



ТЕХНИЧЕСКИ УНИВЕРСИТЕТ – СОФИЯ

Факултет по телекомуникации

Катедра Радиокомуникации и видеотехнологии

маг. инж. Владимир Христов Кънчев

**ВЕРОЯТНОСТНИ МЕТОДИ
ЗА СЕГМЕНТАЦИЯ НА ИЗОБРАЖЕНИЯ**

А В Т О Р Е Ф Е Р А Т

на дисертация за придобиване на образователна и научна степен
"ДОКТОР"

Област: 5. Технически науки
(шифър и наименование)

Професионално направление 5.3: Комуникационна и компютърна техника

Научна специалност: Телевизионна и видеотехника

**Научен ръководител: проф. д-р инж. Огнян Бумбаров
доц. д-р инж. Антоанета Попова†**

Рецензенти:
доц. д-р Георги Глухчев
доц. д-р инж. Агата Манолова

СОФИЯ
2017 г.

Дисертационният труд е обсъден и насочен за защита от Катедрения съвет на катедра „Радиокомуникации и видеотехнологии“ към Факултет по телекомуникации на ТУ-София на редовно заседание, проведено на 09.01.2017 г. от 15.45 часа.

Публичната защита на дисертационния труд ще се състои на 02.05.2017 г. от 15,00 часа в Конферентната зала на БИЦ на Технически университет – София на открито заседание на научното жури, определено със заповед № ОЖ-47 / 24.01.2017 г. на Ректора на ТУ-София в състав:

1. проф. д-р инж. Огнян Бумбаров – председател
2. доц. д-р инж. Агата Манолова – научен секретар
3. доц. д-р Георги Глухчев
4. доц. д-р инж. Димо Димов
5. проф. д-р инж. Кирил Конов

Рецензенти:

1. доц. д-р Георги Глухчев
2. доц. д-р инж. Агата Манолова

Материалите по защитата са на разположение на интересуващите се в канцеларията на катедра „Радиокомуникации и видеотехнологии“, Факултет по телекомуникации на ТУ-София, блок №1, кабинет № 1254.

Дисертантът е редовен докторант към катедра „Радиокомуникации и видеотехнологии“, Факултет по телекомуникации. Изследванията по дисертационната разработка са направени от автора, като някои от тях са подкрепени от научноизследователски проекти.

Автор: маг. инж. Владимир Кънчев

Заглавие: Вероятностни методи за сегментация на изображения

Тираж: 30 броя

Отпечатано в ИПК на Технически университет – София

I. ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД

Актуалност на проблема

Сегментацията на изображения спада към предварителните операции в анализа на изображения и компютърно зрение. Според класическата дефиниция [1] тя представлява *разделяне на дадено изображение на множество от неприпокриващи се области, чието обединение е цялото изображение*. Идеята на сегментацията е изображението да се раздели на части, които да подпомагат дадено приложение. Целта е да се улеснят операциите от по-високо ниво. В компютърното зрение сегментацията се занимава с пространственото съдържание на изображенията и целта е да се разпознаят обекти (хора, животни, небе и т.н.) в произволно изображение, а при анализа на изображения обикновено сцената и обектите са предварително известни.

Въпреки че сегментацията води началото си от първите години на развитие на компютърното зрение, тя все още е запазила актуалността си. Методите за сегментация се влияят от наличния хардуер, софтуер и разработения математически апарат за дадения момент, което води до съответното изменение на актуалните проблеми и съответните им решения с течение на времето. Например, бързото развитие на техниката за медицинска визуализация и на мобилните устройства през последните 20 години е довело до нови проблеми за разрешаване като наличие на различни артефакти, ниска разделителна способност на изображения и т.н.

Цел на дисертационния труд, основни задачи и методи за изследване

Настоящата дисертация има за цел да предложи алгоритми и методи за решения на два от проблемите при сегментацията на изображения: сегментация на тъкани и откриване и сегментация на обекти в медицински изображения от ядрено-магнитен резонанс (MR) и мамограми, както и сегментация на разфокусирани области в естествени изображения. Въпреки че двата проблема са от различни области съответно на медицинската обработка на изображение и компютърното зрение, идеята е те да бъдат поставени в обща рамка заедно с подходите за решаването им.

От целта на дисертационния труд произтичат и следните основни задачи:

1. Разработване на алгоритми за детекция и сегментация на доброкачествени и злокачествени обекти и нормална тъкан в мамографски изображения;
2. Разработване на алгоритми за сегментация на мастни тъкани с Гаусов модел от MR изображения на човешко бедро;
3. Разработване на алгоритми за сегментация на здрави и дегенерирани тъкани в MR изображения на човешки мозък;
4. Разработване на алгоритъм за детекция и сегментация на разфокусирани области в естествени изображения;
5. Разработване на алгоритъм за сегментация на тъкани от човешки мозък чрез съгласуване на 2D хистограми.

Научна новост

Комбинация от съществуващи алгоритми и методи за сегментация на изображения. Разработване на оригинален метод за сегментация на изображения при задача 5.

Практическа приложимост

В медицински системи за диагностика и профилактика на различни заболявания. В инженерни системи за откриване на области с понижено качество в естествени изображения.

Апробация

Основните теоретични и експериментални резултати са изложени в пет публикации, съответно от конференции, едно списание и една глава от книга на издателство *Springer*. Конференциите са както следва: *International Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST)*, *International Conference on Communication, Electrotechnics and Medical Application (CEMA)*, *Intelligent Data Acquisition and Advanced Computing Systems (IDAACS)*, списанието е *Computer & Communications Engineering*, а главата е в книгата „*New Approaches in Intelligent Image Analysis*”.

Публикации

Основни постижения и резултати от дисертационния труд са публикувани в 5 публикации:

- [D1] **Kanchev, V.** and O. Boumbarov, “**Segmentation of Fat Tissue in MRI Images with Gaussian Models**”, *International Scientific Conference on Energy and Information Systems and Technologies 2009 (ICEST'2009)*, 25-27 June, pp. 397-400, 2009;
- [D2] Popova A., **V. Kanchev**, I. Draganov, “**Mammographic Image Segmentation by Thresholding and Fuzzy C-means Clustering**”, *Computer & Communications Engineering*, Vol. 4, No. 1, pp. 31-36, 2010;
- [D3] **Kanchev, V.**, A. Popova, I. Draganov, „**Segmentation of Neuro MR Images through Semi-Supervised Learning**“, *International Conference on Communication, Electrotechnics and Medical Application (CEMA)*, Sofia, Bulgaria, pp. 79-83, 2011;
- [D4] **Kanchev, V.**, K. Tonchev, O. Boumbarov. „**Blurred image regions detection using wavelet-based histograms and SVM**“. In *Intelligent Data Acquisition and Advanced Computing Systems (IDAACS)*, 2011 *IEEE 6th International Conference on*, Vol. 1, pp. 457-461, 2011;
- [D5] **Kanchev, V.** and R. Kountchev. "**Tissue Segmentation Methods Using 2D Histogram Matching in a Sequence of MR Brain Images**", Chapter in book *New Approaches in Intelligent Image Analysis*, Springer International Publishing, pp.83-222, 2016.


Структура и обем на дисертационния труд

Дисертационният труд е в обем от **188** страници, като включва увод, **5** глави за решаване на формулираните основни задачи, списък на основните приноси, списък на публикациите по дисертацията и използваната литература. Цитирани са общо **229** литературни източници, като всички са на латиница. Работата включва общо **43** фигури и **11** таблици. Номерата на фигурите и таблиците в автореферата съответстват на тези в дисертационния труд.

II. СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

ГЛАВА 1. ОБЗОР ПО ПРОБЛЕМА

Методите за сегментацията на изображения се делят на различни видове според зададените критерии. Например, според използваната информация сегментацията на изображения се класифицира на три вида: с учител, без учител или с частично обучение (Фиг. 1.1, среден клон): към първата група принадлежат методите с деформируеми контури/шаблони (наличие на предварителни знания за обектите), към втората – използва се текуща информация само от самото изображение - различните видове клъстеризации, а при третата – използва се частична предварителна информацията.



Фигура 1 Класификация на методите за сегментация на изображение

В раздел 1.3 на първа глава на дисертацията допълнително е направен обзор на част от съществуващите методи за сегментация на естествени и медицински изображения на базата на следните критерии: *видове признаци, количество предварителна информация и начин на вземане на решение* (Фиг. 1.1, ляв и десен клон).

В рамките на първа глава на настоящия автореферат ще бъдат описани накратко пет основни сегментационни задачи, насоките за решаване според литературата и ще бъдат направени общи изводи.

1.4.1 Детекция на образувания чрез сегментация на мамограми

Ракът на гърдата се смята за най-честото срещано раково заболяване непосредствено след рака на кожата и е отговорно за 16% от всички случаи [47] и това се дължи на съвременния начин на живот – затлъстяване, засилена консумация на алкохол и отказ от кърмене. Други рискови фактори са пол, възраст, наличие на ракови болни сред предците и високи хормонални нива [48]. Основният начин за намаляване на смъртността в момента е чрез превенция – намаляване на рисковите фактори, ранна детекция и диагностика [47], която се извършва чрез сканиране или редовни прегледи при жените.

Мамограмите се построяват след излагане на пациенти на X лъчи с нисък интензитет, които се използват масово по време на преглед. Рентгенолозите търсят в изображението аномални обекти - *микрокалцифицирани обекти* (microcalcification) и злокачествени или доброкачествени *образувания* (masses) или наречени още тумори. Микрокалцифицираните обекти образуват клъстери и се простират от 20 до няколко стотин микрона в диаметър. Образованието на гърдата е локална подутина, отток или бучка. Характеризира се с местоположение, размер, форма, граници, изкривяване на структурата и контраст. Тези характеристики се изследват от рентгенолозите и се използват при класификацията и цифровите мамографски системи за визуализация. В [49] е представен интуитивен метод за отделяне на микрокалцифицирани области.

Откриването на образувания в гърдите в мамограмите е труден проблем, поради високата сложност на отделните тъкани, присъствието на гръдни мускули, както и разнообразната форма и размер на образуванията.

Мамограмите имат различни характеристики според пациента и начина на сканиране. Злокачествените обекти имат характерна, но променлива форма; тя може да бъде описана с помощта на геометрични признаци след предварителната обработка на мамограмите. След това вариациите на формата на обектите в различните изображения могат да бъдат преодоляни с помощта на клъстеризация на признаците.

1.4.2 Сегментация на мастни тъкани в MR изображения на човешко бедро

Наднорменото тегло е индивидуално клинично заболяване и се счита за сериозен здравен проблем в развитите и развиващите се страни. Смята се още за рисков фактор при хронични злокачествени заболявания като диабет 2-ри тип, високо кръвно налягане, артерио-склероза и т.н. [67]. Точното и последователно измерване на обема на мастната тъкан позволява количествена оценка на наднорменото тегло. Визуализацията на тъкани с MR технология е предпочитан метод, защото вместо йонизираща радиация се използва радио-честотно поле, което е безвредно за пациента и осигурява разделителна способност, сравнима с разделителната способност на СТ.

Яркостта на MR изображения зависи от насищането на тъканите на човешкото тяло с водородни атоми и периода T1 за възстановяване на напречен магнитен момент на ядрата на атомите им (подраздел 1.2.2 на дисертацията). Затова тъканите с различни магнитни свойства и насищане се появяват с различни яркости в MR изображенията. За T1-притеглените изображения мастната тъкан притежава по-висока яркост от мускулната тъкан. За съжаление, яркостните им интервали не са постоянни и зависят от параметрите на сканиране, размера и позицията на пациента, качеството и типа на магнитите на скенера. Нехомогенността на постоянното магнитно поле води до допълнителни разлики в яркостните нива на пикселите на тъканите, разположени на различни места на човешкото тяло на пациента.

Този сегментационен проблем е частен случай на проблема за сегментация на здрави тъкани в MR изображения. Мастната и мускулната тъкан притежават характерно местоположение, както и променлива форма и площ. Променливият характер на яркостното разпределение на отделните тъкани се включва в Гаусовия модел чрез адаптацията му спрямо едномерната хистограма на всяко следващо MR изображение и така се преодоляват ограниченията на Гаусовия модел за сегментация.

1.4.3 Обзор на методите за сегментация на невро MR изображения с дегенерирани тъкани

Заболяването от Алцхаймър (AD) е нелечимо, дегенеративно заболяване с летален край. В момента на диагностициране заболяването вече се е разпространило в човешкия мозък и целта на лечението е да се поддържа приемливо качество на живот на пациента.

Първо трябва да се разграничат отделните заболявания - AD, умерено когнитивно увреждане (MCI) и деменция. Заболяването AD представлява нарастващо неврогенеративно смущение, което е свързано с нарушения на функцията на невроните и води до постепенно влошаване на когнитивната функция и поведение на пациента [87]. Заболяването MCI описва ранно и аномално влошаване на когнитивните способности, при кое-то хората все още се справят добре с ежедневните си дейности [88]. Приблизително 10 – 15% от пациентите с MCI развиват AD годишно [87], така че MCI е важен рисков фактор за развитието на AD. Деменцията е сериозна загуба на когнитивни способности в по-голяма степен от очакваната за възрастта му.

Промяната при пациенти болни от MCI и AD се дължи на атрофията в кортикалните и подкортикалните области на мозъка. Тъй като свиването на тъканите при пациентите, болни от MCI и AD, протича най-силно в определени области, то те могат да бъдат отделени от цялото тестово MR изображение чрез маски и да се изчислят статистическите им характеристики. Така може да се определи дали даденото MR изображение принадлежи на здрав или болен от MCI и AD пациент.

Алгоритмичните решения на трите описани сегментационни проблеми ще бъдат дадени в Глава 2 на дисертацията, а резултатите – съответно в раздели 5.2, 5.3 и 5.4.

1.4.4 Сегментация на локални разфокусирани области в естествено изображение

Артефактите в естествени изображения са разфокусираност (out-of-focus blur), изместване на средна яркост, промяна на яркостната скала, JPEG артефакти, както и различните видове геометрични преобразувания [115]. При разфокусираност, вследствие на размиване на изображението, се получава визуално заглаждане на преходите и цветовете на изображението, и така се губи информация. Също така се изменя спектъра на обектите като се намаляват ВЧ компоненти и се изглаждат преходите на обектите.

Наличието на разфокусираност в естествени изображения се смята за влошаване на качеството и се разработват алгоритми за откриване и/или премахването му.

Общата функция на влошаване на качеството на изображенията има следния вид [114]:

$$g(\tau(x, y)) = (f * h)(x, y) + n(x, y), \quad (1.2)$$

където $x = 1, \dots, M, y = 1, \dots, N$ са индексите на пикселите, а M и N са размерите на изображението, $f(x, y)$ и $g(x, y)$ представляват истинското и наблюдаваното (с влошено качество) изображение, съответно, $h(x, y)$ е функция на разсейване на точката (PSF), която обикновено е неизвестна, $n(x, y)$ е адитивен случаен шум, τ е трансформация на пространствените координати поради проекционната геометрия на изображението и $*$ описва 2D конволюцията. Възстановяване на истинското изображение представлява откриване на $f(x, y)$ и на $h(x, y)$ като се знае $g(x, y)$, използвайки частична информация за визуалната система.

В честотната област влошаването на изображение има следния вид [114]:

$$G(u, v) = H(u, v) \cdot F(u, v) + N(u, v), \quad (1.3)$$

където $H(u, v)$ е линейно инвариантен позиционен процес, който в честотната област се нарича предавателна функция, $F(u, v)$ и $G(u, v)$ са истинското и наблюдаваното изображение в честотната област, а $N(u, v)$ е адитивна некорелирана функция на шума, а (u, v) са координатите в честотна област.

1.4.4.4 Математически модели на различните видове артефакти

От разгледаните пет артефакти в този подраздел в дисертацията се използва следния артефакт със следния математически модел:

разфокусирано размиване (out-of-focus blur) - размиване, дължащо се на факта, че част от сцената не е на фокус и съответства обикновено на фона в изображенията.

$$h(i, j) = \begin{cases} \frac{1}{(\pi \cdot R^2)} & i^2 + j^2 \leq R^2 \\ 0 & \text{в останалите случаи} \end{cases}, \quad (1.7)$$

където R представлява радиус на PSF на филтъра, а в пространствената област $h(i, j)$ се нарича функция на разсейване на точката PSF, а (i, j) са пространствените координати на ядрото на филтъра.

1.4.4.5 Откриване и възстановяване на разфокусирани изображения

Алгоритмите се делят на две основни групи: (1) откриване и (2) възстановяване на разфокусирани естествени изображения. В първия случай е важно да бъдат открити части от или цели изображения с наличие на разфокусираност. Използва се в случаите, когато е необходимо да се открие кои от естествените изображения имат нужда от допълнителна обработка заради влошено качество или са били подложени на обработка за промяна на съдържанието (например скриване на лица, табелки на автомобили).

Във втория случай целта е да се възстанови оригиналното естествено изображение преди размиването му. Това е изчислително по-сложна операция и представлява в момента актуален проблем. Трудностите идват от липсата на информация за деградиращата функция на разсейване на точка (PSF), наличния шум с неизвестни параметри, както и появата на артефакти при възстановяването на изображението.

1.4.4.6 Оценка на качеството на естествени изображенията при наличие на артефакти и разфокусиране

Разработени са голям брой признаци за детекция за качеството на изображението: статистика на естествената сцена (NSS) [137], контраст [138, 139, 140], признаци на локалната структура [138], множествен мащаб и структура [131, 142] и цвят [143, 144]. Други съвременни методи за оценка от последните години са невронни мрежи с дълбоко обучение [145], разреден метод [146] и пространствената и спектралната ентропия [147]. В момента в най-новите системи се използва комбинация от тях.

Друг проблем е как да се открият естествени изображения с извънфокусно или Гаусово разфокусиране и частично разфокусиране (partial blur) (локални разфокусирани области в изображение). Първият проблем е решен до голяма степен като се използва разликата, която естествените изображения с и без разфокусиране имат в честотната област, тъй като размиването значително намалява високочестотната (ВЧ) съставка. Другите варианти използват разликата в ширината на преходите при наличието и отсъствието на Гаусово разфокусиране [114, 148] или в уейвлет пространството - промяната на стойностите на уейвлет коефициентите според различния тип и сила на размиването [149]. Интересен подход е базиран на човешкото възприятие на едва забележимото разфокусиране (just noticeable blur) [153], където се оценява силата на разфокусиране за всеки преход в изображението с прагове на кумулативни разпределения.

Този проблем е актуален, защото често изкуствено се въвеждат локални разфокусирани области от изображенията чрез НЧ размиване с цел скриване, промяна или подмяна на съдържание. Откриването на наличието и местоположението на такива области би подпомогнало експертите в много области като полицейски разследвания, филмова и ТВ индустрия. Отделно възстановяването на разфокусирани области изисква голям изчислителен ресурс, който е по-добре да се приложи върху отделни части от изображенията.

Алгоритъм за решаването на този сегментационен проблем ще бъде предложен в Глава 3 на дисертацията чрез хистограмни разпределения на уейвлет коефициенти, а резултатите ще бъдат представени в раздел 5.5.

1.4.5 Сегментация на здрави тъкани в MR изображения на човешки мозък

Основната задача е сегментация на области в MR изображения на човешкия мозък, които отговарят на здрави невро-анатомичните тъкани: бяла тъкан (WM), сива тъкан (GM) и гръбначно-мозъчна течност (CSF). Обзорът е насочен към методите, свързани с използваните признаци, операциите към тях, класификаторите и методите за оценка.

Обикновените хистограмни методи за медицинска сегментация, базирани на яркостта на отделните пиксели, използват информация директно извлечена от хистограмата. Част от методите извършват бинаризация чрез прагове [157], а други методи анализират формата на хистограмата или моделират пиковите [158], относителните позиции [159] или адаптират вероятностни разпределения [160]. Друг вид използвана хистограма на изображение е 2D хистограма, която се използва за сегментация на изображения от биопсия на бъбреци [173].

Пространствената корелация, свързана с пространствената изгладеност в рамките на дадена област на тъкан в MR изображение, се описва с две групи методи за сегментация: методи, свързани с MRF и вариационни и level set методи. В първата група методи дискретният енергиен модел включва контекстуална информация и пространствена непрекъснатост. При втората група на вариационни методи, MR изображението се моделира с частично гладка функция, докато при level set методите, контурите или повърхностите се представят като нулеви нива на функция от по-висок ред. Втората група методи постига подпикселова точност, затворен контур на сегментация и успява автоматично да извлече комплексни граници.

Съгласуването на хистограма (histogram matching) (още позната като спецификация на хистограма (histogram specification)) на едно изображение е метод за обработка на изображения, който се използва с цел генериране на друго, подобро, изображение. Тя се прилага чрез изчисляване на преобразуването между двете хистограми чрез таблица на

търсенето (LUT) или динамично оптимизиране [176]. В обработката на медицински изображения се прилага при различни операции: стандартизация на хистограми [177], проблем, възникващ поради разлики в яркостното разпределение на MR изображения, при различните сканирания, нормализация [178], регистрация [179, 180] или подобряване на MR изображения [181, 182]. В литературните източници, съгласуването на хистограмата се извършва преди сегментацията на изображения.

Сегментацията на MR изображения представлява и класификация на отделните пиксели и според използваната предварителна информация се разделя на три групи: без учител, с учител или с частичен учител – индуктивно и трансдуктивно обучение. Методите за обучение с учител конструират модел и затова постигат по-добри резултати, но налагат стриктни ограничения към MRI данните, които не винаги са изпълнени. Методите без учител групират подобните пиксели и не използват предварителна информация – притежават по-голяма възпроизводимост и адаптивност и имат по-малки ограничения към данните. Методите с частичен учител използват частична информация и са няколко вида: ансамбълна рамка [183], Бейсово трансдуктивно обучение [184] и спектрална клъстеризация [185]. Трансдуктивните методи са специален вид методи с частичен учител и не построяват функция на предсказването. Те използват вътрешната структура на всички тестови данни по време на класификацията и са изчислително по-сложни от индуктивните методи.

Стандартните едномерни хистограми не включват съществуващата корелация в MR изображенията на човешки мозък. От друга страна 2D хистограмите в литературните източници не използват съществуващата корелация между двойките пиксели в съседните MR изображения в MR последователността. Добре изследваните методи за обработка на стандартни едномерни хистограми помагат да се трансферират методи като еквилизация и съгласуване на едномерна хистограми в случая на 2D хистограма и така да се използва съществуващата корелация.

В Глава 4 ще бъде представен оригинален метод за сегментация на MR изображения чрез съгласуване на 2D хистограма, а в раздел 5.6 - резултатите.

1.5 Изводи от глава I

От анализа на литературните източници се изясни, че при сегментацията на изображения липсва общ подход, който да е успешен при всички видове изображения. Въпреки значителните си разлики, сегментационните алгоритми от литературния обзор могат да бъдат класифицирани на базата на следните критерии (според отделните си етапи):

1. използвани признаци, изчислени от тестовите изображения и от обучаващата извадка от изображения;
2. количество използвана предварителна информация;
3. метод за обучение на използвания класификатор/класификатори в сегментационния алгоритъм;
4. начин за вземане на крайно решение за отделния признак.

От направения анализ може да се направят следните изводи:

1. Яркостта на единичния пиксел не е достатъчен устойчив признак за създаването на сегментационен модел. Необходима е комбинация от различни признаци;
2. Необходимо е обучение на сегментационния модел с допълнително знание – сегментирани изображения от същия тип със същите признаци;
3. Необходимо е преминаване в друго признаково пространство, след линейно или нелинейно преобразуване, и връщане в пространството на изображението накрая;
4. Необходима е адаптация на сегментационния алгоритъм към промените на характеристиките на обектите и областите за сегментация.

ГЛАВА 2. АНАЛИЗ НА ОБЗОРА И ИЗГОТВЯНЕ НА КЛАСИФИКАЦИЯ

Основната идея в тази глава е да се създадат сегментационни модели с различни типове признаци за първите три сегментационни проблема и да се покаже как влияе

различното количество предварителна информация за обучение и вземане на решение на базата на избраните признаци. Изборът на тип признаци и на количество предварителна информация зависи от типа на изображенията и вида и характеристиките на обектите за сегментация.

Сегментацията и в трите случая само подпомага диагностиката на пациентите от страна на лекарите, защото точността на сегментационните алгоритми не е достатъчно голяма. От друга страна, те притежават значителни предимства като стабилност на работа и възможност да включат предварителни знания.

Тук ще бъдат представени три вида разработени алгоритми за сегментация на обекти и тъкани в мамограми, MR изображения на човешко бедро и човешки мозък:

1. Детекция и сегментация на доброкачествени и злокачествени обекти и нормална тъкан в мамографски рентгенови (X-ray) изображения чрез използването на клъстеризация в признаковото пространство;
2. Сегментация на мастни тъкани с едномерен Гаусов модел от MR изображения на човешко бедро;
3. Сегментация и изчисляване на статистически оценки на нормални и дегенерирали тъкани в MR изображения на човешки мозък чрез предварително създаден сегментационен модел – пространствени 3D сегментационни маски.

2.1 Алгоритъм за детекция и сегментация на злокачествени образувания в мамографски изображения

Сегментацията на обекти в мамограмите е сложна задача, тъй като мамограмите варират като наситеност, сложност и вид на текстурата на различните обекти и фон. Целта на сегментационния алгоритъм е да се отделят и класифицират злокачествените (malignant) и доброкачествените (benign) образувания (masses) – първите притежават груби и замазани (blurred) граници със голям брой частици, докато втората група - притежават кръгла и овална форма със вградени граници.

Други обекти в мамограмите освен туморите, биват калцификации (calcification) и микрокалцификации (microcalcification), които притежават различни размери. Тъй като калцификациите и микрокалцификациите представляват индикатор за присъствие на тумори, те биват включени в нашия алгоритъм при вземането на крайното решение.

2.1.1 Обща блокова схема на алгоритъма

Обектите, които се търсят, варират като размери, форма и контраст. Преходите на обектите също така се различават значително по качествата си – могат да бъдат остри и замазани. Затова е необходима предобработка, която да сегментира обектите от различните класове и да се адаптира към характерните свойства на входните мамограми – яркостен обхват, наличие на шумове, качество на преходите и т.н. Размитата класификация предотвратява появата на фалшиви позитиви и истински негативи, дава гъвкавост при вземането на решения в рамките на една мамограма. По този начин се намалява необходимото предварително знание.

В настоящия алгоритъм ще бъде представен метод за сегментация с няколко признаци, извлечени от бинарни обекти. Използва се комбинация от следните три признаци: *полутонново яркостно ниво, площ и ексцентрицитет на обектите* от изображението след извършването на морфологичните операции. Използва се минимално количество предварителна информация – интервали на допустимите стойности на отделните признаци.

Разработеният алгоритъм е описан със блокова диаграма на Фиг. 2.1. При предобработката (ст. 1, Фиг. 2.1) мамограмите се обработват и се засилват преходите, за да се увеличи точността при извличането на признаците и да се намали влиянието на съществуващия шум. За целта се прилага също медианна филтрация и подобряване на контраста на мамограмата чрез еквилизация на хистограмата ѝ.

След това се създава морфологично градиентно-амплитудно изображение, нарече-но още и морфологична градиентна карта, на базата на входната мамограма (ст. 2, Фиг. 2.1) чрез следните операции (Фиг. 2.2 в дисертацията): ерозия, дилатация и изчисляване на

разликата на двете получени маски. След това се инвертира получената морфологична градиентна карта (ст. 3, Фиг. 2.2 в дисертацията), за да се улесни визуализацията, и да се конструира хистограмата и. Изчислява се първоначалния яркостен праг (ст. 3, Фиг. 2.1), съответстващ на кумулативен вероятностен праг на хистограмата ѝ. Накрая се извършва бинаризация на инвертираната морфологичната градиентна карта (ст. 4, Фиг. 2.1) чрез изчисления праг и признаците се извличат от бинарните обекти (ст. 5, Фиг. 2.1).

Използват се следните признаци [194], за да се постигне по-добра разграничимост между различните видове образувания и микрокалцификациите при клъстеризацията:

1. ексцентрицитет;
2. площ на елипсата.

Стойностите на признаците се предават към блока с клъстеризация (ст.5, Фиг.2.1), където се изчисляват параметрите на клъстеризацията. Тогава извлечените признаци на текущата сегментирана маска итеративно се проверяват дали удовлетворяват предварителното условия за наличие на паталогични изменения. Обратната връзка се организира чрез прагова стойност, адаптирана към броя клъстери и броя сегментирани обекти. Целта е да се открият и сегментират областта на масата в мамограмата като размитата класификация дава адаптивност към вариациите на формата на обектите.

Правилата за детекция на злокачествени образувания (или паталогично изменена тъкан) са: присъствие на микрокалцификации, размер на площта в предварително зададени граници, стойности на ексцентрицитета и яркостта на предполагаемата област на паталогично изменената тъкан, както и броя клъстери.



Фигура 2.1 Обща блокова схема на алгоритъма за сегментация на мамограми

Настоящия алгоритъм е представен в статия [D2] в списанието *Computer & Communications Engineering* през 2010 година.

2.2 Сегментация на мастни тъкани в MR изображения с Гаусов модел

В този случай за сегментация на MR изображения се използва едномерен, единичен Гаусов модел върху едномерна хистограма на MR изображение. Моделът се обучава с

сегментирана маска на мастна тъкан от експерт на първото MR изображение от поредицата – изчисляват се първоначално параметрите на Гаусовия модел. След това този модел се прилага последователно с две статистически оценки върху извадка от хистограмите (за мастната тъкан) за всяко MR изображения от поредицата и се извършва сегментация на базата на яркостни прагове, изчислени от модела.

В началото, Гаусовият модел се построява на базата на яркостното разпределение на мастната тъкан от първото MR изображение на поредицата, изчислена чрез аности-раната от лекар радиолог-експерт бинарна маска, която определя местоположението на пикселите от мастната тъкан. За да се компенсира разликата в яркостите на мастната тъкан в последващите MR изображения от MR последователността, в зависимост от позицията им в човешкото бедро, оценките на параметрите на Гаусовия модел μ и σ (2.8 в дисертацията) се изчисляват чрез следните две статистически приближения:

1. оценка с максимално правдоподобие (ML);
2. Бейсова оценка (BE) на разпределението на параметрите.

За да се провери дали е изпълнено условието за нормално разпределение на яркостното разпределение на единичните пиксели на мастната тъкан се използва теста за нормалност на Колмогоров-Смирнов (KS). Този тест (подраздел 2.2.3 на дисертацията) проверява дали яркостното разпределение на мастната тъкан в хистограмата на изображението отговаря на изискванията за нормалност, за да бъде изпълнено условието за прилагане на Гаусовия модел. В следващия подраздел ще бъде дадена последователността от операции за всяко следващо MR изображение.

2.2.1 Блокова схема на алгоритъма за сегментация на мастна тъкан с Гаусов модел

Гаусовият модел се създава на базата на яркостите на отделните пиксели на мастната тъкан от MR изображението от напречен разрез на човешко бедро. Тъй като разпределението на пикселите се изменя по протежение на човешкото бедро, параметрите на разпределението се адаптират спрямо мастната тъкан на всяко следващо MR изображение. За първото MR изображение параметрите на Гаусовия модел се получават директно след прилагане на ML оценка върху яркостното разпределение на сегментираната мастна тъкан.


Алгоритъмът за сегментация на мастна тъкан от в последователността от MR изображения на бедро е показан на Фиг. 2.3. На фигурата са дадени информацията, които се предава между сегментацията на отделните MR изображения от поредицата: параметрите на Гаусовия модел, както и прагове за извличане на извадката на хистограмата от текущото MR изображение.

Алгоритъмът за сегментация е докладван [D1] на конференцията ICEST '09 във Велико Търново, България.

2.3 Сегментация на невро MR изображения чрез обучение с частичен учител

В този случай ще бъде извършена сегментацията в пространството на 3D MR изображението на човешки мозък като се използват разликите между яркостите на съответните пиксели на отделните тъкани: така не е необходимо да се изгради хистограма, но е необходима регистрация на MR отделните изображения, както и допълнителна клъстеризация. За признаци служат яркостите на вокселите на регистрираните изображения.

Тук са дадени два етапа на сегментационния алгоритъм: първият е за пресмятане на сегментационната 3D маска (Фиг. 2.4), обхващаща тези части от човешкия мозък в MR изображението, при които присъствието на дегенериралите тъкани е най-вероятно. Маската се създава след прилагане на SVM класификатор или Kullback-Leibler (KL) критерий за



Фигура 2.3 Блокова статия за сегментация на MR изображения на мастна тъкан

дивергенция за определяне на най-отличаващите се области в две предварително обработени и регистрирани MR изображения на два пациента – AD и здрав пациент. След това във втория сегментационен алгоритъм (Фиг. 2.5) сегментационната маска се налага върху MR изображения на човешки мозък на диагностицирани с AD и MCI пациенти, както и на здрави пациенти, за да се извърши сегментация. След това се изчисляват статистическите оценки на яркостта на извлечените воксели на отделните сегментирани тъкани при различните класове MR изображения.

Сегментационните алгоритми трябва да се справят със следните предизвикателства: различни характеристики на тъканите на човешкия мозък в MR изображенията в зависимост от използваното MR сканиращо устройство, различни размери на човешкия мозък в зависимост от възрастта и пола на пациента, различна деградация на тъканите на мозъка според различния прогрес на развитие на AD, присъствие на различни артефакти и шумове в MR изображението.

Алгоритъмът за сегментация е докладван [D3] на конференция СЕМА'11 в София, България.

2.4 Резултати и изводи

2.4.1 Резултати

Резултати за раздел 2.1:

1. Мамограмите притежават променливи характеристики според типа на скенера и условията на сканиране. Аналогично, злокачествените образувания също имат изменливи характеристики според типа и етапа на развитието си;
2. Липсата на сегментационен модел води до недобра сегментация на злокачествените образувания в зададената мамограма - необходими са предварителни прагове/интервали за стойностите на отделните признаци;
3. Използването на повече признаци би увеличило точността на класификация.

Резултати за раздел 2.2:

1. Едномерните хистограми, базирани на единични пиксели, не съдържат пространствена информация и затова са необходими допълнителни последващи обработки;
2. Използването на единичен Гаусов модел при класификацията на сегменти в едномерната хистограма води до поява на значителни области на припокриване;
3. Фиксираният избор на MR изображение за създаване на сегментационен модел води до усложнения на приближеното изчисляване на оценките на параметрите на Гаусовия модел за сегментация спрямо всяко следващо MR изображение;
4. Няма пълно съответствие между всяко MR изображение и хистограмата му – затова е необходима адаптация на Гаусовия модел за всяко ново MR изображение.



Фигура 2.4 Създаване на 3D сегментационна маска на 3D MR изображение на здрав и болни (AD, MCI)



Фигура 2.5 Алгоритъм за сегментация на MR изображение на тъканите в човешкия мозък и изчисляване на пациенти статистически параметри на отделните тъкани

Резултати за раздел 2.3:

1. Пространството на 3D MR изображението не е подходящо, за да се открият най-представителните воксели при деградираните, от MCI AD болести, тъкани – предобработката изменя характеристиките им;
2. Статистиката на тези воксели не е достатъчна за изчисляване на дискриминативните статистически оценки между здрави и деградирани тъкани;
3. Необходимо е да се използва друго пространство, за да се постигне по-точна сегментация и/или да се използват непараметрични сегментационни модели.

2.4.2 Изводи

Изводи за раздел 2.1:

1. Сегментацията на аномални образувания в мамограмите изисква въвеждането на параметричен или непараметричен модел, за да се получат по-добри резултати;
2. Въвеждането на по-голям брой параметри в модела, както и методи за приближение на модела към всяка нова тестова мамограма би повишил точността му.

Изводи за раздел 2.2:

1. Класификацията на хистограмата в отделни сегменти води до поява на припокриващи се области – изисква се изчисляване на границата в тази област;
2. Адаптивният метод за избор на MR изображение (както и мамограма) за построяването на модел за сегментация би повишил точността на крайните резултати.

Изводи за раздел 2.3:

1. Пространството на изображението не позволява да се изчислят статистически оценки на яркостите на вокселите им, които да разграничат MR изображенията на здрави и болни от AD и MCI пациенти и да се открият деградираните от болести тъкани.

ГЛАВА 3

В настоящата глава е представен разработеният алгоритъм за откриване и сегментация на локални области с разфокусирано размиване (out-of-focus blur) в естествено изображение. Използва се предварително обучен SVM класификатор с признаков вектор от едномерно разпределение на сумата на хоризонтални и вертикални уейвлет коефициенти. Използваният признаков вектор е получен след уейвлетно преобразуване и отговаря на хоризонталните и вертикалните градиенти, съответно на хоризонталните и вертикалните преходи в изображението. За целта се преминава в друго уейвлет пространство, за да се постигне по-добро откриване на локалните разфокусирани области.

Естествените изображения се характеризират с голям брой градиенти (преходи), които са сравнително равномерно разпределени и зависят от съдържанието им. Локалното разфокусиране намалява значително стойностите на градиентите, пропорционално на степента си и намалява наличната информация в изображенията. Чрез уейвлет преобразуването се постига също подчертаване на вертикалните и хоризонталните градиенти.

В нашия алгоритъм се използва също така и относителната разлика, която се причинява от локалното размиване, между едномерното разпределение на уейвлет коефициентите на разфокусираната област спрямо съответното разпределение на останалата част на изображението. Използват се локални квадратни фрагменти с определен размер, което едновременно позволява локализация на разфокусираната област и същевременно построяване на непрекъснати уейвлет разпределения.

Сегментационният алгоритъм е реализиран на три етапа – първо, се обучава SVM класификатор, след това се класифицират сегментите от изображението и като изход на втория етап има разфокусирана област, добре фокусирана област и преходна област между двете, която съдържа едновременно разфокусирани и фокусирани пиксели. За по-точно определяне на границите на разфокусираната област се прави допълнителна бинаризация на преходната област (трети етап) с прагове, получени от уейвлет разпределенията на класифицираната като разфокусирана област от втория етап.

3.1 Описание на алгоритъма

Първо, обучението на SVM класификатора се извършва със съответните едномерни разпределения на уейвлет коефициенти на два класа: качествени, фокусирани, изображения на обучителното множество и съответните им разфокусирани размити изображения. За целта една тестова база с изображения се подлага на НЧ Гаусово филтриране.

Обучението на SVM класификатора се състои от следните стъпки (Фиг. 3.1):

1. Зареждат се фокусираните естествени RGB изображения от тестовата база (ст.1, Фиг.3.1) - първи клас изображения;
2. Прилага се Гаусово НЧ глобално филтриране върху всички естествени фокусирани изображения (ст. 2, Фиг. 3.1) - втори клас изображения;
3. Преобразуват се входните цветни изображения от RGB в YUV цветово пространство и се извличат Y компонентите на двата класа от естествени изображения (ст. 3, Фиг. 3.1): качествени (фокусирани) и разфокусирани;
4. Извършва се уейвлет преобразуване (раздел 3.2 от дисертацията) и се построяват уейвлет разпределенията на Y компонентите (ст. 3, Фиг. 3.1) на двата класа изображения от т. 3 според формула 3.4 от дисертацията, съответстващи на сумата от вертикални и хоризонтални градиенти на отделните изображения (Фиг. 3.2);
5. Обучава се SVM класификатора (ст. 4, Фиг. 3.1) с уейвлет разпределенията от т. 4;


Обучението се извършва чрез крос-валидация с k на брой подгрупи от изображения, за да се увеличи генерализацията на сегментационния алгоритъм при малък брой изображения и да се изберат най-добрите параметри на ядрото на SVM класификатора.

Вторият етап се състои от следните стъпки:

1. Построява се уейвлет градиентна карта като се извличат припокриващи се фрагменти (Фиг. 3.4 б) с размери 64×64 (ст. 7, Фиг. 3.1) и се построява хистограмно


- уейвлет разпределение на сумата от хоризонталните и вертикалните градиенти за всеки извлечен фрагмент (ст. 8, Фиг. 3.1) (Фиг. 3.9) по формула 3.4;
2. Прилага се обучен вероятностен SVM класификатор спрямо уейвлет хистограмите на всички фрагменти (ст. 9, Фиг. 3.1) и се получава изходна оценка в интервала $[0,1]$ за разфокусираност за дадения фрагмент: ако предсказаната стойност е ≥ 0.5 - разфокусиран фрагмент, ако $e < 0.5$ - фокусиран, качествен фрагмент;
 3. Построява се вероятностна карта (Фиг. 3.5) на тестовото изображение, базирана на предсказаните стойности от SVM класификатора за всички фрагменти;
 4. Построява се разпределение (Фиг. 3.6) на вероятностите на предсказаните стойности на всички фрагменти за тестовото изображение;
 5. Анализира се полученото разпределение и се изчисляват два прага θ_1 и θ_2 (Фиг. 3.6) за класификация на вероятностната карта в разфокусирана (размита) област (РО), неразфокусирана (качествена) област (НРО) и преходна област (ПО) (ст. 10, Фиг. 3.1).

В стъпка 2 се използват припокриващи фрагменти, за да се увеличи точността на откриване на разфокусираните области и устойчивостта на алгоритъма към вариациите на границите на търсената разфокусирана област. Размерът на квадратния фрагмент се определя в резултат на компромис: големите стойности биха довели до ниска точност на детектираната област, а ниските стойности до построяване на прекъснати уейвлет разпределения. Плъзгащият се прозорец се измества в хоризонтална и вертикална посока с изместване (размер на фрагмента) * 0.25 (Фиг. 3.4б).



Фигура 3.1 Обща блокова схема на алгоритъма за сегментация на разфокусирани области в изображение

В стъпка 7 от втория етап (сегментация на тестовото изображение) се използват два прага: нисък θ_1 и висок θ_2 . За първият праг е избрана стойност $\theta_1 = 0.5$, защото е праг на предсказването за наличие на разфокусираност на вероятностния SVM. Стойността на втория праг θ_2 се определя емпирично като първия бин (по посока на намаляваща вероятност), чиято стойност е равна на 80% от локалната пикова стойност на хистограмата в интервала $[0.5, 1]$. Графичното представяне на хистограмата на вероятностната карта (разпределението на предсказаните вероятности на отделните фрагменти на изображението) и пресметнатите два прага са показани на (Фиг. 3.6):




Фиг. 3.2 Разпределения на уейвлет коефициентите на размити (разфокусирани) и качествени (фокусирани) изображения от обучаващата извадка от изображения



Фигура 3.3 Тестово изображение - “buildings.jpg” from LIVE база изображение с локална разфокусирана област


Третият етап на предложения алгоритъм се състои от следните стъпки:

1. Построяват се едномерни разпределения на уейвлет коефициентите за РО и НРО от уейвлет градиентната карта (ст. 11, Фиг. 3.1);
2. Извършва се ML статистическа оценка на параметрите на Лапласово разпределение (3.8 в дисертацията), за да се моделира градиентното разпределение на РО (ст. 11, Фиг. 3.1);
3. Изчисляват се прагове t_1 и t_2 , които съответстват на 99% доверителен интервал (3.10 в дисертацията) на Лапласовото разпределение от предишната точка 2 (Фиг. 3.7) (ст. 11, Фиг. 3.1);
4. Сегментира се ПО в уейвлет картата чрез изчислените прагове t_1 и t_2 , и се получават разфокусирана и неразфокусирана област РО1 и НРО1 (ст. 12, Фиг. 3.1);




а б
Фигура 3.4 Неприпокриващи се (а) и припокриващи се фрагменти (блокове) (б) за вероятностна SVM оценка

Фигура 3.5 Вероятностна карта на класифицираните фрагменти на изображението



Фигура 3.6 Хистограма на фрагментите на вероятностната карта и изчислените прагове

- Бинарните маски на РО1 и РО се комбинират в една глобална бинарна маска на сегментираната разфокусирана област. Прилага се бинарна морфологична операция затваряне със структурен елемент 5×5 върху получената бинарна маска (ст. 12, Фиг. 3.1), за да се премахнат шумовите елементи.



Фигура 3.7 Разпределение на уейвлет коефициентите на разфокусирана област (РО) и неразфокусирана област (НРО) и пресмятане на праговете

Този алгоритъм е докладван [D4] на конференцията IDAACS'11 в Прага, Чешка република.

3.5 Резултати и изводи

3.5.1 Резултати

1. Отделянето на разфокусирана област в естествени изображения се постига чрез използване на дискриминативни признаци, съставени от хистограмни уейвлет разпределения на сумата от вертикални и хоризонтални градиенти на изображението.
2. Отделянето на разфокусираната област изисква използвания SVM класификатор да бъде обучен с разфокусирани изображения със сходна степен, за да се получи по-точна сегментация;
3. Използват се прагове за по-точно класифициране на градиентите на преходната област, използвайки факта, че хистограмното уейвлет разпределение на отделената разфокусирана област от втория етап се подчинява на Лапласово разпределение;
4. Естествените изображения предварително се разделят на две групи: природни изображения и "man-made" изображения, за да се постигне по-точна класификация и сегментация на разфокусираната област.

3.5.2 Изводи

1. Отделянето на разфокусираната област се извършва в уейвлет пространството: според литературните източници това може да се направи също чрез SVD преобразуване [155] или чрез преобразуване на Фурие [115];
2. Адаптирането на Лапласовото уейвлет разпределение на разфокусираната област позволява адаптиране спрямо съдържанието на тестовото изображение;
3. За да се сегментира най-точно разфокусираната област е необходимо класификаторът SVM да се обучи със сходен тип изображения, разфокусирани със степен, сходна на степента на разфокусиране на търсената област в изображението.

ГЛАВА 4

В тази глава ще бъде представен разработения нов метод за сегментация на здрави тъкани в MR изображения на човешки мозък чрез съгласуване на 2D хистограми (2D histogram matching). Целта е да се сегментират невроанатомичните тъкани на здрав мозък в MR изображения: бяла тъкан (WM), сива тъкан (GM) и гръбначно-мозъчна течност (CSF). Използват се още и три допълнителни класове преходи за съседните двойки пиксели: сива тъкан–бяла тъкан (GM-WM), гръбначно-мозъчна течност–сива тъкан (CSF-GM) и гръбначно-мозъчна течност–бяла тъкан (CSF-WM).

Сегментационният метод е построен на базата на трансдуктивно частично обучение (подраздел 6.4.1 в [D6]) и затова тестовите MR изображения и MR изображенията, от които се създава сегментационния модел, принадлежат на една и съща MR последователност. Сегментационният модел, от своя страна, се състои от 2D хистограмите на отделните тъкани и матрицата на преходите за всяка MR подпоследователност.

Основните операции от предложения сегментационен метод се извършват върху 2D хистограмите на отделните MR изображения. От една страна 2D хистограмите осигуряват стабилно представяне на корелацията между отделните съседни MR изображения, а същевременно дават и достатъчно точна и богата информация за всяко MR изображение: класове тъкани и преходи. По този начин се оценява подобие то между отделните съседни MR изображения, като се избягва нестабилността на оценката на подобие то в пространството на MR изображенията.

4.1 Основни идеи на разработения сегментационен метод

Накратко, разработеният сегментационен метод от тази глава се характеризира със следните оригинални идеи: (1) въвежда се собствена 2D хистограма на двойките пиксели в MR изображение на човешки мозък, (2) предлага се алгоритъм за съгласуване на 2D хистограми, (3) изпълнява се алгоритъм за сегментация на здравите тъкани на човешки мозък в MR изображение чрез обратна проекция на класифицираната 2D хистограма.

4.2 Стъпки на предложения сегментационен метод

На Фиг. 4.1 са представени отделните стъпки на разработения сегментационен метод: предобработка на всяко MR изображение и разделяне на MR последователността на MR подпоследователности (ст. 1), избор на MR изображения модели (ст. 2), изчисляване на тестовите 2D хистограми, 2D хистограмите модели и предобработката им (ст. 3). След това се извършва съгласуване на тестовата 2D хистограма (ст. 4) с 2D хистограмите модели и получаване на обучителни матрици за отделните тъкани, обучение на метриката на разстояние и класификация с kNN класификатор на тестовата 2D хистог-рама (ст. 5). Накрая се извършва сегментация на тестовото MR изображение чрез обратна проекция на класифицираната вече 2D хистограма (ст. 6).

Като входни данни се използват последователности от MR изображения от тестовите MRI данни, сегментационни “ground-truth” маски за отделни тъкани на избраните MR изображения за построяване на сегментационния модел. Сегментационните маски са получени чрез ръчно сегментиране на отделните тъкани на човешкия мозък от лекари радиолози и са важна част от тестовите MRI данни. Останалите сегментационни маски на MR изображенията от поредицата се използват за оценка на резултата от сегментацията.

Отделните стъпки на метода за сегментация имат следното по-подробно описание: (ст. 1) всички MR изображения се подлагат на предварителна обработка и цялата MR последователност се разделя на няколко MR подпоследователности като се изчисли т. нар. вълново контурно разстояние (wave hedges distance) между 2D хистограмите на отделните MR изображения (раздел 4.4 в дисертацията). Целта е да се запази нормираната му стойност в предварително емпирично зададен интервал (Фиг. 4.5 в дисертацията).

След това (ст. 2) въз основа на тъканите от първото и последното MR изображения за всяка MR подпоследователност се построяват *2D хистограми - модели*: *2D хистограма модел* за всяка тъкан и *2D хистограма модел на преходите* между отделните тъкани (Фиг. 4.6 в дисертацията). След това 2D хистограмите модели на отделните тъкани се подлагат на предобработка (раздел 4.5 в дисертацията).

За всяко *тестово MR изображение* (ст. 3) се построява *тестова 2D хистограма*, на която се премахват биновете (двойките пиксели) на преходите, които съвпадат с ненулевите бинове на 2D хистограмите на преходите, и се запазват за последния етап на



Фигура 4.1 Обща блокова схема на метода за сегментация на MR изображения чрез съгласуване на 2D хистограми

сегментация на MR изображение чрез обратна проекция. След това тестовата 2D хистограма се разделя на няколко сегмента (Фиг. 4.9 в дисертацията), които съответстват на тъканите

CSF, GM и WM. Това съкращаване се извършва, за да се отделят съответните бинове за дадената тъкан и съгласуването да се извърши между 2D хистограми с близък брой бинове.

За да се получат обучителни матрици на тъканите (раздел 4.6 в дисертацията), отделните *сегменти на тестовата 2D хистограма се съгласуват* (ст. 4) спрямо съответните 2D хистограми модели на тъканите (Фиг. 4.7 в дисертацията). За целта ненулевите бинове на двете 2D хистограми се преобразуват чрез зиг-заг обхождане съответно във тестови вектори и вектори модели. След това векторите се подлагат на съкращаване в рамките на предварително избран процентилен интервал. Съгласуването на 2D хистограмите се извършва чрез изчисляването на вектор на съответствията (vector mapping - таблица на търсенето (LUT) чрез съответната "разгъната" 1D хистограма) (Фиг. 4.8 в дисертацията) и се изчислява специфициран вектор, който притежава дължината на тестовия вектор и стойностите на съответния вектор модел.

След съгласуването, за да се получи обучителния вектор за всяка тъкан, от новополучения специфициран вектор на всеки сегмент на тестовата 2D хистограма се изважда съответния му вектор преди спецификацията (Фиг. 4.7 в дисертацията). Разликата им се квантува чрез клъстеризация *с*ксредни стойности. Запазват се елементите с най-големи стойности, които принадлежат на клъстера с най-голяма средна стойност (центроид). Тези запазени елементи се проектират в рамките на началната тестова 2D хистограма и по този начин се получават обучителни матрици за отделните тъкани (Фиг. 4.9 в дисертацията). Те притежават по-стабилно и по-концентрирано разпределение, както и по-малък брой бинове, отколкото съответните им 2D хистограми модели.

След това *тестовата 2D хистограма се класифицира* (ст. 5) (Фиг. 4.9 в дисертацията) като се използват отделните сегменти на тестовата 2D хистограма и обучителните матрици за отделните тъкани (раздел 4.7 в дисертацията). За да се постигне по-добра точност, се прилага метод най-близък съсед с голямо отстояние (LMNN) за обучение на метриката на разстояние между отделните бинове на обучителните матрици. След това обучената метрика се прилага върху биновете от сегментите на тестовата 2D хистограма и те се класифицират с помощта на класификатор най-близък съсед (kNN).

За да се извърши *сегментация* (ст. 6) на *тестовото MR изображение* се създават вероятностни карти за всяка тъкан и на фона (Фиг. 4.11 в дисертацията), като се използва обратна 2D хистограмна проекция на класифицираната вече тестова 2D хистограма (раздел 4.8 в дисертацията). На всеки пиксел се присвоява коефициент с плаваща запетая между 0 и 1 в зависимост от това, колко от осемте двойки пиксели в локалния прозорец, принадлежат на съответния клас тъкан или фон в класифицираната тестова 2D хистограма. Биновете на преходите между тъканите в класифицираната 2D хистограма се прибавят с равна тежест към вероятностните карти на съответните им тъкани. Накрая крайното решение за принадлежност на даден пиксел към определена тъкан се извършва с вземане на решение по болшинство между отделните вероятностни карти.

Разработеният метод за сегментация е приложен върху тестови бази с последователности от MR изображения на човешки мозък IBSR 18, IBSR 20 и BrainWeb. Получените резултати са по-добри или сравними по точност по отношение на известните съвременни алгоритми за сегментация.

Настоящият метод за сегментация е публикуван в [D5] като глава от книгата *New Approaches in Intelligent Image Analysis* (2016), издателство Springer.

4.9.1 Резултати

1 Предложената 2D хистограма (сума от GLCM матрици) разграничава по-добре тъканите и преходите в MR изображение от стандартната 2D хистограма [173].

2 Съществува корелация между 2D хистограмите на съседните MR изображения. Тази корелация намалява с увеличение на разстоянието по между им (Фиг. 4.5 в дисертацията) и се измерва с нормираното вълново разстояние.

3. Алгоритмът за съгласуване на 2D хистограмите в едномерното пространство (спецификация на вектори) се извършва с помощта на LUT (Фиг. 4.7 и 4.8 в дисертацията). Това е изчислително най-сложната част от предложения сегментационен метод.

4. Алгоритмът за сегментация на тестово MR изображение чрез обратна проекция повишава точността си, защото извършва сегментацията на базата на класифицираната тестова 2D хистограма и откритите двойки пиксели на преходите (Фиг. 4.10 и 4.11 в дисертацията).

4.9.2 Изводи

1 Предложената 2D хистограма (сума от GLCM матрици) е по-добра от предложената в [173] 2D хистограма; тя позволява последващо обратно връщане в пространството на MR изображението и сегментацията му.

2. Сегментацията на базата на класификацията на тестовата 2D хистограма е по-стабилна и по-точна след съгласуването на 2D хистограмите в процентилен интервал. Причина за това е премахването на негативното влияние на силно отдалечените елементи.

3. Точността на сегментационния алгоритъм се увеличава след добавянето на преходите към основните тъкани по време на сегментацията с обратна проекция (Фиг. 4.9 и 4.10 в дисертацията). Това засяга сегментацията на пикселите по границите между съседните тъкани.

ГЛАВА 5. ЕКСПЕРИМЕНТАЛНА ПРОВЕРКА

В настоящата глава ще бъдат описани резултатите от разработените сегментационни алгоритми върху избрани тестови изображения, както и публично достъпни тестови бази от изображения.

Първо се описват параметрите за оценка на резултатите от сегментацията (раздел 5.1) с приложенията си в дисертацията. След това биват представени резултатите от разработените алгоритми за сегментация на: злокачествени образувания и калцификации/микрокалцификации в мамограми (раздел 5.2), мастна тъкан в MR изображения на човешко бедро (раздел 5.3) и дегенерирали тъкани на човешки мозък в MR изображения (раздел 5.4), локални разфокусирани области в естествени изображения (раздел 5.5) и най-накрая нормални, здрави тъкани на човешки мозък в MR изображения (раздел 5.6). За всеки алгоритъм ще бъдат дадени използваните тестови данни, програмния език, на който сегментационните алгоритми са програмирани и резултатите от сегментацията.

5.1. Коефициенти за оценка на резултатите от сегментацията

За да се оценят резултатите от сегментацията, се използват следните параметри за оценка между сегментираната област S_1 и съответната област за проверка (ground-truth) S_2 : Jaccard и Dice коефициенти [209], precision, recall, specificity и FPR оценки [210]. Параметрите са подробно описани в раздел 5.1 на дисертацията.

5.2 Резултати от сегментация на мамографски изображения чрез прагове и клъстеризация

Алгоритмите са тествани върху изображения мамограми от публично достъпната минибаза MIAS [211] и са показани резултатите за две от тези изображения. Първата мамограма съдържа гърда със мастна тъкан на фона, с злокачествени образувания (Фиг. 5.1a) – болен пациент, докато при втората мамограма (Фиг. 5.2a) има мастна гранулезна тъкан на фона и няма абнормални елементи – това е случай на здрав пациент. Алгоритъмът е разработен в програмната среда Matlab 2008a.


В началото шумовете и артефактите в мамограмите се премахват с използването на медианен филтър (7×7). След това се извършва подобряване на контраста в мамограмата чрез еквализация на хисторамата ѝ. Така се постига разширяване на яркостния обхват на тъканта на гърдата и на наличните болестни образувания.

На следващия етап се създава морфологична градиентна карта, при която границите на абнормалните елементи биват подобвени. Целта е да се постигне по-добра визуализация


при наличие на подозрителните области за болестни образувания и микро-калцираните обекти (Фиг. 5.1б и Фиг. 5.2б), и така да се повиши качеството на преходите.

Градиентната карта се бинаризира чрез първоначален яркостен праг, съответстващ на 90% кумулативен праг и се използва стъпка $\Delta\theta = 1\%$ за подобряване на резултатите като се спазват редица допълнителни изисквания относно броя бинаризирани обекти. Използват се предварителни знания за присъствието в градиентната карта на злокачественото раково образувание: то притежава почти кръгова форма и освен това се отчита присъствие на обекти – микрокалцификати, които имат по-малка площ и промен-лива форма. Затова трябва да се оцени всеки праг за бинаризация на базата на следните параметри: *брой клъстери* K на размитата клъстеризация, *брой малки обекти* в бинарното изображение (възможни микрокалцифицирани обекти), *площ на главния обект* след бинаризацията, *яркостта му* и *параметъра му ексцентрицитет*. Целта е да се постигне разделяне с три клъстера $K = 3$ образувание на тумора, фона и шум/микрокалцификати. За да се намалят шумовите елементи след бинаризацията с праг, се променя стойността на прага, докато броят N обекти е по-малък от 10.

Друга предварителна информация, която се използва в този случай, е позицията на фона и по-високата му яркост (след инверсията на картата). Признаците са сравнително добре разграничими, но е необходимо да се регулира стойността на прага, заради различните яркостни обхвати на абнормалните обекти в различните мамограми. В първият случай областта с подозрително образувание се сегментира при наличието на следните обхвати от стойности на отделните признаци: *площ* – 2000 – 4000 пиксели, *ексцентрицитет* 0.3 – 0.6, и *максимално яркостно ниво* (Фиг. 5.1в), докато във втория случай предимно фона е отделен (Фиг. 5.2в). Алгоритъмът не сегментира областите с шумови елементи в тъканта на гърдата, защото съответните стойности на признаците остават извън споменатите интервали.



Фигура 5.1 Мамограма с болестно образувание: (а) входна мамограма, (б) инвертирана морфологична градиентна карта, (в) бинаризирана инвертирана морфологична градиентна карта



Фигура 5.2 Мамограма без абнормални образувания: (а) входна мамограма, (б) инвертирана морфологична градиентна карта, (в) бинаризирана инвертирана морфологична градиентна карта


5.3 Резултати от сегментация на мастна тъкан в MR изображения на човешко бедро чрез Гаусов модел

В настоящия алгоритъм се използва тестова MR последователност от 10 MR изображения (1-Тесла MR скенер) на човешко бедро от таза до коляното, в аксиалната равнина, на пациент затлъстяла жена в напреднала възраст. Целта е да се оцени обема на мастната и мускулната тъкан, за да бъде определено здравословното състояние на пациента. Всички MR изображения са в DICOM файлов формат, не е извършена предварителна обработка, филтриране или компресиране и не са публично достъпни в Интернет.


Обучението на Гаусовия модел се прилага върху всички MR изображения от обучаващата извадка от MR изображения като първоначално параметрите му се пресмятат със статистическа оценка максимално правдоподобие (ML) с помощта на аотирана маска от експерт за първото MR изображение. След като Гаусовият модел се адаптира и параметрите му се преизчисляват, базирайки се на хистограмите на всяко изображения от MR последователността.

След обучението на Гаусовият модел, той се използва заедно с хистограмата на текущото MR изображение, за да се извърши сегментацията. Използват се фиксирани процентилни стойности за изчисляване на яркостните прагове $\theta_1 = 2.5\%$ и $\theta_2 = 97.5\%$ за сегментиране на мастната тъкан в MR изображенията.


Показани са резултатите от сегментацията на две MR изображения от MR последователността – 4-тото MR изображение (от горната част на коляното) (Фиг. 5.3а и 5.4) и 10-тото MR изображение (от долната част на бедрото до коляното) (Фиг. 5.3б и 5.5). Тези изображения са избрани, за да се покаже разликата в характеристиките на мастната тъкан по протежение на MR последователността. Нормираните яркостни прагове за двете MR изображения са дадени в Таблица 5.1.



Фигура 5.3 Входни тестови MR изображение – 4-то и 10-то MR изображение от MR последователността.



Фигура 5.4 Сегментационна маска на мастната тъкан в 4-то MR изображение



Фигура 5.5 Сегментационна маска на мастната тъкан в 10-то MR изображение

Таблица 5.1 Нормирани яркостни прагове за сегментацията на мастната тъкан в 4-то и 10-то MR изображение

Номер на MR изображение	Долен яркостен праг	Горен яркостен праг
4-то MR изображение	0.3823	0.9136
10-то MR изображение	0.4119	0.8868

За количествена оценка на резултатите от сегментацията на мастната тъкан в MR изображението се използват следните коефициенти - TPR и FPR (Таблица 5.2). Характеристиките на областите на костта, мускулите и мастната тъкан се различават значително. Резултатите от сегментацията на мастната тъкан визуално са представени на Фиг. 5.4 и 5.5. Точността при 10-тото MR изображение е по-слаба въпреки последователното определяне на параметрите на Гаусовия модел, поради разликите в характеристиките на мастната тъкан в средата и в краищата на MR последователността. Тъй като костта притежава яркостно разпределение, подобно на това на мастната тъкан, е необходимо да се премахне сегментираната кост по време на пост-морфологичната обработката, използвайки местоположението ѝ (Фиг. 5.4 и 5.5).

Таблица 5.2 Оценка на резултатите от сегментацията на мастна тъкан в 4-то и 10-то MR изображение

Номер на MR изображения	Преди бинарна филтрация		След бинарна филтрация		
	TPR	FPR	TPR	FPR	Площ [%]
4-то MR изображение	0.984	0.006	0.977	0.001	47.89
10-то MR изображение	0.952	0.016	0.953	0.005	62.67

5.4 Сегментация на дегенерирани тъкани в 3D MR изображения на човешки мозък и статистически оценки

В настоящия раздел се разглежда последователността от MR изображения на човешки мозък като едно 3D MR изображение, а яркостното разпределение на отделните воксели се използват като признак за извършване на отделните операции.

За да се конструира 3D сегментационна маска на човешкия мозък, се избират две различни MR изображения на човешки мозъци на два пациенти, единия диагностициран с AD, а другия на здрав пациент. На базата на най-различаващите се тъкани от двете MR изображения се изчислява карта на дискриминативните области в съответните MR изображения след регистрацията на двете MR изображения и клъстеризация. След това маската и картата се налагат върху тестови MR изображения на човешки мозък на здрави пациенти и на пациенти съответно болни от MCI и AD.

Извършва се също автоматично премахване на черепната тъкан и кожа, обвиваща човешкия мозък с BrainSuite [212], регистрация на невро MR изображенията и статистическа оценка на яркостните стойности чрез BrainImage Suite [213]. Невро MR изображенията са избрани произволно от тестовата база ADNI - Alzheimer's Disease Neuroimaging Initiative от MR изображения. Изчисляват се статистически оценки – средна стойност и стандартно отклонение на яркостите на вокселите от трите тъкани (в интервал 0 – 255) – гръбначно-мозъчна течност (CSF), сива тъкан (GM) и бяла тъкан (WM) от приложената маска върху невро изображения от здрави пациенти, болни от AD и от MCI (Таблица 5.2) пациенти, съответно.

Таблица 5.3 Статистически оценки на яркостите на вокселите на отделните тъкани при здрави пациенти и пациенти болни от MCI и AD

	Средна стойност на яркостта на вокселите от сегментираните тъкани			Стандартно отклонение на яркостта на вокселите от сегментираните тъкани		
	CSF	GM	WM	CSF	GM	WM
1. Здрави пациенти	30	124.9	224,1	9	60	167.4
2.MCI болни пациенти	51	148.7	211.7	22	65.2	102.6
3.AD болни пациенти	27	87.5	217.8	5	40.7	53.5

Основната последица от наличието на заболяванията MCI и AD е, че средната яркостна стойност на отделните тъкани – CSF, GM и WM – се измества в две различни посоки. При AD заболяването се получава намаляване на стандартното отклонение на яркостите на отделните тъкани, както и намаляване на средната яркост на GM тъкан. Това е резултат на дегенерацията на тъканите – пространственото им свиване и съответно намаляването на броя на вокселите им.

От разработения алгоритъм може да се направи извод, че сегментационните модели на базата на статистически оценки на яркостното разпределение на единичните воксели се припокриват значително. Това води до ограничено приложение за сегментация и детекция на здрави и дегенерирани тъкани в MR изображения на човешки мозък.

5.5 Резултати от алгоритъм за откриване на разфокусирани области в естествени изображения

Приложен е алгоритъм за откриване и отделяне на области с особени характеристики в естествени изображения – локални разфокусирани области. За тестване на алгоритъма за откриване на локалните разфокусирани области в изображенията е използвано множество от 100 некомпресирани естествени изображения, комбинация от публичната база от изображения LIVE [121], [214] и [215] и от www.PBase.com.

Във всяко изображение разфокусираната област се създава чрез НЧ филтрация с Гаусов филтър, която извършва НЧ разфокусиране (Gaussian blur filter). Разфокусираната област представлява правоъгълник, който варира от 10% до 30% от цялото изображение. Примери за тези тестови изображения са дадени на Фиг. 5.8. Те съдържат природен (Фиг. 5.8а) или градски пейзаж (Фиг. 5.8б). Прилагат се три степени на филтриране, за да се оцени работата на сегментационния алгоритъм.

В началото тестовата база от изображения се разделя на две основни групи: 50 естествени изображения от природен пейзаж и 50-от градски пейзаж. Двете групи изображения притежават различни характеристики спрямо количеството и вида на преходите. Представянето на алгоритъма се измерва чрез 5-кратна крос-валидация, а точността му се оценява чрез FPR, Accuracy, Specificity и Recall (TPR). Параметрите на ядрото на SVM класификатора γ и c се изчисляват чрез крос-валидация само върху обучителната извадка. Тестовите резултати са дадени в Таблицы 5.3 и 5.4 съответно.

Тестовото изображение се разделя на квадратни фрагменти с размери 64×64 размер, които се класифицират от вероятностния SVM, след обхождане по два начина – с и без припокриване. В случая на припокриващи се фрагменти изместването на плъзгащия се прозорец е в рамките на 0.25 част от размера на фрагмента в хиупосоки.

Докато първият клас изображения (Фиг. 5.8а) съдържат естествени пейзажи, при които хоризонталните и вертикалните преходи не са толкова добре изразени, то вторият клас съдържа градски пейзажи (Фиг. 5.8б) - главно сгради със силни хоризонтални и вертикални преходи. От таблици 5.4 и 5.5 се вижда, че резултатите за откриване и сегментация на разфокусирани области при градските пейзажи са по-добри при средна и силна степен на разфокусираност заради по-голямата разлика между градиентните разпределения при разфокусираните и останалите области. От друга страна при изображенията с природни пейзажи резултатите са по-слаби, но и по-стабилни, при различна степен на прилагане на Гаусовата НЧ разфокусираност. Друга особеност на нашия алгоритъм за сегментация е наличието на блоковост при крайните резултати (Фиг. 5.9, 5.10) впоследствие използването на локални квадратни фрагменти.

Дадени са сегментационни резултати от изображението от първия клас при наличието на слаба и силна разфокусираност (Фиг. 5.10а и 5.10б). При ниска степен на разфокусираност се получава неточна сегментация на разфокусираната област, докато при висока степен сегментацията е по-точна, заради по-добре изразените градиенти.

За да се получат добри резултати от сегментацията, е необходимо да се спазват следните изисквания на алгоритъма:

1. Разделя се тестовата поредица на две групи изображения – природни и градски пейзажи;
2. Използват се фрагменти със среден размер - 64×64 пиксела;
3. Обучава се класификатора с изображения със степен на разфокусираност, сходна на търсената степен на разфокусираност в тестовото изображение.



Фигура 5.8 Тестови изображения: (а) естествен пейзаж, (б) градски пейзаж


Таблица 5.4 Оценка на резултати от сегментацията на разфокусирани области в естествени изображения с природен пейзаж

Степен на разфокусиране	FPR	Accuracy	Specificity	Recall
Слабо	0.006	0.981	0.957	0.886
Средно	0.092	0.979	0.934	0.904
Силно	0.009	0.979	0.931	0.909

Таблица 5.5 Оценка на резултати от сегментацията на разфокусирани области в естествени изображения с градски пейзаж

Степен на разфокусиране	FPR	Accuracy	Specificity	Recall
Слабо	0.013	0.972	0.989	0.787

Средно	0.0089	0.988	0.94	0.969
Силно	0.0049	0.99	0.946	0.965



Фигура 5.9 Резултати от детекцията на разфокусирана област: (а) реалната разфокусирана област, (б) сегментирана разфокусирана област от втория етап, (в) преходна област, получена от втория етап, (г) сегментирана разфокусирана област – краен резултат



Фигура 5.10 Резултати от сегментацията при:
(а) ниска степен на разфокусираност,
(б) висока степен на разфокусираност

5.6 Резултати от сегментацията на тъкани в MR изображения на човешки мозък чрез съгласуване на 2D хистограми

Тук ще бъде представени резултатите от предложения метод за сегментация на здрави тъкани в MR изображения на човешки мозък, където ще бъдат описани тестовите данни, резултатите от изпълнението му и ще бъдат сравнени на резултатите му с резултатите на други съвременни алгоритми и методи за сегментация.

5.6.1 Тестови данни и тестова РС конфигурация

Алгоритмите са приложени върху трите тестови бази с MR последователности: IBSR 18 [216], IBSR 20 и BrainWeb [217]. Първите две тестови бази се състоят от реални MR последователности, получени след MR сканиране на човешки мозъци на хора пациенти, докато третата тестова база – от изкуствено генерирани, симулирани анатомич-ни модели на тъкани на човешки мозък.

Тестовата база IBSR 20 или IBSR v.1.0 се състои от 20 MR последователности с ниска разделителна способност на здрав човешки мозък, които не са филтрирани и съот-ветно за част от MR изображенията в тях са характерни различни артефакти и шумове. Втората тестова база IBSR 18 или IBSR v.2.0 се състои от 18 MR последователности с ви-сока разделителна способност (Таблица 5.6 в дисертацията), също на здрав човешки мо-зък, 1.5 mm T1-притеглени сканирани последователности, където MR данните са филтри-рани, а от своя страна артефактите са поправени. Третата тестова база BrainWeb се състои от 20 MR последователности, които са изкуствено генерирани, T1-претеглени.

5.6.3 Резултати от сегментационния алгоритъм

Резултатите от предложения сегментационен метод се различават в зависимост от използваните тестови данни: дали са изкуствено генерирани MR данни (BrainWeb), реални (нефилтрирани) MR данни (IBSR 20) или реални (филтрирани) MR данни (IBSR 18) (Фиг. 5.12). Първо, алгоритъмът ни показва леко по-лоши резултати, когато се прилага върху симулираните MR изображения от BrainWeb тестови данни, сравнение с резултатите от

приложението на софтуерните пакети SPM8-Seg, FSL и BrainSuite [219] и с резултатите от публикуваните сегментационни методи (Таблица 5.7): APRS [220] и RiCE [221].

Сегментацията на реалните MR последователности (IBSR 20) представлява по-сложна задача: вижда се от Таблица 5.8 и Фиг. 5.13, че разработеният алгоритъм се представя по-добре от алгоритмите за сравнение, представени на IBSR сайта: adaptive MAP (aMAP), biased MAP (bMAP), MAP, размит c-means (fuzzy), Tree-structure k-means (tskmeans) и максимално правдоподобие (ML). За да се направи съпоставка с алгоритми, представители на съвременните подходи за сегментация на MR изображения: размити методи, методи със смесени модели, Маркови случайни полета (MRF)/скрити Маркови полета (HMM), в таблицата са включени резултати от следните методи, публикувани през последните няколко години (Таблица 5.8): FLGMM [226], GMM-CSA [227], MLHMM [228], RiCE и APRS. Вижда се, че разработеният метод показва близки резултати по точност, а в някои случаи и по-добри.

Последователностите от MR изображения от IBSR 18 тестови данни са префилтрирани и съответно PVE и INH артефактите премахнати или подтиснати, което води до значително по-добри резултати от IBSR 20 тестови данни (Таблица 5.9).

Таблица 5.7 Резултати от сегментацията със съгласуване на 2D хистограми (DSC коефициент) и сравнение с други методи върху BrainWeb тестови MRI данни


Алгоритъм за сегментация	Бяла тъкан (WM) (%)	Сива тъкан (GM) (%)	Гръбначно-мозъчна течност (CSF) (%)
SPM8-Seg	92±4	90±3	62±5
FSL	93±2	92±2	74±6
Brainsuite	91±6	80±16	46±16
APRS	96	96	96
RiCE	97	95	96
Предложения метод	91±0.5	90±1	87.5±1.6

Таблица 5.8 Резултати от сегментацията със съгласуване на 2D хистограми (JSC коефициент) и сравнение с други методи върху IBSR20 тестови MRI данни


Алгоритъм за сегментация	Бяла тъкан (WM) (%)	Сива тъкан (GM) (%)	Гръбначно-мозъчна течност (CSF) (%)
Manual	83	88	Na
aMap	57±18	56±13	7±3
bMap	56±21	56±17	7±3
FCM	57±20	47±12	5±2
MAP	55±21	55±16	7±4
Tskmeans	57±20	48±12	5±2
ML	55±21	54±16	6±3
APRS	74±3	83±3	71±6
MLHMM	56	70	Na
FLGMM	74	77	Na
Предложения метод	70±7	78±8	50±19

Таблица 5.9 Резултати от сегментацията със съгласуване на 2D хистограми (DSC коефициент) и сравнение с други методи върху IBSR18 тестови MRI данни

Алгоритъм за сегментация	Бяла тъкан (WM) (%)	Сива тъкан (GM) (%)	Гръбначно-мозъчна течност (CSF) (%)
MLHMM	77	86	Na
GMM-CSA без атлас	87	81	17
RiCE	87±2	94±1	Na
Предложения метод	88±1.3	87±1.3	24±9.6



Фигура 5.12: Сегментационните резултати на MR изображение от 9-та MR последователност (IBSR 20), от 14-та MR последователност (IBSR 18), изкуствено генерирано MR изображение от 11-та MR последователност (BrainWeb), както следва: (а), (г), (ж) входно MR изображение (предварително обработено) , (б), (д), (з) сегментирани CSF, GM и WM тъкани за сравнение, съответно, (в), (е), (и) сегментирани CSF, GM и WM тъкани (предложения алгоритъм)



Фигура 5.13 Сравнение на крайните резултати с benchmark алгоритмите (IBSR 20) за следните тъкани: (а) GM, (б) WM

НАУЧНО-ПРИЛОЖНИ И ПРИЛОЖНИ ПРИНОСИ

6.1 Научни приноси

1. Разработен е оригинален подход за сегментация на здрави тъкани на човешки мозък в последователности от MR изображения чрез съгласуване на 2D хистограми.

6.2 Научно-приложни приноси:

1. Предложен е алгоритъм за отделяне на анормални обекти в мамограми след класификация с яркостни, топографски и геометрични признаци;
2. Предложен е алгоритъм за отделяне на мастна тъкан от MR изображения на човешко бедро чрез едномерен Гаусов модел, получен от едномерни хистограми;
3. Разработен е алгоритъм за отделяне на нормални и дегенерирали тъкани в 3D MR изображения чрез предварително аотирани маски и клъстеризация, и изчисляване на статистически оценки на яркостното разпределение на отделните воксели;
4. Разработен е алгоритъм за сегментация на разфокусирани области в естествени изображения с обучени SVM класификатори и уейвлет хистограмни разпределения;
5. Разработен е алгоритъм за разделяне на последователност от MR изображения в MR подпоследователности, след оценка на подобие на 2D хистограми за всяка двойка съседни MR изображения чрез вълново контурно разстояние;
6. Разработен е алгоритъм за съгласуване на 2D хистограми, след преобразуването им във вектори и спецификация чрез LUT в рамките на процентилен интервал;
7. Разработен е алгоритъм за класификация на тестовите 2D хистограми чрез обучение на метрика на разстояние на kNN класификатор и сегментация на MR изображения чрез обратна проекция от класифицирана 2D хистограма.

6.3 Приложни приноси:

1. Извършени са експериментални изследвания на алгоритъма за детекция на абнормални обекти върху тестови мамограми;
2. Извършени са експериментални изследвания на алгоритъма за сегментация чрез единичен Гаусов модел върху MR изображения на човешко бедро;
3. Извършени са експериментални изследвания на алгоритъма за сегментация на здрави и дегенерирали тъкани в MR изображения на човешки мозък;
4. Извършени са експериментални изследвания на алгоритъма за сегментация на разфокусирани области в изображения –“man-made” и природни пейзажи;
5. Извършени са експериментални изследвания на алгоритъма за сегментация чрез съгласуване на 2D хистограми върху публичните бази IBSR 20 и 18, Brainweb;
6. Извършени са експериментални изследвания на алгоритъма от т. 5, показващи предимствата на разделена на MR подпоследователности с променлива дължина;
7. Извършени са експериментални изследвания на алгоритъма от т.5 при различни процентилен интервали, които се използват за съкращаване на векторите.

СПИСЪК НА ПУБЛИКАЦИИТЕ ПО ДИСЕРТАЦИОННИЯ ТРУД

- [D1] Kanchev, V. and O. Boumbarov, “**Segmentation of Fat Tissue in MRI Images with Gaussian Models**”, *International Scientific Conference on Energy and Information Systems and Technologies 2009 (ICEST'2009)*, 25-27 June, pp. 397-400, 2009;
- [D2] Popova A., V. Kanchev, I. Draganov, “**Mammographic Image Segmentation by Thresholding and Fuzzy C-means Clustering**”, *Computer & Communications Engineering*, Vol. 4, No. 1, pp. 31-36, 2010;
- [D3] Kanchev, V., A. Popova, I. Draganov, „**Segmentation of Neuro MR Images through Semi-Supervised Learning**“, *International Conference on Communication, Electrotechnics and Medical Application (CEMA)*, Sofia, Bulgaria, pp. 79-83, 2011;
- [D4] Kanchev, V., K. Tonchev, O. Boumbarov. „**Blurred image regions detection using wavelet-based histograms and SVM**“. In *Intelligent Data Acquisition and Advanced*

- [D5] Kanchev, V. and R. Kountchev. "Tissue Segmentation Methods Using 2D Histogram Matching in a Sequence of MR Brain Images", Chapter in book *New Approaches in Intelligent Image Analysis*, Springer International Publishing, pp.83-222, 2016.

SUMMARY

Vladimir Hristov Kanchev, M. Sc.

Probabilistic methods for image segmentation

Abstract of Phd dissertation

Image segmentation aims to partition image into meaningful regions, which are used later for further analysis. The successful application of the segmentation task is important for the success of the higher level tasks of computer vision and image understanding.

In the proposed dissertation five methods and algorithms for image segmentation are developed: of abnormal cancerous and benign masses for medical diagnosis, of fat tissue estimation in MR images of human thigh, tissue segmentation of brain MR images with AD and MCI diseases, of local blurred regions in images and of healthy brain tissues in MR images. The developed methods are described in three chapters, while the introduction and experimental results are presented into separate chapters.

In the first chapter we present an overview of the current state-of-the-art of the image segmentation problem and its relation to other problems in computer vision and image processing. Main algorithmic segmentation approaches are presented, as well. Then, in the second part we provide a short literary review of each of the segmentation methods and algorithms developed in the dissertation.

In the second chapter we describe a methodological and a formal math description of each of the first three segmentation methods: abnormal cancer masses segmentation, fat tissue estimation and brain tissue segmentation of MDI and AD diagnosed patients.

In the third chapter we present a methodological and a formal math description of the developed algorithm for segmentation of local blurred regions in natural images. It consists of three stages: training a SVM classifier with quality and their corresponding blurred natural images, segmentation of image patches by classifying their corresponding wavelet histograms and detailed border determination of the blurred region.

In the fourth chapter we show an original segmentation method for MR brain images using a 2D histogram matching. A detailed formal mathematical description of the method is given and some figures are added to show the main algorithmic points.

In the fifth chapter are presented experimental results of the developed segmentation methods tested with publicly available and private scientific test image data. For that purpose, we use some parameters as Jaccard and Dice coefficients, precision, recall, specificity and FPR coefficients. Also, we show the final segmentation results as images of segmented masks and tables and some intermediate results.

Finally, in the sixth chapter we present the main contributions of the dissertation: scientific, applied-scientific, and applied contributions.