




VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ
ÚSTAV ELEKTROTECHNOLOGIE

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF ELECTRICAL AND ELECTRONIC
TECHNOLOGY

SEGMENTACE V MIKROSKOPICKÝCH OBRAZECH Z ROSTLINNÝCH PREPARÁTŮ

SEGMENTATION IN MICROSCOPIC IMAGES

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS


AUTOR PRÁCE
AUTHOR

JAROSLAV VLK

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. RADIM KOLÁŘ, Ph.D.

BRNO 2009



**VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ**

**Fakulta elektrotechniky
a komunikačních technologií**

Ústav elektrotechnologie

Bakalářská práce

bakalářský studijní obor
Mikroelektronika a technologie

Student: Jaroslav Vlk

ID: 83144

Ročník: 3

Akademický rok: 2008/2009

NÁZEV TÉMATU:

Segmentace v mikroskopických obrazech z rostlinných preparátů

POKYNY PRO VYPRACOVÁNÍ:

Seznamte se s vlastnostmi mikroskopických obrazů rostlinných preparátů. Dále prostudujte obecné metody pro segmentaci objektů v obraze. V prostředí Matlab realizujte metodu segmentace, která bude založená na prahování snímku. Dále použijte některou pokročilejší metodu pro segmentaci dle doporučení vedoucího práce. Zabývejte se také možnostmi předzpracování těchto snímků.

DOPORUČENÁ LITERATURA:

Podle pokynů vedoucího práce.

Termín zadání:

Termín odevzdání:

Vedoucí práce: Ing. Radim Kolář, Ph.D.

prof. Ing. Radimír Vrba, CSc.

Předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

Anotace

Práce studuje vlastnosti mikroskopických obrazů a následně tyto vlastnosti uplatňuje při segmentaci obrazu. Práce se snaží využívat hlavně jednodušší metody zpracování obrazu. Zároveň se zabývá metodami pro předzpracování obrazu. Při volbě metody a jejího použití klade důraz na rychlost a jednoduchost výpočtu.

Klíčová slova

segmentace, přizpůsobená filtrace, mikroskopický obraz, předzpracování

Abstrakt

Work studying the properties of microscopic images and then the following applies in the segmentation of the image. Work is trying to use a simpler methods image processing mainly. At the same time, deals with methods for preprocessing image. In the choice of methods and the use of emphasis on speed and simplicity of calculation.

Keywords

segmentation, matched filtering, microscopic image, preprocessing

Prohlášení

Prohlašuji, že bakalářskou práci na téma Segmentace v mikroskopických obrazech z rostlinných preparátů jsem vypracoval samostatně pod vedením vedoucího semestrálního projektu a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedeného semestrálního projektu dále prohlašuji, že v souvislosti s vytvořením tohoto projektu jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne 1. června 2009

.....
podpis autora

Poděkování

Děkuji vedoucímu bakalářské práce Ing. Radimu Kolářovi, Ph.D za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mého semestrálního projektu.

V Brně dne 1. června 2009

.....
podpis autora

Obsah

Úvod.....	8
1 Analýza vstupích dat	9
1.1 Pořízení digitálního záznamu	9
1.2 Parametry pořízeného vzorku.....	9
2 Metody zpracování	20
2.1 Charakteristika a rozdělení segmentačních metod	20
2.1.1 Metody založené na detekci hran	20
2.1.2 Metody založené na detekci oblastí	21
2.1.3 Statické metody segmentace	21
2.1.4 Hybridní metody	21
2.1.5 Znalostní metody.....	21
2.2 Volba metody segmentace.....	22
2.3 Metody předzpracování.....	22
2.3.1 Filtrace přizpůsobenými filtry	22
2.3.2 Anizotropní difúze.....	33
2.4 Metody segmentace	35
2.4.1 Segmentace obrazu prahováním.....	35
2.4.2 Filtrace mediánovým filtrem	37
2.4.3 Connected component labelling	38
2.4.4 Matematická morfologie	40
3 Závěr.....	45
Seznam použité literatury.....	46

Seznam obrázků

Obrázek 1.1: Vstupní obraz	10
Obrázek 1.2: Vstupní obraz – šedotónové zobrazení	10
Obrázek 1.3: Histogram úrovní šedi vstupního obrazu	11
Obrázek 1.4: Vybraná rostlina pro další zpracování	11
Obrázek 1.5: Histogram úrovní šedi vybrané rostliny	11
Obrázek 1.6: Pozadí obrazu	12
Obrázek 1.7: Lístky rostliny	13
Obrázek 1.8: Kořen rostliny	13
Obrázek 1.9: Vlákna kořenné části	14
Obrázek 1.10: Ukázkový profil vlásečnic s úzkým profilem	15
Obrázek 1.11: Ukázkový profil vlásečnic s širokým profilem	15
Obrázek 1.12: Ukázkový profil vlásečnic se středně širokým profilem	16
Obrázek 1.13: Výřez z vybrané rostliny	17
Obrázek 1.14: Výřez rostliny pro nastavení segmentačních metod	18
Obrázek 1.15: Vliv zbarvení rostliny	19
Obrázek 2.1: Body pro tvorbu filtrů	24
Obrázek 2.2: Úzký filtr – nejmenší amplituda	25
Obrázek 2.3: Úzký filtr – střední amplituda	25
Obrázek 2.4: Úzký filtr – největší amplituda	26
Obrázek 2.5: Středně široký filtr – nejmenší amplituda	26
Obrázek 2.6: Středně široký filtr – střední amplituda	27
Obrázek 2.7: Středně široký filtr – největší amplituda	27
Obrázek 2.8: Středně široký filtr pro profily druhé skupiny	28
Obrázek 2.9: Široký filtr – nejmenší amplituda	29
Obrázek 2.10: Široký filtr – střední amplituda	29
Obrázek 2.11: Široký filtr – největší amplituda	30
Obrázek 2.12: Masky pro úzký filtr – nejmenší amplituda	30
Obrázek 2.13: Masky pro středně široký filtr – nejmenší amplituda	30
Obrázek 2.14: Masky pro středně široký filtr – profily z druhé skupiny	31
Obrázek 2.15: Masky pro široký filtr – nejmenší amplituda	31
Obrázek 2.16: Výsledná odezva - zprůměrování	31
Obrázek 2.17: Výsledná odezva - maximum	32
Obrázek 2.18: Rozdíl počtu iterací při anizotropní difúzi	33
Obrázek 2.19: Aplikace anizotropní difúze	34
Obrázek 2.20: Aplikace metody prahování	36
Obrázek 2.21: Aplikace mediánového filtru	37
Obrázek 2.22: Princip indexování shluků metodou Cc labelling	38
Obrázek 2.23: Druhy okolí jednotlivých pixelů	38
Obrázek 2.24: Použití metody Cc labelling na odstranění děr	39
Obrázek 2.25: Použití metody Cc labelling na odstranění skvrn	39
Obrázek 2.26: Aplikace metody CC labelling	40
Obrázek 2.27: Aplikace Eroze	42
Obrázek 2.28: Aplikace CC labelling na erodovaný obraz	42
Obrázek 2.29: Aplikace Dilatace	43
Obrázek 2.30: Výsledná maska	43
Obrázek 2.31: Výsledek metody segmentace	44

Úvod

Cílem této práce je nalezení postupu zpracování obrazových dat obsahujících biologické informace vedoucí k oddělení významných informací od nevýznamných, tedy k segmentaci těchto dat. Vstupní biologickou informací je zde snímek pořízený digitálním mikroskopem obsahující několik klíčků geneticky upravené rostliny.

Práce obsahuje analýzu vstupních dat, zejména zjištění rozložení intenzity barevného spektra pomocí histogramů a nalezení určité zákonitosti mezi významnými informacemi. Další postupy se poté opírají o takto zjištěné parametry.

Jako hlavní metoda segmentace je zde použita metoda prahováním, která se vyznačuje rychlostí a jednoduchostí. Aby bylo dosaženo co největší efektivnosti, je metoda doplněna několika dílčími metodami, které se podílejí na samotné segmentaci, anebo mají funkci předzpracování a vstupní data upravují, aby aplikace segmentačních metod byla úspěšnější.

Mezi metody podílející se na samotné segmentaci patří mimo zmíněné metody segmentace také metoda connected component labelling [6] (Cc labelling), která pracuje s ohraničenými oblastmi menšími než segmentovaný objekt, a dále filtrace mediánovým filtrem. Tato metoda neprovádí přímo segmentaci, ale přebírá část funkce Cc labellingu a tím zkracuje dobu zpracování vzhledem k množství potřebných výpočtů. Do této skupiny je také zahrnuta možnost použití matematické morfologie.

Hlavní metodou předzpracování je filtrace přizpůsobenými filtry, tedy využití parametrů získaných analýzou vstupních dat k zvýraznění užitečných informací, které za normálních okolností splývají s nevýznamnými a při segmentaci způsobují velkou nepřesnost. Konkrétně je to vlásnění kořenové části klíčků. Tato metoda se dá použít na různá biomedicínská data. Například při segmentaci cévního řečiště z retinálních snímků [4]. Dále je do této oblasti zařazena anizotropní difúze [1] a je zkoumána možnost jejího využití při předzpracování.

Veškeré metody jsou zkoumány a popisovány pouze na části vstupních dat, protože vzhledem k velikosti snímku by to bylo časově velmi náročné. Po nalezení všech nastavení metod je sestaven postup a aplikován na větší část vstupních dat, které zahrnují minimálně jeden klíček.

1 Analýza vstupních dat

Při genetických úpravách rostlin je třeba posoudit úspěšnost úprav. Je tedy třeba zjistit, z jak velké části se povedlo rostlinu změnit. Toto posuzování úspěšnosti genetické modifikace se provádí na základě pozorování změny zbarvení při chemické reakci. Aby bylo možno tento proces zautomatizovat a přenechat rozhodování, zda část rostliny je změněná, je třeba pořídit digitální záznam vzorku. Z tohoto záznamu poté na základě zjištěných parametrů vysegmentovat vhodnými metodami rostlinu. Takto získaný segment již lze přenechat algoritmu pro posouzení úspěšnosti genetické modifikace.

1.1 Pořízení digitálního záznamu

Digitální záznam vzorku byl pořízen systémem **dotSlide** od firmy Olympus. Tento systém s mikroskopem je především určen pro biologické vědy. Osvícení vzorku se provádí standardně 100 W halogenovou žárovkou s následnou fluorescencí vzorku s možností polarizace emitovaných fotonů. Osvícený vzorek je poté snímán digitální CCD kamerou s velikostí jednoho pixelu (6,45 x 6,45)μm. [9]

CCD je elektronická součástka používaná pro snímání obrazové informace. CCD využívá podobně jako všechny ostatní světlocitlivé součástky fyzikálního jevu známého jako fotoefekt. Tento jev spočívá v tom, že částice světla foton při nárazu do atomu dokáže přemístit některý z jeho elektronů ze základního do tzv. excitovaného stavu. V polovodiči se takto uvolněný elektron může podílet na elektrické vodivosti, respektive je možno ho z polovodiče odvést pomocí přiložených elektrod tak, jak se to děje například u běžné fotodiody. Ta proto po dopadu světla vyrábí elektrický proud. Stejně fungují i fotočlánky, které se používají jako zdroj elektrické energie. U CCD je ovšem elektroda od polovodiče izolována tenoučkou vrstvičkou oxidu křemičitého SiO₂, který se chová jako dokonalý elektrický izolant, takže fotoefektem uvolněné elektrony nemohou být odvedeny pryč. Tyto uvolněné elektrony se pak přivádějí na zesilovač, který zesílí malý proud tvořený volnými elektrony na napěťové úrovni vhodné pro další zpracování. [7]

Fluorescence je jedním z druhů luminiscence, což je děj, u kterého nastává emise světla z látky a způsobují ji excitované elektronové stavy. Při fluorescenci lze registrovat pohasnutí emise téměř ihned po ukončení buzení. [8]


1.2 Parametry pořízeného vzorku

Vzhledem k velikosti pořízeného obrazu, který má obrovské rozlišení, je zde použit pouze výřez, který obsahuje pouze několik částí rostlin. Pro výběr a testování metod je však naprosto dostačující, protože obsahuje veškeré informace jako celý snímek. Celý snímek obsahuje jen více rostlin.

Každý bod (pixel) vstupního obrazu je reprezentován třemi barevnými složkami RGB (červenou složkou, zelenou složkou a modrou složkou).




Obrázek 1.1: Vstupní obraz



Obrázek 1.2: Vstupní obraz – šedotónové zobrazení


Z obrázku (Obrázek 1.1) je patrné, že největší část zabírá pozadí. To je tvořeno roztokem, ve kterém jsou rostliny položeny, a který obsahuje fluorofor. Hodnoty pixelů pozadí po převodu na odstíny šedi jsou v rozmezí 210 až 220, jak ukazuje Obrázek 1.6. Tato hodnota je stejná na celém pozadí. Jak ukazuje histogram odstínů šedi (Obrázek 1.3), největší část pixelů je právě v rozmezí 210 až 220. Pro zjednodušení lze říci, že všechny rostliny na obraze jsou natolik podobné, aby na ně bylo možno použít stejné metody se stejným nastavením parametrů. Díky tomu je možno původní obraz zmenšit. Zmenšením se zde rozumí vyříznutí takové části, která bude obsahovat pouze jednu rostlinu a pozadí bude stále nejpočetnější složkou. Zde byla vybrána spodní rostlina.




Obrázek 1.3: Histogram úrovní šedi vstupního obrazu



Obrázek 1.4: Vybraná rostlina pro další zpracování



Obrázek 1.5: Histogram úrovní šedi vybrané rostliny





Obrázek 1.6: Pozadí obrazu a) výřez z obrazu, b) histogram úrovní šedi výřezu

Po zobrazení histogramu (Obrázek 1.5) tohoto výřezu je patrné, že pozadí stále mnohonásobně převyšuje ostatní části. Proto je možno takto zmenšený obraz ještě více zmenšit a ušetřit tak množství výpočtů a výpočetní náročnost pro návrh metody. Než se však tento krok provede, je třeba prozkoumat další vlastnosti rostliny, aby nedošlo k přehlédnutí některých důležitých parametrů pro nastavení segmentačních metod.

Jak bylo řečeno dříve, pozadí se pohybuje v rozmezí hodnot 210 až 220. Aby bylo možno pokračovat dále, je třeba stejným postupem prozkoumat i ostatní části. Ostatními částmi je myšlena právě rostlina. Po bližším pozorování může být rozdělena na 3 části.

První částí rostliny jsou její lístky. Jak je vidět z obrázku (Obrázek 1.7), její histogram mimo jiné obsahuje i hodnoty, kterými je definováno pozadí. Celý histogram má však rozsah přes celou škálu odstínů, takže oblast překrytí je z celkového pohledu malá. Přesto by však při použití metody prahování, jejíž význam bude popsán později, došlo ke ztrátě informací. Tomu lze předejít použitím vhodné metody předzpracování nebo použití metody upravující naprahovaný obraz, popřípadě kombinací obou.




a)

b)

Obrázek 1.7: Lístky rostliny a) výřez z obrazu, b) histogram úrovní šedi výřezu

Druhou částí rostliny je její kořen. Z histogramu (Obrázek 1.8b) je vidět, že stejně jako u předchozí části i zde dochází k překrytí s pozadím. Avšak četnost zastoupení pixelů mimo tuto oblast je ještě větší než v předchozí části a tudíž bude ztráta informací ještě menší. V tomto případě lze také pro eliminaci ztráty dat použít jak metody předzpracování, tak metody upravující naprahovaný obraz.




a)

b)

Obrázek 1.8: Kořen rostliny a) výřez z obrazu, b) histogram úrovní šedi výřezu

Třetí částí je vlasnění kořenové části rostliny. Při pohledu na histogram (Obrázek 1.9b) by se dalo říci, že zde platí stejné kolize histogramů a bylo by možno i zde použít stejných řešení. Avšak zde je třeba část zkoumat z hlediska uspořádání. Vlasnění kořenové části rostliny obsahuje shluk tenkých vlásečnic, které se přes sebe v různých směrech překrývají a v místech, kde neleží žádná vlásečnice, prosvítá pozadí. Tyto oblasti prosvítání mohou být různě velké. Navíc samotné vlásečnice svým rozsahem odstínů šedi mnohdy překrývají histogram pozadí. Zde by proto pouze metody upravující již naprahaný obraz nestačily a je třeba použít některou z možných metod předzpracování. Aby bylo možno vybrat správnou metodu předzpracování a vhodně nastavit její parametry, je třeba se více zaměřit na vlastnosti samotných vlásečnic.




a) b)
Obrázek 1.9: Vlasnění kořenové části a) výřez z obrazu, b) histogram úrovní šedi výřezu

Aby bylo možno vlásečnice vhodně předzpracovat, je třeba zjistit, čím se od pozadí odlišují. První věc je rozsah úrovní stupňů šedi, což bylo zmíněno v předchozím odstavci. Dále to je jejich definovaná šířka. Vlásečnice nejsou všechny stejně široké, stejně jako nemají všechny stejný rozsah, ale měřením bylo zjištěno, že se všechny pohybují v určitém rozsahu. Minimální šířka byla naměřena 15 pixelů a zastoupená je jen ojediněle. Maximální šířka byla naměřena 36 pixelů. Všechny šířky vlásečnic pak leží v tomto rozpětí.

Další, co je třeba zjistit, je chování vlásečnic mezi krajními body jejich šířky. To znamená proměřit profily vlásečnic a pokusit se mezi nimi najít vztah.


Jednotlivé profily byly měřeny od nejširších vlásečnic po nejužší. Porovnáním jednotlivých profilů bylo na základě tvarových vlastností zjištěno, že lze všechny rozdělit do tří základních skupin.

První skupinou jsou vlasečnice s šířkou profilu mezi 15 a 21 pixelů. V tomto rozmezí se tvar profilů řídí podobnými pravidly. Ukázkový profil pro tuto skupinu je zobrazen na obrázku (Obrázek 1.10). Označení této skupiny je tedy vlasečnice s úzkým profilem.




Obrázek 1.10: Ukázkový profil vlasečnic s úzkým profilem

Druhou skupinou jsou vlasečnice s šířkou profilu mezi 29 a 36 pixelů. V této skupině se tvar profilů řídí podobnými vlastnostmi jako v první skupině. Rozdíl jejich šířek je však natolik velký, že jsou zařazeny do samostatné skupiny. Navíc se zde uplatňuje větší velikost střední části než v předešlé skupině. Ukázkový profil je na obrázku (Obrázek 1.11). Označení této skupiny je vlasečnice s širokým profilem.




Obrázek 1.11: Ukázkový profil vlasečnic s širokým profilem

Třetí skupinou jsou vlasečnice s šířkou profilu mezi 22 a 28 pixelů. Tato skupina je trochu odlišná od předchozích dvou, protože jsou v ní zahrnuty 2 podskupiny. Jedna část skupiny se opět řídí podobnými vlastnostmi jako předchozí dvě skupiny a tvoří mezi nimi přechod. Druhá část vybočuje ve své prostřední části. Je natolik členitá, že kvůli výběru metody předzpracování je vhodné ji alespoň částečně oddělit. Ukazkové profily obou dvou podskupin jsou na obrázku (Obrázek 1.12). Označení této skupiny je vlasečnice se středně širokým profilem.



a)



b)


Obrázek 1.12: Ukázkový profil vlasečnic se středně širokým profilem a) první skupina, b) druhá skupina

Existují výjimky, kdy profil ze druhé skupiny má prostřední část stejně členitou jako profil ze třetí skupiny. Četnost těchto profilů však není natolik velká, aby bylo třeba zařazovat novou skupinu. Prozatím postačí se o existenci takového profilu zmínit a pokusit se ho zohlednit při použití metody předzpracování.

Nyní si tedy lze shrnout parametry potřebné pro další zmenšení vstupního obrazu použitého pro volbu a návrh všech metod zpracování. Prvním a hlavním parametrem je, aby pozadí stále tvořilo několikanásobně vyšší maximum v histogramu, než ostatní části. Ostatní části jsou list rostliny, kořen rostliny a vlásnění kořenové části. Druhý parametr se týká právě těchto částí a sice, že zde musí být všechny zastoupeny. Poslední parametr zahrnuje výše změřené profily vlásečnic a to tak, že zde musí být všechny zahrnuty.



a)




b)

Obrázek 1.13 Výřez z vybrané rostliny a) zobrazení, b) histogram úrovní šedi

Na obrázku (Obrázek 1.13) je dále zmenšený vstupní obraz. Z jeho histogramu vyplývá, že pozadí je stále dost velké, aby bylo možno obraz více zmenšit. I všechny části rostliny a všechny skupiny profilů vlásečnic jsou zde zastoupeny ve velkém množství. Proto je možno vstupní obraz ještě zmenšit (Obrázek 1.14). Toto zmenšení je však již konečné, protože po dalším zmenšení by se již některé rozhodující parametry dostaly na kritickou hodnotu.




a)



b)

Obrázek 1.14: Výřez rostliny pro nastavení segmentačních metod a) zobrazení, b) histogram úrovní šedi

Nakonec je třeba při analýze dat přihlédnout k tomu, jak by se obraz choval při zbarvení způsobeném reakcí geneticky zbarvené částí rostliny. Toto demonstruje obrázek (Obrázek 1.15). Obsahuje jednak zbarvenou část lístku rostliny a jednak její histogram. Na něm je vidět, že zbarvení dosti významným způsobem posune rozsah úrovní šedi mimo oblast pozadí a tím ji naprosto odliší, proto tato možnost bude automaticky zahrnuta v nastavení metod pro případ nezbarvených částí.



Obrázek 1.15: Vliv zbarvení rostliny a) výřez z rostliny, b) histogram úrovní šedi

2 Metody zpracování

2.1 Charakteristika a rozdělení segmentačních metod

Segmentace obrazu je souhrn funkcí, metod a pravidel, který rozdělí obraz na jednotlivé části, které korespondují s konkrétními objekty v obraze. Segmentace obrazu bývá používána jako metoda předzpracování předcházející mnohem složitějším algoritmům, které obrazová data dále zpracovávají. Segmentace funguje na principu významu segmentů v obraze. Hledá konkrétní předem definované objekty, popřípadě hledá neznámé objekty podle obecných kritérií a snaží se tyto objekty popsat.

Metod, které se pro segmentaci obrazu používají, je spousta. A velká je i škála složitosti algoritmů používaných pro segmentaci. Dále jsou tyto metody doplňovány metodami předzpracovávajícími obrazová data, případně upravujícími vysegmentovaná data.

Nejzákladnějším kriteriem dělení segmentačních technik je jejich složitost a náročnost. Děleny jsou podle [3] takto:

- Základní – využívají jednoduchých algoritmů a vyznačují se rychlostí zpracování.
- Pokročilé – využívají širokou škálu metod z oblasti zpracování obrazových dat a kladou větší nároky na dobu zpracování.
- Speciální – využívají velmi složité algoritmy, bývají úzce specializovány na konkrétní případ a vyžadují výbornou znalost významu dat v obraze

2.1.1 Metody založené na detekci hran

Hranová detekce patří do oblasti nižší úrovně zpracování obrazových dat. Je založena na hledání takových bodů, u kterých je světlost výrazně odlišná od sousedního bodu. Spojením takových pixelů dostaneme hrany objektu. Na idealizovaných příkladech je tato metoda velice účinná, avšak na reálných obrazech vyvstává mnoho problémů. I přesto je ale tato metoda jedna z nejvýznamnějších.

Při popisu metody detekce hran je třeba také zmínit druhy hran, které se v obrazech vyskytují. Každá hrana má svůj směr a gradient. Podle [3] jsou tyto druhy hran:

- skoková
- rampová
- liniová
- střecha

Pro detekci těchto hran se používají různé detektory. Detektor je kriterium, podle kterého se rozhoduje, zda zkoumaný bod je či není hrana. Detektory lze rozdělit do tří hlavních skupin podle [2]:

- Detektory aproximující první derivaci a posuzující velikost skoku.
- Detektory aproximující druhou derivaci a detekující její průchod nulou.
- Detektory aproximující obrazovou funkci parametrickým modelem.

2.1.2 Metody založené na detekci oblastí

Detekce oblastí pracuje na podobném principu jako detekce hran. Pouze nevyhledává hrany, ale oblasti, které leží vně nějaké hranice. Teoreticky by měly obě cesty vést ke stejnému výsledku. Ve skutečnosti tomu tak není. Je to způsobeno necelistvostí hran a zašuměním obrazu.

Do této oblasti patří například metoda šíření oblastí. Po zvoleném počátečního bodu se posuzují všechny okolní pixely a rozrůstá se oblast. Rozrůstání pokračuje dokud jsou všechny sousední body stále vyhodnoceny jako součást oblasti. Pokud se už oblast nemůže dále rozrůstat, je klasifikována jako segmentovaný objekt a pokračuje se rozrůstáním další oblasti, do které již nemohou být brány body z předchozí. [3]

2.1.3 Statické metody segmentace

Základními stavebními bloky statických metod jsou statické vlastnosti analyzovaných dat. Často jsou to hodnoty jas jednotlivých pixelů, střední hodnoty v určitém okolí bodu, rozptyl a podobně.[3]

Do této skupiny patří například metody prahování a Connected component labelling, které budou popsány podrobněji později.

Další statické metody:

- Adaptivní prahování – pracuje stejně jako jednoduché prahování s tím rozdílem, že nejdříve se obraz rozdělí na několik částí, každá se potom prahuje zvlášť a u každé se použije individuální hodnota prahu.
- Amplitudová projekce – vytváří průměrné amplitudové projekce ve směru řádků a sloupců
- Shluková analýza – metoda shlukuje pixely, u kterých byly naměřeny shodné hodnoty měřené veličiny. Pod pojmem měřená veličina může být také soubor měřených veličin.
- dále jsou to například metody Kohonenovy mapy, Fuzzy connectednes a další. [3]

2.1.4 Hybridní metody

Jsou to metody, které v sobě zahrnují prvky všech tří předešlých skupin. Patří sem například metody založené na matematické morfologii. Hybridní metody pro segmentaci využívají matematických charakteristik obrazu. Jednou z hybridních metod je například metoda Neuronové sítě. [3]

2.1.5 Znalostní metody

Metody využívají toho, že jsou předem známy parametry hledaného objektu. Můžou to být barva, tvar, struktura a podobně. Pro používání těchto metod je třeba vytvořit slovník objektů. Objekty ze slovníku se různě transformují a porovnávají s objekty nalezenými v obraze. Slovník je vytvářen buďto automaticky učením, nebo je vložen uživatelem. [3]

2.2 Volba metody segmentace

Při volbě metody a jejího způsobu použití byla brána v potaz rychlost zpracování, jednoduchost zpracování a vlastnosti vstupních dat.

Rychlost zpracování vstupních obrazových dat, tedy čas potřebný k provedení všech operací vedoucích k vysegmentování objektu, je jedna z kritických hodnot ovlivňujících výběr metody zpracování. Při výběru metody byla snaha vybrat metodu co nejrychlejší, aby rychlost vývoje metody a algoritmu a následné testování dávaly co největší prostor k vyzkoušení velkého počtu možností a kombinací zvolených funkcí.

Dalším kritériem jsou zvolené metody zpracování. Zde byla snaha využívat co nejvíce jednoduchých metod zpracování obrazových dat. Zjistěte existuje spousta pokročilých metod, které využívají složité algoritmy a vedou k výborným výsledkům. Nevýhodami těchto metod jsou velká náročnost na výpočetní techniku, menší rychlost zpracování a mnohdy i nutnost zásahu uživatele zadáním parametru nezbytného pro pokračování výpočtů. Naproti tomu jsou jednodušší metody rychlejší a variabilnější. Jejich algoritmus lze mnohdy modifikovat podle aktuálních potřeb. A pokud jsou vhodně kombinovány s dalšími doplňkovými metodami, dosahují v podstatě stejných výsledků jako metody složitější.

Cílem výběru je tedy metoda jednoduchá, rychlá a co nejpřesnější. Z analýzy vstupních dat je patrné, že tuto segmentaci žádná dostupná segmentační metoda nedokáže, pokud bude použita samostatně. Proto je třeba obraz nejprve upravit a poté na něj aplikovat kombinaci segmentačních a doplňkových metod.

Samotná segmentace bude spočívat ve vytvoření binárního obrazu, ve kterém se vysegmentuje plocha patřící objektu, takže objekt v binárním obraze bude korespondovat s objektem v původním obraze. Tento binární obraz tedy vytvoří masku původního obrazu. Vynásobením obou obrazů dojde k vysegmentování objektu v původním obraze.

Jako hlavní metoda pro segmentaci byla zvolena metoda prahování.

2.3 Metody předzpracování

2.3.1 Filtrace přizpůsobenými filtry

Charakteristika metody

Filtrace přizpůsobenými filtry je velmi častá metoda zpracování signálových dat. Využívá se převážně pro zvýrazňování signálu a detekci signálu, který je rušen šumem, popřípadě je jím úplně překryt. Filtrace spočívá v hledání známého signálu v zašuměném. Aby bylo možno tuto metodu použít, je třeba nejdříve hledaný signál správně popsat. Úspěšnost metody tedy spočívá ve správném nastavení filtru. Filtrace se pak provádí výpočtem konvoluce mezi navrženým filtrem a zašuměným signálem.[10] Konvoluce vypočítává míru korelace. Jinak řečeno ukazuje, jak moc spolu filtr a právě zkoumaná část signálu souhlasí. Při aplikaci na obrazová data, kde obraz je chápán jako dvourozměrný signál, se konvoluce vypočítá

$$g(x, y) = f(x, y) * h(x, y), \quad (2.1)$$

kde x, y – prostorové souřadnice,
 h – navržený filtr.

A vzhledem k tomu, že obrazová data jsou navzorkovaná, lze rovnici (2.1) přepsat do tvaru pro diskrétní oblast podle [5]:

$$g(i, k) = f * h | (i, k) = h * f | (i, k) = \sum_{a=-\infty}^{\infty} \sum_{b=-\infty}^{\infty} f(i-a, k-b)h(a, b). \quad (2.2)$$

Jedná se tedy o lokální maskový operátor, masku (filtr) s rozměry $A \times B$, která se postupně posouvá po vstupní matici bodů a v každé pozici je vypočtena odezva, která je rovna lineární kombinací hodnot pod filtrem.


Aby nedocházelo k příliš velké chybovosti způsobené buď falešnými detekcemi signálu nebo nedostatečným reagováním, je třeba vedle správného nastavení tvaru a amplitudy filtru také nastavit nulovou střední hodnotu filtru. [10]

Výhodou této metody je, že se skládá pouze z lineárních operací. Proto i když se později ukáže, že zabírá nejvíce času výpočtu, je v porovnání s nelineárními metodami zpracování výhodná, obzvláště je-li znám hledaný signál.

Aplikace metody

Jak bylo zjištěno při analýze dat, je pozadí překryto z hlediska úrovně šedi rostlinou. Proto je třeba tyto hodnoty od sebe více oddělit. Nejjednodušším způsobem, jak toho dosáhnout, je zvýraznění rostliny. Pro tento účel byla mezi metody předzpracování zařazena filtrace přízpůsobenými filtry.

Prvním krokem této metody je vytvoření filtrační masky. K tomu lze využít právě skutečností zjištěných při analýze vstupních dat. Jak bylo řečeno při analýze vstupních dat, lze vlasečnice rozdělit do tří základních skupin. Vlasečnice s úzkým profilem (Obrázek 1.10), vlasečnice se středně širokým profilem (Obrázek 1.12a) a vlasečnice s širokým profilem (Obrázek 1.11). Pro tyto tři skupiny je tedy potřeba navrhnout masky.




Obrázek 2.1: Body pro tvorbu filtrů

Cílem je pro každou skupinu určit takový profil, který bude mít pokud možno co nejbližší ke všem profilům v rozsahu daném pro každou skupinu. Vytvoření takového profilu spočívá v proměření profilů dané skupiny a sestavení v ideálním případě průměru všech takto naměřených profilů. Avšak vzhledem k tomu, že žádný z těchto profilů není dokonale souměrný a často dochází k jednostranným deformacím, je nutno z těchto profilů odměřit hlavní parametry, významné pro filtr. Tyto parametry tvoří body, kde se výrazně mění směr křivky profilu, nebo kde křivka prochází hodnotou okolního pozadí. Na obrázku (Obrázek 2.1) jsou tyto body označeny čísly 1 až 11. Dalším krokem je těmito body proložit křivku. Byla zvolena Gaussova křivka dána vztahem:


$$h(x) = -e^{\left(\frac{-x^2}{2\sigma^2}\right)}, \quad (2.3)$$

kde x – vektor bodů mezi zvolenými krajními body.


Pro vlasečnice s úzkým profilem bude tedy filtrační profil složen z pěti křivek, jejichž šířky byly určeny dle změřených profilů. Při měření bylo dále zjištěno, že profily se stejně širokými částmi mohou nabývat různých špičkových hodnot. Pro pokrytí všech možností byl interval pomocí minimální a maximální hodnoty rozdělen na tři části. Pro skupinu vlasečnic s úzkým profilem byly tedy vytvořeny tři profily lišící se pouze amplitudami. Ty byly získány z jednotlivých intervalů a to tak, že z každého intervalu byla vybrána vždy prostřední hodnota. Nastavení jednotlivých hodnot ukazuje obrázek (Obrázek 2.2, 2.3, 2.4).



Obrázek 2.2: Úzký filtr – nejmenší amplituda




Obrázek 2.3: Úzký filtr – střední amplituda




Obrázek 2.4: Úzký filtr – největší amplituda


Pro vlasečnice se středně širokým profilem se filtr získal stejným způsobem jako pro předešlou skupinu. Byly zjištěny body, kde profil významně mění směr nebo prochází hodnotou pozadí, a následně proloženy křivkou. Stejně jako v předchozí skupině, i zde bylo zapotřebí vytvořit tři profily zahrnující různé amplitudy křivek. Profily se skládají z pěti křivek. Nastavení jednotlivých hodnot ukazuje obrázek (Obrázek 2.5, 2.6, 2.7).



Obrázek 2.5: Středně široký filtr – nejmenší amplituda




Obrázek 2.6: Středně široký filtr – střední amplituda




Obrázek 2.7: Středně široký filtr – největší amplituda

Do této skupiny je navíc zařazen profil, který se svým tvarem odlišuje od ostatních v této skupině (Obrázek 1.12b). Proto je zde na rozdíl od předchozí skupiny zařazen ještě jeden filtr, který má za úkol detekovat vlasečnice s podobným profilem. Z poznatků získaných měření a s přihlédnutím k době zpracování výpočtů byl tento profil navržen pouze pro jednu hodnotu amplitud a jeho šířka nastavena tak, aby pokryl co největší množství takových profilů, protože i když není dokonalá shoda filtru a obrazu, vyskytne se dostatečná odezva i tam, kde se trochu liší. Nastavení filtru ukazuje obrázek (Obrázek 2.8).




Obrázek 2.8: Středně široký filtr pro profily druhé skupiny


Filtr pro skupinu širokých vlasečnic byl získán stejně jako u skupiny úzkých vlasečnic. Opět je tvořen pěti křivkami a rovněž zde bylo zapotřebí vytvořit tři filtry kvůli vlivu velikosti amplitud. Nastavení jednotlivých hodnot ukazuje obrázek (Obrázek 2.9, 2.10, 2.11).



Obrázek 2.9: Široký filtr – nejmenší amplituda




Obrázek 2.10: Široký filtr – střední amplituda




Obrázek 2.11: Široký filtr – největší amplituda

Celkem bylo vytvořeno deset různých profilů filtrů. Další krokem je z těchto profilů vytvořit dvourozměrnou masku, která by byla po vstupním obraze posouvána. Vytvoření dvourozměrné masky spočívá ve zkopírování profilu pod sebe tolikrát, kolik hodnot profil má, čímž se vytvoří čtvercová matice se stejnými řádky. Toto roztažení filtru se provádí kvůli falešným detekcím. Roztažení profilu tedy klade podmínku návaznosti na sousední profil ve vstupním obraze.


Při pohledu na vstupní obraz je vidět, že vlasečnice jsou v něm poskládány náhodně v různých směrech. Proto by filtry tak, jak jsou navrženy, měly malou úspěšnost. Je tedy třeba každou vytvořenou masku několikrát pootočit a opět vypočítat odezvu. Bylo zvoleno natáčení s krokem 15° v rozmezí $(0 - 180)^\circ$. Z toho vyplývá, že každá maska byla vytvořena ve dvanácti různých směrech, tedy celkem bylo vytvořeno 120 masek. Ukázky masek obsahuje obrázek (Obrázek 2.12, 2.13, 2.14) Po každém natočení se však změní střední hodnota, proto je třeba ji pokaždé upravit na nulu.




Obrázek 2.12: Masky pro úzký filtr – nejmenší amplituda




Obrázek 2.13: Masky pro středně široký filtr – nejmenší amplituda



Obrázek 2.14: Masky pro středně široký filtr – profily z druhé skupiny




Obrázek 2.15: Masky pro široký filtr – nejmenší amplituda



Obrázek 2.16: Výsledná odezva - zprůměrování

Po výpočtu konvolucí se všemi 120 maskami se dostane 120 odezev. Tyto odezvy lze následně zpracovat dvěma způsoby. Prvním způsobem je zprůměrování. To znamená, že výsledná hodnota každého pixelu je vypočtena jako aritmetický průměr všech odpovídajících si pixelů (Obrázek 2.16). Druhým způsobem je výběr maxima. Výběr probíhá porovnáním odpovídajících si pixelů, kde je následně největší hodnota nastavena jako hodnota výstupního pixelu (Obrázek 2.17). V obou dvou případech byl rozsah hodnot posunut a upraven, aby byl v rozsahu od 0 do 1.



Obrázek 2.17: Výsledná odezva - maximum


Vzhledem k odlišnosti obou výsledků je zapotřebí v dalším uvažovat pouze jeden. Proto bude použita odezva získaná pomocí maximálních hodnot.

2.3.2 Anizotropní difúze

Charakteristika metody

Anizotropní difúze je další metoda zpracování obrazu, která významnou měrou usnadňuje následnou segmentaci objektu. Její hlavní předností je, že vlivem jejího působení dochází k rozmazání obrazu a tím k zrušení struktury jednotlivých částí segmentu. Narozdíl od ostatních metod, které dokáží rozmazat obraz, jako je například zprůměrování lokálních oblastí, anizotropní difúze provádí rozmazání podle lokálních vlastností obrazu. Jednou z výhod takového přístupu je, že rozmazání se vyhýbá ostrým hranám. Navíc je zvýšen kontrast oblasti, které tyto hrany rozdělují. Metoda je navržena podle dějů, které probíhají v nehomogenním materiálu při šíření tepla.[1]

Anizotropní difúze se zpravidla aplikuje na obraz několikrát za sebou, protože po jedné aplikaci není výsledek příliš patrný. S každou další iterací zmizí ty nejslabší hrany a obraz se více rozmáže. Pokud se použije příliš mnoho iterací, obraz příliš zesvětlá. V extrémním případě dojde až k úplné ztrátě dat a všechny pixely obrazu budou rovny hodnotě jedna (popřípadě 255). Dále je nutno dodat, že anizotropní difúze pracuje pouze s obrazy v odstínech šedi.




Obrázek 2.18: Rozdíl počtu iterací při anizotropní difúzi. a) bez difúze, b) po dvou iteracích, c) po deseti iteracích, d) histogram bez difúze, e) histogram po dvou iteracích, f) histogram po deseti iteracích


Aplikace na metody

Vzhledem k nehomogenitě pozadí, čili rozpětí hodnot, kterých může pozadí nabývat, by docházelo k velké chybovosti při použití segmentačních metod. Proto je třeba tyto hodnoty

dostat pokud možno na velmi blízké hodnoty. A právě tomuto účelu slouží anizotropní difúze. Aby nedošlo k přílišnému rozmazání a ztrátě potřebných informací, provádí se aplikace metody ve dvou opakováních. Před aplikací metody byla nejdříve zvětšena dynamika obrazu umocněním každého pixelu na pátou s následným vrácením rozsahu do intervalu mezi 0 a 1.



a)



b)

Obrázek 2.19: Aplikace anizotropní difúze a) zobrazení, b) histogram úrovní šedi

2.4 Metody segmentace

2.4.1 Segmentace obrazu prahováním

Motivace použití metody prahování

Prahování je segmentační metoda, která se vyznačuje svou jednoduchostí a rychlostí, což byl hlavní důvod volby této metody. Další výhodou je to, že metoda pracuje s poznatkami získanými analýzou histogramu obrazu, protože analyzovaná data mají právě histogram s výraznou složkou pozadí.

Charakteristika metody prahování

Segmentace obrazu prahováním se řadí mezi statické metody pro segmentaci obrazu. Metoda spočívá v převodu původního šedotónového obrazu na obraz binární, kde právě zvolený práh určuje, které body budou převedeny na hodnotu 0 a které budou převedeny na hodnotu 1. Metoda tedy projde veškeré pixely obsažené ve zpracovávaném obraze, porovná je s nastaveným prahem a poté převede na výslednou hodnotu. Metoda prahováním není omezena pouze jedním prahem, ale může pracovat s libovolným počtem prahů. [3]

Metoda využívá rozdělení úrovní šedi ve zpracovávaném obraze. Toto rozdělení popisuje histogram obrazu. Histogram obsahuje informace o počtu pixelů v obraze s konkrétní úrovní šedi. Nejčastější metodou pro nastavení prahů je právě analýza histogramu obrazu. Nejpoužívanější hodnoty pro nastavení prahů jsou globální a lokální maxima. Při použití globálního maxima se hledá maximum z celého histogramu. Toto maximum může být nalezeno pro jednu konkrétní hodnotu úrovně šedi nebo pro interval hodnot úrovně šedi. Při hledání maxima také nemusíme hledat pouze maximum, ale také maximum a přilehlé úrovně v bezprostředním okolí maxima. Lokální maxima se využívají při segmentaci obrazu za použití více prahů, nebo pokud je dopředu známo, že segmentovaná oblast leží pouze v určitém intervalu úrovně šedi.

Výsledkem základního prahování je tedy binární obraz, který obsahuje pouze dva druhy pixelů – je a není objekt. Převod na binární obraz lze tedy popsat rovnicí (). Samotná je tato metoda pro segmentaci nevhodná. Jejím výstupem je pouze hrubě nasegmentovaný obraz a je třeba jej dále zpracovat vhodnými metodami. [3]

Nevýhodou získávání hodnot prahů z histogramu je absence prostorové informace o pixelu. To znamená, že například čtverec o velikosti 5x5 pixelů bude mít stejný histogram jako dvacet pět roztroušených pixelů. To znamená, že tato metoda není vhodná pro všechny obrazy a ve většině případů je nutné před samotným prahováním obraz upravit, po prahování dosegmentovat a dočistit.

Aplikace metody

Jak ukazuje obrázek (Obrázek 2.18b), vlivem předzpracování došlo k odsunutí hodnot pozadí na okraj hodnot. Tento jev je užitečný, protože dovoluje použít metodu prahování s jedním prahem. Vstup pro tuto metodu jsou dva obrazy. Prvním je obraz, na který byla aplikována anizotropní difúze, a druhým je obraz, na který nebyla aplikována anizotropní difúze. Nastavení prahu proběhlo u obou variant stejným způsobem a to nalezením úrovně

šedi s maximální četností. Vzhledem k tomu, že ani v jedné variantě aplikace metody není po zpracování pozadí homogenní, bylo třeba tuto hodnotu prahu modifikovat. Hodnota posunu prahu byla stanovena měřením a testováním. Pro variantu s aplikací anizotropní difúze byla stanovena hodnota posunu od maximální četnosti 0,018 a u varianty bez aplikace anizotropní difúze byla stanovena hodnota posunu 0.016.



a)



b)

Obrázek 2.20: Aplikace metody prahování a) bez anizotropní difúze, b) s anizotropní difúzí

Obrázek (Obrázek 2.19) ukazuje rozdíl mezi oběma variantami. Je patrné, že po aplikaci anizotropní difúze je menší tendence k chybně detekovaným pixelům jako pozadí. Proto v dalším zpracování bude uvažována jen tato varianta.

2.4.2 Filtrace mediánovým filtrem

Jedná se o doplňkovou metodu, která pouze upravuje již naprahovaný obraz pro další zpracování. Jejím hlavním úkolem je zaplnění malých děr, které vznikly uvnitř masky nastavením prahových hodnot při aplikaci prahování.

Metoda definuje hodnotu každého pixelu podle velikosti hodnot pixelů v jeho okolí. Velikost okolí je právě jediným parametrem potřebným k aplikaci mediánového filtru. Filtrace spočívá v uspořádání všech pixelů z okolí a vybrání prostředního členu. Metoda patří do skupiny lokálních operátorů.

Při použití následujících metod se stává tato metoda v podstatě zbytečná, ale zmenší počet operací, které následující metody musí provést, a také omezí jejich chyby. Jedná se především o následující metodu connected component labelling. Mediánový filtr byl na obraz použit dvakrát a v obou případech s velikostí masky 3x3.



Obrázek 2.21: Aplikace mediánového filtru

2.4.3 Connected component labelling

Charakteristika metody

Další z řady segmentačních metod zpracovávajících binární data. Metoda rozdělí obraz na pozadí (pixely s hodnotou nula) a detekované oblasti, což jsou shluky propojených pixelů s hodnotou 1. Výstupem je matice bodů o velikosti původního obrazu (matice bodů). Každý nalezený shluk v původní matici dostane svůj index. Index je celé vzrůstající číslo. Indexování začíná od čísla 1, protože index 0 je automaticky přiřazen bodům pozadí. Každému pixelu ve výstupní matici je přiřazena hodnota odpovídající indexu detekovaného shluku, do kterého náleží. [3], [6]



Obrázek 2.22: Princip indexování shluků metodou Cc labelling: a) původní obraz, b) výsledná matice

Pomocí této výsledné matice lze pracovat s jednotlivými shluky jako s celky. Každý pixel v původní matici má shodné souřadnice jako odpovídající pixely ve výstupní matici. A jestliže je tedy shluk ve výstupní matici reprezentován pixely o stejné hodnotě, pak vypsáním všech těchto bodů dostáváme souřadnice všech pixelů náležících do shluku v původní matici. Connected component labelling (dále jen CC labelling) lze použít ve dvou úrovních citlivosti. Jaká úroveň bude použita, záleží na volbě velikosti okolí, pro které se zkoumaný pixel posuzuje. Detekce shluku se provádí postupným zvětšováním počtu pixelů shluku. Pro každý krajní pixel shluku se zjišťuje, zda v jeho okolí leží jiný pixel. Jsou dva druhy okolí. A to 4-okolí a 8-okolí. Ve 4-okolí se posuzují pouze krajní pixely ležící na svislé a vodorovné ose okolí. V 8-okolí se posuzují navíc i pixely ležící na úhlopříčkách okolí. Pokud je v okolí krajního pixelu nalezen pixel, je začleněn do shluku a stává se krajním pixelem. [6]



Obrázek 2.23: Druhy okolí jednotlivých pixelů: a) 4-okolí, b) 8-okolí

Aplikace Cc labelling metody

Metoda Cc labelling byla aplikována na segmentovaný obraz dvěma způsoby. První způsob aplikace vedl k odstranění chybně detekovaných pixelů jako pozadí, odstranění děr. Druhý způsob vedl k odstranění chybně detekovaných pixelů jako maska, odstranění skvrn.

Odstranění děr

Vlivem nastavení prahu při prahování obrazu došlo v místech preparátu, světlostí blízkých pozadí, k odstranění malých částí uvnitř preparátu. Metoda Cc labelling všechny tyto oblasti vyhledá a vyhledá také další oblasti, které nejsou pro segmentaci potřebné, a také oblasti, které jsou nevhodné. Tyto oblasti se při dalším zpracování přeskočí nastavením prahové hodnoty, která omezuje velikost zpracovávaného shluku, tedy shluky s počtem pixelů větším, než je prahová hodnota, nebudou dále zpracovávány.

Zpracování detekovaných shluků spočívá v nastavení pixelů shluku na hodnotu masky. Pro odstranění děr byla metoda použita s nastavením okolí 8.



a)



b)

Obrázek 2.24: Použití metody Cc labelling na odstranění děr a) před aplikací, b) po aplikaci

Odstranění skvrn

Vlivem nečistot na pozadí a nehomogenitě jsou na pozadí místa malých rozměrů, které jsou výrazněji tmavší, popřípadě světlejší, než pozadí, a která se nepodařilo při předzpracování eliminovat. To způsobuje, že se na pozadí po vyprahování objeví oblasti, které jsou škodlivým artefaktem vzhledem k dalšímu zpracování obrazu. Metoda Cc labelling tyto oblasti vyhledá a přiřadí indexy.

Odstranění těchto oblastí spočívá v nastavení jejich hodnoty na hodnotu pozadí. Opět se použije prahové hodnoty omezující velikost oblasti vzhledem k počtu pixelů. Před aplikací metody je ještě třeba zinvertovat původní obraz, protože metoda vyhledává bílé oblasti v černých.



a)



b)

Obrázek 2.25 Použití metody Cc labelling na odstranění skvrn a) před aplikací, b) po aplikaci



Obrázek 2.26: Aplikace metody CC labelling

2.4.4 Matematická morfologie

Matematická morfologie je soubor matematických nástrojů, které využívají pro úpravu a extrakci obrazu tvarových vlastností jednotlivých částí obrazu. Jsou založeny na nelineárních operacích a narozdíl od předchozích metod nepracují s jednotlivými body, ale s množinami bodů. Matematická morfologie zpracovává binární nebo šedotónové obrazy. Obrazy s více úrovněmi jasu jsou pro zpracování mnohem složitější než binární a s ohledem na to, že data, na která bude aplikována matematická morfologie, jsou binární, bude dále uvažována pouze varianta zpracovávání binárních dat. [2]

Základní názvosloví matematické morfologie podle [2]:

- Množina bodů – neboli objekt je v binárním obraze chápán jako množina dvourozměrných bodů o souřadnicích x a y a majících hodnotu 1.
- Množinový doplněk – neboli pozadí je oblast za objektem, která je chápána jako množina 2D bodů o souřadnicích x a y a s hodnotami 0 a doplňujících objekt na matici velikosti obrazu.
- Transformace – je relace mezi původním objektem a zadaným strukturním elementem.
- Strukturní element – maska zadaná uživatelem definující tvar hledaného objektu. Strukturní element je při morfologické transformaci posouván po vstupním obraze.

Nejjednodušší metody matematické morfologie:

- Dilatace
- Eroze
- Otevření
- Uzavření

Dilatace

Dilatace skládá body dvou množin pomocí vektorového součtu. Dilatací obrazu a strukturního elementu vzniká množina všech možných vektorových součtů pro dvojice pixelů. Hlavní využití dilatace je zaplnění malých děr a úzkých zálivů. Jako příklad lze uvést dilataci se strukturním elementem o velikosti 3x3. Tato dilatace způsobí, že všechny pixely pozadí, které jsou sousedící s objekty na body objektů, zvětší objekty o jednu vrstvu pixelů. [2]

Eroze

Eroze je duální, avšak ne invertní operací k dilataci. Eroze se využívá ke zjednodušení objektů a k odstranění nechtěných částí. Další hlavní aplikací je získání obrysů objektu. To se provádí odečtením erodovaného obrazu od původního. Například při použití strukturního elementu 3x3 zmizí z obrazu čáry tloušťky jeden pixel a celý objekt se zmenší o jednu vrstvu pixelů. [2]

Otevření

Otevřením se nazývá eroze následovaná dilatací za použití stejného strukturního elementu. Operace otevření vede k celkovému zjednodušení obrazu. Otevření odděluje objekty, které jsou spojeny úzkou šíjí.

Pokud zůstane po aplikaci metody otevření obraz nezměněn, je tento obraz pro použitý strukturní element otevřený. [2]

Uzavření

Uzavřením se nazývá dilatace následovaná erozí za použití strukturního elementu. Operace, stejně jako u metody otevření, vede k celkovému zjednodušení obrazu. Uzavření spojuje objekty, které jsou blízko u sebe. [2]

Aplikace matematické morfologie

Jak ukazuje obrázek (Obrázek 2.26), po aplikaci metody CC labelling stále v obraze zůstávají artefakty. Proto je nutno obraz dále zpracovat. Častým jevem je zde můstek, který spojuje rostlinu s artefaktem. Pro odstranění se nabízí eroze. Jako strukturní element byl nastaven obdelník 3x6.



Obrázek 2.27: Aplikace Eroze

Z obrázku (Obrázek 2.27) je patrné, že můstky byly odstraněny a zůstaly osamocené artefakty. K jejich odstranění se nabízí opět metoda CC labelling v nastavení pro odstranění skvrn.



Obrázek 2.28: Aplikace CC labelling na erodovaný obraz

Použitím eroze však došlo zároveň k poškození částí rostlin. Tento stav již sice není vratný, ale lze to částečně napravit použitím dilatace se stejným strukturálním elementem. Poškození navíc není tak velké, aby mělo velký vliv na chybovost výsledku.



Obrázek 2.29: Aplikace Dilatace

Dilatací však došlo k zvětšení objektu. Ve spojení s falešnými odezvami při použití filtrace přizpůsobenými filtry, došlo k tomu, že maska příliš přesahuje objekt ve vstupním výřezu, obzvláště vlasečnice. Proto je třeba opět použít erozi, tentokrát se strukturním elementem 3x3, který při jednom použití ubere z okraje masky vždy jeden pixel. Eroze byla aplikována pětkrát, tedy došlo k odebrání pěti pixelů z okraje masky.




Obrázek 2.30: Výsledná maska

Výsledek metody segmentace lze zobrazit vynásobením vstupního výřezu s invertovanou maskou (Obrázek 2.31).



a)



b)

Obrázek 2.31: Výsledek metody segmentace a) vstupní výřez, b) výstupní výřez

3 Závěr

Cílem práce bylo prostudování obrazu pořízeného systémem dotSlide s CCD kamerou, který obsahuje geneticky upravené klíčky rostliny. Na základě takto získaných parametrů navrhnout metodu segmentace, která by ze vstupního obrazu vybrala pouze objekt, kterým je klíček rostliny. Vzhledem k velikosti vstupních dat je celý proces navržen a zkoušen pouze na výřezu ze vstupního obrazu. Předpokládá se však, vzhledem k stejným vlastnostem jednotlivých klíčků, že bude fungovat i na celém vstupním obraze.

Metoda byla rozdělena na dvě základní části. První částí je předzpracování a druhou částí je samotná segmentace s následným dopracováním. V části předzpracování je využito získaných tvarů profilů vlásečnic. Tyto profily jsou rozděleny do tří skupin a na základě tohoto rozdělení jsou vytvořeny filtrační masky pro přizpůsobenou filtraci. Díky této metodě dojde k zvýraznění objektu oproti pozadí. Dále je na takto upravený obraz aplikována anizotropní difúze, která z obrazu odstraní jemné struktury a způsobí slabé rozmazání, které respektuje silné hrany. Takto upravený obraz je již vstupem pro druhou část metody. Jako první je na obraz aplikována hlavní segmentační metoda, a to metoda prahování. Prahování je provedeno na základě vlastností obrazu získaných z histogramu úrovní odstínů šedi. Prahování je provedeno s jedním prahem a po jeho aplikaci se získá hrubě naprahovaný obraz. Na ten je dále aplikován mediánový filtr pro eliminaci jednopixelových chyb při prahování. Hlavní výhodou mediánového filtru je zmenšení počtu operací při následující metodě. Tou je connected component labelling. Jejím úkolem je detekování souvislých oblastí na základě zadané maximální velikosti oblasti. Tyto oblasti poté smaže, pokud jsou identifikovány jako falešný objekt, a nebo nastaví na hodnotu objektu, pokud jsou identifikovány falešně jako pozadí. Na takto již téměř hotovou binární masku jsou aplikovány operace z oblasti matematické morfologie. Operace eroze pro narušení můstků spojujících objekt s vadnými oblastmi je následována opět metodou connected component labelling pro odstranění uvolněných oblastí. Poté je aplikována operace dilatace pro kompenzaci ztrát při operaci eroze. Nakonec je ještě aplikována operace eroze se strukturním elementem 3x3 pro zúžení celého objektu, kvůli rozšíření při operaci dilatace a kvůli falešným odezvám při filtraci přizpůsobenými filtry. Aplikací takto získané masky na vstupní obraz dojde k segmentaci.

Z obrázků, ukazujících průběh návrhu, je vidět, že metoda správně detekuje klíček. Avšak zároveň s tímto klíčkem po segmentaci zůstává na obraze i část pozadí v blízkém okolí klíčku. To je z velké části způsobeno různými profily vlásečnic a tedy nutností navrhnout více filtračních masek. Z toho následně plyne i větší množství falešných odezev. Dalším nevhodným artefaktem na testovaném výřezu je pak oblast na spodní části klíčku. Tato oblast vnikla vlivem struktury pozadí v této části a je způsobena skvrnou v roztoku.

Při aplikaci navržené metody v praxi by jako nejvhodnějším způsobem použití bylo rozdělení metody na více částí a po provedení každé části vyčkání na potvrzení, popřípadě úpravu parametrů. Tím by bylo možno předejít chybovosti způsobené odlišnostmi mezi jednotlivými obrazy pořízenými snímacím systémem.

Seznam použité literatury

- [1] Radim Kolar, Libor Kubecka, and Jiri Jan, "Registration and Fusion of the Autofluorescent and Infrared Retinal Images," *International Journal of Biomedical Imaging*, vol. 2008, Article ID 513478, 11 pages, 2008. doi:10.1155/2008/513478
- [2] Václav Hlaváč, Miloš Sedláček, "Zpracování signálů a obrazů," Praha: Vydavatelství ČVUT, 214 stran, 2001.
- [3] Michal Španěl, Vítězslav Beran, "Obrazové segmentační techniky," Dostupné z [www: http://www.fit.vutbr.cz/~spanel/segmentace/.cs.iso-8859-2#_Toc125769329](http://www.fit.vutbr.cz/~spanel/segmentace/.cs.iso-8859-2#_Toc125769329), 2006, Article ID 513478, 11 pages, 2005.
- [4] ODSTRČILÍK, J. *Analýza barevných snímků sítnice se zaměřením na segmentaci cévního řečiště: diplomová práce*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2008. 82 s., 2 přílohy. Vedoucí diplomové práce je prof. Ing. Jiří Jan, CSc.
- [5] JAN J.: *Medical Image Processing, Reconstruction and Restoration – Concepts and Methods*. CRC Tylor and Francis, New York 2005; ISBN 0-8247-5849-8.
- [6] Mathworks, , "Matlab help," Mathworks, 2004
- [7] CCD : *Charge-Coupled Devi* [online]. [2006-2009] [cit. 2009-05-20]. Dostupný z WWW: <<http://cs.wikipedia.org/wiki/CCD>>.
- [8] FIŠAR, Zdeněk. *Principy fluorescenční spektroskopie* [online]. [2005] [cit. 2009-05-20]. Dostupný z WWW: <<http://psych.lf1.cuni.cz/fluorescence/Default.htm>>.
- [9] „Technické údaje pro dotSlide“ dostupné z [www: http://www.olympus.cz/microscopy/22_8974.htm](http://www.olympus.cz/microscopy/22_8974.htm)
- [10] JAN, J.: *Číslicová filtrace, analýza a restaurace signálů*. VUTIUM 2002 ISBN 80-214-1558-4