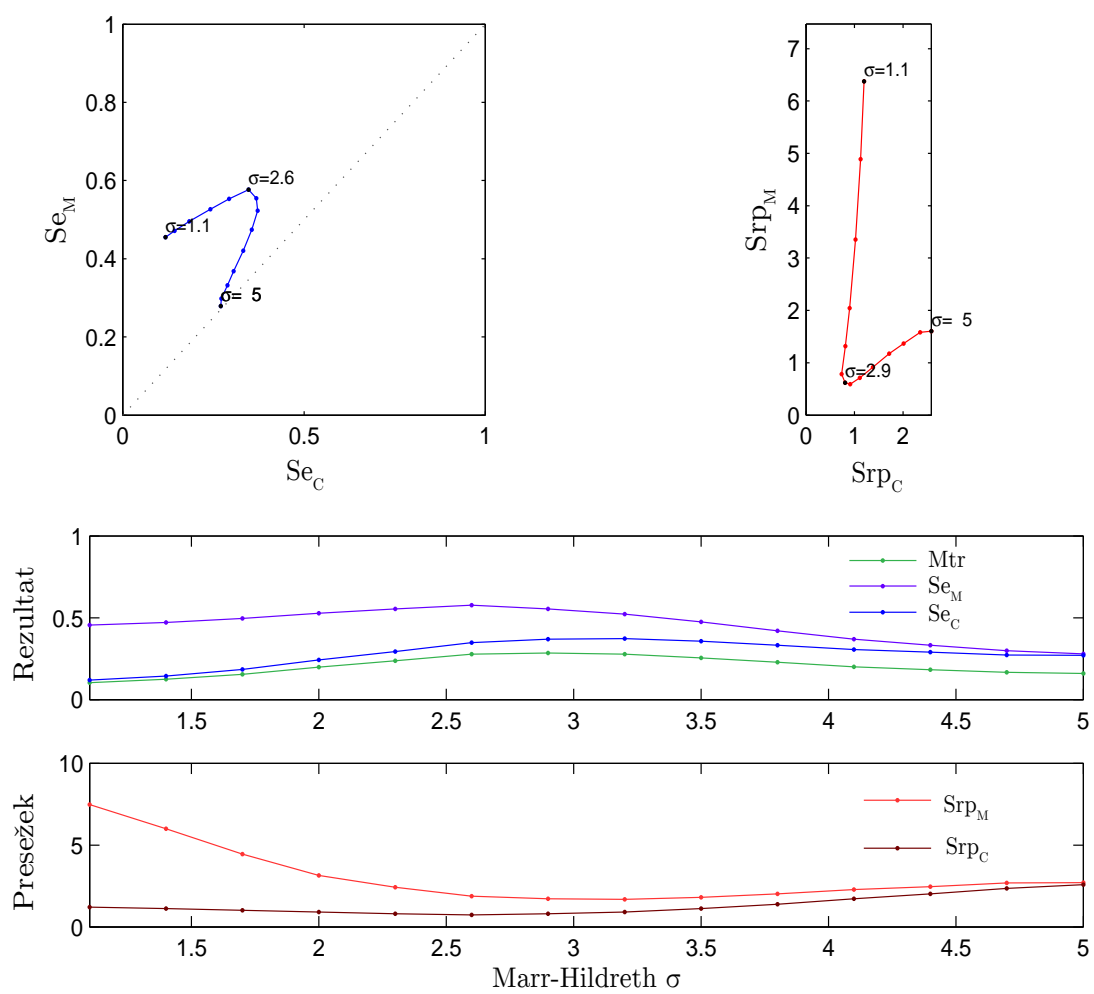


Slika B.3: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 1 - CT).



Posnetek št. 2



Slika B.4: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 2 - CT).

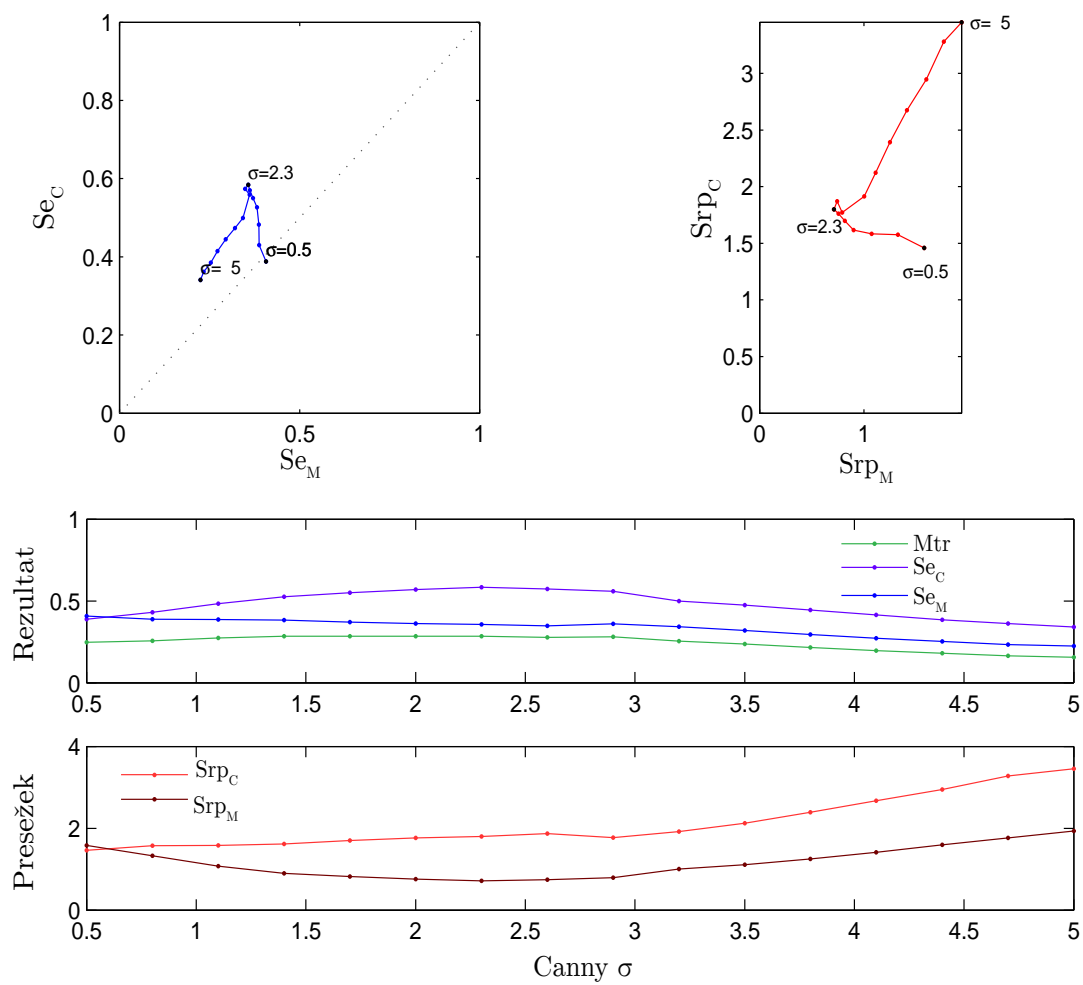


Slika B.5: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 2 - CT).

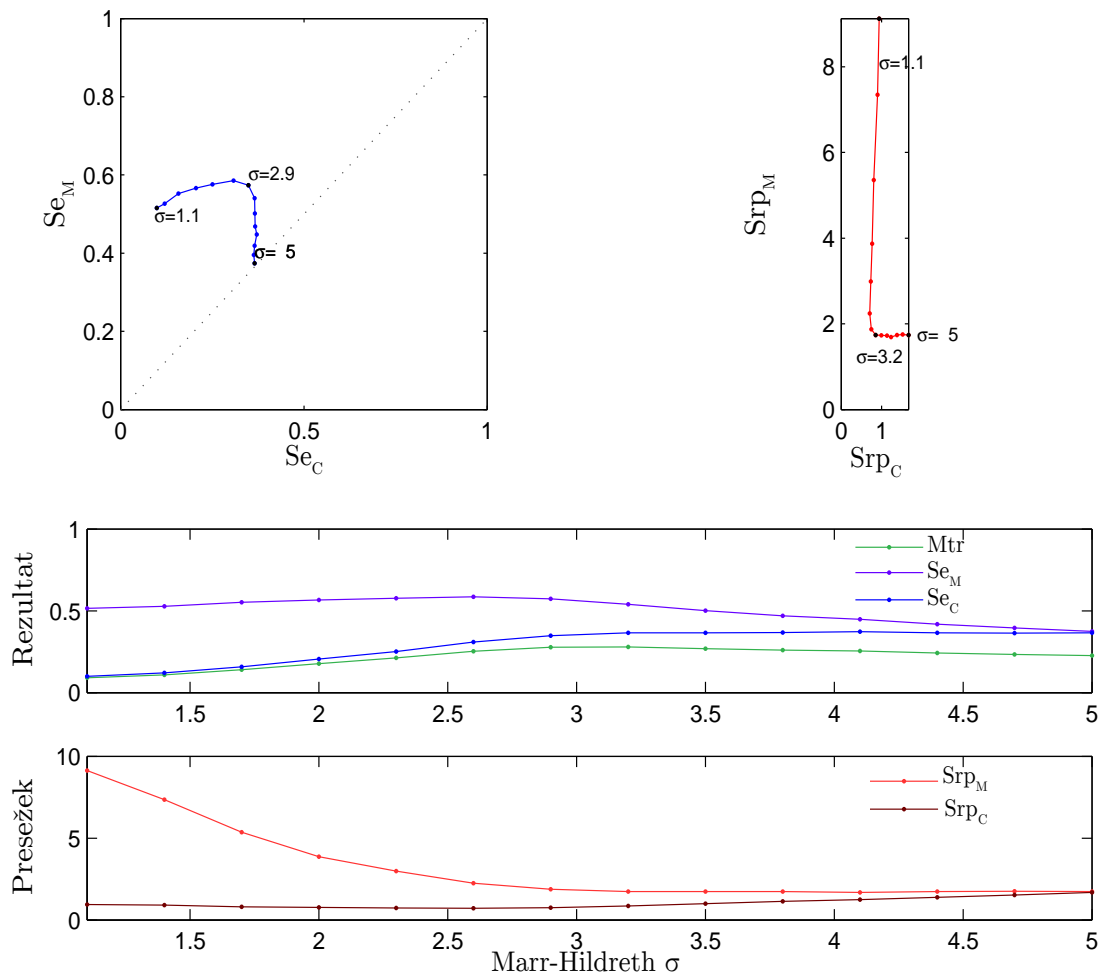


Slika B.6: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 2 - CT).

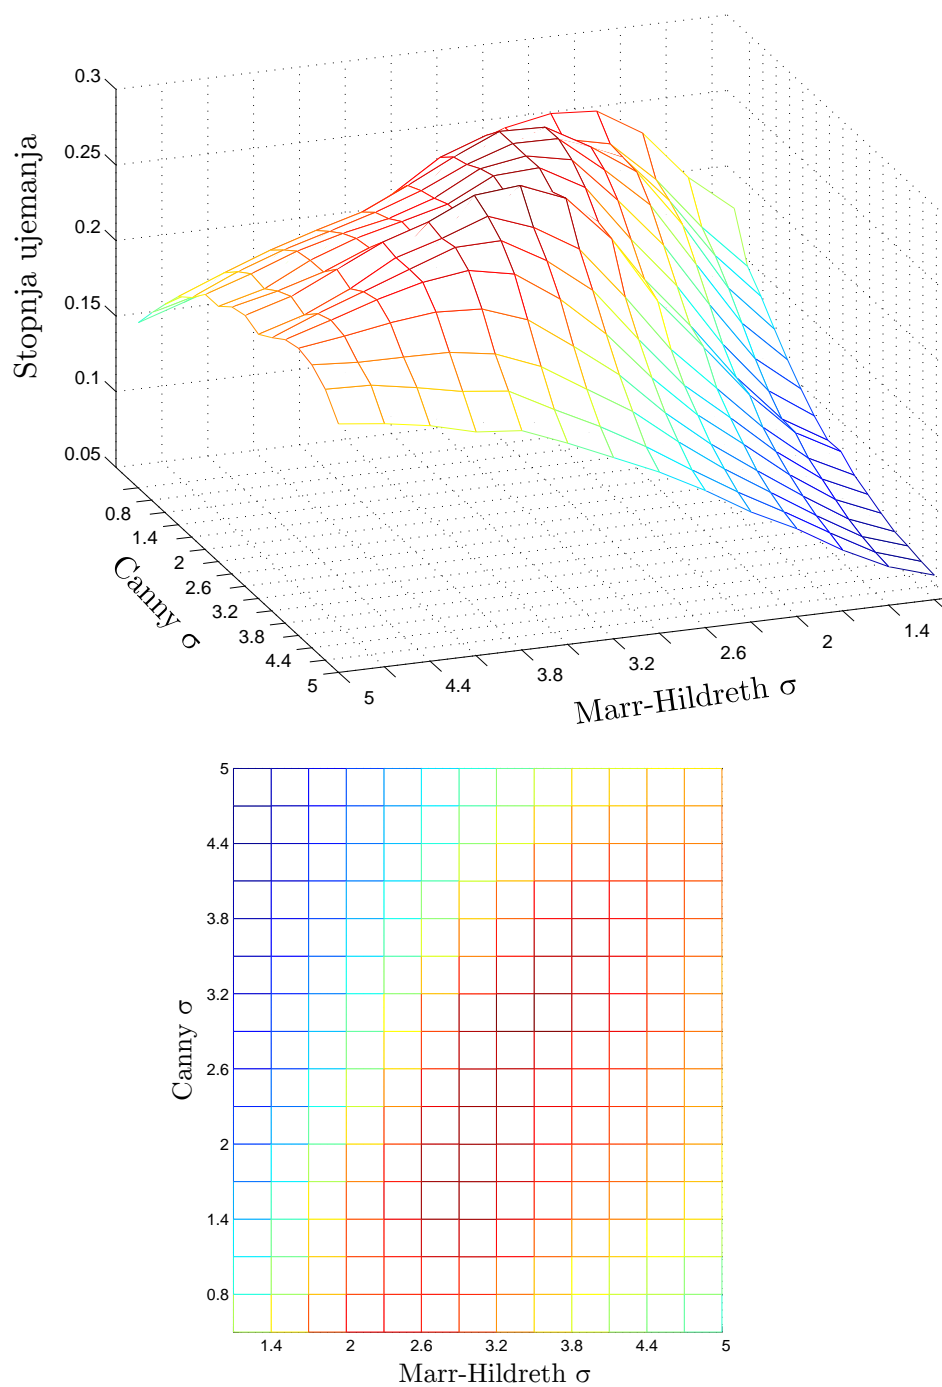
Posnetek št. 3



Slika B.7: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 3 - CT).

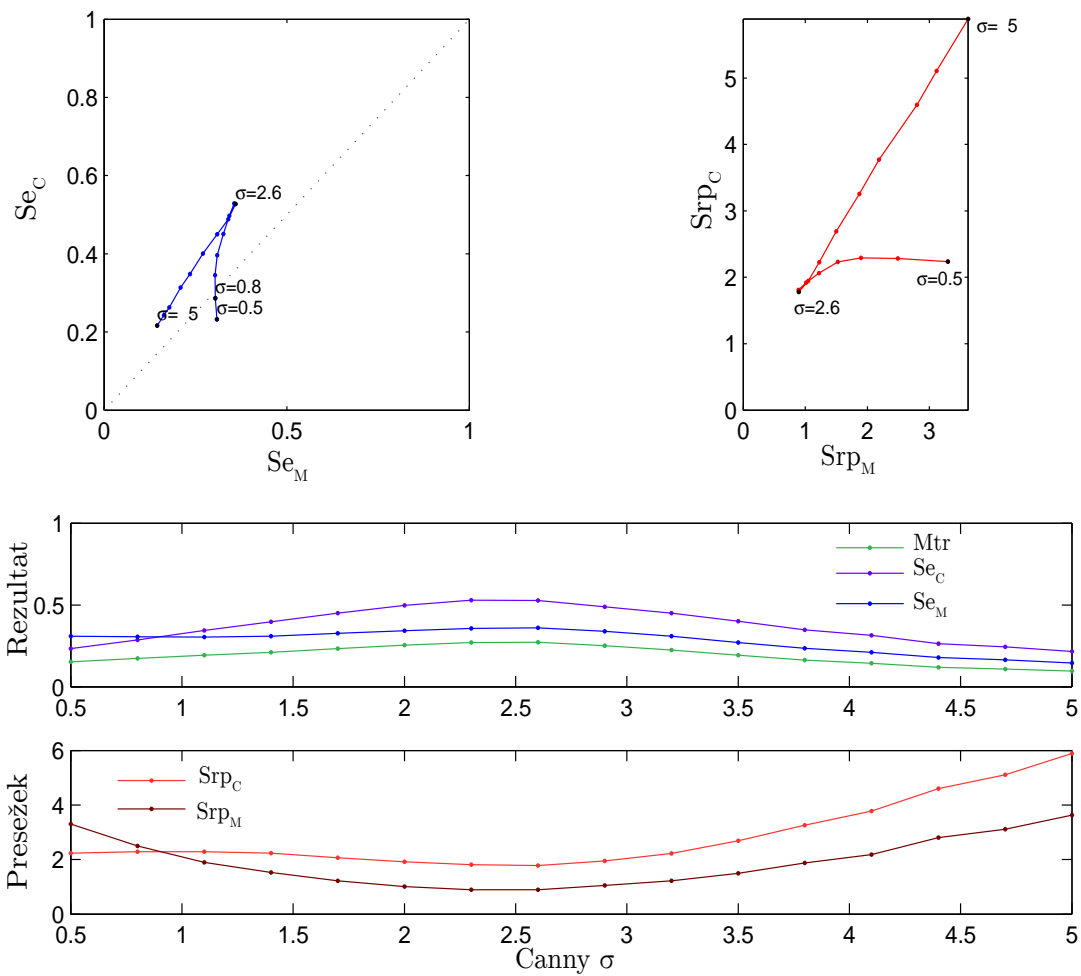


Slika B.8: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 3 - CT).

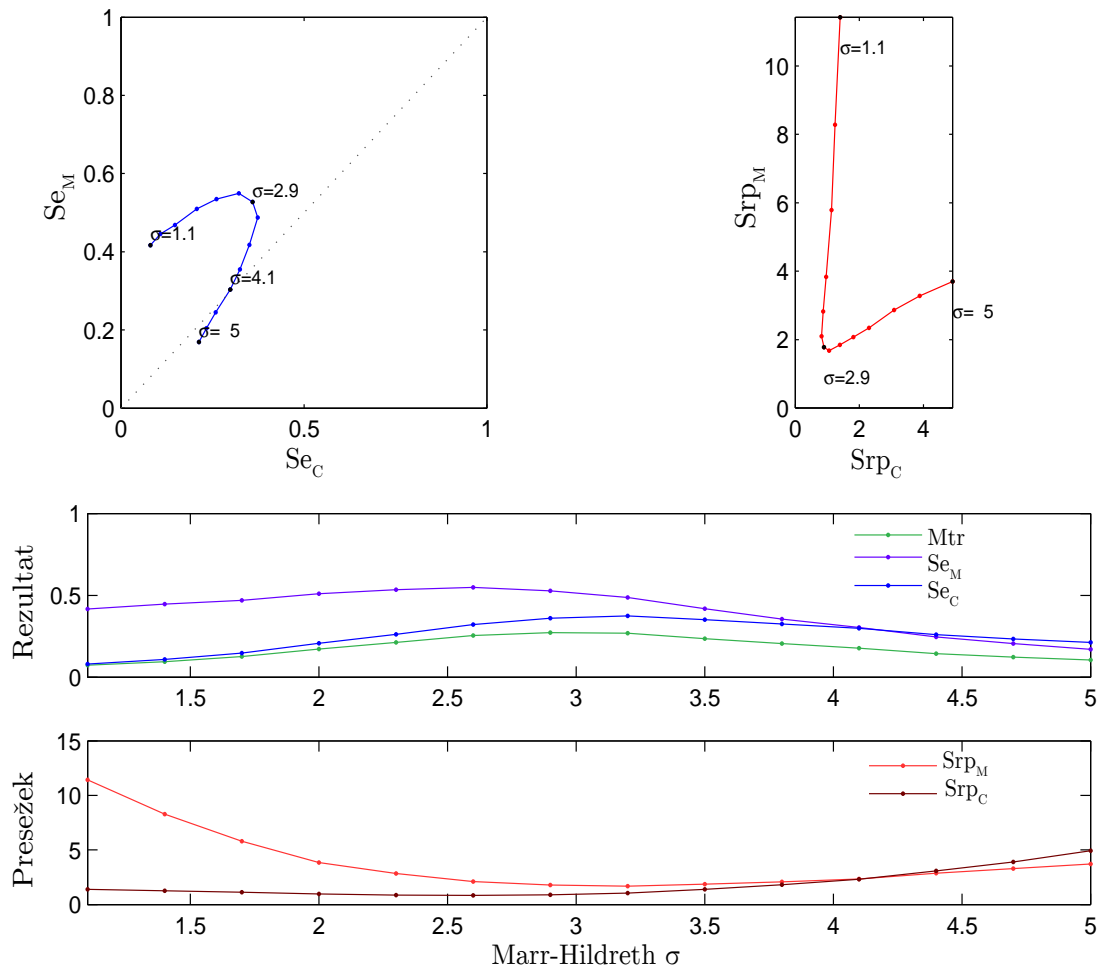


Slika B.9: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 3 - CT).



Posnetek št. 4



Slika B.10: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 4 - CT).

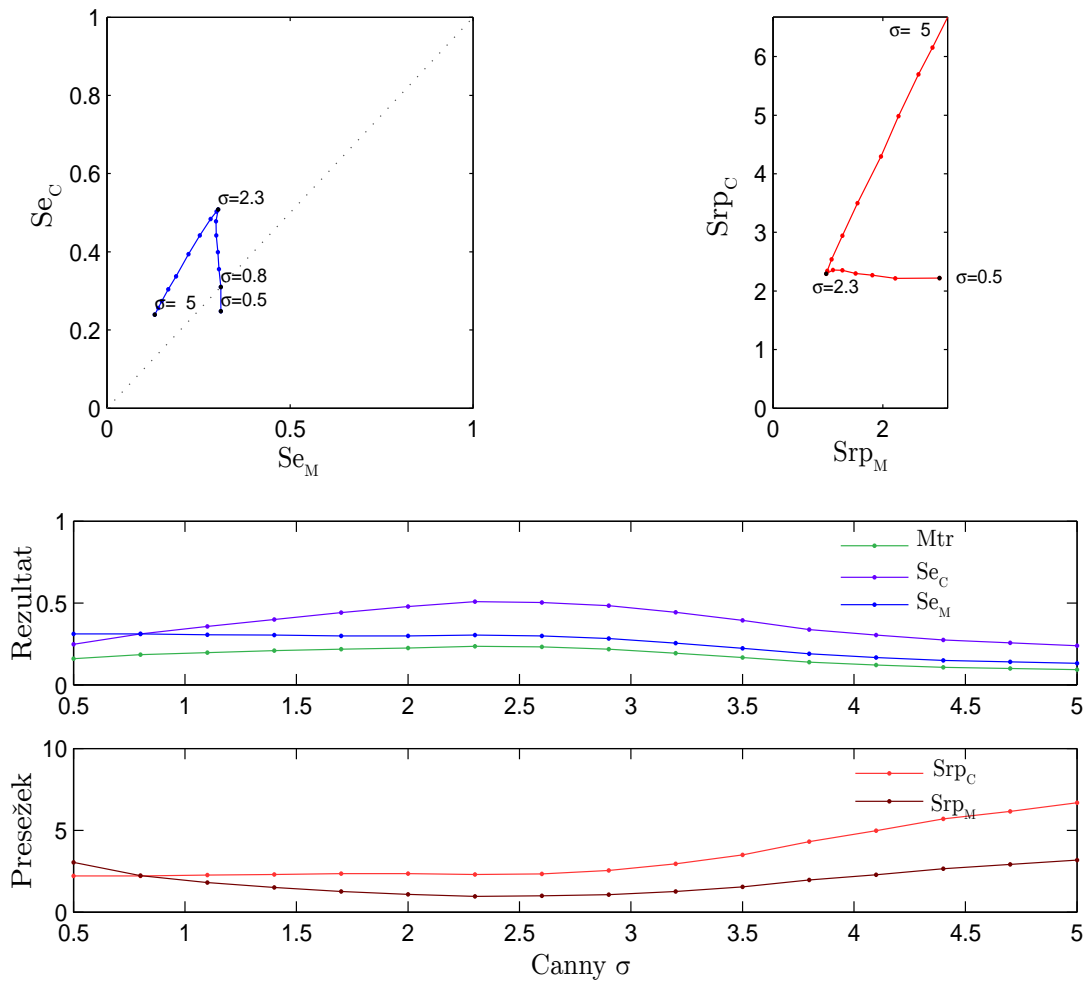


Slika B.11: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 4 - CT).

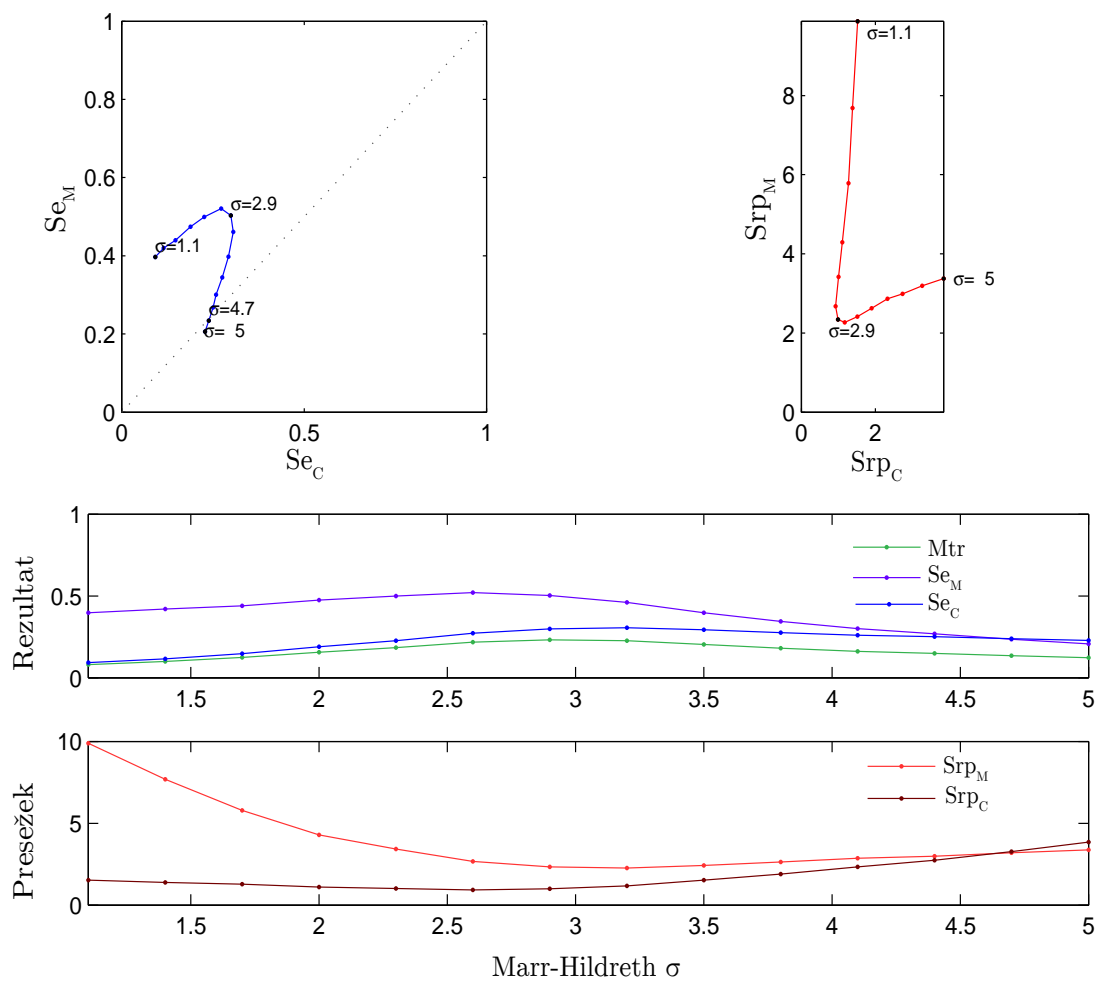


Slika B.12: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 4 - CT).



Posnetek št. 5



Slika B.13: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 5 - CT).

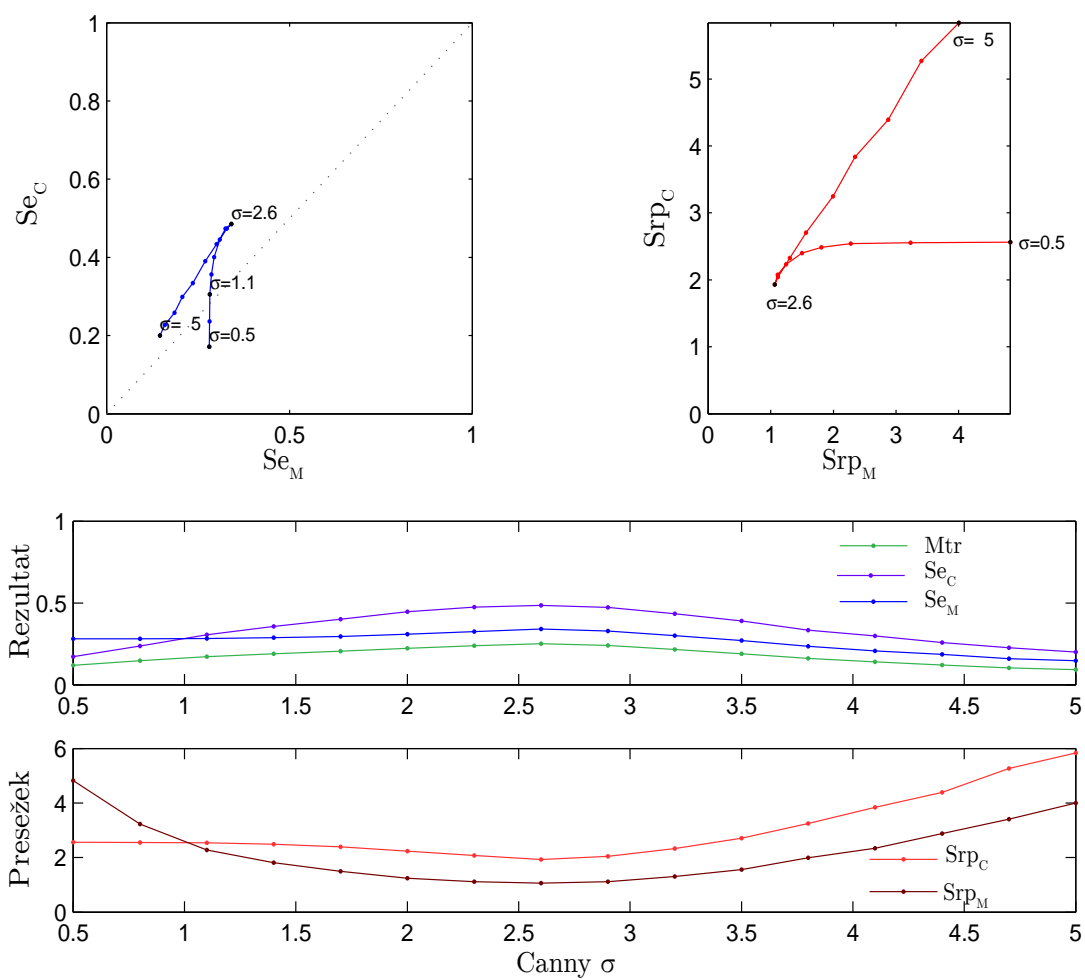


Slika B.14: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 5 - CT).

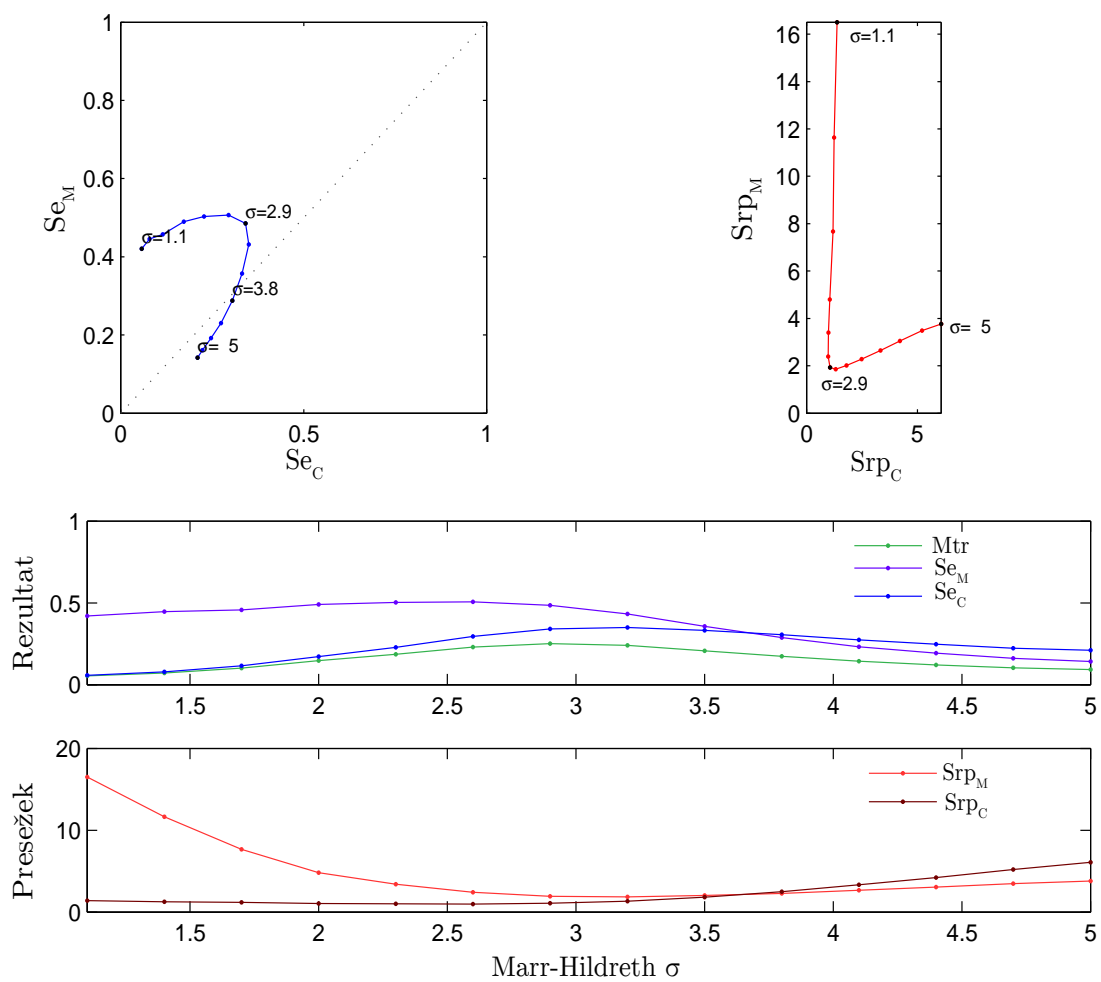


Slika B.15: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 5 - CT).



Posnetek št. 6



Slika B.16: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 6 - CT).

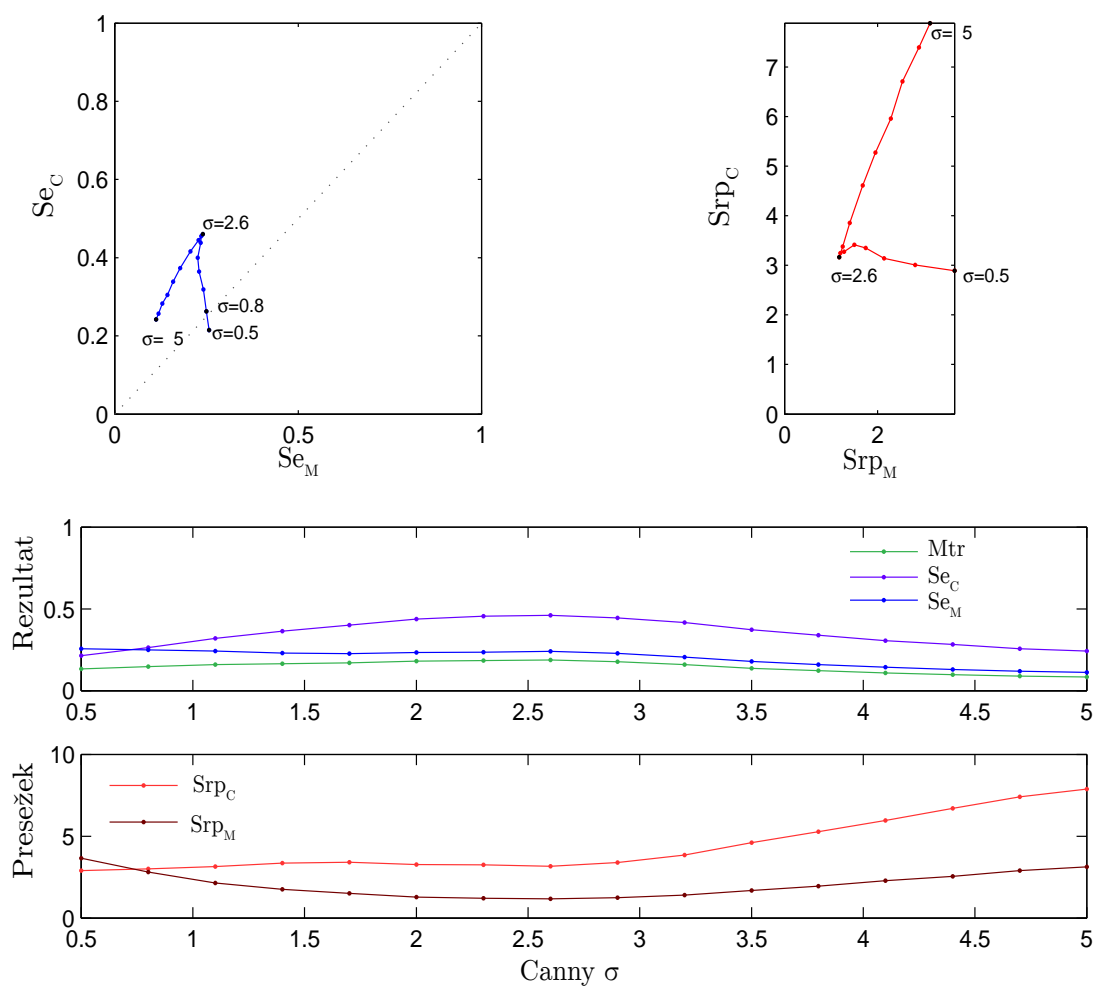


Slika B.17: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 6 - CT).

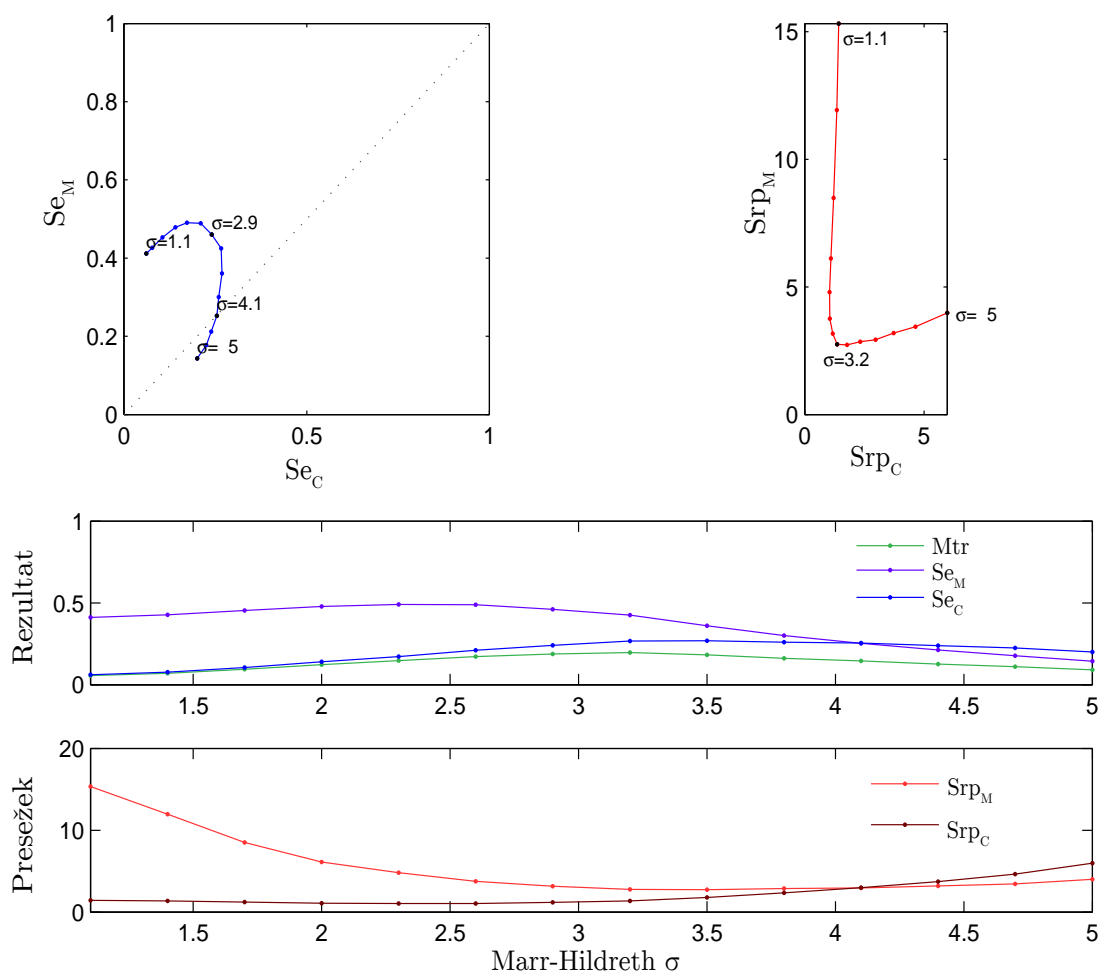


Slika B.18: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 6 - CT).



Posnetek št. 7



Slika B.19: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 7 - CT).

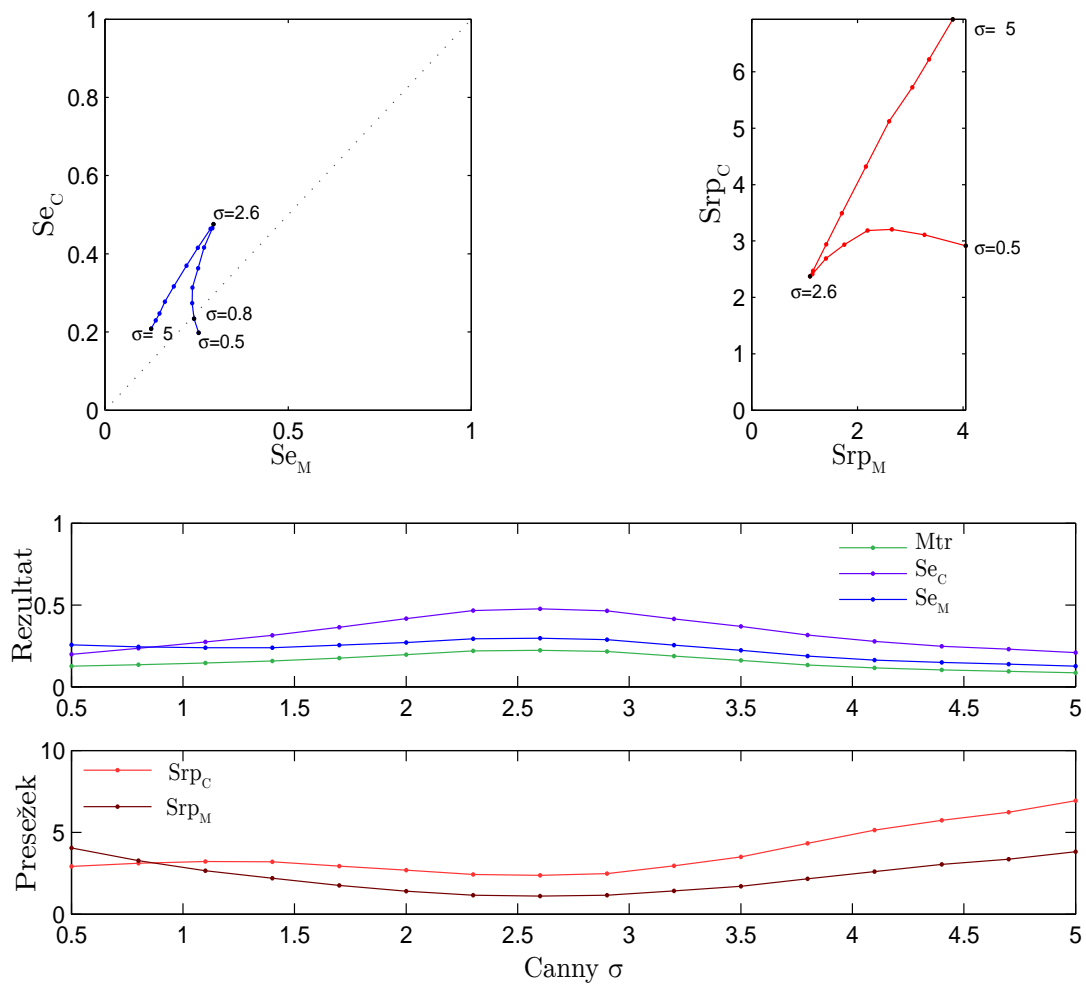


Slika B.20: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 7 - CT).

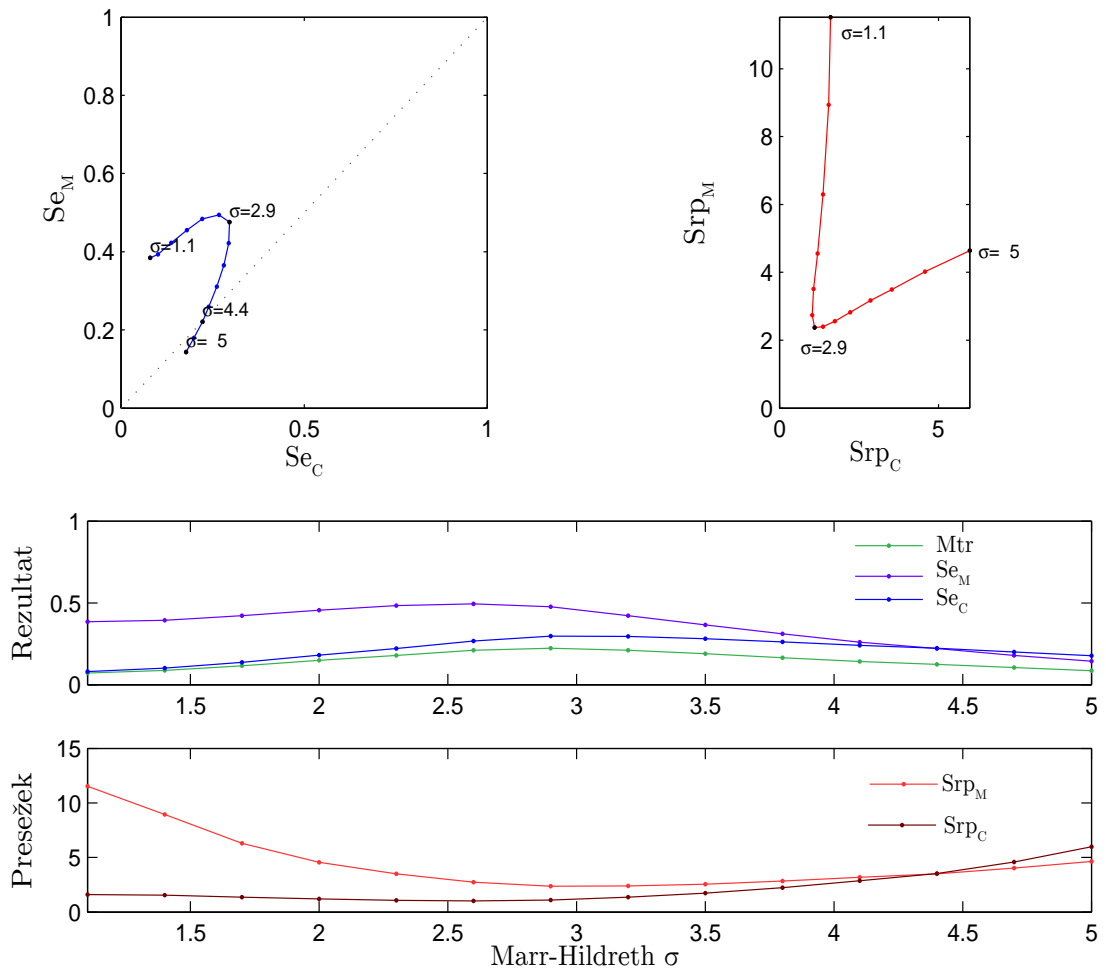


Slika B.21: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 7 - CT).



Posnetek št. 8



Slika B.22: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 8 - CT).

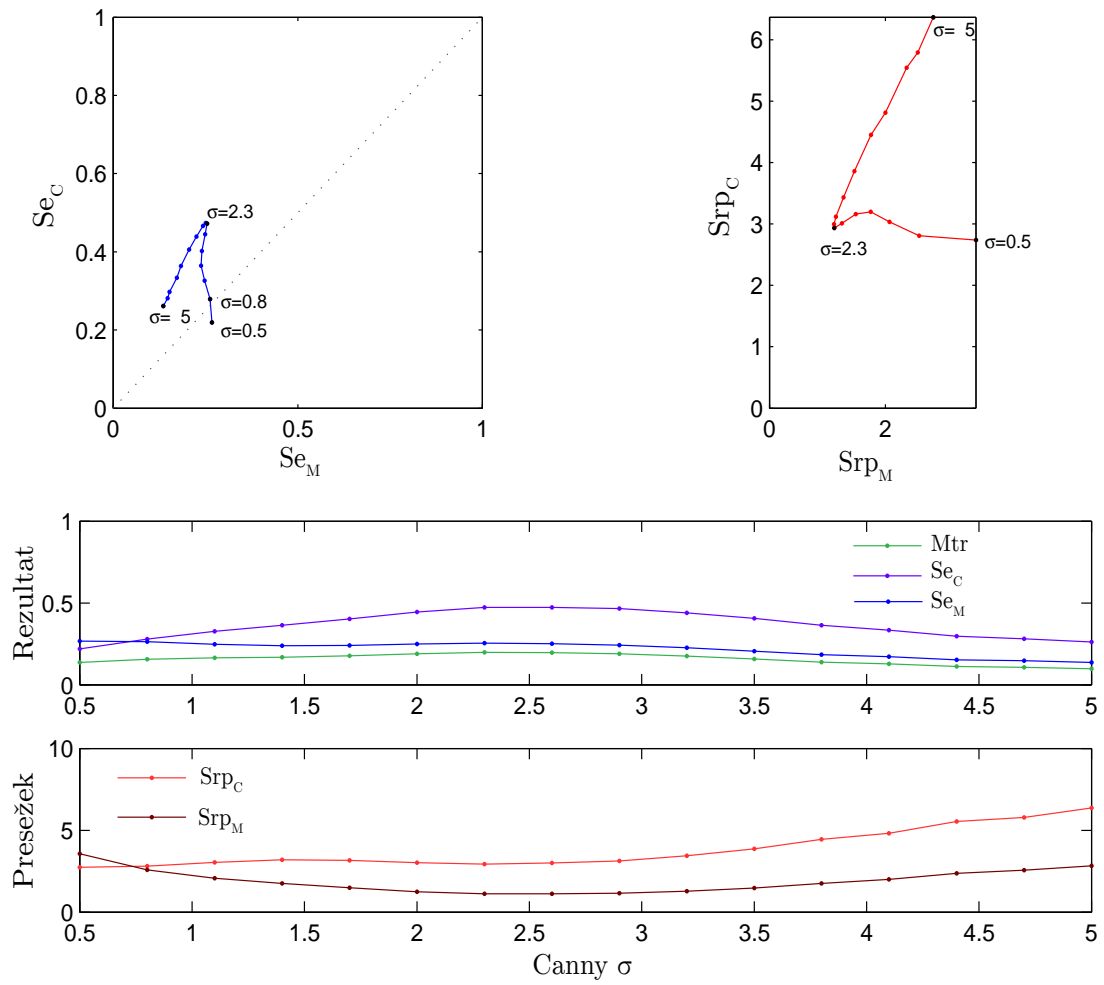


Slika B.23: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 8 - CT).

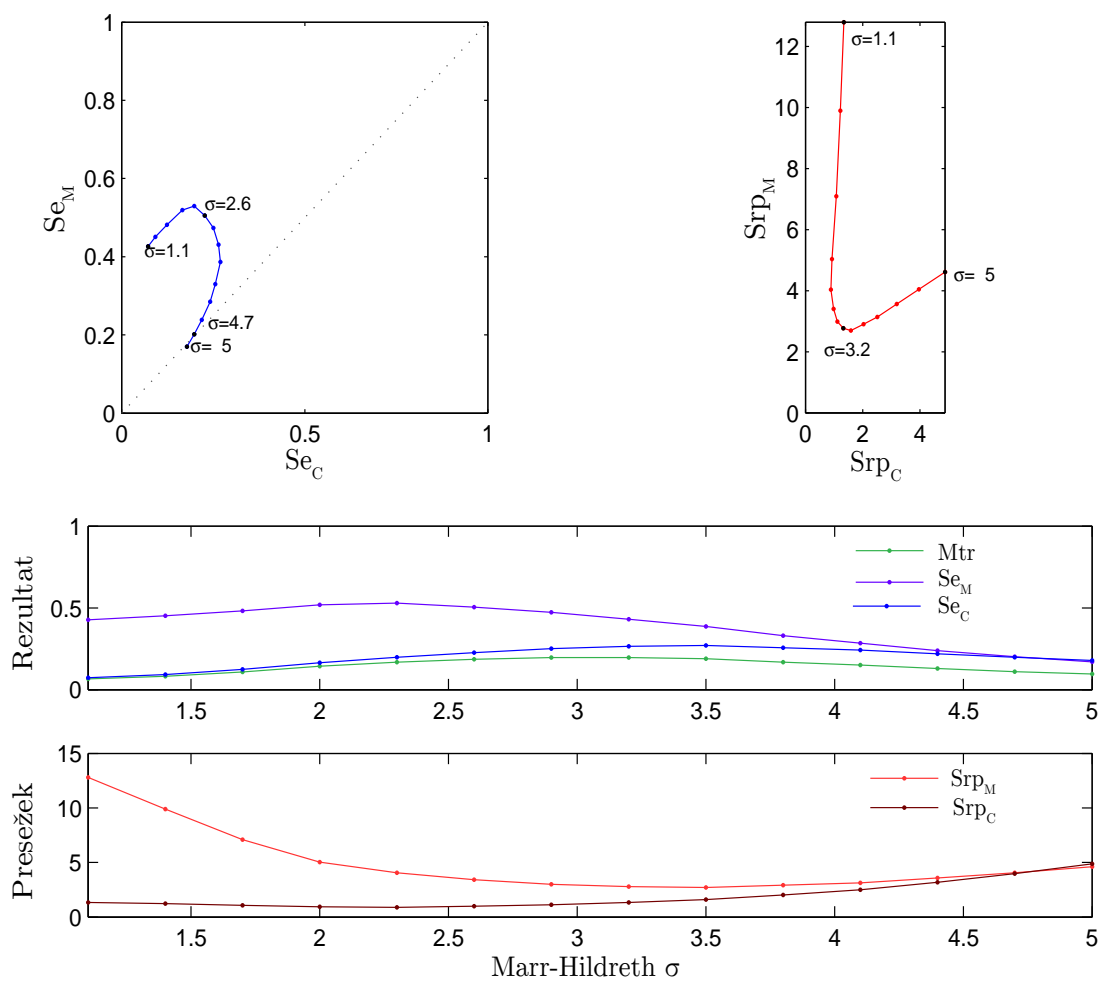


Slika B.24: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 8 - CT).



Posnetek št. 9



Slika B.25: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 9 - CT).

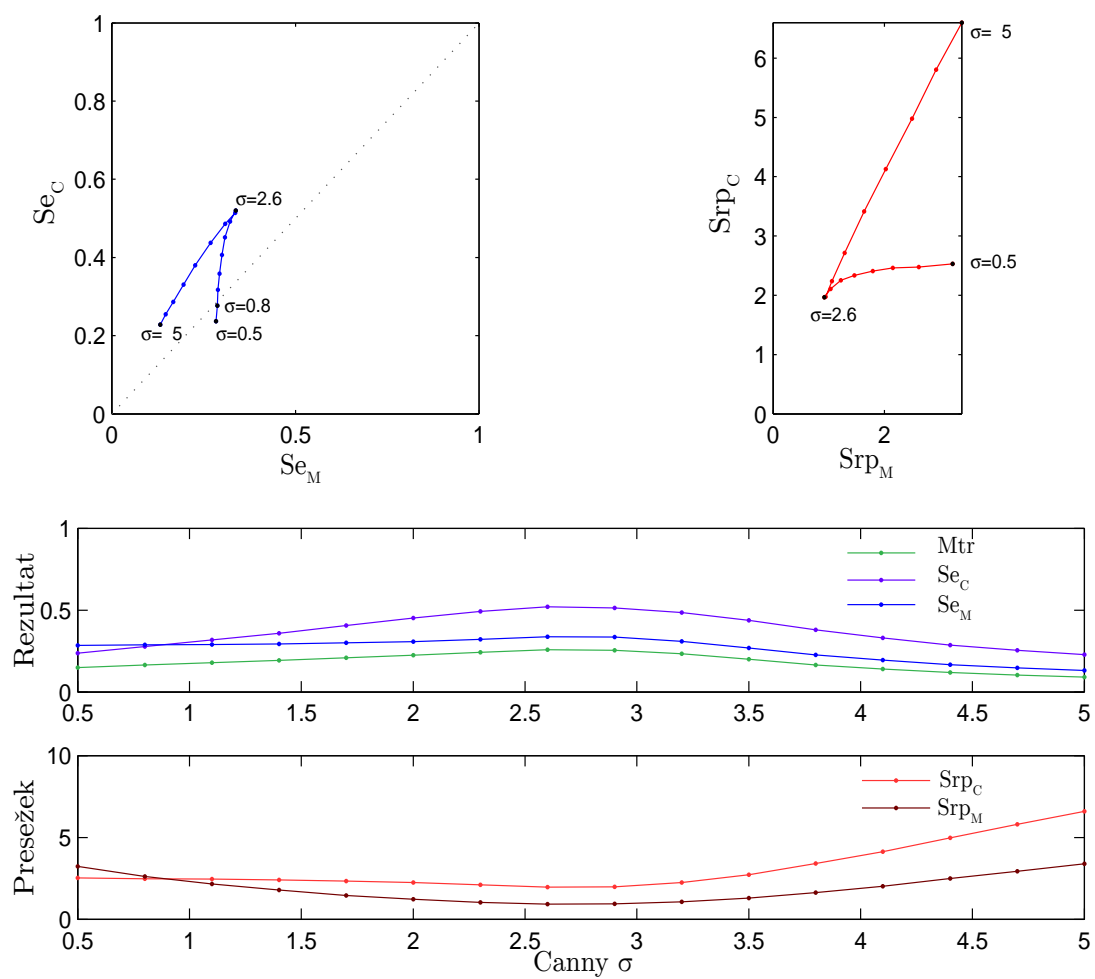


Slika B.26: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 9 - CT).

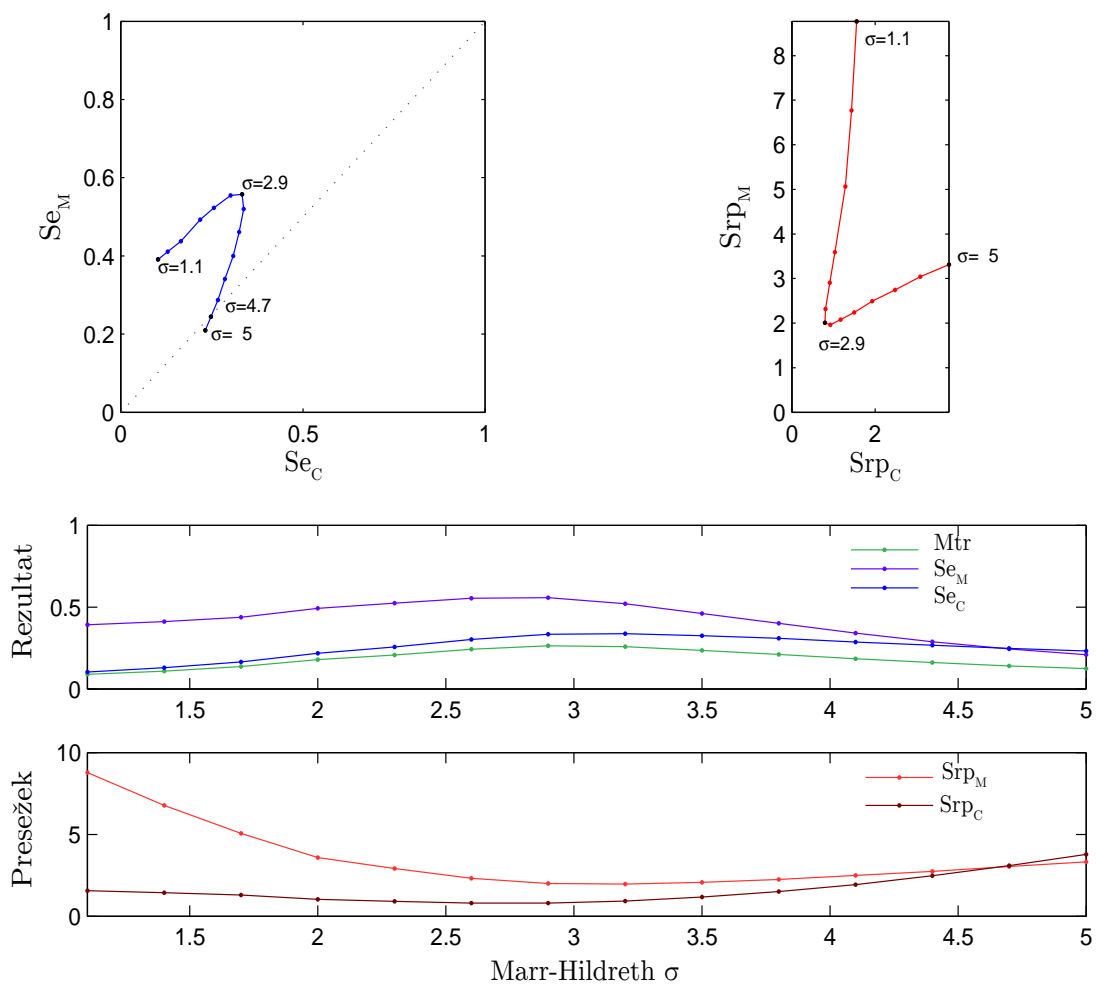


Slika B.27: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 9 - CT).

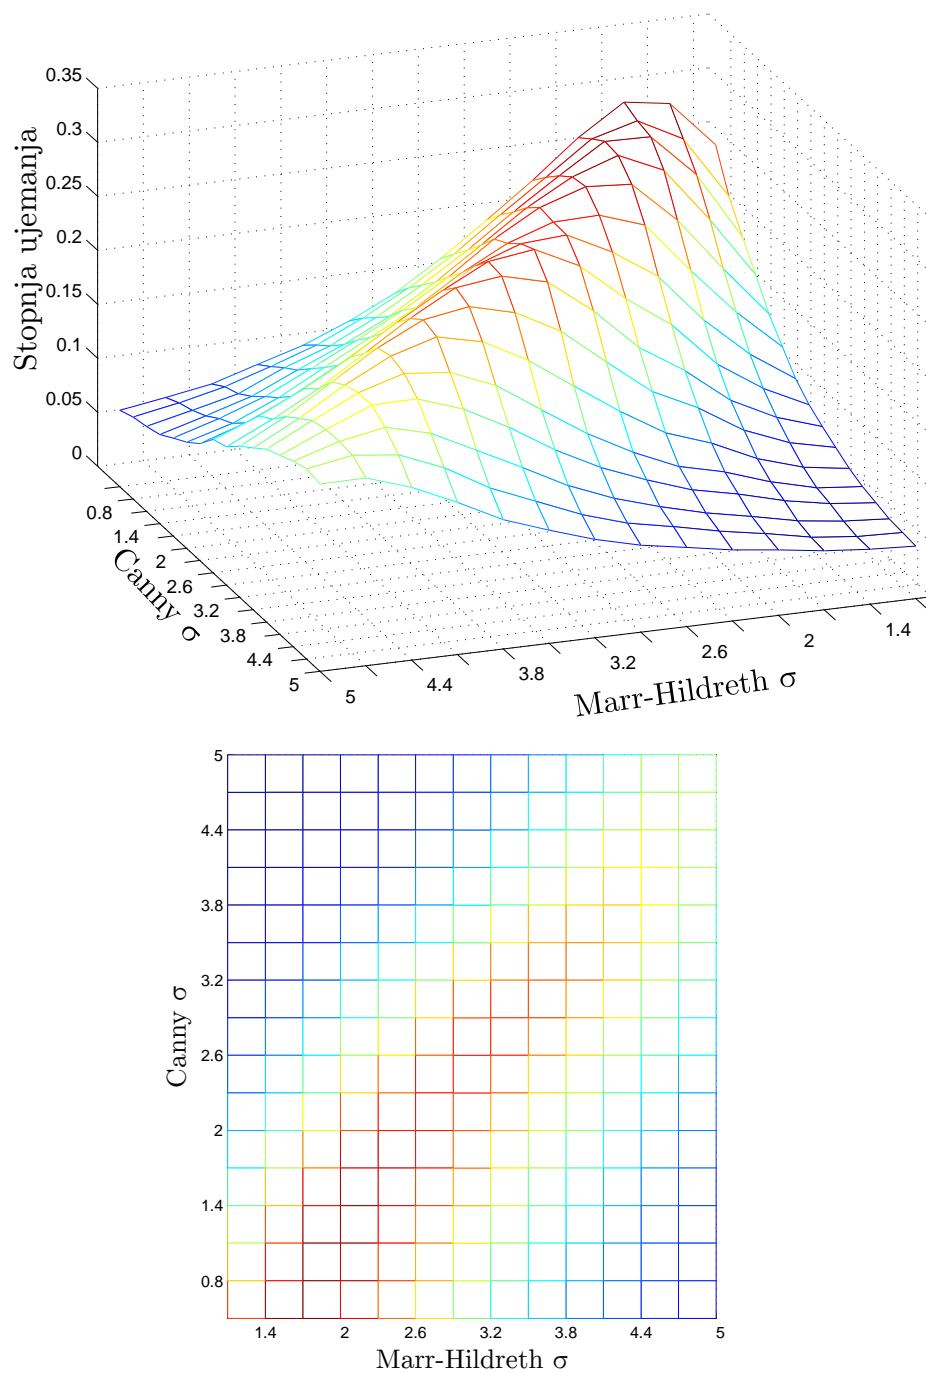
Posnetek št. 10



Slika B.28: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 10 - CT).

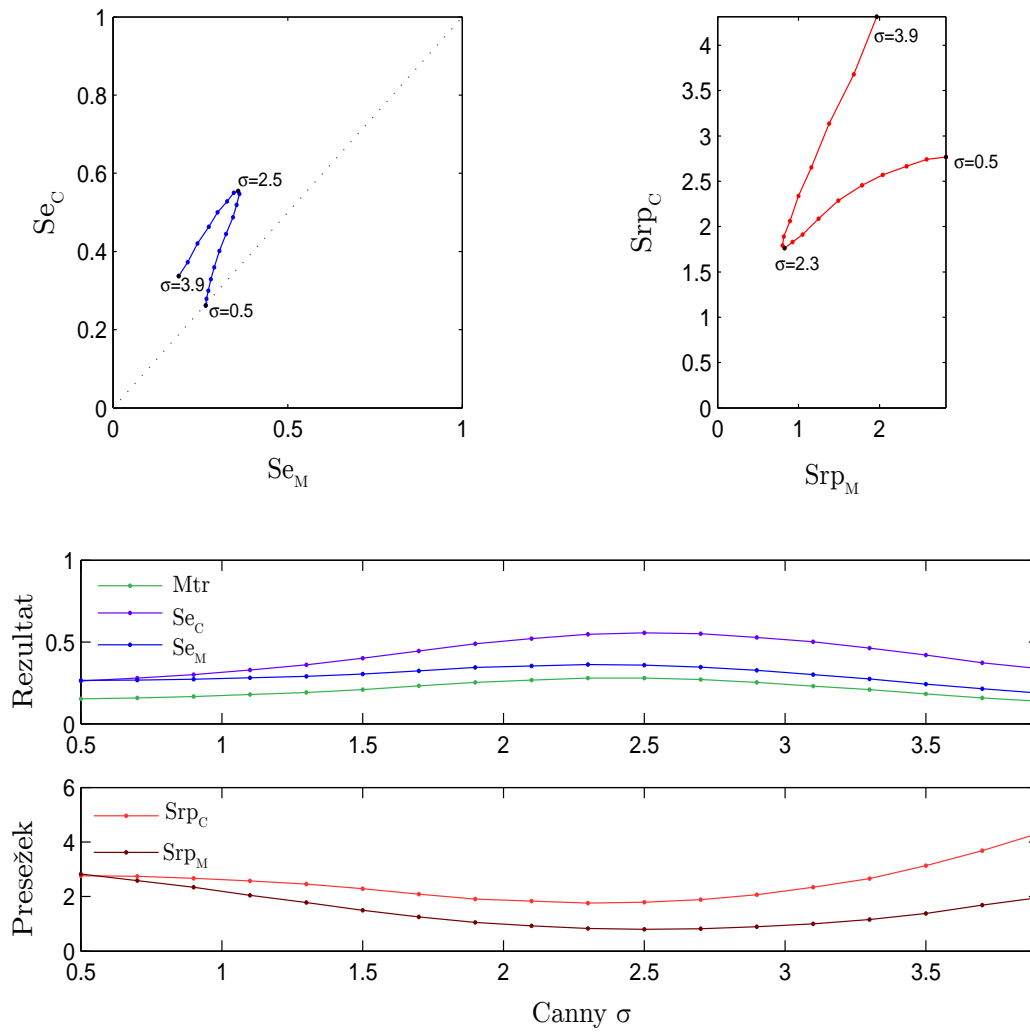


Slika B.29: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 10 - CT).

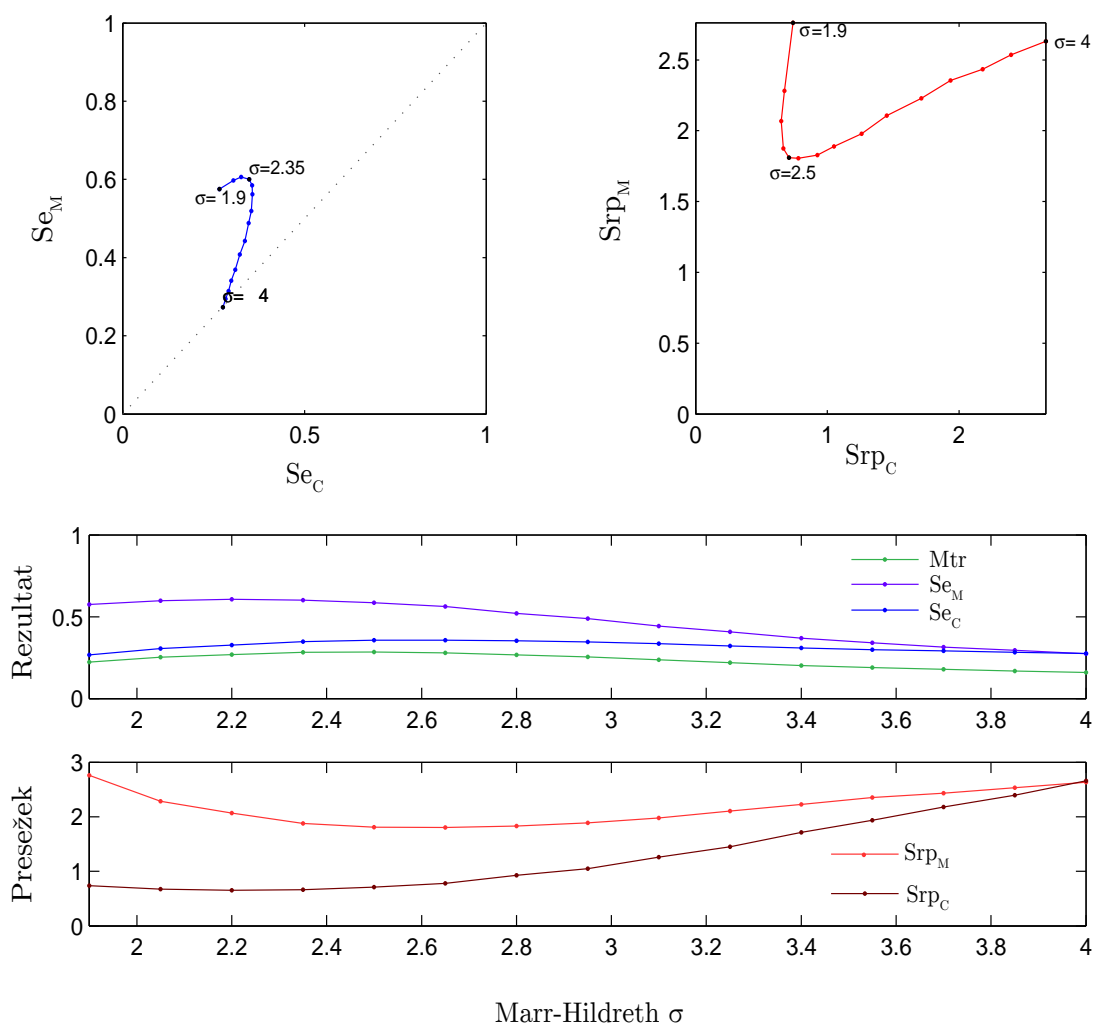


Slika B.30: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 10 - CT).

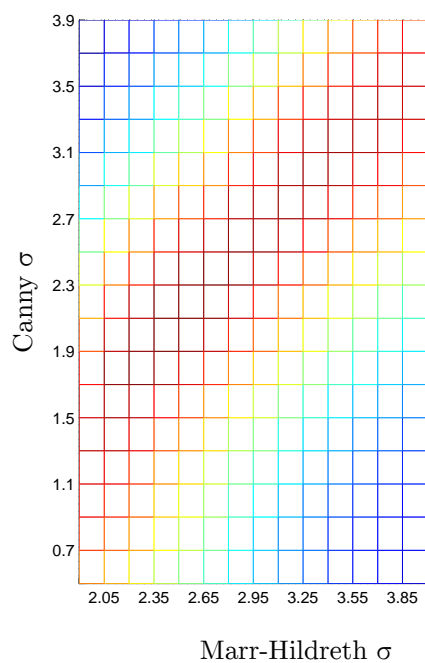

Posnetek št. 11



Slika B.31: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 11 - MRI).

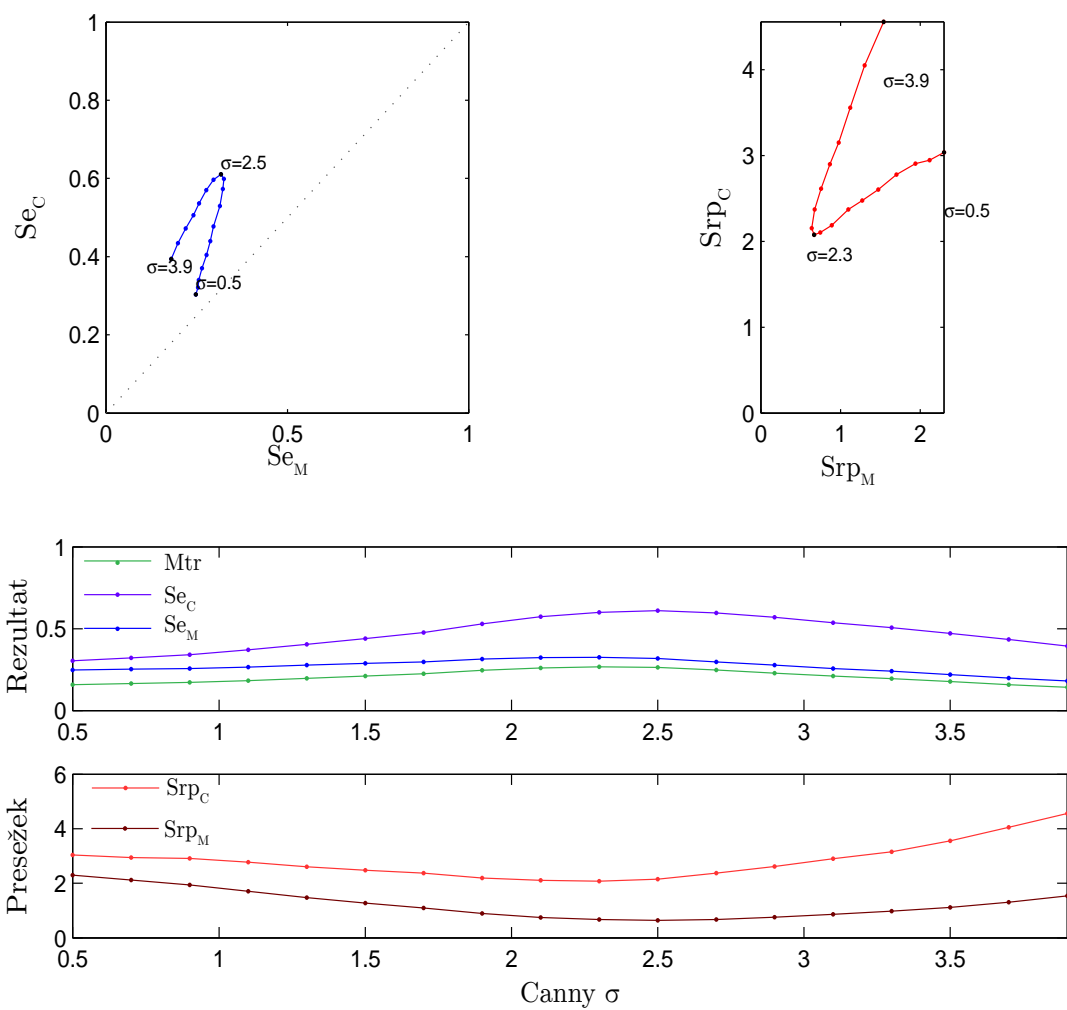


Slika B.32: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 11 - MRI).

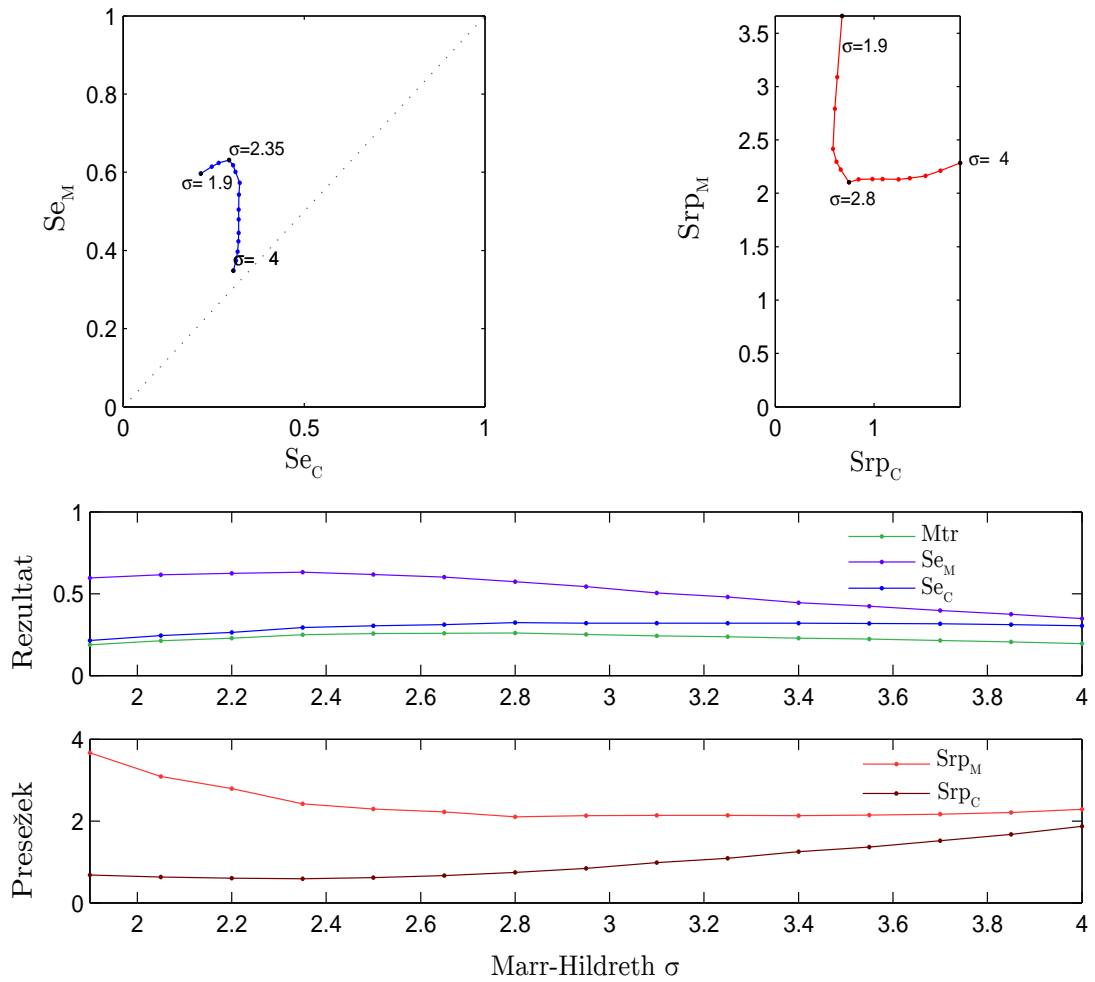


Slika B.33: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 11 - MRI).



Posnetek št. 12



Slika B.34: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 12 - MRI).

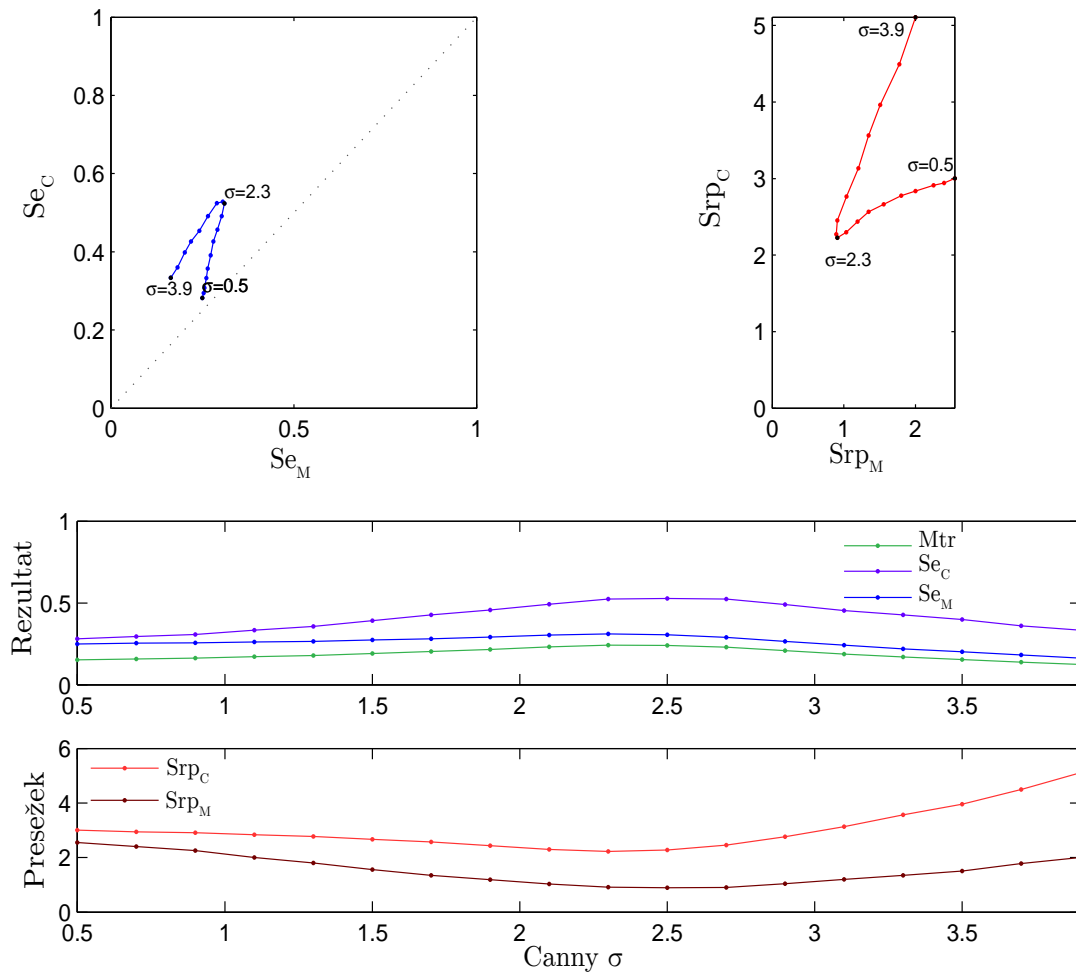


Slika B.35: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 12 - MRi).




Slika B.36: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 12 - MRI).

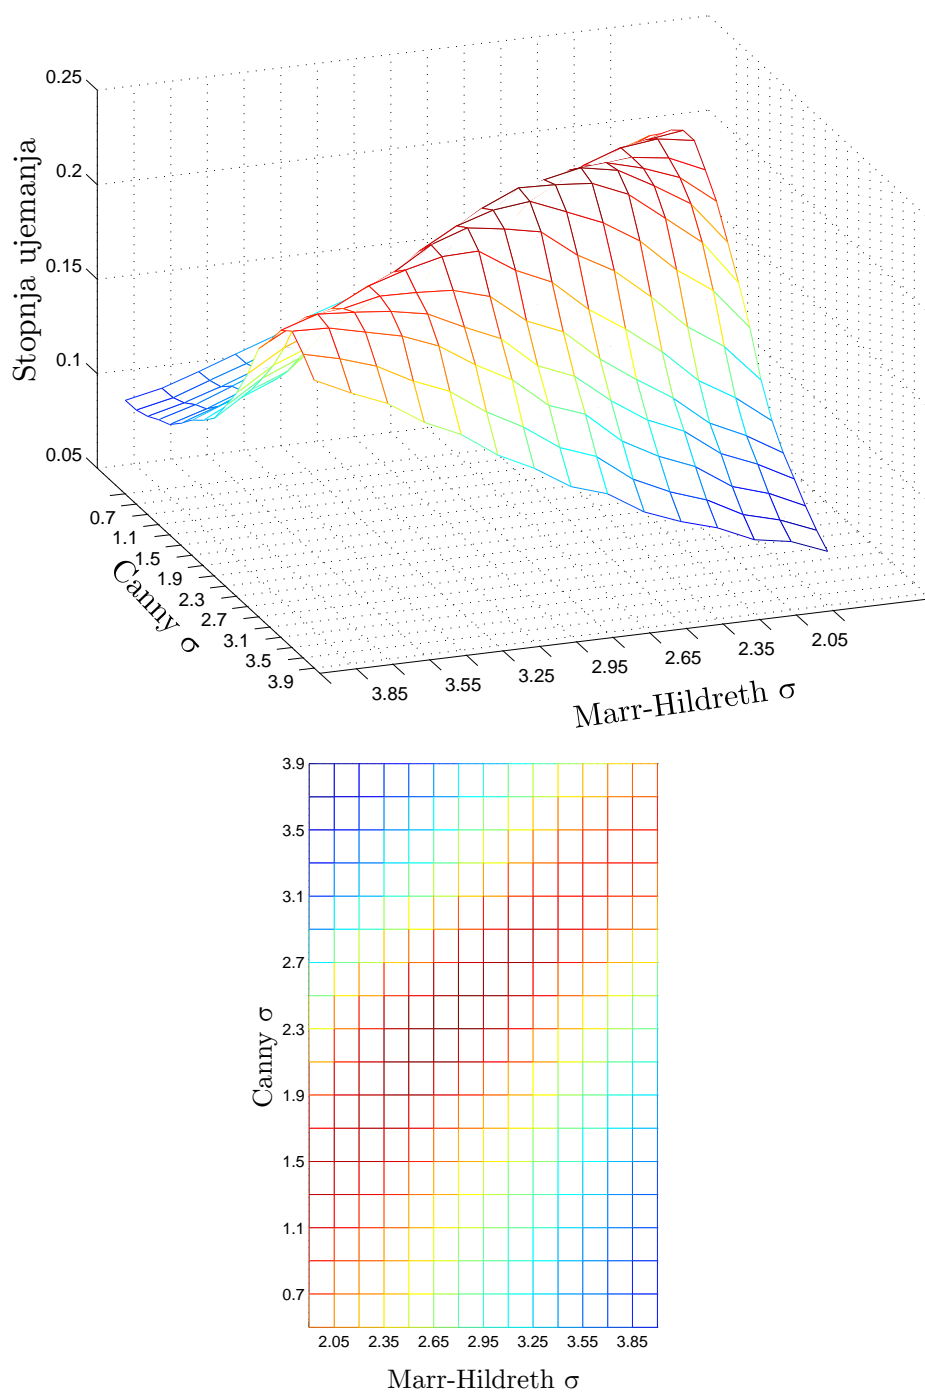
Posnetek št. 13



Slika B.37: Rezultat uporabe metrik - referenca je Marr-Hildrethov detektor (posnetek št. 13 - MRI).



Slika B.38: Rezultat uporabe metrik - referenca je Cannyjev detektor (posnetek št. 13 - MRI).



Slika B.39: Stopnja ujemanja detektorjev za vse kombinacije vrednosti parametra σ (posnetek št. 13 - MRI).