

Univerza v Ljubljani
Fakulteta za računalništvo in informatiko

Luka Šajn

**Večresolucijska parametrizacija
za klasifikacijo tekstur in uporaba
za analizo scintigrafskih slik**

DOKTORSKA DISERTACIJA

Ljubljana, 2007

Univerza v Ljubljani
Fakulteta za računalništvo in informatiko

Luka Šajn

**Večresolucijska parametrizacija
za klasifikacijo tekstur in uporaba
za analizo scintigrafskih slik**

DOKTORSKA DISERTACIJA

Mentor: prof.dr. Igor Kononenko

Ljubljana, 2007

Moji Maji

Izjava

Izjavljam, da sem doktorsko disertacijo izdelal samostojno pod vodstvom mentorja prof. dr. Igorja Kononenka. Izkazano pomoč drugih sodelavcev sem v celoti navedel v zahvali.

Luka Šajn

Zahvala

Najlepše se zahvaljujem prof. dr. Igorju Kononenku za mentorstvo, usmerjanje pri raziskovalnem delu in potrpežljivost. Za vzpodbudno vzdušje pri delu in diskusije o osnovnih idejah predlaganih postopkov se zahvaljujem kolegom doc. dr. Matjažu Kukarju, doc. dr. Marku Robniku-Šikonji in dr. Matjažu Bevku. Prispevali so tudi veliko koristnih nasvetov in zanetili marsikatero idejo, ki je sestavni del te disertacije. Medicinski del raziskav ne bi bil mogoč brez pomoči doc. dr. Metke Milčinski, Ivana Slodnjaka, ing.radiol., doc. dr. Jureta Fetticha ter prof. dr. Sergeja Hojkerja, ki je zaslužen za mojo povezavo z medicino. Zahvaljujem se tudi dr. Cirilu Grošlju za podatke za scintigrafijo srčne mišice in ponovno doc. dr. Matjažu Kukarju za pomoč pri poskusih v tej domeni.

Najlepša hvala tudi Marjanu za pomoč in nasvete pri pisanju disertacije, Aniti za njeno podporo ter babici in dedku, ki sta mi stala ob strani in verjela vame. Nenazadnje pa seveda moji Maji za njeno ljubezen in podporo.

Podiplomski študij mi je omogočilo Ministrstvo za šolstvo in šport, ki je financiralo moj študij in Fakulteta za računalništvo in informatiko v Ljubljani, ki mi je nudila okolje za delo.

Povzetek

Disertacija spada na širše področje računalniških znanosti, podrobneje na področje strojnega učenja, računalniškega vida, računalniško podprte analize medicinskih slik in uporabe inteligentnih sistemov v medicini.

V disertaciji se ukvarjamo z vprašanjem večresolucijske parametrizacije tekstur in predlagamo algoritem ARes za iskanje primernih resolucij pri uporabi obstoječega algoritma za parametrizacijo ArTex. Rezultate primerjamo z metodami, kot so Gaborjevi filtri, Haarovi valčki, Lawsovi filtri in programom Image Processor.

Idejo za predlagani algoritem ARes smo dobili ob študiji algoritma SIFT, s katerim tudi primerjamo njegovo uspešnost. Algoritem SIFT v osnovi sicer služi prileganju slik istega objekta iz različnih zornih kotov, vendar za določanje značilnosti uporablja iskanje ekstremov preko različnih resolucij. Ta postopek lahko takoj povežemo z iskanjem zakonitosti vzorcev tekstur znotraj določenega območja, saj praviloma geometrijske metode za parametrizacijo zaradi časovne in računske zahtevnosti opazujejo le omejeno okolico točkovnega elementa. Za zagotavljanje primerne velikosti okolice opazovanja je potrebno poiskati resolucije, pri katerih nastopajo ekstremiti. Pri teh resolucijah lahko potem opišemo lokalne značilnosti, ki so dovolj majhne, da jih uporabljeno območje preiskovanja zajame in opiše kar v največji meri.

Pri obravnavi večresolucijskega pristopa za parametrizacijo tekstur smo pokazali, da obstaja določena povezava med vsebino slike določene resolucije in kvaliteto parametrizacije, še posebej pri algoritmu ArTex. Z vsemi testiranimi algoritmi (geometrijski, transformacijski ali statistični) smo dosegli boljše rezultate pri uporabi več resolucij, kar potrjuje ugotovitev, da je pri parametrizaciji slik zelo pomembna tudi izbira resolucij. Za pomoč pri določanju bolj informativnih resolucij smo z razvitim algoritmom ARes dosegli značilno boljše rezultate v kombinaciji z ArTex-om v primerjavi z osnovno resolucijo in tudi v primerjavi z uporabo enakomerno porazdeljenega prostora resolucij. ARes tudi pri drugih

algoritmih za parametrizacijo v primerjavi z osnovno resolucijo dosega večinoma značilno boljše rezultate, sicer pa vsaj brez značilnih razlik. Ugotovili smo tudi, da z uporabo enakomerno porazdeljenih resolucij pri parametrizaciji dosegamo boljše rezultate kot pri eksponentnih, ki jih uporablja večina avtorjev.

Kot aplikacije večresolucijske parametrizacije so obravnavani medicinski problemi, ki zajemajo scintigrafijo srčne mišice pri diagnosticiranju ishemične bolezni srca in scintigrafijo celotnega okostja pri ocenjevanju patologij posameznih sklopov kosti.

Predstavljen je postopek segmentacije scintigrafskih slik okostja s pomočjo detekcije orientacijskih točk za iskanje referenčnih točk. Podana je tudi ocena uspešnosti določanja referenčnih točk in dva postopka segmentacije scintigrama s pomočjo referenčnih točk. Pri segmentaciji smo uvedli uporabo enoznačno določljivih referenčnih točk, do katerih pridemo s kombinacijo prilagojenih standardnih orodij računalniškega vida. Z razvito kombinacijo dosežemo zadovoljivo točnost detekcije referenčnih točk na scintigrafskih slikah, ki imajo značilno nizko ločljivost. Da lahko doseže zadovoljive rezultate mora zaradi nizke ločljivosti v primerjavi z rentgenskim slikanjem, prisotnosti artefaktov in patologij postopek uporabiti vso možno predznanje o človeški anatomiji v smislu lokacije posameznih kosti in prostorskih razmerjih med njimi. Z opisanim postopkom smo dobili dobre rezultate in v nadaljevanju pričakujemo, da bodo študije s segmentacijo na osnovi referenčnih točk še izboljšale rezultate v primerjavi s študijami, ki segmentacije ne uporabljajo. Razviti ekspertni sistem za obdelavo scintigrafije celotnega okostja predstavlja napredek pri avtomatizaciji rutinskih kliničnih postopkov. Razviti postopek se lahko uporabi kot dodatna pomoč radiologu, saj lahko opozori na morebitno spregledane patologije ali pa celo odpre kakšen nov pogled na možno oceno stanja.

Postopek diagnosticiranja srčne mišice z uporabo večresolucijskega pristopa, opisom scintigrafije s povezovalnimi pravili in uporabo metod strojnega učenja predstavlja novo alternativo klasičnemu diagnosticiranju. Rezultati kažejo, da kvaliteta parametrov, pridobljenih z večresolucijskim pristopom parametrizacije, dosega enake ali boljše rezultate kot ročno določeni atributi zdravnikov specialistov. S kombinacijo obeh vrst parametrov, večresolucijskih in kliničnih, pa dobimo precej boljše rezultate v primerjavi s klinično prakso. Skoraj deset odstotno izboljšanje diagnosticiranja nepatoloških in patoloških pacientov, ki jim ne bi bilo potrebno opraviti zahtevnejših in dražjih testov, predstavlja občutno racionalizacijo in izboljšavo obstoječega postopka, brez nevarnosti nepravilnega diagnosticiranja večjega števila pacientov.

Ključne besede

analiza tekstur, povezovalna pravila, klasifikacija tekstur, večresolucijska parametrizacija, analiza medicinskih slik, analiza scintigrafskih slik, segmentacija okostja

Abstract

The dissertation contributes to the new approaches in the major area of computer science, specifically in the domain field of machine learning, computer vision, texture parametrization and intelligent data analysis in medical applications.

In the dissertation multiresolutional texture parametrization is addressed and the original algorithm ARes for finding more informative resolutions in the sense of classification accuracy is proposed. ARes is designed to be used in combination with the existing parametrization algorithm ArTex developed by Bevk (2005). The results obtained using the ArTex parametrization algorithm in combination with ARes are compared with standard parametrization methods such as Gabor filters, Haar and Laws wavelets and Image Processor.

The idea on multiresolutional approach is based on the algorithm SIFT which was later also compared to the developed algorithm ARes. Algorithm SIFT is a computer vision algorithm for extracting distinctive features from images, to be used in algorithms for tasks like matching different views of an object or scene and object recognition. The major step in the computation of the image features is scale-space extrema detection, which can be directly applied to the search of resolutions at which a geometric parametrization algorithm captures most textural information inside a certain region. The observed pixel neighborhood size in case of geometric algorithms is limited due to the time and computational complexity. To extract most rules inside a certain region the resolutions at which the most extremes take place should be used. This enables the parametrization algorithm to describe local characteristics which can be covered with the predefined region size.

Our study explores the multiresolutional texture parametrization approach based on the image content with regard to the parametrization quality, especially in case of the ArTex algorithm. The tested parametrization algorithms (geometric algorithms, signal processing methods and statistical methods) using multiresolutional approach have demonstrated significant improvements in results over one

scale parametrization. This supports the hypothesis that the resolution selection is important for texture parametrization. The developed algorithm ARes in combination with the ArTex algorithm has shown to be an appropriate tool as it achieves statistically significant improvements over single resolution and also over equidistant resolutions. The algorithm ARes in many cases also improves the performance of other parametrization algorithms in comparison to single resolution approach, whereas compared to the equidistant resolution approach it usually shows no significant improvement. We have confirmed that the use of the equidistant resolution space when parameterizing textures significantly outperforms the use of the exponential resolution space, which is used by majority of authors.

For the multiresolution parametrization applicative domain two medical cases have been used, sequential diagnostics of coronary artery disease and diagnostics of whole-body bone scintigraphy.

The whole-body scintigraphy segmentation process is presented which uses reference points detected with local cumulative uptake extremes. Some standard image processing algorithms were tailored and used in combination to achieve the best reference point detection accuracy on scintigraphic images. In order to work satisfactorily, the presence of artifacts, pathologies and poor resolution of scintigraphic images, compared to radiography, requires algorithms to use as much background knowledge on anatomy and spatial relations of bones as possible. This combination gives good results and we expect that further studies on automatic scintigram diagnostics using reference points for image segmentation will improve the accuracy and reliability of results regarding previous approaches. The presented computer-aided system for bone scintigraphy is a step towards automating the routine medical procedures. This approach can be used as an additional tool for radiologists as it can point out some unregistered pathologies or even give some new insight on the patient condition. The reference point detection is evaluated on a clinical data-set and two methods for bone segmentation using the proposed reference points are presented.

In the case of coronary artery disease we have shown that multi-resolution ArTeX parametrization using machine learning techniques can be successfully used as an intelligent tool for image evaluation, as well as as a part of the sequential diagnostic process. Automatic image parametrization and machine learning methods can help physicians to evaluate medical images and thus improve their combined performance (in terms of accuracy, sensitivity and specificity). The most significant contribution of our study is the improvement of the predictive power of the sequential diagnostic process. Almost 10% improvement of positive and negative diagnosis of patients who would not need to be examined with costly additional tests, represents a significant contribution in quality and potential

rationalization of the existing CAD diagnostic procedures.

Keywords

texture analysis, association rules, texture classification, multiresolutional texture parametrization, medical image analysis, scintigraphy analysis, whole-body bone scintigraphy segmentation

Kazalo

1	Uvod	1
1.1	Cilji in motivacija	1
1.2	Pregled področja	2
1.2.1	Večresolucijski pristop	3
1.2.2	Pregled obravnave slik v medicini	4
1.2.3	Diagnosticiranje in segmentacija scintigrafij	7
1.3	Prispevki k znanosti	8
1.4	Vsebina disertacije	9
2	Medicinski problemi	11
2.1	Obdelava in analiza scintigrafskih slik	11
2.2	Scintigrafija srčne mišice	11
2.2.1	Diagnosticiranje stanja srčne mišice	12
2.2.2	Metode in podatki	13
2.3	Scintigrafija okostja	15
2.3.1	Metode in podatki	16
3	Segmentacija scintigrafskih slik okostja	19
3.1	Postopek segmentacije	19
3.1.1	Iskanje referenčnih točk okostja	20
3.1.2	Detekcija orientacijskih točk za iskanje referenčnih točk	22
3.1.3	Ramenski del	25
3.1.4	Medenica	26
3.1.5	Glava in vrat	28
3.1.6	Torakalni del	30
3.1.7	Spodnje in zgornje okončine	31
3.2	Ocena uspešnosti določanja referenčnih točk	32
3.3	Segmentacija scintigrama z referenčnimi točkami	32

3.3.1	Neposredni izrez delov okostja	34
3.3.2	Segmentacija s pomočjo maske	34
4	Večresolucijska parametrizacija tekstur	37
4.1	Iskanje primernih resolucij	38
4.1.1	Algoritem SIFT	38
4.1.2	ARes - prilagoditev algoritma SIFT za določanje resolucij .	40
4.2	ArTex	42
4.2.1	Klasifikacija	43
4.2.2	Uporaba ArTexa na več resolucijah	43
5	Testiranje večresolucijske parametrizacije	45
5.1	Primerjani algoritmi	45
5.1.1	Gaborjevi filtri	45
5.1.2	Lawsovi filtri	46
5.1.3	Haarovi valčki	46
5.1.4	Image Processor	47
5.2	Generične baze podatkov	47
5.3	Rezultati	48
5.4	Enakomerna ali eksponentna porazdelitev resolucij	55
6	Aplikacije večresolucijske parametrizacije na scintigramih	57
6.1	Scintigrafija srčne mišice	57
6.2	Scintigrafija okostja	60
7	Zaključki	65
7.1	Večresolucijska parametrizacija tekstur	65
7.2	Scintigrafija srčne mišice	66
7.3	Scintigrafija okostja	67
7.4	Nadaljnje delo	68
	Literatura	71
	Dodatek	79
	Rangi generičnih baz podatkov	79
	Scintigrafija okostja	82

Poglavje 1

Uvod

Algoritmi za parametrizacijo tekstur so danes zelo pomembni za računalniško podprto analizo vzorcev pri avtomatizaciji različnih procesov. Uporabljajo se za pripravo vhodnih podatkov za klasifikacijo vzorcev z uporabo metod strojnega učenja. Tako je dobrodošla vsaka izboljšava teh algoritmov. V literaturi zasledimo navajanje izboljšanih rezultatov ob uporabi večih resolucij pri izpeljavi značilnk slikovnih vzorcev, kar nam ponuja novo področje vredno raziskovanja.

1.1 Cilji in motivacija

Osnovni cilj disertacije je izboljšanje klasifikacijske točnosti pri klasifikaciji poljubnih tekstur parametriziranih z geometrijskim algoritmom za parametrizacijo ArTex (Bevk, 2005), kar želimo doseči z uporabo večeresolucijskega pristopa. Motivacija izhaja iz raziskav avtomatskega diagnosticiranja scintigrafij, kjer se srečamo s slikovnimi vzorci, ki jih skušamo klasificirati z večeresolucijskim pristopom z namenom izboljšanja obstoječih postopkov diagnosticiranja v obliki podpore zdravnikom pri odločanju.

V preteklosti smo se ukvarjali z avtomatskim diagnosticiranjem patologij na scintigrafijah celotnega okostja (Šajn in sod., 2004), kar se je kasneje izkazalo za primerno aplikativno domeno pri večeresolucijskem obravnavanju vzorcev. Pri avtomatski diagnostiki patologij je pomembno, da poleg vprašanja, ali je na scintigramu prisoten sum na patologijo, opredelimo tudi lokacijo domnevne patologije, za kar je potrebno obravnavati posamezne sklope okostja posebej in zato potrebujemo tudi segmentacijo celotne slike na željena anatomska območja. Tudi ta postopek je podan v disertaciji. Razvit in ovrednoten je na največji znani bazi scintigrafskih slik okostij, ki so jih označili radiološki strokovnjaki (Šajn in sod., 2005b).

1.2 Pregled področja

Analiza slik je široko interdisciplinarno področje, ki obravnava avtomatsko odkrivanje raznovrstnih lastnosti in tako prodira na številna področja, med katerimi zaradi zahtev po natančnosti, zanesljivosti, ponovljivosti, hitrosti in avtonomnosti izrazito izstopata področji medicine in vizualne kontrole kakovosti v industriji. Temeljna naloga obdelave in analize slik v medicini je razpoznavanje in analiza anatomskih struktur in funkcij le-teh, v industriji pa avtomatsko vizualno pregledovanje surovin in izdelkov. Področje analize tekstur lahko razdelimo na 4 podpodročja, povzeto po (Bevk, 2005):

1. Izpeljava značilk (angl. feature extraction)
se ukvarja z odkrivanjem karakterističnih numeričnih značilk, ki opisujejo ključne lastnosti tekstur.
2. Segmentacija tekstur (angl. texture segmentation)
obrnava problem segmentacije kompleksne slike na perceptualno homogena področja.
3. Klasifikacija tekstur (angl. texture classification)
obrnava problem klasifikacije ali razvrščanja tekstur v nekaj vnaprej določenih razredov.
4. Oblika iz tekture (angl. shape from texture)
je podpodročje, ki se ukvarja s 3D rekonstrukcijo površine na osnovi slike tekture.

Izpeljava značilk je prva faza skoraj vsakega postopka v analizi tekstur. Rezultati izpeljave značilk se uporabljajo tako za segmentacijo kot tudi za klasifikacijo tekstur in nenazadnje tudi za indukcijo 3D površine iz tekture. Metode za izpeljavo značilk so razdeljene v 4 skupine (v oklepajih so navedeni uporabljeni algoritmi):

- Geometrijske (ArTex),
- Statistične (Image processor),
- Modelno usmerjene,
- Transformacijske (Haar, Laws in Gabor).

1.2.1 Večresolucijski pristop

Pri pregledu literature lahko ugotovimo, da velika večina večresolucijskih algoritmov uporablja le več medsebojno različnih resolucij, ki pa niso določene glede na lastnosti obravnavanih vzorcev (Ferreira in Borges, 2001; Comer in Delp, 1999; Ojala in sod., 2002). Skoraj praviloma taki algoritmi dosegajo značilno boljše rezultate, avtorji pa ugotavljajo, da pri večjem številu uporabljenih resolucij (>3), klasifikacijska točnost začne padati pod točnost doseženo z osnovnim algoritmom brez večresolucijskega pristopa. Ob študiju večresolucijske obravnave smo želeli ugotoviti, kje bi lahko bil vzrok za take rezultate. Ugotovitve so podane v razdelku 4.1 in zaključku. Obstaja več pristopov, ki se obravnavajo kot večresolucijski, npr. valčna transformacija (Chui, 1992), ki jo mnogi obravnavajo kot večresolucijsko metodo, saj opisuje teksture z značilkami, ki so izračunane z iterativnim postopkom razpolavljanja slike. Tudi ta metoda ne upošteva specifične vsebine slik. Analizo iskanja primerne resolucije z vidika teorije informacij najdemo v delu (Solina in Leonardis, 1998), ki obravnava teoretičen pogled na to problematiko.

V disertaciji se ukvarjamo s tem vprašanjem in predlagamo algoritem ARes za iskanje primernih resolucij pri uporabi ArTex-a (Bevk, 2005). Rezultate primerjamo z obstoječimi metodami, kot so Gaborjevi filtri (Grigorescu in sod., 2002), Haarovi valčki, Lawsovi filtri (Laws, 1980) in programom Image Processor (Bevk in Kononenko, 2002).

Več člankov o večresolucijski obravnavi slik najdemo na področju iskanja in kategorizacije objektov na slikah. Skoraj vsi poskusi kategorizacije temeljijo na lokalnih pristopih. Postopki, ki se jih poslužujejo različni avtorji, so si med seboj podobni. Najprej poiščejo točke zanimanja, nato okolice teh točk opišejo z lokalnim deskriptorjem. V kasnejši fazi lokalne deskriptorje združujejo v večje skupine. Model pa je nekakšen geometrični konstrukt, ki je sestavljen iz posameznih lokalnih opisov posamezne kategorije. Tu se uporabljajo algoritmi, kot so iskanje točk zanimanja s pomočjo entropije slike (Kadir in Brady, 2001), metoda Gaussovih razlik (DOG) (Lowe, 2004), variacije Laplaceovih filtrov (Mikolajczyk in sod., 2005) idr. Podroben pregled teh metod je podan v disertaciji (Mele, 2005). Za vse predlagane algoritme je značilno, da so osredotočeni na iskanje vogalov in robov na slikah, kar pa za opis tekstur ni vedno primerno, saj so teksture lahko sestavljene iz kombinacij točk, ki same po sebi niso izstopajoče v smislu razlik odvodov v različnih smereh. Opažene pa postanejo zaradi periodičnega ponavljanja vzorca, ki se ob spreminjanju resolucije izrazi kot ekstrem v smislu lokalne okolice.

Poleg kategorizacije je tudi prileganje slik pomembna operacija pri mnogih metodah v računalniškem vidu (npr. razpoznavo objektov ali okolja na različnih

slikah, sledenje gibanju, stereo vid ali gradnja 3D modelov iz več slik). Za realizacijo omenjenih postopkov potrebujemo dovolj dobre slikovne značilke, kot jih npr. zagotavlja algoritem SIFT (Lowe, 2004). Idejo za predlagani algoritem ARes smo dobili prav ob študiji algoritma SIFT. Algoritem SIFT v osnovi sicer služi prileganju slik istega objekta iz različnih zornih kotov, vendar za določanje značilk uporablja iskanje ekstremov preko različnih resolucij. Ta postopek lahko povežemo z iskanjem zakonitosti vzorcev tekstur znotraj določenega območja, saj praviloma geometrijske metode za parametrizacijo zaradi časovne in računske zahtevnosti opazujejo le omejeno okolico točkovnega elementa. Za zagotavljanje primerne velikosti okolice opazovanja je potrebno poiskati tiste resolucije, pri katerih nastopajo ekstremi. Pri teh resolucijah lahko potem opišemo lokalne značilnosti, ki so dovolj majhne, da jih uporabljeno območje preiskovanja zajame in opiše kar v največji meri.

1.2.2 Pregled obravnave slik v medicini


Informacijska vsebina biomedicinskih slik - sivinskih ali barvnih, statičnih ali dinamičnih, dvodimenzionalnih ali trodimenzionalnih, mikro- ali makroskopskih, rentgenskih, CT-(računalniška tomografija), MRI-(magnetna resonanca), US-(ultrazvok), SPECT-(fotonska emisijska računalniška tomografija), PET-(pozitronska emisijska tomografija) - je bistvenega pomena za odkrivanje in razumevanje normalnih in bolezenskih stanj človeškega organizma. Slikovna informacija je pomembna tako pri postavljanju pravilne diagnoze in načrtovanju terapije kot tudi pri sledenju učinkovitosti terapije oz. napovedovanju bolezni in pri načrtovanju ter izvedbi kirurških posegov. Računalniško podprta analiza medicinskih slik v zadnjih letih vse bolj dopolnjuje klasično - ročno odčitavanje in vrednotenje slik. Področje računalniške obdelave in analize medicinskih slik obsega postopke zajemanja in rekonstrukcije slik, zgoščevanja in shranjevanja slik, postopke izboljševanja, poravnave, razgradnje in vizualizacije slik, postopke merjenja anatomskih in fizioloških parametrov na slikah ter postopke sledenja gibanja in odkrivanja sprememb iz časovnega zaporedja slik (Duncan in Ayache, 2000). Obsežna baza medicinskih slik za testiranje algoritmov je nastala pod okriljem inštituta "National Library of Medicine" (NLM) z imenom "The Visible Human Project" (http://www.nlm.nih.gov/pubs/factsheets/visible_human.html), kjer so na voljo tomografije moškega in ženske v prečnih prerezih po 4mm in 0.3mm.

Pred samo uporabo postopkov strojnega učenja slike običajno še predobdelamo s pomočjo filtrov za ostrenje robov, valčne transformacije za izboljšanje kvalitete radioloških slik (Jammal in Bijaoui, 2004), morfološke metode za poudarjanje oblik na magnetno resonančnih slikah itd. V splošnem lahko ločimo uporabo algoritmov strojnega učenja na biomedicinskih slikah na dve veji. Ena veja upo-

rablja običajne metode, kot so odločitvena drevesa, metoda podpornih vektorjev (SVM), nevronske mreže idr. na pridobljenih značilkah izpeljanih iz statističnih parametrov slik, kot so statistike prvega in drugega reda (Bevk in Kononenko, 2002). Taki postopki so sicer enostavni, vendar v večini primerov praktične uporabe v medicini niso primerni, saj so uporabni predvsem za razpoznavanje vzorcev in ne nudijo odgovorov na vprašanja tipa "Na katerem delu organa se nahaja patologija?". Obstajajo tudi poskusi direktne uporabe slike na vhodu nevronske mreže, ki pa se do sedaj niso izkazali zaradi pomanjkanja razumljivosti izpeljanega postopka (Anderson in Crawford-Hines, 1998). Tako se druga veja ukvarja predvsem s segmentacijo in poravnavo človeških organov na različnih vrstah slik. Pravzaprav lahko o klasifikaciji govorimo šele, ko je slika segmentirana in nastopi faza razpoznavanja patoloških sprememb, kjer pa lahko za klasifikacijo vzorcev spet uporabimo statistične parametre (Herlidou in sod., 2001) in metode umetne inteligence. V praksi se izkaže, da je prvi del (segmentacija) zahtevnejši problem, zato se v resnici večina raziskav na biomedicinskih slikah nanaša na področje računalniškega vida. Seveda je meja med obema področjema zelo nejasna, na kar kaže tudi dejstvo, da se znani laboratoriji, kot je "AI lab" na fakulteti Massachusetts Institute of Technology MIT (<http://www.ai.mit.edu>, članki <ftp://publications.ai.mit.edu>), ukvarjajo s projekti, kot so pomoč pri vodenju kirurških posegov s pomočjo poravnave 3D slik pred in med operacijo, načrtovanjem uporabniškega vmesnika za vizualno učenje anatomije, statistično analizo anatomskih struktur iz medicinskih slik, elastično poravnavo s pomočjo končnih elementov (Bajcsy in Kovačič, 1989) itd. S podobnimi vsebinami se ukvarjajo tudi pri nas na Fakulteti za elektrotehniko v Ljubljani v laboratoriju za slikovne tehnologije (<http://lit.fe.uni-lj.si/>).

Večina avtorjev se ukvarja predvsem s slikami mehkega tkiva in okostja. Veliko aplikacij, ki obdelujejo medicinske slike, vsebuje proces segmentacije za določanje kontur delov telesa. Sledenje konturam na medicinskih slikah omogoča izračun različnih kliničnih mer (ploščina, volumen, orientacija itd.), s čimer olajšajo različne kvantitativne izračune, potrebne za oceno poteka in planiranje nadaljnjih postopkov zdravljenja. Veliko je že razvitih metod za segmentacijo anatomskih struktur in označevanje kontur organov na različnih tipih medicinskih slik, kjer večinoma poskušajo identificirati maligna območja. Ker je segmentacija takih medicinskih slik ključnega pomena za učinkovito avtomatizacijo procesov, torej tudi tistih, ki uporabljajo metode umetne inteligence, naj omenimo nekaj referenc obstoječih postopkov segmentacije najbolj pogostih tipov slikanj. Magnetna resonanca (MR) (Jin in Ladak, 2004; Lötjönen, 2003; Heinonen in sod., 1997; Freeborough in sod., 1997; V. Barra, 2002), računalniška tomografija (CT - rentgensko slikanje telesnih organov v plasteh), fotonska emisijska računalniška tomografija, pozitronska emisijska tomografija (Subašić in sod., 2005), scintigrafija

(Šajn in sod., 2005b, 2007), DNK mikromreže (Barra, 2006), biopsija (Rodríguez, 2006), histopatologija (Adiga in Chaudhuri, 2000), ultrazvok, rentgen in mamografija (Méndez in sod., 1996). Avtorica Kapur in sod. (1996) predlaga shemo tipov segmentacij na sliki 1.1.



Slika 1.1: Tipi segmentacije

Načini segmentacije se razlikujejo predvsem po tem, kako uporabljajo predhodno anatomsko znanje. V grobem lahko segmentacijo delimo v tri skupine: razgradnja s povezanimi deformabilnimi modeli, statistični modeli topologije ter morfološko procesiranje. Pregled uporabe različnih metod segmentacije najdemo tudi v članku avtorjev Pham in sod. (2000).

Deformabilni modeli

Deformabilni modeli so modeli kontur ali površin, ki jim lahko spreminjamo prostorske lastnosti in teksturo, z namenom, da se kar najbolj prilagodijo konkretnemu objektu na dani sliki. Deformabilni modeli so v zadnjem času zaradi svoje splošne uporabnosti in prilagodljivosti pri modeliranju in predstavitvi objektov deležni velike pozornosti. Poseben, zelo zanimiv razred deformabilnih modelov tvorijo aktivni deformabilni modeli. To so modeli, ki sami prilagodijo svojo obliko glede na dano sliko, torej uporabljajo implicitni model. Vsebujejo torej že vgrajen optimizacijski algoritem, zato jim pravimo aktivni modeli. Uporabni so zaradi svoje vsestranskosti in zmožnosti istočasnega upoštevanja geometrijskih omejitev kot tudi lokalne slikovne vsebine (Bernard, 2001).

Za modeliranje sil, ki vodijo deformacijo oblike, večinoma uporabljamo dva kriterija: kriterij deformacije modela in kriterij skladnosti modela s sliko. Kriterij deformacije modela meri stopnjo deformacije modela, to je odstopanje trenutnega modela od referenčne, nedeformirane konfiguracije modela, kar imenujemo tudi

energija modela. Kriterij skladnosti modela s sliko pa meri odstopanje med trenutnim modelom in dano sliko.

Primere uporabe deformabilnih modelov najdemo v delih avtorjev Poon in sod. (1994); Syn in sod. (1994), povzeto po (Kapur in sod., 1996). Zanimiv pristop lokalizacije in segmentacije posameznih kosti na radioloških slikah z uporabo deformabilnih modelov se imenuje Active Shape Models (ASM) in je opisan v Mahmoodi in sod. (1999).

Tukaj naj omenimo še metode superkvadrikov v kombinaciji z deformacijami za trodimenzionalno modeliranje različnih organov človeškega telesa. Tipičen primer je modeliranje srca (Bardinet in sod., 1996). Superkvadriki pa se uporabljajo tudi za trodimenzionalno segmentacijo človeškega telesa (Krivic in Solina, 2004).

Statistični modeli

Temeljna lastnost statističnih deformabilnih modelov je sposobnost zajemanja *a priori* znanja o lastnostih struktur z učenjem. Iz množice primerno označenih učnih slik lahko statistični deformabilni model samodejno zajame obliko in teksturo strukture, njune značilne variacije ter obseg le-teh. Po učenju je model dovolj splošen, da lahko pravilno obravnava variacije znotraj obravnavane strukture, hkrati pa ostaja specifičen za strukturo ter se v postopku prilaganja na sliko ne more poljubno preoblikovati ter skušati opisati sosednjih struktur, prisotnih na sliki. Primere uporabe statističnih modelov najdemo v delu Cootes in sod. (1993), povzeto po (Kapur in sod., 1996).

Morfološki modeli

Morfološko procesiranje se uporablja tako na binarnih, kot na sivinskih slikah in je namenjeno poudarjanju robov, zapiranju ali odpiranju slikovnih elementov ter spajanju ali razdvajanju kontur, kar pomaga pri sledenju robov in iskanju območij pri segmentaciji. Postopek je dobil ime zaradi spreminjanja oblike opazovanega objekta in se imenuje tudi matematična morfologija. Morfološke operacije so nelinearne, osnovni funkciji pa sta postopek erozije in raztezanja. Torej lahko na morfološko procesiranje gledamo kot na neko vrsto predobdelave slike. Brummer in sod. (1993) so predlagali postopek, ki izmenično uporablja erozijo in raztezanje za ekstrakcijo možganskega tkiva iz magnetno resonančnih slik, povzeto po (Kapur in sod., 1996).

1.2.3 Diagnosticiranje in segmentacija scintigrafij

Prvi poskusi avtomatizacije diagnosticiranja scintigrafije za strukturo in delovanje ščitnične žleze, segajo v leto 1973 (Maisey in sod., 1973). Kasnejši po-

skusi so večinoma zanemarjali pomembnost lokalizacije anatomskih struktur in so se omejili na iskanje lezij z uporabo enostavnih morfoloških metod. Tako npr. Noguchi in sod. (2003) uporablja intenzitetno upragovljenje in ročno štetje lezij, pri čemer tudi ročno označi anatomsko specifična območja (ang. region of interest ROI). Taki postopki zadoščajo le za odkrivanje močnejših in bolj izstopajočih patologij, pri čemer lahko tiste, ki so za radiologe specialiste pomembnejše, spregledamo.

Novejše raziskave (Yin in Chiu, 2004) uporabljajo sistem mehke logike za iskanje lezij, ki je omejen le na intenzitetno izstopajoče lezije v točkovni obliki. Priprava scintigramov vsebuje tudi grobo segmentacijo slike okostja na šest regij z vnaprej določenimi velikostmi in pozicijami, tako da ne upošteva dejanskega položaja in oblike okostja. S takim načinom segmentacije ne moremo specifično ločevati posameznih delov okostja.

Nekaj raziskav avtomatskega diagnosticiranja je bilo narejenih tudi s pomočjo segmentacije scintigrafije celotnega okostja. Te raziskave so bile narejene v Nemčiji na Inštitutu medicinske informatike na Univerzi v Hildesheim-u med leti 1994 in 1996. Glavna prispevka sta disertaciji (Berning, 1996; Bernauer, 1995), ki opisujeta semantični opis okostja in obdelavo scintigramov. Njune ideje izhajajo iz sistema "*SzintExpert*" (Markwardt, 1990), katerega začetek sega v 80-ta leta in temelji na dinamični binarizaciji, kar predstavlja pionirsko delo na področju avtomatizacije scintigrafije. Avtor Benneke (1997) v svojem diplomskem delu implementira njune predlagane algoritme in sestavi ekspertni sistem, ki se kasneje ni razvijal ali uporabljal.

1.3 Prispevki k znanosti

Deli disertacije so bili objavljeni v sledečih publikacijah: Šajn in sod. (2004, 2005b,a, 2007). Znanstveni prispevki disertacije so bili uporabljeni v sledeči študiji (Kukar in sod., 2007).

Disertacija vsebuje naslednje prispevke k znanosti:

- **Segmentacija scintigrafskih slik.** Pri avtomatskem diagnosticiranju scintigrafskih slik celotnega okostja, je največji problem lokalizacija patologije. Za potrebe aplikacije ekspertnega sistema v klinično okolje je podana metoda za segmentacijo slike celotnega ali delnega okostja.
- **Ekspertni sistem za segmentacijo.** Razvili smo ekspertni sistem za segmentacijo celotnega oz. delnega okostja. Rezultati segmentacije so uporabni za poljuben algoritem diagnosticiranja, ki potrebuje segmentacijo kosti.

- **Ovrednotenje ekspertnega sistema na realni domeni.** Predstavljeni ekspertni sistem za segmentacijo scintigrafskih slik je ovrednoten na obstoječi bazi slik. Rezultati potrjujejo učinkovitost razvitih metod za segmentacijo.
- **Avtomatska izbira primernih resolucij.** Za boljšo klasifikacijsko točnost razpoznavanja slikovnih vzorcev s sistemom ArTex je razvit algoritem ARes za avtomatsko določanje resolucij slik, pri katerih lahko izluščimo bolj informativne attribute in dobimo tako večjo klasifikacijsko točnost.
- **Analiza primerjave algoritmov za parametrizacijo tekstur.** Izboljšan algoritem ArTex je primerjan z ostalimi obstoječimi algoritmi na umetnih in realnih domenah. Statistično so ovrednoteni rezultati primerjanih algoritmov. Potrjeno je, da ARes signifikantno izboljša večresolucijsko parametrizacijo ArTex-u.
- **Analiza primerjave algoritma ARes za avtomatsko določanje resolucij z algoritmom SIFT.** Predlagani algoritem ARes za določanje resolucij je primerjan z algoritmom SIFT (Scale Invariant Feature Transform), iz katerega tudi izhaja ideja predlaganega algoritma. Potrjene so signifikantno boljše resolucije, ki jih predlaga algoritem ARes, od resolucij, ki jih predlaga SIFT.
- **Aplikacije z ARes-om.** Izboljšani algoritem ArTex je testiran na scintigrafijah kosti in srčne mišice. Rezultati so primerjani z diagnozami zdravnikov specialistov in ostalimi algoritmi. Primerjava potrjuje superiornost ArTex-a v kombinaciji z ARes-om.

1.4 Vsebina disertacije

V drugem poglavju predstavimo obravnavane medicinske probleme, ki zajemajo scintigrafijo srčne mišice in scintigrafijo celotnega okostja. Predstavljene so osnovne metode in struktura uporabljenih baz podatkov. Tretje poglavje podaja postopek segmentacije scintigrafskih slik okostja s pomočjo detekcije orientacijskih točk za iskanje referenčnih točk. Podana je tudi ocena uspešnosti določanja referenčnih točk in dva postopka segmentacije scintigrama s pomočjo referenčnih točk. V četrtem poglavju je predstavljen algoritem ARes za določanje primernih resolucij pri parametrizaciji tekstur z geometrijskimi metodami, ki je razvit s pomočjo ideje algoritma SIFT. Predstavljen je tudi algoritem ArTex, za katerega je bil algoritem ARes razvit. Peto poglavje podaja rezultate testiranja večresolucijske parametrizacije na devetih generičnih bazah podatkov z algoritmom ArTex v

kombinaciji z ARes-om in še s štirimi drugimi algoritmi za parametrizacijo. Podana je tudi primerjava z algoritmom SIFT. Šesto poglavje predstavlja aplikacijo večresolucijske parametrizacije na scintigramih srčne mišice in okostja. Sedmo poglavje podaja zaključke o večresolucijski parametrizaciji in komentira dobljene rezultate obeh medicinskih domen. V dodatku so navedeni rezultati doseženih rangov klasifikacijskih točnosti algoritmov po posameznih uporabljenih generičnih domenah, ki v sami disertaciji niso navedeni. Prav tako so navedeni tudi rezultati klasifikacijskih točnosti nekaterih algoritmov za parametrizacijo pri scintigrafiji okostja.

Poglavje 2

Medicinski problemi

Za aplikativni domeni smo izbrali medicinske slike, natančnejše scintigrame, zato najprej predstavimo obe domeni. Domena scintigrafskih slik okostja je potrebovala še predpripravo, pri kateri smo se ukvarjali s segmentacijo, ki je predstavljena kasneje.

2.1 Obdelava in analiza scintigrafskih slik

Nuklearna medicina uporablja radioaktivne snovi (radiofarmake) za določitev velikosti, oblike in delovanja nekaterih organov (srce, ledvice, jetra, ščitnica, možgani, pljuča, kosti idr.) in ugotavljanje narave njihovega tkiva. Uporablja se zelo majhne količine radioaktivnih snovi s šibko aktivnostjo, ki omogočajo prikaz delovanja organov, navadno v obliki slike (scintigrama).

Pri scintigrafiji okostja injiciranje radiofarmaka omogoča vpogled v presnovo vseh kosti. Spojina, ki se vbrizga v žilo, potuje po krvi do kostnega sistema, kjer se nabere sorazmerno presnovni aktivnosti posameznih delov okostja. Pri preiskavi srca (radioizotopska ventrikulografija) pa na podoben način ugotavljamo delovanje srčne mišice levega srčnega prekata.

Hitro razvijajoče področje računalniškega vida danes omogoča avtomatizacijo nekaterih rutinskih medicinskih diagnostičnih postopkov. V nadaljevanju bomo predstavili možno avtomatizacijo analize scintigrafij srca in okostja.

2.2 Scintigrafija srčne mišice

Žile, ki srcu dovajajo kri, imenujemo koronarne arterije. V procesu ateroskleroze pride do zožitve koronarnih arterij in pretok krvi je oslavljen, zato dobi srce

premalo krvi in kisika. Bolezen imenujemo ishemična bolezen srca ali koronarna bolezen srca.

Ishemična bolezen srca IBS (ang. ischaemic heart disease IHD) je danes ena od najpogostejših vzrokov smrti, zato je vsaka izboljšava diagnosticiranja zelo dobrodošla. Za odkrivanje ishemične bolezni srca obstaja več diagnostičnih testov. Najosnovnejša preiskava v kardiologiji je elektrokardiogram (EKG), torej grafični zapis električne aktivnosti srca. EKG lahko odkrije nepravilne utripe, ishemijo srčne mišice, povečanje srca in določena področja srca, ki so v preteklosti že utrpela škodo.

V disertaciji opisana študija predstavlja razširitev obstoječe metode, ki so jo razvili Kukar in sod. (1999); Kukar in Grošelj (1999), z uporabo večeresolucijskega pristopa in uporabo algoritma ArTex za parametrizacijo scintigramov srčne mišice.

2.2.1 Diagnosticiranje stanja srčne mišice

S preiskavo obremenitvenega testiranja snemamo EKG, pri čemer bolnik vozi kolo ali hodi po tekočem traku. Stopnja obremenitve je na začetku testa majhna in se s časom povečuje. Obenem merimo krvni tlak in srčni utip. Ta test nam pomaga odkriti težave, ki se pojavijo z večanjem navora. Obremenitveni test je koristen za odkrivanje ishemične bolezni srca, vendar ni popolnoma zanesljiv, saj se v določenem manjšem odstotku lahko pojavljalo lažno pozitivni ali lažno negativni rezultati. Poleg tega se opravljajo še obremenitvena testiranja, pri katerih bolniku med obremenitvijo vbrizgamo v žilo radioizotop (talij ali tehnecij). Radioizotop se kopiči v srčni mišici, kar prikažemo s snemanjem z gama kamero in dobimo podatek o prekrvitvi srčne mišice.

Funkcija srca je črpanje krvi do vseh organov v telesu. Za opravljanje te zelo zahtevne naloge potrebuje srce nepretrgano oskrbo s kisikom. Ta poteka po koronarnih arterijah do srčne mišice miokarda. V primeru zmanjšanega pretoka skozi koronarne arterije se razvije ishemična srčna bolezen, ki v končni fazi vodi do odmrtnosti dela srčne mišice miokardnega infarkta. Ob obremenitvah se količina krvi, ki jo mora na časovno enoto prečrpati srce, močno poveča. Zato se mora ustrezno povečati tudi tok krvi po koronarnih arterijah. V začetnih fazah IBS pretok skozi koronarne žile ob mirovanju ali majhnih obremenitvah še zadošča, simptomi bolezni (tiščanje v prsih) se pojavijo šele ob večjih (kontroliranih) obremenitvah. Diagnostika stanja srčne mišice je sestavljena iz ocen štirih diagnostičnih stopenj (Grošelj, 1999):

1. Anamneza, status in EKG (elektrokardiogram) pacienta ob mirovanju.
2. EKG testiranje med kontrolirano obremenitvijo (cikloergometrija). S spre-

minjanjem stopnje obremenitve in primerjavo sprememb EKG med obremenitvijo je možno postaviti diagnozo.

3. Če rezultati cikloergometrije ne zadoščajo za zanesljivo postavljanje diagnoze ali če želimo dodatne podatke o stanju srčne mišice, se izvrši miokardna scintigrafija. V telo se vbrizga radioaktivni izotop, ki se akumulira v srčni mišici. Slikanje se opravi v mirovanju in nato še med kontrolirano obremenitvijo. S primerjavo obeh slik je možno potrditi prisotnost IBS in lokalizirati ishemično tkivo.
4. V skrajnih primerih, ko se sumi na potrebo premostitve (bypass) zamašenih koronarnih žil, se opravi invaziven diagnostični postopek koronarna angiografija (slikanje koronarnih arterij ali koronarografija). Kontrastni material se vbrizga direktno v koronarne žile in posname z rentgenskim postopkom. Ta postopek daje sicer zanesljive rezultate, vendar pa je zelo drag (aparature), dolgotrajen, za pacienta neprijeten in celo nevaren (smrtnost 0.1 promila). Koronarografija se zaradi svoje zanesljivosti uporablja kot referenčna metoda pri primerjavi kvalitete drugačnih preiskav.

Naša študija se nanaša na izboljšanje tretje diagnostične stopnje (miokardna scintigrafija). Ta stopnja je sestavljena iz zaporedja scintigramov, ki ne ogrožajo zdravja pacientov in so cenovno sorazmerno lažje dosegljivi. V klinični praksi so ti scintigrami ročno ovrednoteni (parametrizirani) in ocenjeni s strani radiološkega strokovnjaka.

2.2.2 Metode in podatki

Scintigrafija miokarda je sestavljena iz zaporedja devetih slik srca pod različnimi obremenitvami, tako v mirovanju, kot med nadzorovanimi vadbam pacientov. Vsako sliko posebej parametriziramo z večresolucijskim pristopom, dobljene attribute pa nato, s pomočjo metode za izbiro podmnožice atributov, omejimo le na najbolj informativne.

Pacienti

V študiji smo obravnavali 288 pacientov, za katere smo imeli potrebne klinične in laboratorijske podatke, potake o EKG testiranjih, miokardno scintigrafijo in koronarno angiografijo. Vse te preiskave so bile narejene zaradi suma na IBS. Ti pacienti so bili izbrani iz populacije nekaj tisoč pacientov, ki so obiskali Kliniko za Nuklearno Medicino med leti 2001 in 2006. 162 pacientov je doživelo srčni infarkt le kratek čas pred diagnosticiranjem. Izbrali smo samo paciente z

opravljenim celotnim diagnostičnim postopkom (vse štiri diagnostične stopnje). Osnovne karakteristike podatkov so prikazane v tabeli 2.1.

Značilke EKG slikanj in scintigrafskih podatkov so ročno ovrednotili zdravniki specialisti. Pri predobdelavi slik smo uporabili 10 pacientov za potrebe večeresolucijskega pristopa in določanja povezovalnih pravil z algoritmom ArTex. Tako smo za končno testiranje uporabili 278 pacientov (66 žensk in 212 moških s povprečno starostjo 60 let). Pri 149 pacientih je koronarografija potrdila IBS, pri 129 pa izključila.

Tabela 2.1: Pregled števila osnovnih IBS atributov pri različnih diagnostičnih fazah. Od razpoložljivih atributov koronarne angiografije smo v eksperimentih uporabili le binarni atribut končne diagnoze


Diagnostična faza	Število atributov		
	Diskretni	Zvezni	Skupaj
1. Anamneza in status	22	5	27
2. Cikloergometrija	11	7	18
3. Scintigrafija (+9 slik pri različnih obremenitvah)	8	2	10
4. Koronarna angiografija	1	6	1
Porazdelitev razredov	129 (46.40%)	IBS negativna	
	149 (53.60%)	IBS pozitivna	

Potrebno je omeniti, da obravnavani pacienti predstavljajo zelo specifično populacijo, saj so mnogi že imeli operacijo srca ali širjenje koronarnih arterij. Zaradi staranja populacije v Evropi se dobljeni rezultati (porazdelitev populacije in moč napovedovanja) močno razlikujejo od predhodnih študij, ki so obravnavale paciente med leti 1991 in 1994 (Grošelj in sod., 1997; Kukar in sod., 1996). Tako naših rezultatov ne moremo posploševati na celotno populacijo.

Scintigrami

Slike v mirovanju in pod obremenitvijo so bile zajete s kamero General Electric eNTEGRA SPECT, ki generira 64 8-bitnih sivinskih slik, z resolucijo 64×64 . Zaradi stalnega gibanja srca in delne obstrukcije s strani ostalih organov te slike niso neposredno uporabne brez dodatne obdelave. V ta namen je bila uporabljena programska oprema *ECToolbox* (GeneralElectric, 2001), ki omogoča izračun devetih diagramov v polarni obliki za vsakega pacienta. Polarno predstavitev sta v prejšnjih študijah predlagala Lindahl in sod. (1998), ki sta pokazala, da ima taka predstavitev uporabno diagnostično vrednost.

Na sliki 2.1 je primer polarnih diagramov za pacienta, ki ima tipično obliko



Slika 2.1: Polarni diagrami po obremenitvi (prvi stolpec), v mirovanju (drugi stolpec), in njihova razlika (tretji stolpec). Prva vrstica vsebuje osnovne slike, druga vsebuje t.i. blackout slike, in tretja vsebuje standardno deviacijo. Črne regije označujejo manj prekrvavljeno srčno tkivo (mogoča patologija)

IBS. Običajno razlike slik med obremenitvijo in mirovanjem niso tako izrazite kot v podanem primeru na sliki 2.1. Interpretacija in ocenjevanje takih scintigramov zato potrebuje obsežno znanje in izkušnje radiologa specialista. Čeprav so na voljo specializirana orodja, kot je programska oprema *ECTtoolbox* (GeneralElectric, 2001), zdravnik še vedno potrebuje precej znanja in izkušenj, da lahko zadovoljivo oceni rezultate. Zato je namen naše študije razvoj algoritma za avtomatsko parametrizacijo scintigramov, ki služi kot vhod metodam za strojno učenje, ki omogočajo dodatno diagnostično orodje.

2.3 Scintigrafija okostja

Scintigrafija okostja je eden najpogostejših diagnostičnih postopkov v nuklearni medicini že vrsto let, saj omogoča detekcijo morebitnih patoloških stanj (Budihna in sod., 1994; Müller in sod., 2001; Hendler in Hershkop, 1998). Prednost teh opazovanj je v tem, da lahko nastanek neke bolezni opazujemo še preden so zaznani simptomi in preden je patologija vidna na rentgenskih slikah (Müller in sod., 2001). Scintigram celotnega okostja služi običajno kot prva klinična slika pacienta. Iz te slike se nato diagnosticira, v katerem delu telesa je prišlo do razvoja določene patologije. Ko je to območje določeno, se zanj lahko

naredi nov scintigram, ki zajema le prizadeti del okostja. Na podrobnejši sliki se nepravilnosti še veliko bolje opazijo in diagnosticiranje je veliko lažje kot na scintigramu celotnega okostja. Avtomatizacija tega postopka je zelo dobrodošla. Seveda dandanes računalniški vid in algoritmi še niso tako napredovali, da bi lahko nadomestili zdravnika specialista, lahko pa so v pomoč pri pregledovanju scintigramov in pri opozarjanju na območja, ki bi jih radiolog lahko spregledal.

Kot ugotavljata avtorja Hendler in Hershkop (1998), scintigrafija okostja omogoča zaznavanje različnih kliničnih stanj, kot so benigni in maligni tumorji, vnetja, degenerativne spremembe, idr. Naloga radiologa specialista je, da oceni morebitna patološka dogajanja, ki so vidna na scintigraskih slikah. Problem teh slik je v nizki ločljivosti, ki je posledica majhne doze izsevanih gama žarkov, saj bi ob večji dozi radioaktivnega izotopa prišlo do prevelikih sevanj, nevarnih za pacienta. Pri scintigrafiji okostja dobimo anteriorno in posteriorno planarno sliko okostja, na kateri je vidnih približno 158 kosti (Noguchi in sod., 2003). Slike se ocenjujejo ročno in zaradi slabe ločljivosti in števila možnih potencialnih patoloških lokacij je ocena teh slik v določenih primerih lahko precej težavna. Ko radiolog specialist ocenjuje scintigrafsko sliko, oceni vsak del okostja glede na več možnih patologij (t.j. lezije, malignomi, metastaze, degenerativne spremembe, vnetja ter druge redkeje patologije). Lahko se tudi zgodi, da dva različna radiološka specialista različno ocenita stanje. To pa pomeni da bi računalniška pomoč lahko prišla prav, saj bi lahko opozorila na morda spregledane podrobnosti.

Namen študije je načrtovanje in izvedba algoritma za robustno segmentacijo scintigrafske slike celotnega ali delnega okostja in diagnosticiranje posameznih delov kosti. V tem poglavju so predstavljene osnovne ideje algoritma za segmentacijo scintigrafije okostja v osnovne sklope.

2.3.1 Metode in podatki

Pacienti in slike

Baza obsega 467 scintigrafskih slik 461 različnih pacientov, za obdobje od oktobra 2003 do junija 2004. Slike smo dobili na Kliniki za Nuklearno Medicino v Univerzitetnem kliničnem centru v Ljubljani. V študiji smo obravnavali vse slike iz tega obdobja, brez predhodnega ločevanja. Za zajeto obdobje devetih mesecev smo predpostavili, da dovolj dobro predstavlja dejansko distribucijo pacientov, ki prihajajo na slikanje. Taka distribucija je potrebna za gradnjo zadovoljivega algoritma za segmentacijo.

Nekatere slike so vsebovale tudi različne artefakte, kot so vidno mesto injiciranja radiofarmaka (se pogosto pojavlja in lahko zakriva del slike), kontaminacija z urinom in medicinski dodatki (npr. urinarni katetri) (Weiner in sod., 2001).

S pomočjo radiologov specialistov smo ocenili vsebino slik. Tako smo ugo-

tovili, da je 21% slik brez patologij in brez artefaktov. 60% scintigrafij je bilo diagnosticiranih, kot lažje patologije, ne glede na vsebovane artefakte in 18% je bilo ocenjenih kot močna patološka stanja. Poleg teh slik pa smo imeli tudi 1% t.i. superscanov. Superscan se imenuje scintigrafija, kjer določeno zelo močno patološko dogajanje absorbira skoraj ves vbrizgani radiofarmak, tako da ostali deli okostja skoraj niso vidni (berljivi).

18% slik je vsebovalo samo delne posnetke okostja (t.j. manjkajoči del glave ali zgornjih oziroma spodnjih okončin), kar otežuje avtomatski proces segmentacije. Poseben primer pa so tudi adolescenti (5% slik), kjer so vidne rastne cone, ki se odražajo kot povečana osteoblastna aktivnost v dobro ločenih močno poudarjenih odčitkih radioaktivnih vrednosti.

Postopek slikanja

Vse slike pacientov so bile zajete z gama kamero Siemens MultiSPECT z dvema detektorjema, opremljenima z LEHR (Low Energy High resolution) kolimatorjema. Hitrost slikanja je bila 8cm na minuto, brez povečevanja točkovnih elementov. Uporabljen je bil tehnecijev fosfonat (^{99m}Tc -DPD, *Techneos^R*). Slikanje je bilo opravljeno v dveh do treh urah po intravenoznem injeciranju radiofarmaka z vsebnostjo 750 MBq. Celotno vidno polje kamere je bilo uporabljeno za slikanje in je obsegalo 1024×256 točkovnih elementov ($\approx 205\text{cm} \times 61\text{cm}$). Tako pridobljene sivinske slike s 16-bitno globino, predstavljajo število zaznanih gama žarkov na prostorsko enoto, ki nastanejo ob radioaktivnem razpadu tehnecijevega izotopa.

Poglavje 3

Segmentacija scintigrafskih slik okostja


Brez segmentacije okostja ne moremo opredeliti potencialne lokacije patoloških dogajanj, zato je potrebno okostja najprej segmentirati, kar je predstavljeno v tem poglavju.

3.1 Postopek segmentacije

Naloga segmentacije je prepoznavna in ekstrakcija posameznih delov okostja. Razvitih je sicer veliko metod za segmentacijo določenih delov na medicinskih slikah, vendar je vsaka metoda zelo specifična, kar pomeni, da je ne moremo neposredno uporabiti na slikah drugih modalnosti. Obstajajo tudi algoritmi za določanje prostorskih slikovnih značilnk (npr. SIFT (Lowe, 2004)), ki pa na samih scintigramih ne dosegajo dovolj dobrih rezultatov. Ti algoritmi ne upoštevajo dodatnega znanja o anatomiji človeškega telesa, sami scintigrami pa se med seboj preveč razlikujejo, da bi lahko zadovoljivo poiskali enoznačne prostorske značilke.

Celotno okostje je na scintigramih predstavljeno s sorazmerno majhnimi slikami, zaradi česar uveljavljeni algoritmi, kot so npr. PCA (Murase in Nayar, 1995) ali iskanje vzorcev s korelacijo, niso primerni. Zaradi vseh teh posebnosti smo razvili pristop, ki združuje znanje o anatomiji in uporabo enostavnih obvladljivih grafičnih algoritmov. Ti algoritmi so binarizacija, erozija, raztezanje, Houghova transformacija, Gaussovo glajenje (Jammal in Bijaoui, 2004), iskanje s pomočjo žarka ter prileganje krogov in elips z metodo najmanjših kvadratov. Zaradi nizkih ločljivosti scintigrafskih slik in velikega števila posameznih kosti predlagani postopek uporablja veliko predhodnega znanja o človeški anatomiji,

ki pripomore h kvaliteti segmentacije. Uporaba teh algoritmov je opisana v nadaljevanju. Groba ideja razvitega postopka segmentacije in diagnosticiranja je prikazana na sliki 3.1.




Slika 3.1: Razvoj in uporaba algoritma

Zaradi majhne resolucije scintigramov in slabe izraženosti posameznih kosti uporabljamo najprej iskanje v naprej določenih referenčnih točk, s pomočjo katerih lahko kasneje na več načinov segmentiramo posamezne kosti. Za primerne referenčne točke smo izbrali tiste, ki jih je na veliki večini obravnavanih scintigramov mogoče zadovoljivo enoznačno določiti, saj se sami scintigrami lahko precej razlikujejo med seboj (slika 3.2). Scintigrafije okostja so tudi močno odvisne od velikosti pacienta, kontrasta in osvetlitve (odvisno od absorbiranega radiofarmaka na volumsko enoto) ter samih strukturnih razlik okostja (slika 3.3).

3.1.1 Iskanje referenčnih točk okostja

Veliko scintigramov v praksi je le delnih, bodisi ker nas zanima le določen del okostja, ali pa zaradi omejitev vidnega polja kamere (pacient je previsok ali pa preveč obilen). Zaradi takih omejitev je sam postopek zaporeden, tako da najprej



Slika 3.2: Določene karakteristične referenčne točke

poiščemo referenčne točke, ki jih je najlažje najti, nato pa iz teh točk nadaljujemo iskanje s pomočjo predhodnega znanja o prostorskih relacijah med deli okostja. S tem znanjem lahko določimo predvideno območje iskanja (ang. region of interest - ROI) posamezne nove referenčne točke, tako da močno zožimo območje iskanja. Samega iskanja pa se lotimo s pomočjo prej navedenih grafičnih algoritmov. Vsako na novo določeno referenčno točko še dodatno premaknemo (največ 3 točke) do območja z najvišjo kumulativno intenziteto.

Pri študiji smo opazili, da le na dveh scintigramih od 467-ih ramena niso bila vidna. Ostala možna začetna območja so bolj pogosto manjkala ali so bila slabo vidna (npr. glava, roke, ena ali obe nogi). Zato smo ramena izbrali kot glavni referenčni točki. Tako je potreben pogoj za delovanje algoritma viden ramenski del. Poleg te predpostavke je potrebna le še predpostavka o orientaciji slike. Ta predpostavka ni moteča, saj so vsi scintigrami posneti s pokončno orientacijo.

Za odlično pomoč pri iskanju ostalih referenčnih točk so se izkazali intenzitetni vrhovi slike. S temi vrhovi smo želeli vsaj delno opisati definirane referenčne



Slika 3.3: Primeri raznolikosti scintigramov in okostij

točke, saj so bile te izbrane tudi na osnovi večjih intenzitet v okolici. Ideja je podobna kot pri algoritmu SIFT (Lowe, 2004), kjer prostorske značilke predstavljajo najbolj izstopajoči vrhovi pri različnih resolucijah. Kasneje se je izkazalo, da pri nadaljnjem iskanju ni več vedno potrebno uporabljati samega scintigrama, temveč zadostujejo najdeni intenzitetni vrhovi, kar močno zmanjša časovno zahtevnost samega postopka (saj se lahko izvaja v linearnem času v odvisnosti od velikosti slike [pohitritev iz $\sim 500s$ na $\sim 100s$]).

3.1.2 Detekcija orientacijskih točk za iskanje referenčnih točk (intenzitetni vrhovi)

Obstaja več načinov za iskanje intenzitetnih vrhov na sliki. Najprej smo poskusili z metodo SIFT, ki pa je vrnila premalo značilnk, da bi lahko omogočila zadovoljivo dobro podporo pri iskanju referenčnih točk. Druga metoda je s pomočjo Cannyjevega filtra iskala robove na sliki. Najdene točke so služile kot intenzitetni vrhovi. Teh točk je bilo preveč za zanesljivo določanje željenih regij. Zato smo za iskanje intenzitetnih vrhov razvili svoj algoritem (glej alg. 1), ki je prilagojen za delo s scintigrami. Algoritem uporablja Gaussovo glajenje slike in linearno filtriranje

Algoritem 1: Iskanje intenzitetnih vrhov Ω

Potrebuje: originalni scintigram $I[x_i, y_j], i \in [0, m-1], j \in [0, n-1]$; Gaussov filter $G_{3 \times 3} = \left(\frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \right)$; velikost okna za povprečenje W ($w \times h$ kjer sta w in h liha); d - minimalna razdalja med najdenimi vrhovi;

$$W_{w \times h} = \left(\frac{2}{w+h} \begin{bmatrix} 1 & 2 & \dots & \frac{w+1}{2} & \dots & 2 & 1 \\ 2 & 3 & \dots & \frac{w+1}{2} + 1 & \dots & 3 & 2 \\ \vdots & \vdots & & \vdots & & \vdots & \vdots \\ \frac{h+1}{2} & \frac{h+1}{2} + 1 & \dots & \frac{w+h}{2} & \dots & \frac{h+1}{2} + 1 & \frac{h+1}{2} \\ \vdots & \vdots & & \vdots & & \vdots & \vdots \\ 2 & 3 & \dots & \frac{w+1}{2} + 1 & \dots & 3 & 2 \\ 1 & 2 & \dots & \frac{w+1}{2} & \dots & 2 & 1 \end{bmatrix} \right)$$


Zagotovi: množico intenzitetnih vrhov Ω

- 1: $I_1 \leftarrow I \times G$ {aplikacija Gaussovega filtra}
- 2: $I_2 \leftarrow I_1 \times W_{w \times h}$ {aplikacija večjega linearnega filtra za povprečenje}
- 3: dodaj vse točkovne elemente iz slike I_2 , ki imajo večjo intenziteto od levega in desnega sosedu, v množico Ω_1 {horizontalni prehod}
- 4: dodaj vse točkovne elemente iz slike I_2 , ki imajo večjo intenziteto od spodnjega in zgornjega sosedu, v množico Ω_1 {vertikalni prehod}
- 5: uredi množico Ω_1 po padajoči intenziteti vsebovanih elementov
- 6: iz množice Ω_1 dodaj zaporedoma vse elemente, ki imajo razdaljo do vseh elementov v množici Ω večjo ali enako d , v množico Ω .

slike z eksperimentalno določeno velikostjo okna, kar je sorodno osnovni ideji algoritma SIFT.

Omejena količina vbrizganega radiofarmaka, zaradi varnosti bolnika, povzroči majhno število izsevanih gama žarkov, zaradi česar so scintigrami posneti v majhni resoluciji in niso tako izraziti, kot je npr. rentgensko slikanje. Robove kosti na scintigramu lahko poudarimo s filtriranjem ali povprečenjem slike (npr. valčne transformacije, medianin ali Gaussov filter - Jammal in Bijaoui (2004)). Pri iskanju referenčnih točk smo za izboljšanje detekcije uporabili Gaussov filter. Pri glajenju s tem filtrom porežemo intenzitete, večje od 90 gama žarkov na točkovno enoto, saj pri normalnih stanjih bolnika ne ugotovimo večjih intenzitet. Tak popravek omeji vpliv močnejših patoloških delov, kjer intenzitete dosežejo tudi 1000 in več gama žarkov na točkovno enoto, kar pa nas pri iskanju referenčnih točk ne zanima in nas le ovira.

V primeru scintigramov lahko uporabimo metode, ki so občutljive na spremembo merila, saj nam tak način slikanja zagotavlja nespremenljivo merilo (100 slikovnih točk $\approx 24cm$). Velikost okna $W_{w \times h}$, s katerim povprečimo sliko, je bila eksperimentalno določena na 11×5 ($\simeq 2.6cm \times 1.2cm$), saj smo pri tej velikosti dobili najboljše rezultate v smislu točnosti segmentacije.



Slika 3.4: Primer najdenih intenzitetnih vrhov na anteriorni in posteriorni sliki z uporabo algoritma 1 ($d = 1, w \times h = 11 \times 5$) (vsi najdeni vrhovi so tudi prezrcaljeni na nasprotno sliko - označeni rumeno)

Referenčne točke na sliki 3.2 iščemo s pomočjo določenih intenzitetnih vrhov (slika 3.4). Obe sliki, posteriorno in anteriorno, preiskujemo vzporedno, v enakem vrstnem redu iskanja referenčnih točk. Detektirane točke na vsaki izmed slik so hkrati prezrcaljene tudi na nasprotno stran, kar poudari obliko kosti še na nasprotni strani. Zrcaljenje je mogoče zaradi istočasnega snemanja obeh slik, kar

pomeni, da imata enako velikost in da sta že poravnani. Poljubno točko $pt_{(x,y)}$ na eni sliki prezrcalimo na drugo sliko v točko $pt'_{(x',y')}$, kjer je $x' = image_{width} - x$, $y' = y$. Nekateri deli okostja so zaradi razdalje do senzorjev gama kamere boljše vidni na posteriorni sliki, drugi na anteriorni, nekateri pa se jasno izrazijo šele s kombinacijo obeh (npr. kolčnica). V vsakem koraku segmentacije se novo zaznane referenčne točke, vidne na obeh slikah, primerjajo. Glasovalni algoritem izbere boljše referenčno točko od obeh in jo preslika na nasprotno stran. Za vsak tip referenčne točke (koleno, kolčnica, sramnica, ramena itd.) smo določili pripadajočo mero za odločanje o njeni kvaliteti.

Pri meri za določanje boljše referenčne točke se upoštevata dva vidika. Pričakovana intenziteta okolice referenčne točke in prostorska razmerja do drugih že določenih referenčnih točk drugih tipov (npr. pričakovana dolžina nadlahtnice je približno 0.67 dolžine hrbtenice, ki sega od temenice do trtice). Bolj podroben opis ostalih pravil se nahaja v izvorni kodi (Šajn, 2007).

Nekatere kosti (npr. lobanja, kolčnica in sramnica) lahko, za potrebe segmentacije, predstavimo z osnovnimi geometrijskimi oblikami (npr. krogi, elipse in premice), ki jih lahko določimo z metodo najmanjših kvadratov. Prileganju geometrijskih oblik pripomore tudi zrcaljenje intenzitetnih vrhov med anteriorno in posteriorno sliko.


Vrstni red določanja referenčnih točk je bil določen na osnovi anatomskega znanja in nasvetov zdravnikov specialistov. Anatomsko znanje je predstavljeno v obliki parametričnih pravil za vsak del okostja posebej. Parametri pravil (npr. intenzitetni pragovi, prostorska in intenzitetna razmerja itd.) so bili najprej določeni s pomočjo radiologov, kasneje pa še izboljšani na osnovi ločene učne množice slik.

Iskanje referenčnih točk poteka v naslednjem vrstnem redu: ramena, medenični del, glava, prsni del in okončine.

3.1.3 Ramenski del

Začetni točki segmentacije sta ramenski referenčni točki. Za začetno ramensko točko določimo prvo intenzitetno točko na sliki 3.4, ki jo najdemo v diagonalni smeri iz levega oz. desnega roba slike (slika 3.5). Velikost območja iskanja je določena eksperimentalno kot pravokotnik z višino (190točk $\approx$ 40cm) in širino, ki ustreza 30% širine slike.

Naslednji korak je določitev ramenske referenčne točke znotraj območja začetne ramenske točke (14×7 točk). Začetno točko premaknemo do mesta, kjer se, v določenem območju, nahaja najvišja kumulativna intenziteta (na glajeni sliki). Le v petih primerih od 467 slik zaradi nepravilnega položaja glave, ki je oviral diagonalno detekcijo, ramena niso bila določena pravilno.



Slika 3.5: Iskanje ramenskih referenčnih točk

Iz določenih ramenskih referenčnih točk lahko že povzamemo nekaj informacije o sami sliki, ki nam služi za nadaljnjo segmentacijo. Izračunamo lahko širino ramen (razdalja med obema določenima referenčnima točkama) in nagib (kot med obema rameni). To informacijo kasneje uporabimo za določanje velikosti in naklonov območij iskanja ostalih referenčnih točk (npr. ocenjena dolžina hrbtenice znaša $1.76 \times \text{širina ramen}$).

3.1.4 Medenica (kolčnica, sramnica in kolk)

Medenica se nahaja na koncu hrbtenice in ima približno enako širino, kot ramena. Da bi določili položaj medenice, moramo najprej določiti grobo lokacijo hrbtenice. Hrbtenico najprej poiščemo s pomočjo žarka (slika 3.7a). Žarek predstavlja pravokotnik, čigar velikost in začetna orientacija sta določeni s podatki, izračunanimi iz ramenskih referenčnih točk. Začetna pozicija žarka je določena s sredinsko točko med rameni, končna pa z ocenjeno dolžino in je pravokotna na premico med rameni. Žarek rotiramo okrog ramenske sredinske točke in pri kotu, kjer žarek pokrije največ intenzitetnih vrhov, določimo grobo smer poteka hrbtenice. Tak postopek lahko uporabimo, saj je v hrbetnici največ absorbirane radiofarmaka in v tem območju dobimo največ intenzitetnih vrhov. Ker uporabljamo le predhodno določene intenzitetne vrhove, se izognemo računanju kumulativnega izseva gama žarkov za vsak žarek posebej. Tako veliko prihranimo na časovni zahtevnosti postopka, saj lahko samo preštejemo intenzitetne vrhove znotraj žarka.

Najbolj razpoznavna kost v medeničnem delu je kolčnica, ki ima večji izsev, kot njena okolica, sestavljena iz mehkega tkiva. Kolčnica ima v zgornjem delu krožno obliko in je tako zelo primerna za prileganje krožnice z uporabo metode najmanjših kvadratov. Kolčnica je tudi dobro opisana z že najdenimi intenzitetnimi vrhovi, kot je prikazano na sliki 3.7b. Pričakovana lokacija leve

in desne kolčnice je ocenjena s pričakovanimi razmerji med referenčnimi točkami obeh kolčnic in ostalimi referenčnimi točkami, ki smo jih določili do tega koraka. Pseudo koda programa za iskanje kolčnice je prikazana na sliki 3.6

```

iliumBone(iliumCircleParam):-
    spine(spineLocation),
    iliumStart(spineLocation, iliumROI),%iskanje se začne pri 60% ocenjene dolžine hrbtenice
    navzdol in se ustavi, ko se znotraj iskalnega okna iliumROI nahajajo vsaj trije intenzitetni vrhovi, ali
    pa se kumulativni izsev znotraj iskalnega okna iliumROI spremeni za več kot 80% glede na prejšnjo
    stanje iskalnega okna.
    extendAndNarrowIliumROI(iliumROI, newIliumROI),
    circleLSM(newIliumROI, circleParam),%z metodo najmanjših kvadratov poišči krog, ki ga
    opisujejo intenzitetni vrhovi znotraj območja iliumROI
    improveCircleLSM(newIliumROI, circleParam, iliumCircleParam, 0),

extendAndNarrowIliumROI(iliumROI, newIliumROI):-
    getROIsize(iliumROI, width, height),
    changeROIsize(iliumROI, newIliumROI1, width, width), %razširi višino iskalnega okna ili-
    umROI na njegovo širino
    narrowIliumROI(newIliumROI1, newIliumROI),%zoži območje iskanja iliumROI s
    pomočjo dinamične binarizacije


improveCircleLSM(iliumROI, iliumCircleParam, newIliumCircleParam, N):-
    ((N > 3;
    circleCoversAllPeaks(iliumROI, iliumCircleParam),
    newIliumCircleParam = iliumCircleParam);
    (removeOuterPeaks(iliumROI, iliumCircleParam), %izloči vse intenzitetne vrhove, ki
    ležijo izven kolobarja, ki je določen s 50% večjo in 50% manjšo krožnico od zadnjega izračunanega
    kroga iliumCircleParam
    circleLSM(iliumROI, iliumCircleParam1), %določanje novih parametrov krožnice z metodo
    najmanjših kvadratov
    N1 is N + 1,
    improveCircleLSM(iliumROI, iliumCircleParam1, newIliumCircleParam, N1))) %pona-
    vljamo to iteracijo, dokler niso vsi intenzitatni vrhovi iz območja iliumROI znotraj krožnice iliumCir-
    cleParam

```

Slika 3.6: Primer parametričnih pravil za iskanje kolčnice (sintaksa jezika *Prolog*)

Levo in desno sramnico poiščemo v pričakovanem območju, ki ga določimo s pomočjo že določenih referenčnih točk obeh kolčnic, kjer uporabimo njihove razdalje in nagib. Pričakovano območje zožimo s pomočjo dinamične binarizacije, ki razdeli opazovano območje na bele in črne točke. Opazovano območje zožimo toliko, da so točke razdeljene v razmerju 60% črnih in 40% belih. V novem območju najprej poiščemo še dodatne intenzitetne vrhove z algoritmom 1, pri čemer uporabimo manjše okno za povprečenje slike $W_{w \times h}$ (7×3 točk). Nato na podlagi dodatnih intenzitetnih vrhov ponovno poiščemo krožnice, ki opisujejo iskane kosti (slika 3.7b). Določanje krožnic še izboljšamo z največ tremi iteracijami, kjer najprej iz množice intenzitetnih vrhov odstranimo tiste, ki so od najdene krožnice oddaljeni več kot $\frac{r}{2}$, nato pa ponovno poiščemo parametre krožnice na novi množici vrhov in ponovimo postopek. S tem postopkom dobimo boljše približke iskanih kosti krožne oblike. Postopek je prikazan na sliki

3.6 (predikat *improveCircleLSM*).



Slika 3.7: Iskanje z žarkom in detekcija v medeničnem predelu

3.1.5 Glava in vrat


Ko imamo določeno orientacijo slike in lokacijo ramen, lahko določimo približno lokacijo sredine vratu med rameni. Iskanje same glave ni zapleteno, je pa problematična njena orientacija, še posebej takrat, ko je viden le del glave na sliki. Za najbolj zanesljivo metodo določanje pozicije in orientacije glave se je izkazalo prilaganje elipse na obris glave. Obrisi glave je določen tako, da s horizontalnim prehodom vrha slike nad rameni določimo točke, ki z leve in desne strani presežejo nek vnaprej določen prag. Tako s pomočjo upravljanja zunanega obrisa glave nad rameni dobimo konturo, ki jo lahko opišemo s funkcijo elipse, kot je vidno na sliki 3.8a (kontura je prikazana z majhnimi točkami).

Prilaganje funkcije elipse, ki najbolje opiše lego in orientacijo glave, je izvedeno s pomočjo metode najmanjših kvadratov (LSM).

Splošna kvadratna enačba elipse v xy -ravnini je polinom drugega reda.

$$a_{11}x^2 + 2a_{12}xy + a_{22}y^2 + b_1x + b_2y + c = 0 \quad (3.1)$$

Vse stožnice lahko predstavimo s to enačbo. Za elipse pa velja, da je $a_{11}a_{22} - a_{12}^2 > 0$. Iz tega lahko izpeljemo (Eberly, 2003), da je ob upoštevanju te omejitve, center elipse $C(k_1, k_2)$ podan z naslednjo enačbo



Slika 3.8: Detekcija glave

$$C(k_1, k_2) = \frac{(a_{22}b_1 - a_{12}b_2, a_{11}b_2 - a_{12}b_1)}{2(a_{12}^2 - a_{11}a_{22})}. \quad (3.2)$$


Glavne osi in orientacija, se lahko izrazijo s koeficienti polinoma.

Naj bo $\mu = 1/(a_{11}k_1^2 + 2a_{12}k_1k_2 + a_{22}k_2^2 - c)$ ter določimo $m_{11} = \mu a_{11}$, $m_{12} = \mu a_{12}$ in $m_{22} = \mu a_{22}$. Priredimo $\lambda_1 = ((m_{11} + m_{22}) + \sqrt{(m_{11} - m_{22})^2 + 4m_{12}^2})/2$. Dolžina male osi elipse b je $b = \frac{1}{\sqrt{\lambda_1}}$. Na enak način določimo dolžino velike osi. Postavimo $\lambda_2 = ((m_{11} + m_{22}) - \sqrt{(m_{11} - m_{22})^2 + 4m_{12}^2})/2$, tako je dolžina velike osi a enaka $a = \frac{1}{\sqrt{\lambda_2}}$.

Kot Θ med veliko osjo elipse in pozitivno osjo x zadošča enačbi

$$\tan(2\Theta) = -\frac{a_{12}}{a_{22} - a_{11}}. \quad (3.3)$$

Enačbo 3.1 lahko rešimo s pomočjo metode najmanjših kvadratov in z dobljenimi koeficienti izračunamo vse parametre elipse, ki predstavljajo lego glave. Poskusi so pokazali zelo dobre rezultate glede orientacije glave in posledično tudi vratnih vretenc (slika 3.9).



Slika 3.9: Primeri detekcije glave pri različnih nagibih

Z vertikalnim preiskovanjem od sredinske točke ramen navzgor do mesta, kjer zaznamo največje število izsevanih gama žarkov, določimo pozicijo spodnjega dela temenice, ki hkrati predstavlja tudi konec hrbtenice. Temenica je najbolj primerna za določanje pravil iskanja, saj v tem delu absorbira največ radiofarmaka in je obkrožena le z mehkim tkivom, ki ne ovira iskanja. Iskalno okno ima velikost 5×15 točk, intenziteta izseva pa se ocenjuje kot seštevek žarkov v tem pravokotniku. Orientacija pravokotnika se med iskanjem ohranja in je določena s predhodno ugotovljeno lego elipse, ki opisuje glavo.


3.1.6 Torakalni del (vretenca in rebra)

Hrbtenica ima dokaj konstantna prostorska razmerja med vretenci, kar ugotavljajo tudi Holmaas in sod. (2006). Ker imamo na scintigramu le planarno projekcijo hrbtenice, ki je pri različnih pacientih različno vzdolžno ukrivljena, se tudi razmerja ne ohranjajo v celoti. Poleg tega pa so tudi pacienti lahko različno vzdolžno nagnjeni na mizi kamere. Povprečne medvretenčne razdalje med posameznimi vretenci smo eksperimentalno določili iz starostno enakomerno porazdeljenega vzorca pacientov z normalnimi okostji. Ko je območje hrbtenice približno določeno s pomočjo do sedaj določenih referenčnih točk, ga navpično razdelimo na 10 delov glede na eksperimentalno določena razmerja. Tako določena območja vretenc nato zožimo in premaknemo glede na predhodno najdene intenzitetne vrhove. Tak postopek je potreben predvsem v primerih ukrivljene hrbtenice (skolioza), da lahko sledimo obliki hrbtenice.

Rebra so najtežji del okostja pri detekciji, saj so običajno na sliki precej nejasno izražena, njihova oblika pa se lahko med scintigrami precej razlikuje. V primeru patologij je samo rebro na sliki lahko tudi prekinjeno, tako da moramo avtomatsko poiskati tudi njegovo nadaljevanje. Z uporabo do sedaj določenih vretenc (od TH6 do TH11) določimo začetne točke reber, od koder nato sledimo obliki, kot je prikazano na sliki 3.10. Za sledenje konturam pri algoritmih za obdelavo slik obstaja več tehnik (npr. procedura 'turtle', sledenje razpok, sledenje robov itd. - Kindratenko (1997)). Te tehnike potrebujejo neprekinjeno sled iskane oblike na slikah in zato niso neposredno uporabne za sledenje reber. Razvili smo izviren postopek, ki uporablja morfološke slikovne operacije, predvsem naslednje tri dobro znane algoritme:

1. dinamična binarizacija,
2. raztezanje in erozija (Blum, 1967),
3. Houghova transformacija (Hough, 1959).

Algoritem za določanje poteka reber uporablja kratke žarke za iskanje poteka reber. Iskanje se začne pri posameznem vretencu in nadaljuje do konca opazova-



Slika 3.10: Koraki detekcije reber na scintigramu z močnimi patologijami. (A) območje reber binariziramo, (B) binarizirano sliko erodiramo, (C) na erodirani sliki uporabimo Houghovo transformacijo za iskanje linearnih enačb premic, (D) določimo referenčne točke na osnovi izračunanih parametrov premic, (E) posamično sledimo sledem reber z algoritmom, ki upošteva predznanje o pričakovani obliki reber

nega rebra. Dolžina žarka za iskanje je enaka širini vretenca, od koder sledimo rebbru. S pomočjo žarka ugotovimo, pri katerem naklonu zajamemo največji kumulativni izsev in ta naklon uporabimo za določanje nove začetne točke iskanja. Iskanje nadzorujemo s predznanjem o pričakovani ukrivljenosti obravnavanega rebra, ugotovljeni na učni bazi slik, s čimer omogočimo preskakovanje neizrazitih delov rebra, ki se pojavijo na scintigramih z močnejše izraženimi patologijami. To storimo tako, da za naslednji žarek uporabimo pričakovano ukrivljenost in nadaljujemo iskanje iz nove pozicije. Konec rebra določimo takrat, ko žarek v območju pričakovane smeri ne zazna več nobenega večjega izseva in je skupna dolžina rebra že dosegla ali presegla pričakovano dolžino. Iskanje pa ustavimo tudi v primeru, ko s preskakovanjem nevidnega dela rebra presežemo pričakovano dolžino. S tem postopkom lahko tudi napačno določimo lokacijo manjkajočega rebra, kar pa je v praksi zelo redek primer (pri obravnavanih scintigramih se ni pojavil) zato se s tem nismo ukvarjali.

3.1.7 Spodnje in zgornje okončine (stegenica, koleno, golenica, mečnica, stopalo, nadlahtnica, rama, koželjnica in podlahtnica)

Okončine so pogosto le delno vidne na slikah, bodisi zaradi omejene velikosti vidnega polja gama kamere, ali zaradi slikanja le določenega dela okostja. V praksi največja širina slikovnega polja (61cm) običajno ni dovolj za zajem zgornjih okončin v celoti. Območja nadlahtnice, podlahtnice in koželjnice, kot tudi stegenice, golenice in mečnice, so določene s podobnim postopkom nadzorovanega iskanja z žarki, kot je uporabljen pri iskanju reber. Dolžine žarkov so določene s pomočjo prostorskih razmerij v okostju, ugotovljenih na osnovi učne množice (npr. dolžina stegenice je ocenjena kot 78% razdalje med temenico in zgornjo referenčno točko trtice). Postopek upošteva možnost manjkajoče okončine, tako v celoti kot tudi le delno, in poišče toliko referenčnih točk, kolikor jih je na sliki še dosegljivih.

3.2 Ocena uspešnosti določanja referenčnih točk

Približno polovica razpoložljivih scintigramov je bila uporabljena za uravnavanje parametrov algoritma za iskanje referenčnih točk, druga polovica pa za oceno uspešnosti razvitega postopka. Vseh 246 pacientov, pregledanih med oktobrom 2003 in marcem 2004, je služilo za učno množico, ostalih 221, pregledanih med aprilom in junijem 2004, pa za testno množico. V učni množici je 38.9% slik vsebovalo manjše artefakte, na 47.5% slikah je bilo vidno mesto vbrižga in 6.8% slik je predstavljalo odrasčajoče osebe z vidnimi rastnimi conami. Podobna porazdelitev se pojavi tudi pri testni množici (34.5% manjših artefaktov, 41.0% vidnih mest vbrižga in 2.9% adolescentov). Večina manjših artefaktov je bila posledica kontaminacije z urinom v medeničnem predelu (81.4% vseh artefaktov), ostalih tipov pa je bilo manj (urinski kateter 13%, umetni kolk 4% in svinčeni ščiti 1.6%). Pri adolescentih z vidnimi rastnimi conami ni bilo nobene napačno najdene referenčne točke, kar je posledica homogenih in jasno ločenih kosti. Algoritem deluje tako na slikah odraslih oseb kot tudi na slikah adolescentov brez interakcije uporabnika. Rezultati detekcije referenčnih točk na testni množici so prikazani v tabeli 3.1.

Rezultati so prikazani za različne stopnje patologij, saj smo pričakovali, da posamezna patološka stanja različno vplivajo na kvaliteto segmentacije. Rezultati so pokazali, da ni večjih razlik med različnimi patološkimi skupinami.

Postopek segmentacije smo implementirali v ekspertnem sistemu "Skelet 1.6" (Šajn, 2007) (program je napisan v okolju Java 2 (SE) v 1.4.2) (slika 3.11). Obstoječi sistem vsebuje obdelavo slik, uporabo večih linearnih filtrov, konverzijo v druge formate, paketno shranjevanje slik in referenčnih točk v SQL bazo, izvoz v XML obliko, ročno popravljanje referenčnih točk, označevanje slike in iskanje regij s pomočjo prilagodljive korelacije vzorcev. S pomočjo spremenljivega območja korelacije smo dodatno testirali tudi postopek iskanja delov okostja vnaprej določenih vzorcev v novi sliki. Tako iskanje je dalo precej slabše rezultate od predstavljenega postopka, tako da ga nismo razvijali naprej.

V razvitem sistemu smo se skušali izogniti vsem časovno zahtevnim algoritmom. Uporabljene algoritme pa smo v čim večji meri optimizirali glede računske zahtevnosti. Tako detekcija referenčnih točk na anteriorni in posteriorni sliki potrebuje okoli 3s na opremi Pentium 4, 2.8GHz procesor in 1GB RAM.


3.3 Segmentacija scintigrama z referenčnimi točkami

Določene referenčne točke, ki smo jih našli z opisanim postopkom v razdelku 3.1.1, nam omogočajo segmentacijo scintigrama, kar lahko dosežemo na več načinov. Razvili smo nekatere metode za izrez območij posameznih kosti, na katerih lahko

Tabela 3.1: Število pravilno določenih referenčnih točk na testni množici za različne stopnje patologij. Prikazana so števila primerov in odstotki

<i>Kost</i>	<i>brez patologije</i>		<i>blaga patologija</i>		<i>močna patologija</i>		<i>super-scan</i>		skupaj	
ženske	22		78		15		1		116	
kolčnica	22	100%	76	97%	13	87%	0	0%	111	96%
sramnica	22	100%	76	97%	14	93%	1	100%	113	97%
kolk	22	100%	77	99%	15	100%	1	100%	115	99%
rame	22	100%	78	100%	14	93%	1	100%	115	99%
okončine	21	96%	74	95%	15	100%	1	100%	111	96%
hrbtenica	22	100%	78	100%	14	93%	1	100%	115	99%
rebra	16	73%	70	90%	12	80%	1	100%	99	85%
vrat	22	100%	76	97%	15	100%	1	100%	114	98%
<i>povprečje</i>	96%		97%		93%		88%		96%	
moški	24		55		24		2		105	
kolčnica	24	100%	55	100%	20	83%	2	100%	101	96%
sramnica	22	92%	54	98%	23	96%	2	100%	101	96%
kolk	24	100%	55	100%	24	100%	2	100%	105	100%
rame	24	100%	55	100%	24	100%	2	100%	105	100%
okončine	20	83%	48	87%	24	100%	2	100%	94	90%
hrbtenica	24	100%	53	96%	24	100%	2	100%	103	98%
rebra	19	79%	46	84%	24	100%	2	100%	91	87%
vrat	22	92%	53	96%	24	100%	2	100%	101	96%
<i>povprečje</i>	93%		95%		97%		100%		95%	
skupaj	46		133		39		3		221	
kolčnica	46	100%	131	98%	33	85%	2	67%	212	96%
sramnica	44	96%	130	98%	37	95%	3	100%	214	97%
kolk	46	100%	132	99%	39	100%	3	100%	220	100%
rame	46	100%	133	100%	38	97%	3	100%	220	100%
okončine	41	89%	122	92%	39	100%	3	100%	205	93%
hrbtenica	46	100%	131	98%	38	97%	3	100%	218	99%
rebra	35	76%	116	87%	36	92%	3	100%	190	86%
vrat	44	96%	129	97%	39	100%	3	100%	215	97%
<i>povprečje</i>	95%		94%		96%		96%		96%	

izvajamo strojno učenje. S temi metodami lahko avtomatiziramo diagnosticiranje posameznih patoloških regij. Referenčne točke smo uporabili na dva načina, ki sta predstavljena v naslednjih razdelkih. Pred samo uporabo smo napačno določene referenčne točke ročno popravili, kot to omogoča razviti ekspertni sistem (Šajn, 2007), da ne bi razširjali napake naprej na segmentacijo, kar bi oteževalo ocenjevanje diagnostične točnosti.




Slika 3.11: Program "Skelet"

3.3.1 Neposredni izrez delov okostja

Pri tem načinu uporabimo referenčne točke tako, da izrežemo dele slike, ki so določeni s trakovi določene širine, katerih oglišča so določena z vnaprej določenim potekom skozi referenčne točke. Tako lahko iz predlaganih referenčnih točk (slika 3.2) izluščimo 26 kosti oz. delov okostja. To so okončine, vrat, prsni del hrbtenice, ledveni del hrbtenice, 10 reber, kosti medenice in glava. Tak tip segmentacije je bil uporabljen pri testiranju uspešnosti klasifikacijskih algoritmov. Primere teh izrezov vidimo na sliki 3.12.

3.3.2 Segmentacija s pomočjo maske

Referenčne točke lahko še razširimo z virtualnimi točkami, ki jih določimo na osnovi najdenih referenčnih točk. Nove točke določimo s preprostimi geometrij-



Slika 3.12: Primeri segmentiranih delov okostja (A - vratni del hrbtenice, B stopalo, C - rebra, D - stegenica, E - ledveni del hrbtenice, F - prsni del hrbtenice, G - sakroiliakalni sklep)


skimi metodami. Točke poiščemo tako, da daljico, ki povezuje dve referenčni točki, zarotiramo za kot 90 stopinj in jo skrajšamo za primeren odstotek. Na ta način pridobimo dve novi točki. Virtualne točke so prikazane na sliki 3.13a. Med temi točkami lahko še sestavimo mrežo med seboj neprekrivajočih se trikotnikov (slika 3.13b), ki omogočijo linearne preslikave poljubnih mask iz enega scintigrama na drugega.

S pomočjo predlaganega postopka lahko na izbranem scintigramu definiramo poljuben obris željenih kosti in ga preslikamo na nov scintigram. Na novem scintigramu s pomočjo najdenih referenčnih točk določimo novo trikotniško mrežo z enako topologijo. Nato preslikamo določen obris kosti (opisan z lomljenimi črtami) z linearno transformacijo za vsak trikotnik posebej. Vsako vozlišče lomljene črte je vsebovano v nekemu trikotniku mreže. To vozlišče preslikamo na novo sliko tako, da koordinate $p_{im}(x_{im}, y_{im})$ množimo z matriko A , ki je določena iz pripadajočih koordinat trikotnika osnovne slike $v_{1o}(x_{1o}, y_{1o})$, $v_{2o}(x_{2o}, y_{2o})$, $v_{3o}(x_{3o}, y_{3o})$ in nove slike $v_{1m}(x_{1m}, y_{1m})$, $v_{2m}(x_{2m}, y_{2m})$, $v_{3m}(x_{3m}, y_{3m})$.


$$A = \begin{bmatrix} x_{1m} & x_{2m} & x_{3m} \\ y_{1m} & y_{2m} & y_{3m} \\ 1 & 1 & 1 \end{bmatrix} \cdot \begin{bmatrix} x_{1o} & x_{2o} & x_{3o} \\ y_{1o} & y_{2o} & y_{3o} \\ 1 & 1 & 1 \end{bmatrix}^{-1}, p_{im} = A \cdot p_{io}$$

Segmentirani deli okostja so parametrizirani s pomočjo večeresolucijske parametrizacije z algoritmom ArTex tako, da lahko morebitna patološka območja klasificiramo s pomočjo različnih algoritmov strojnega učenja. Izračunani parametri so neodvisni od rotacije in osvetliteve. Zadnje je še posebej pomembno zaradi različnih absorbcij radiofarmaka v telesu.

Tak pristop omogoča avtomatsko zaznavo patoloških sprememb, kar poleg



(a) Dodatne virtualne referenčne točke (označene s krožci)



(b) Trikotniška mreža in primer preslikave označenega območja

Slika 3.13: Trikotniška mreža, sestavljena s pomočjo dodatnih referenčnih točk

odkrivanja običajnih lezij omogoča odkrivanje še drugih tipov patologij, ki so bolj kompleksne narave in zahtevajo odločanje na osnovi kombinacije sprememb v različnih delih okostja (npr. degenerativne spremembe in vnetja).

Poglavje 4

Večresolucijska parametrizacija tekstur

Kako izluščiti in izbrati najboljše značilke na slikah za namene klasifikacije, je težak problem, ki ga rešujemo na različne načine. Slikovni podatki so prostorsko zahtevne strukture, ki pa v osnovni obliki ne razkrivajo značilk, s katerimi bi lahko učinkovito razločevali med različnimi razredi objektov. Slikovne podatke, ki so običajno predstavljeni v matrični obliki, je tako potrebno preslikati v numerične ali diskretne značilke (parametre), ki zadovoljivo razlikujejo opazovane razrede objektov. Za namene klasifikacije slikovnih podatkov so že dalj časa v uporabi algoritmi za parametrizacijo, bodisi slik objektov v določenem okolju, bodisi t.i. tekstur, ki prikazujejo nek periodično ponavljajoči se vzorec (Gurevich in Koryabkina, 2006). Izkazalo se je, da so ti algoritmi pogosto občutljivi na različne specifičnosti slik, kot so osvetlitev, afine transformacije, obstrukcija opazovanih objektov in druge. Pojavi pa se še en problem, ki izhaja iz dejstva, da so slike v digitalni obliki opisane s točkovnimi elementi. Tako je pri algoritmih za parametrizacijo slik neizbežna uporaba lastnosti posameznih točkovnih elementov in/ali relacij med temi elementi.

Relacije med točkovnimi elementi vzorca so odvisne od resolucije slike in tako postane pomembno tudi, pri kakšni resoluciji sliko opazujemo. Ker običajno na sliki nimamo samo enega objekta, ki je pomemben za razločevanje razredov in so ti objekti različnih velikosti, se sama po sebi ponuja rešitev opazovanja slik pri različnih resolucijah. Tako lahko pridobimo značilke posameznih objektov različnih velikosti in jih za boljšo klasifikacijo opazovanih slik oziroma vzorcev, združimo v množico značilk. To je še posebej pomembno pri geometrijskih algoritmih, ki računajo statistične lastnosti strukturnih primitivov in le-te uporabljajo

za značilke teksture. Tak je tudi algoritem ArTex, ki ga želimo izboljšati.

Že v disertaciji (Bevk, 2005), ki opisuje algoritem ArTex, avtor navaja možno razširitev osnovnega opisa tekstur s parametri iz različnih resolucij. Predlaga pa uporabo algoritma pri osnovni resoluciji R , ter nekaj pod-resolucijah $\frac{1}{2^n}R; n > 0$. Pri testiranju algoritma opazimo, da se kvaliteta parametrizacije močno spreminja glede na izbrane resolucije. Slednje nam pove, da je potrebno resolucije prilagajati povprečni vsebini razredov opazovanih vzorcev. Pri uporabi večresolucijskega pristopa pri razpoznavanju tekstur se postavi vprašanje, katere resolucije so primerne za obravnavo.


4.1 Iskanje primernih resolucij

Pri uporabi ene same resolucije lahko spregledamo sliko kot celoto in pregovorno ne vidimo gozda zaradi dreves. Pri običajni uporabi večresolucijskega pristopa izbira resolucij ni določena na osnovi vsebine slike, kar lahko pri geometrijskih algoritmih povzroča izločitev posameznih elementov slike in veliko dvojnih opisov istih oblik osnovne slike. Zanimivo je da večina raziskav pri uporabi večih resolucij (n) uporabi resolucije R_i oblike $\{R_i = \frac{100}{2^i} | i \in [0..n-1]\}$. Taka izbira morda izhaja iz postopkov, ki zaradi svoje strukture sliko preiskujejo pri takih resolucijah (npr. valčne transformacije) ali pa zaradi enostavnejšega postopka pomanjšave slik (iz slike lahko vzamemo le vsak večkratnik 2^i -tega točkovnega elementa vrstice v vsakem večkratniku 2^i -te vrstice), kar pa zahteva, da je velikost stranic slike potenca števila 2. Pri študiji algoritmov smo opazili, da z uporabo enakomerno porazdeljenega prostora n resolucij R_i oblike $\{R_i = \frac{100i}{n} | i \in [1..n]\}$ dobimo boljše rezultate klasifikacije. To ugotovitev smo preverili s pomočjo opravljenih testiranj v disertaciji Bevk (2005), ki uporablja resolucije oblike $\frac{100}{2^i}$ in navaja, da že pri treh resolucijah začne klasifikacijska točnost padati. Test, ki preveri omenjeno tezo, je podan v razdelku 5.4.

Razvili smo algoritem ARes (alg. 2) za določanje več resolucij, pri katerih dobimo bolj opisne značilke pri parametrizaciji tekstur z algoritmom ArTex. Idejo za iskanje primernih resolucij smo dobili pri algoritmu SIFT (ang. Scale Invariant Feature Transform) (Lowe, 2004), ki za določanje značilnih točk v sliki uporablja preiskovanje slike pri resolucijah z vnaprej določenim korakom. Najprej pogledjmo algoritem SIFT, opisan v naslednjem razdelku.

4.1.1 Algoritem SIFT

V računalniškem vidu danes za potrebe razpoznave objektov, okolja, sledenja gibanju in druge, potrebujemo dovolj dobre slikovne značilke, za kar pogosto uporabljamo algoritem SIFT, ki je namenjen prav iskanju robustnih slikovnih značilk.

Slika 4.1: Klasična uporaba večih resolucij ($n = 4$; 100,0%, 75,0%, 50,0%, 25,0%)

Ideja temelji na predhodnem delu (Moravec, 1981), ki je uporabljal množico lokalnih značilnic na osnovi detekcije robov za poravnavo stereo slik. Algoritem SIFT namesto robov v sliki uporabi točke, ki imajo za določeno pomanjšavo velike odvode v vseh smereh. Značilke SIFT niso odvisne od velikostnega razreda slike, rotacije ter delno tudi od spremembe gledišča in osvetlitve. Algoritem se uporablja za poravnavo različnih slik istih predmetov ali scen (stereo vid) in za razpoznavo objektov.

Algoritem najprej progresivno gladi slike s pomočjo Gaussovega filtra, kjer se deviacija spreminja od σ do $2 * \sigma$. Tako dobimo zaporedje glajenih slik (kaskadno filtriranje), nato pa te slike odštevamo od njihovih neposrednih sosedov (ang. difference of Gaussian). Tak postopek je predlagan zaradi zmanjšanja računske kompleksnosti pri pomanjšavi slik (glajenje je računsko manj zahtevno od spreminjanja velikosti), saj obstaja linearna povezava med glajenjem slike s faktorjem σ in zmanjševanjem njene velikosti. Odštete slike služijo določanju slikovnih značilk po naslednjem postopku:

Detekcija ekstremov preko različnih velikosti slik - vsak točkovni element v odšteti sliki, se primerja s sosednjimi (osmimi na isti sliki in devetimi na sosednjih slikah), izberemo pa tiste, ki od vseh sosedov odstopajo,

Lokalizacija ključnih točk - ključne točke se določijo na osnovi najdenih ekstremov s pomočjo mere stabilnosti,

Določanje orientacije - za vsako ključno točko izračunamo smerne odvode v okolici 16×16 (z uporabo bilinearne interpolacije),

Kompozicija vektorjev ključnih točk - slikovne značilke za določeno resolucijo predstavimo s 128-dimezionalnimi vektorji s pomočjo izračunanih smernih odvodov.

Pri iskanju ujemajočih ključnih točk med različnimi slikami za potrebe poravnave in razpoznavave avtor Lowe uporablja metodo najbližjih sosedov, pri razpoznavi oblik pa še Houghovo transformacijo (Hough, 1959).

4.1.2 ARes - prilagoditev algoritma SIFT za določanje resolucij

Algoritem SIFT v osnovi ni namenjen iskanju primernih resolucij za parametrizacijo, temveč iskanju prostorsko neodvisnih značilk slike. Zato vsebuje filtriranje na osnovi izračunanih orientacij najdenih ekstremov, saj je orientacija ključnega pomena pri poravnavi slik iz različnih zornih kotov. Za določanje primernih resolucij za parametrizacijo ne potrebujemo informacije o enoznačnih orientacijah ekstremnih točk, temveč le resolucije, pri katerih ti ekstremi nastopijo. Postopek SIFT je pri testiranju za določanje resolucij dosegal povprečne rezultate, ki smo jih želeli izboljšati. Pri opazovanih domenah odstrani veliko ekstremov, ki so pomembni za učinkovitost določanja resolucij, tako da neposredna uporaba resolucij, ki jih poda algoritem SIFT, ne zagotavlja kvalitetnejšega opisa značilk, kot je razvidno iz opravljenih testov v razdelku 5.3. Zato smo se odločili razviti svoj algoritem ARes (alg. 2), ki dosega boljše rezultate.

Pri spreminjanju resolucije smo uporabili neposredno linearno pomanjšavo brez uporabe vzorčenja, saj tudi algoritem ArTex uporablja tak pristop, kjer bi sicer dobili resolucije, ki se ne bi ujemale z načinom spreminjanja resolucij v ArTex-u. Algoritem ARes (glej alg. 2) za spreminjanje resolucij ne uporablja metode z Gaussovim glajenjem, saj zaradi tega ni občutno počasnejši, doseže pa boljše rezultate. Poleg tega obstaja tudi problem pri določanju resolucije iz stopnje glajenja, saj ta povezava ni popolnoma ekvivalentna. Pri iskanju vrhov smo uporabili le ekstreme pri opazovani resoluciji brez primerjanja med stopnjo višjo in nižjo resolucijo, kot je to realizirano v algoritmu SIFT. Pri dodatni primerjavi sosednjih resolucij namreč dobimo slabše rezultate zaradi morebitno spregledanih vzorcev v opazovani teksturi pri določeni pomanjšavi.

Razviti algoritem ARes (alg. 2) za izbiro primernih resolucij na osnovi vsebine slike določi potrebne resolucije. Algoritem za prejšnji primer (prikazan na sliki 4.1) najde le dve resoluciji, saj zadostujeta za opis elementov slike (slika 4.2). Večja slika od obeh je predlagana zaradi dveh elementov, ki pri nižji resoluciji izgineta, manjšo pa predlaga zaradi bolj zgoščenega opisa, ki vsebuje več ekstre-

Algoritem 2: Algoritem za določanje resolucij ARes


Potrebuje: množico označenih vhodnih slik Θ , število željenih resolucij η , število γ uporabljanih slik za izračun resolucij za vsak razred posebej, radij ϕ okolice točkovnega elementa, ki jo obravnava kasnejši algoritem za parametrizacijo

Zagotovi: množico predlaganih resolucij Π

- 1:
$$W_{max} = \max_{i=1}^{|\Theta|}(\Theta_{i(sirina)}), H_{max} = \max_{i=1}^{|\Theta|}(\Theta_{i(visina)})$$

 {poiščemo največjo širino in višino vhodnih slik}
- 2: spremenimo velikost vsaki sliki $\Theta_i \in \Theta$ na $W_{max} \times H_{max}$, tako da ji dodamo ustrezne robove, katerih intenziteta je enaka povprečni intenziteti slike Θ_i . Poenotene slike hranimo v množici Θ' {velikosti slik morajo biti enotne, saj le tako lahko primerjamo resolucije med različnimi slikami}
- 3: $\delta = \frac{2 \cdot \phi}{3} \cdot \frac{1}{\min\{W_{max}, H_{max}\}}$ {določimo resolucijski korak pregledovanja slik}
- 4: v množico Θ_1 za vsak razred dodamo γ naključno izbranih slik iz množice Θ'
- 5: $\Omega = \{\}$
- 6: **for** ($\forall \theta \in \Theta_1$) **do**
- 7: $\nu = 1.0$ {začnemo pri 100%}
- 8: **while** ($\min\{W_{max}, H_{max}\} \cdot \nu > 3 \cdot \phi$) **do**
- 9: $\theta_1 = \text{resize}(\theta, \nu)$ {ustrezno spremenimo velikost opazovani sliki}
- 10: poiščemo ekstreme s primerjanjem okolice $[3 \times 3]$ vsakega slikovnega elementa slike θ_1
- 11: v množico Ω dodamo par $\{\nu, \text{število ekstremov}\}$
- 12: $\nu = \nu - \delta$
- 13: **end while**
- 14: **end for**
- 15: množico Ω uredimo po padajočem številu ekstremov in resolucij
- 16: iz urejene množice Ω dodamo prvih η resolucij v končno množico Π

mov, kar je pomembno pri algoritmih, ki delujejo na osnovi preiskovanja omejene okolice slikovnih elementov, kot to počne ArTex. Za prikazani primer algoritem SIFT predlaga več resolucij (40%, 38%, 41%, 30%, 39%, 29%, 42% in 8%), ki so podobne resolucijam, ki jih predlaga ARes, vendar jih je več in po številu najdenih vrhov najmanjša resolucija nastopa šele na osmem mestu, kar pomeni da bi morali za enako uspešnost klasifikacije uporabiti osem resolucij namesto dveh.



Slika 4.2: Primerne resolucije, dobljene s predlaganim postopkom ARes (30,0% in 5,0%)

Algoritem ArTex, ki je predstavljen v nadaljevanju, že sam omogoča parametризacijo tekstur pri vnaprej določenih resolucijah, tako da ni potrebe po ročnem spreminjanju velikosti slik, kot je to potrebno za vse ostale primerjane algoritme.

4.2 ArTex

Čeprav je na prvi pogled morda nenavadno, so bila povezovalna pravila uporabljena tudi za opis tekstur. Na tem mestu bom opisal algoritem ArTex (Bevk, 2005; Bevk in Kononenko, 2006), ki ga uporabljamo v tem delu. Neodvisno je bil predlagan še soroden algoritem, ki so ga podali Rushing in sod. (2001).

Za teksturo so karakteristične lokalne značilnosti točk, ki jo sestavljajo. Povezovalna pravila so uporabljena za iskanje teh pogostih lokalnih značilnosti. Za uporabo povezovalnih pravil na teksturah je ponovno definiran pojem transakcije in elementa transakcije. Prav tako je potrebno prilagoditi algoritem za odkrivanje pravil. Za razumevanje navajamo definicije najosnovnejših pojmov v tem kontekstu:

$n \times n$ **sosesčina** je kvadratna regija texture velikosti $n \times n$.

Korenska točka je točka texture, ki je v središču sosesčine.

Element transakcije je vsaka točka v sosesčini, ki je predstavljena kot vektor trojček (X, Y, I) , kjer sta X in Y odmika od korenske točke, I pa intenziteta točke. Odmika X in Y sta merjena relativno glede na korensko točko.

Transakcija je množica elementov, ki pripadajo isti sosesčini.

Povezovalno pravilo opisuje lokalno strukturo texture. Ker je osnovni element vektor trojček, je tudi pravilo sestavljeno iz takih vektorjev:

$$(X_1, Y_1, I_1) \wedge \cdots \wedge (X_m, Y_m, I_m) \implies \\ (X_{m+1}, Y_{m+1}, I_{m+1}) \wedge \cdots \wedge (X_{m+n}, Y_{m+n}, I_{m+n})$$

Algoritmu za odkrivanje pravil na začetku omejimo množico pravil, ki jih lahko generira, z minimalno podporo in zaupanjem. Pri različici za texture pa moramo nastaviti še več parametrov, ki vplivajo na število in kompleksnost generiranih pravil. Ti parametri so:

- minimalna podpora,
- minimalno zaupanje,
- velikost sosesčine,

- stopnja kvantizacije teksture (vpliva na število vrednosti za intenziteto vsake točke).

Osnovne izvedbe algoritmov za odkrivanje pravil delujejo na alfanumeričnih podatkih, ki so predstavljeni v obliki transakcij. Če bi v tako obliko transformirali teksture, bi na njih, za odkrivanje pravil, lahko uporabili katerikoli standardni algoritem. Vendar je tekstura precej bolj zgoščeno zapisana v svoji izvirni matrični obliki, zato je uporabljena kar matrična oblika, algoritem pa mora poskrbeti za ustrezno interno preslikavo.

4.2.1 Klasifikacija

Primerna izbira povezovalnih pravil omogoča, da se podpora in zaupanje izbranih pravil na dveh razredih dovolj razlikujeta. Klasifikacija izkoristi to dejstvo tako, da uporabi ta dva parametra kot značilki. Postopek je sledeč (Bevk, 2005):

1. Vsak učni primer (teksturo) predstavimo z atributnim opisom. Atributni opis je dvakrat daljši kot je število pravil. Sestavljen je iz podpore in zaupanja za vsako pravilo.
2. Ker imamo atributno predstavljene primere, lahko izbiramo med veliko množico algoritmov za indukcijo klasifikatorjev.
3. Uporaba dobljenega klasifikatorja je dokaj očitna: Za neznano teksturo sestavimo atributni opis, kot je opisano v 1. točki. S pomočjo klasifikatorja iz 2. točke določimo razred.

4.2.2 Uporaba ArTexa na več resolucijah

Že Bevk (2005) navaja možno razširitev osnovnega opisa tekstur s parametri iz različnih resolucij. Avtor predlaga uporabo algoritma pri osnovni resoluciji R , ter nekaj pod-resolucijah $\frac{1}{2^n}R; n > 0$. Razviti algoritem ARes (alg. 2) je namenjen določanju resolucij, pri katerih za obravnavane teksture dosežemo večjo informativnost zgrajenih atributov. Pri razvoju samega algoritma smo dobljene rezultate preverjali z ocenjevanjem klasifikacijske točnosti večresolucijske parametrizacije z uporabo algoritma ArTex. Algoritem ARes je bil razvit prav z namenom izboljšanja opisa tekstur algoritma ArTex.

Poglavje 5

Testiranje večresolucijske parametrizacije

Za potrebe preverjanja uspešnosti predlaganih metod smo najprej uporabili generične domene in uveljavljene algoritme za parametrizacijo, ki so široko uporabljeni v obstoječi objavljeni literaturi.

5.1 Primerjani algoritmi

V tem poglavju primerjamo rezultate predlaganega algoritma ARes v kombinaciji z algoritmom ArTex, ki spada v skupino geometrijskih (strukturnih) metod za izpeljavo značilk, in štirimi drugimi pristopi za parametrizacijo. Čeprav je algoritem ARes namenjen geometrijskim metodam, smo preverili tudi kako se obnese pri drugih skupinah algoritmov. Najprej kratko predstavimo uporabljene algoritme, ki zastopajo še dve drugi skupini metod za izpeljavo značilk: transformacijske in statistične.

5.1.1 Gaborjevi filtri

Gaborjevi filtri (Grigorescu in sod., 2002) so linearni filtri, katerih impulz je določen s harmonično funkcijo, pomnoženo z Gaussovo funkcijo. Zaradi produkta in konvolucije je Fourierova transformacija impulza Gaborjevega filtra enaka konvoluciji harmonične in Gaussove funkcije.

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = e^{-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}} \cos(2\pi \frac{x'}{\lambda} + \psi),$$

kjer je

$$x' = x \cos \theta + y \sin \theta \text{ in } y' = -x \sin \theta + y \cos \theta$$

V enačbi λ predstavlja valovno dolžino kosinusne funkcije, θ orientacijo normale na vzporedne trakove Gaborjevega filtra v stopinjah, ψ je fazni zamik in γ se nanaša na prostorsko razmerje, ki predstavlja sploščenost Gaborjeve funkcije.

Običajno se uporablja kombinacija večih rotacij in sploščenosti teh filtrov, s katerimi pretvorimo vhodni signal v Gaborjev prostor. Algoritem spada v skupino transformacijskih metod za izpeljavo značilk.

5.1.2 Lawsovi filtri

Lawsovi filtri (Laws, 1980) merijo energijo teksture s pomočjo računanja manjših konvolucijskih jeder na sliki, na kateri kasneje izvajajo nelinearne operacije. Običajno se uporabi 5 linearnih konvolucijskih jeder, ki predstavljajo povprečenje okolice (L), poudarjanje robov (E), izstopanje točkovnega elementa (S), dinamiko (W) in valovanje (R). $L=[1 \ 4 \ 6 \ 4 \ 1]$, $E=[-1 \ -2 \ 0 \ 2 \ 1]$, $S=[-1 \ 0 \ 2 \ 0 \ -1]$, $W=[-1 \ 2 \ 0 \ -2 \ 1]$, $R=[1 \ -4 \ 6 \ -4 \ 1]$

Iz teh linearnih filtrov s konvolucijo konstruiramo 25 dvodimenzionalnih filtrov, s katerimi lahko z določenim postopkom za vsak posamezen točkovni element izluščimo 14 rotacijsko invariantnih značilk. Tudi ta algoritem spada v skupino transformacijskih metod za izpeljavo značilk.

5.1.3 Haarovi valčki

Haarova transformacija je posebna vrsta valčne transformacije, kjer so valčki stopničaste Haarove funkcije. Zaradi enostavne uporabe, hitrega algoritma in uspešnosti v praksi je Haarova transformacija zelo pogosto uporabljena valčna transformacija. Haarovo transformacijo na enorazsežnem signalu $I = [i_0, i_1, \dots, i_{n-1}]$ dimenzije $n = 2^m$ izračunamo tako, da koeficiente $i_{2j}, i_{2j+1}; j < \frac{n}{2}$ signala paroma povprečimo, $i'_j = (i_{2j} + i_{2j+1})/2$. Tako dobimo prvo polovico transformiranega signala I' , ki predstavlja originalni signal pri polovični resoluciji. Drugo polovico transformiranke pa predstavljajo koeficienti, ki jim pravimo detajl signala in so po vrednosti odstopanje prvega koeficienta i_{2j} v paru od povprečja $i'_{\frac{n}{2}+j} = i_{2j} - i'_j; j < \frac{n}{2}$. Iz transformiranke I' je mogoče vedno rekonstruirati originalni signal I . Postopek iterativno nadaljujemo na najpomembnejših koeficientih signala (prva polovica signala).

Na dvodimenzionalnih signalih najprej transformiramo vrstice in nato dobljeni signal transformiramo na enak način še po stolpcih. Na tak način dobimo končni rezultat I' , ki se imenuje tudi *standardna Haarova dekompozicija*. Tako kot prva dva algoritma tudi ta spada v skupino transformacijskih metod za izpeljavo značilk.

5.1.4 Image Processor

Program “Image Processor” (Bevk in Kononenko, 2002) parametrizira teksture s pomočjo kombinacije znanih statističnih značilnk, ki temeljijo na sivinskih statistikah slikovnih elementov prvega in drugega reda (Haralick in sod., 1973). Poleg teh statistik pa uporablja tudi nekaj Lawsovih teksturnih značilnk (Laws, 1980). Algoritem spada v skupino statističnih metod za izpeljavo značilnk.

5.2 Generične baze podatkov

Za generične baze podatkov smo uporabili javno dostopne domene tekstur, ki se tudi sicer uporabljajo za testiranje algoritmov za parametrizacijo tekstur. Uporabili smo sledeče zbirke tekstur:

- Outex (Ojala in sod., 2002):
je zelo obsežna zbirka tekstur, ki je nastala na finski Univerzi v Oulu. Vsebuje nabore tekstur za klasifikacijo, segmentacijo in poizvedovanje po slikovnih vsebinah. Zbirka je pregledno urejena, tako da lahko enostavno izberemo domeno ustrezne težavnosti in vrsto problema, ki jo zadeva (npr. variacije v osvetlitvi, rotaciji, resoluciji, ...).

Domene za predstavljene eksperimente smo izbiral iz skupine *Klasifikacija*:

- *Outex 0*
Domena vsebuje 480 tekstur iz 24 razredov. Vsi razredi so enakomerno zastopani kar pomeni 20 tekstur na razred. Vse texture so enakih dimenzij 128×128 . V slike ni namerno vnešena nikakršna variacija.
- *Outex 1*
Podobna domena kot *Outex 0*, le da je tekstur več 2112 (88 primerov na vsak razred) in da so texture manjše 64×64 .
- *Outex 2*
Zopet podobna domena kot *Outex 0*, le da je tukaj še nekoliko več tekstur 8832 (368 primerov na vsak razred) in da so texture še manjše 32×32 kot v domeni *Outex 1*.
- *Outex 10*
Domena vsebuje 4320 tekstur, 24 razredov; 180 tekstur na vsak razred. Texture so zajete pod različnimi rotacijami površine 0° , 5° , 10° , 15° , 30° , 45° , 60° , 75° , 90° . Velikost tekstur je 128×128 točk.
- *Outex 11*
Vsebuje 960 tekstur, 24 razredov; 40 tekstur na vsak razred. Texture

so zajete pri dveh različnih resolucijah 100dpi in 120dpi. Velikost tekstur je 128×128 točk.

– *Outex 12*

Vsebuje 4800 tekstur, 24 razredov; 200 tekstur na vsak razred. Teksture so zajete pri različnih osvetlitvah in pod različnimi rotacijami 0° , 5° , 10° , 15° , 30° , 45° , 60° , 75° , 90° . Velikost tekstur je 128×128 točk.

- Brodatz A (Valkealahti in Oja, 1998):

Baza vsebuje podmnožico tekstur iz Brodatzovega (Brodatz, 1966) albuma materialov. Sestavlja jo 2048 tekstur iz 32 razredov. V vsakem razredu je 64 primerov. Vsak razred vsebuje 16 “originalnih” primerov vsake površine, 16 naključno rotiranih originalnih primerov, 16 primerov različnih resolucij originalnih primerov in 16 primerov naključno rotiranih in naključno skaliranih originalnih primerov. Velikost tekstur je 64×64 točk.

- Brodatz B (Haley in Manjunath, 1999):

Baza vsebuje podmnožico tekstur iz Brodatzovega albuma materialov. Sestavlja jo 1248 tekstur iz 13 razredov. V vsakem razredu je 96 primerov. Teksture so zajete pri 6 različnih rotacijah površine 0° , 30° , 60° , 90° , 120° , 150° . Velikost tekstur je 128×128 pik.

- Brodatz C (Carstensen, 1993):

Tudi ta baza vsebuje podmnožico tekstur iz Brodatzovega albuma materialov. Sestavlja jo 6720 tekstur iz 15 razredov. V vsakem razredu je 448 primerov. Teksture so zajete pri 7 različnih rotacijah površine 0° , 30° , 60° , 90° , 120° , 150° , 200° . Velikost tekstur je 32×32 pik.

5.3 Rezultati

V tem razdelku so predstavljeni rezultati na vseh devetih generičnih bazah. Podani so tudi statistični testi uspešnosti algoritma ARes za posamezne domene. V vseh tabelah najdemo rezultate pri osnovni resoluciji, N enakomerno porazdeljenih resolucijah ter resolucijah ki so določene z algoritmoma ARes in SIFT. Testi so narejeni pri uporabi štirih ($N = 4$) in osmih ($N = 8$) resolucij. Za testiranje klasifikacijske točnosti smo uporabili metodo podpornih vektorjev (SVM) z algoritmom SMO, ki je implementacija SVM algoritma (Cristianini in Shawe-Taylor, 2000) znotraj paketa Weka (Witten in Frank, 1999). Teste smo naredili z uporabo 10-kratnega prečnega preverjanja. Za izpeljavo značilk posameznega razreda smo uporabili tri naključno izbrane slike. Pri algoritmu ArTex smo uporabili še razširitev J-mero, ki daje boljše rezultate na uporabljenih generičnih bazah, kar je ugotovil že Bevk (2005). Uporabili smo velikost preiskovane okolice točkovnih

elementov $r = 5$, vse slike pa smo kvantizirali na 32 sivinskih nivojev. Pri testiranju nismo uporabili nobene redukcije atributnega prostora, saj smo uporabljali različne algoritme, pri katerih bi morali izbrati različne metode za izbiro atributov in bi tako lahko vplivali na rezultate. Tipično pri algoritmu ArTex dobimo veliko atributov, ki jih ne moremo učinkovito izbrati v tako majhnem številu, kot je to mogoče pri ostalih algoritmih za parametrizacijo. Velikostni razredi števila atributov pri uporabljenih algoritmih so prikazani v tabeli 5.1. Pri algoritmih Haar in ArTex je število odvisno od domene in resolucije, tako da je podan le interval.

Tabela 5.1: Velikostni razredi števila atributov pri uporabljenih algoritmih

algoritem	št.atributov
ArTex	280-450
Gabor	49
Haar	20-30
Laws	26
IP	23

V nadaljevanju so predstavljeni rezultati za vsak algoritem posebej, na koncu pa je podan še povzetek vseh tabel za lažjo predstavitev podatkov (tabela 5.7). Statistična primerjava klasifikacijskih točnosti algoritmov je prikazana v tabeli 5.8. Okrajšave v tabelah pomenijo sledeče: *100% res.* pomeni uporabo le osnovne 100% resolucije, *en. 4* in *8* pomeni uporabo enakomerno razdeljenih štirih oz. osmih resolucij, *ARes 4* in *8* pomeni uporabo štirih oz. osmih resolucij, ki jih predlaga algoritem ARes, *SIFT 4* in *8* pa uporabo štirih oz. osmih resolucij, ki jih predlaga algoritem SIFT. V tabelah se nahajajo tudi rezultati algoritma SIFT, ki so označeni z zvezdico. To pomeni, da je algoritem SIFT predlagal resolucijo, ki je premajhna, da bi jo algoritem za parametrizacijo lahko upošteval. V takem primeru je namesto rezultata z uporabo algoritma SIFT, uporabljen kar rezultat ustreznih enakomernih resolucij (npr. namesto *SIFT 8* je uporabljen *en. 8*), s čimer omogočimo primerjavo skupnih povprečij.

V tabeli 5.2 so prikazani rezultati z uporabo algoritma ArTex, za katerega je bil algoritem ARes tudi razvit. Skupna klasifikacijska točnost preko vseh domen pri uporabi resolucij algoritma ARes je značilno boljša od vseh ostalih izbir resolucij, kar potrjuje primernost predstavljenega algoritma. Opazimo tudi, da algoritem SIFT dosega značilno slabše rezultate od enakomernih resolucij in resolucij, ki jih predlaga ARes.

V tabeli 5.3 so rezultati algoritma Haar, pri katerih ugotovimo, da pri neka-

Tabela 5.2: Klasifikacijske točnosti algoritma ArTex

domena	100% res.	en. 4	ARes 4	SIFT 4	en. 8	ARes 8	SIFT 8
outex 0	99,02	98,77	99,26	96,32	98,78	99,75	97,80
outex 1	95,20	94,85	96,42	82,45	96,13	97,21	87,50
outex 2	76,36	77,17	78,93	77,17*	77,96	78,52	77,96*
outex 10	99,08	99,60	99,62	98,78	99,27	99,72	99,11
outex 11	98,54	98,54	99,10	98,09	97,52	99,21	98,76
outex 12	98,77	99,37	99,45	98,92	99,26	99,64	99,26
brodatz A	83,71	95,03	97,13	93,65	95,59	97,44	92,93
brodatz B	99,42	99,75	99,92	99,34	99,59	99,92	99,50
brodatz C	55,12	56,82	58,79	30,92	57,53	57,26	57,53*
povprečje	89,47	91,10	92,07	86,18	91,29	92,07	90,04

terih domenah algoritem ARes značilno izboljša rezultate, pri večini ni značilne razlike, le v enem primeru pa v primerjavi s štirimi enakomernimi resolucijami značilno poslabša rezultat.

Tabela 5.3: Klasifikacijske točnosti algoritma Haar

domena	100% res.	en. 4	ARes 4	SIFT 4	en. 8	ARes 8	SIFT 8
outex 0	94,38	97,50	95,83	94,58	97,50	96,46	95,21
outex 1	91,29	94,51	94,22	88,87	95,60	95,41	92,00
outex 2	75,01	79,99	81,86	69,54	82,96	82,56	72,66
outex 10	85,53	93,17	92,25	87,22	94,93	95,05	90,46
outex 11	93,96	97,19	97,50	95,83	98,33	98,44	96,25
outex 12	88,04	94,52	93,85	89,29	96,40	96,56	93,19
brodatz A	66,01	74,90	78,56	69,67	80,17	82,62	74,32
brodatz B	94,07	96,40	96,31	95,35	97,04	97,04	96,31
brodatz C	64,46	65,22	67,53	65,22*	67,02	67,31	67,02*
povprečje	83,64	88,16	88,66	83,95	89,99	90,16	86,38

V tabeli 5.4 so rezultati algoritma Laws, pri katerih ugotovimo, da pri večini domen v primerjavi z enakomernimi resolucijami algoritem ARes značilno poslabša rezultate, v primerjavi z osnovno resolucijo pa vedno izboljša.

V tabeli 5.5 so rezultati algoritma Gabor, pri katerih ugotovimo, da pri vseh domenah, razen ene, algoritem ARes v primerjavi z enakomernimi resolucijami ne dosega značilno različnih rezultatov. Pri veliki večini domen v primerjavi z osnovno resolucijo, pa dosega boljše klasifikacijske točnosti.

V tabeli 5.6 so rezultati algoritma Image Processor, pri katerih ugotovimo, da pri dobri polovici domen v primerjavi z enakomernimi resolucijami algoritem

Tabela 5.4: Klasifikacijske točnosti algoritma Laws

domena	100% res.	en. 4	ARes 4	SIFT 4	en. 8	ARes 8	SIFT 8
outex 0	93,54	100,00	97,71	99,58	99,79	99,58	99,58
outex 1	93,13	98,20	98,20	96,78	98,53	98,72	97,49
outex 2	88,53	93,55	92,56	91,09	93,98	93,37	92,17
outex 10	85,37	98,17	91,46	95,23	98,84	95,69	96,74
outex 11	94,79	99,48	98,54	99,79	100,00	99,79	99,79
outex 12	83,31	98,27	90,00	96,35	98,96	94,81	97,75
brodatz A	62,89	86,67	84,96	82,47	89,36	88,33	84,96
brodatz B	78,21	94,39	84,54	90,95	96,23	93,99	94,31
brodatz C	66,38	69,18	67,66	69,18*	69,70	68,33	69,70*
povprečje	82,91	93,10	89,51	91,27	93,93	92,51	92,50

Tabela 5.5: Klasifikacijske točnosti algoritma Gabor

domena	100% res.	en. 4	ARes 4	SIFT 4	en. 8	ARes 8	SIFT 8
outex 0	99,58	99,38	99,79	98,54	99,79	99,58	98,75
outex 1	98,53	98,72	98,91	98,06	98,72	98,72	97,78
outex 2	94,79	95,63	95,69	90,13	95,86	95,81	91,40
outex 10	98,06	99,51	99,26	99,24	99,72	99,56	99,49
outex 11	99,58	99,79	99,79	99,48	99,90	100,00	99,58
outex 12	97,44	99,65	99,38	99,33	99,75	99,71	99,60
brodatz A	88,72	89,40	90,43	81,40	90,23	90,82	81,20
brodatz B	91,74	96,64	95,19	94,71	97,91	97,67	96,64
brodatz C	71,73	74,73	74,23	74,73*	75,13	74,51	75,13*
povprečje	93,35	94,83	94,74	92,85	95,22	95,15	93,29

ARes značilno poslabša rezultate, v primerjavi z osnovno resolucijo pa vedno izboljša, podobno kot smo zasledili pri algoritmu Laws.

Tabela 5.7 za lažjo primerjavo rezultatov povzema skupna povprečja doseženih klasifikacijskih točnosti preko uporabljenih domen.

Omenjene značilne razlike med resolucijami in algoritmi so podane v tabeli 5.8.

Za dodatno testiranje uspešnosti algoritma ARes smo izvedli še primerjavo rangov klasifikacijskih točnosti algoritma ArTex na uporabljenih domenah. Primerjava v tabeli 5.9 nam še dodatno potrdi ugotovitev, da algoritem ARes na testiranih domenah dosega boljše rezultate.

Pri primerjavi rangov klasifikacijskih točnosti ostalih algoritmov (tabela 5.10) vidimo, da algoritem ARes pri večini negeometrijskih algoritmov za parametriza-

Tabela 5.6: Klasifikacijske točnosti algoritma Image Processor

domena	100% res.	en. 4	ARes 4	SIFT 4	en. 8	ARes 8	SIFT 8
outex 0	75,83	82,50	81,46	82,71	86,46	85,63	85,83
outex 1	75,43	84,99	84,00	78,60	87,36	87,21	82,62
outex 2	62,61	70,75	68,91	61,98	72,07	70,12	65,95
outex 10	86,41	94,21	90,69	90,44	95,95	93,50	93,08
outex 11	78,85	88,65	85,63	83,96	90,94	89,38	86,88
outex 12	80,17	90,88	85,50	86,94	93,56	89,96	89,69
brodatz A	19,97	57,72	51,91	39,60	65,34	61,38	53,52
brodatz B	96,96	98,88	98,00	97,76	99,12	98,96	99,04
brodatz C	52,40	63,08	63,44	63,08*	64,87	64,20	64,87*
povprečje	69,85	81,29	78,84	76,12	83,96	82,26	80,16

Tabela 5.7: Primerjava povprečij klasifikacijske točnosti algoritmov

algoritem	100% res.	en. 4	ARes 4	<i>SIFT 4</i> *	en. 8	ARes 8	<i>SIFT 8</i> *
ArTex	89,47	91,10	92,07	86,18	91,29	92,07	90,04
Gabor	93,35	94,83	94,74	92,85	95,22	95,15	93,29
Haar	83,64	88,16	88,66	83,95	89,99	90,16	86,38
Laws	82,91	93,10	89,51	91,27	93,93	92,51	92,50
IP	69,85	81,29	78,84	76,12	83,96	82,26	80,16
povprečje	83,84	89,70	88,76	86,07	90,88	90,43	88,47

cijo tekstur ne dosega boljših rezultatov v primerjavi z enakomerno porazdeljenim prostorom resolucij, dosega pa boljše v primerjavi z osnovno resolucijo in resolucijami, ki jih predlaga algoritem SIFT. Rezultati doseženih rangov klasifikacijskih točnosti ostalih algoritmov po posameznih uporabljenih domenah so navedeni v dodatku.

Po priporočilu v Demšar (2006a) smo signifikantnost algoritma ARes ugotavljali s Friedmanovim testom (Friedman, 1940). Pri stopnji zaupanja $\alpha < 0,05$ Friedmanov test pokaže, da se rangi signifikantno razlikujejo, zato nadaljujemo z Bonferroni-Dunn (Dunn, 1961) testom, s katerim ugotavljamo v katerih primerih se uporaba resolucij dobljenih z algoritmom ARes signifikantno razlikuje od klasifikacijskih rezultatov pri uporabi drugih resolucij. Slednji test pokaže, da je pri $\alpha < 0,05$ kritična razdalja med rangi 2,686, pri $\alpha < 0,10$ pa 2,438. Iz tega lahko zaključimo, da algoritem ARes v kombinaciji z algoritmom ArTex pri štirih resolucijah (glej tabelo 5.11) signifikantno izboljša rezultate v primerjavi z vsemi primerjanimi resolucijami, razen v enem primeru. Pri osmih resolucijah (glej tabelo 5.12) pa signifikantno izboljša rezultate v vseh primerih. Pri ostalih

Tabela 5.8: Statistična ocena algoritma ARes pri različnih algoritmihi za parametrizacijo z ne-parametričnim Friedmanovim testom ($\alpha = 0,05$). Številke predstavljajo število domen, pri katerih je ARes: “značilno boljši / ni značilne razlike / značilno slabši”

Alg. ARes v komb. z	št.res. n	en. n	100% res.
ArTex	4	3/6/0	5/4/0
	8	5/4/0	6/3/0
Gabor	4	0/7/1	6/3/0
	8	0/9/0	7/1/0
Haar	4	3/5/1	8/1/0
	8	1/8/0	8/1/0
IP	4	0/3/6	9/0/0
	8	0/5/4	9/0/0
Laws	4	0/2/7	9/0/0
	8	0/5/4	9/0/0
<i>vsota</i>		12/54/23	76/13/0

Tabela 5.9: Primerjava rangov klasifikacijskih točnosti algoritma ArTex pri uporabi različnih resolucij

domena	100% res.	en. 4	ARes 4	<i>SIFT</i> 4*	en. 8	ARes 8	<i>SIFT</i> 8*
brodatz A	7	4	2	5	3	1	6
brodatz B	6	3	1,5	7	4	1,5	5
brodatz C	6	5	1	7	2,5	4	2,5
outex 0	3	5	2	7	4	1	6
outex 1	4	5	2	7	3	1	6
outex 10	6	3	2	7	4	1	5
outex 11	4,5	4,5	2	6	7	1	3
outex 12	7	3	2	6	4,5	1	4,5
outex 2	7	5,5	1	5,5	3,5	2	3,5
<i>povpr. rang</i>	5,61	4,22	1,72	6,39	3,94	1,50	4,61

algoritmih za parametrizacijo tekstur algoritem ARes večinoma dosega značilno boljše rezultate le v primerjavi z osnovno resolucijo in algoritmom SIFT. Razdalje med rangi in statistične značilnosti so prikazane v tabelah 5.11 in 5.12.

Tabela 5.10: Primerjava povprečnih rangov klasifikacijskih točnosti uporabljenih algoritmov pri uporabi različnih resolucij

algoritem	100% res.	en. 4	ARes 4	<i>SIFT 4*</i>	en. 8	ARes 8	<i>SIFT 8*</i>
ArTex	5,61	4,22	1,72	6,39	3,94	1,50	4,61
Gabor	5,78	3,61	3,56	6,06	1,67	2,39	4,94
Haar	6,67	3,44	3,39	6,17	1,83	1,61	4,89
IP	6,89	3,28	4,89	5,72	1,06	2,67	3,50
Laws	7,00	2,67	5,33	4,72	1,28	3,44	3,56
povpr.rang	6,39	3,44	3,78	5,81	1,96	2,32	4,30

Tabela 5.11: Razdalje med povprečnimi rangi klasifikacijskih točnosti algoritmov ob uporabi algoritma ARes pri štirih resolucijah in ostalimi izbirami resolucij. (značilne razlike pri $\alpha = 0,05$ so obarvane rdeče, pri $\alpha = 0,10$ pa oranžno)

algoritem	100% res.	en. 4	SIFT 4	en. 8	SIFT 8
ArTex	3,89	2,50	4,67	2,22	2,89
Gabor	2,22	0,06	2,50	-1,89	1,39
Haar	3,28	0,06	2,78	-1,56	1,50
IP	2,00	-1,61	0,83	-3,83	-1,39
Laws	1,67	-2,67	-0,61	-4,06	-1,78

Tabela 5.12: Razdalje med povprečnimi rangi klasifikacijskih točnosti algoritmov ob uporabi algoritma ARes pri osmih resolucijah in ostalimi izbirami resolucij. (značilne razlike pri $\alpha = 0,05$ so obarvane rdeče, pri $\alpha = 0,10$ pa oranžno)

algoritem	100% res.	en. 4	SIFT 4	en. 8	SIFT 8
ArTex	4,11	2,72	4,89	2,44	3,11
Gabor	3,39	1,22	3,67	-0,72	2,56
Haar	5,06	1,83	4,56	0,22	3,28
IP	4,22	0,61	3,06	-1,61	0,83
Laws	3,56	-0,78	1,28	-2,17	0,11

5.4 Enakomerna ali eksponentna porazdelitev resolucij

V tem razdelku preverjamo hipotezo, da je običajno pri algoritmu ArTex bolje uporabiti enakomerno razdelitev N resolucij $\frac{100 \cdot i}{N}$, kot pa eksponentno obliko $\frac{100}{2^{i-1}}$. Ugotovili smo, da pri uporabi treh resolucij ($N = 3$) ne dobimo značilnih razlik, pri uporabi štirih ($N = 4$) pa že dobimo značilno boljše rezultate z enakomernimi resolucijami za vse uporabljene domene, razen ene (Brodatz B), za katero se značilno ne razlikujejo. Tukaj smo lahko uporabili le pet domen, saj samo te vsebujejo dovolj velike slike (128×128 točk), da še lahko uporabimo tako majhne resolucije, kot jih dobimo pri eksponentnih resolucijah ($\frac{100}{2^{(4-1)}} = 12.5\%$, $128 \times 128 \rightarrow 16 \times 16$). Tudi tu smo za test uporabili Friedmanov ne-parametrični test, pri stopnji zaupanja $\alpha = 0,05$.

Tabela 5.13: Primerjava osnovne, enakomerne in eksponentne izbire resolucij (*eksp. 4* - eksponentne in *en. 4* - enakomerne resolucije). V vseh domenah razen Brodatz B dosega *en. 4* signifikantno boljši rezultat kot *eksp. 4*.

Algoritem	100% res.	en. 4	eksp. 4
outex 0	99,02	98,77	97,30
outex 10	99,08	99,60	98,89
outex 11	98,54	98,54	96,17
outex 12	98,77	99,37	98,84
brodatz B	99,42	99,75	99,34
povprečje	98,97	99,21	98,11

Poglavje 6

Aplikacije večresolucijske parametrizacije na scintigramih

Predlaganim metodam želimo dodati tudi neko otipljivo uporabno vrednost, saj nam sam uspeh na generičnih bazah podatkov ne zadošča.

6.1 Scintigrafija srčne mišice

Z vpeljavo metod strojnega učenja v proces diagnostike ishemične bolezni srca, ki omogoča učinkovito in objektivno obravnavo vseh podatkov, ki so na voljo, lahko dosežemo racionalizacijo celotnega diagnostičnega postopka (uporabo samo res potrebnih diagnostičnih faz).

Rezultati kažejo, da je kvaliteta atributov, pridobljenih z večresolucijsko parametrizacijo scintigramov, primerljiva s parametri, ki jih določijo zdravniki specialisti. Če pa združimo attribute večresolucijske parametrizacije in parametre običajnega postopka diagnosticiranja zdravnikov, dobimo značilno boljše rezultate v primerjavi s klinično prakso.

Kot je bilo že omenjeno v razdelku 2.2.2, je bilo od 288 pacientov uporabljenih 10 za potrebe večresolucijskega pristopa in določanja povezovalnih pravil z algoritmom ArTex. Ti pacienti niso sodelovali v nadaljnji študiji. Pri ostalih 278 pacientih smo vseh devet scintigramov predhodno parametrizirali s tremi resolucijami, ki jih je predlagal algoritem ARes. Te so bile $1.0\times$, $0.7\times$ in $0.5\times$ originalne resolucije. Za vsako sliko smo uporabili 100 najboljših atributov, ki smo jih izbrali z metodo ReliefF (Kira in Rendell, 1992; Robnik-Šikonja in Kononenko, 2003), kar nam je dalo $100 \times 9 \times 3 = 2700$ atributov (parametrov).

Ker je tudi to število atributov preveliko za večino učinkovitih metod stroj-

Tabela 6.1: Rezultati diagnosticiranja zdravnikov specialistov v primerjavi s klasičnimi algoritmi, ki so izpeljani le iz originalnih atributov, ki so jih predlagali zdravniki specialiti. Rezultati, ki se značilno ($\alpha < 0.05$) razlikujejo od kliničnih, so odebeljeni (boljši zeleno in slabši rdeče)

	Originalni atributi		
	točnost	specifičnost	senzitivnost
Zdravniki	64,00	71,10	55,80
Naivni Bayes	68,34	69,80	67,10
SVM	65,10	62,80	67,10
C4.5	57,19	53,50	60,40

nega učenja, smo tudi te attribute ocenili z algoritmom ReliefF, tako da smo za vse slike skupaj vzeli le 200 najbolj ocenjenih atributov.

Pri testiranju klasičnimi točnostmi smo uporabili diskretizacijo atributov z metodo Fayyad-Irani (Fayyad, 1993) in tri znane klasifikatorje: naivni Bayes, metodo podpornih vektorjev in C4.5 odločitveno drevo. Eksperimente smo izvajali z dvema paketoma za strojno učenje, Weka (Witten in Frank, 1999) in Orange (Demšar in sod., 2004).

Pri testiranju smo uporabili 10-kratno prečno preverjanje. Za oznako razreda smo uporabili dvorazredne rezultate koronarografije. Eksperimentalne rezultate smo primerjali s točnostjo, specifičnostjo in senzitivnostjo diagnosticiranja zdravnikov specialistov, ki so za diagnosticiranje uporabljali le scintigrame (tabela 6.1). Rezultati diagnoz zdravnikov specialistov iz klinične prakse so bili preverjeni še z natančnim slepim ocenjevanjem drugega zdravnika specialista.

Za eksperimente s strojnim učenjem smo uporabili tri različne kombinacije vhodnih podatkov. Najprej smo uporabili samo attribute, ki so jih določili radiologi (tabela 6.1), nato smo uporabili samo attribute, ki jih je generiral algoritem ArTex s pomočjo večresolucijske parametrizacije (tabela 6.2), na zadnje pa smo uporabili še kombinacijo obeh množic atributov (tabela 6.3). V nadaljevanju smo ponovili te teste še s predhodnim izborom atributov večresolucijske parametrizacije (200 najboljših atributov) z algoritmom ReliefF (tabela 6.4). Statistične teste specifičnosti razlik na točnosti smo naredili z McNemarovim testom (Demšar, 2006b).

Iz tabele 6.1 lahko vidimo, da so uporabljeni klasifikatorji na osnovi osnovnih atributov na približno enaki ravni kot zdravniki. Naivni Bayesov klasifikator doseže celo značilno boljše rezultate in malo slabšo senzitivnost, kot zdravniki. Odločitveno drevo C4.5 pa doseže značilno slabšo klasičnisko točnost. Za zdravnike je v resnici bolj pomembna izboljšava specifičnosti, kot senzitivnosti,

Tabela 6.2: Eksperimentalni rezultati klasifikatorjev brez večeresolucijskega pristopa. Rezultati, ki se značilno ($\alpha < 0.05$) razlikujejo od kliničnih, so odebeljeni (boljši zeleno in slabši rdeče)

	Vsi slikovni in osnovni atributi			200 najboljših slikovnih in osnovni atributi		
	točnost	specifičnost	senzitivnost	točnost	specifičnost	senzitivnost
Naivni						
Bayes	69,5	63,5	76,6	69,9	63,5	77,3
SVM	62,7	66,2	58,6	65,9	66,9	64,8
C4.5	63,7	68,2	58,6	65,7	66,9	64,1

Tabela 6.3: Eksperimentalni rezultati klasifikatorjev z uporabo vseh razpoložljivih atributov in večeresolucijsko parametrizacijo. Rezultati, ki se značilno ($\alpha < 0.05$) razlikujejo od kliničnih, so odebeljeni (boljši zeleno in slabši rdeče)

	Vsi slikovni in osnovni atributi			Vsi slikovni atributi		
	točnost	specifičnost	senzitivnost	točnost	specifičnost	senzitivnost
Naivni						
Bayes	70,50	69,10	72,10	70,14	68,50	72,10
SVM	69,40	69,80	69,10	61,15	58,10	63,80
C4.5	65,10	60,50	69,10	59,71	63,80	55,00

saj povečana specifičnost zmanjšuje število nepotrebnih nadaljnjih diagnostičnih testov, kar posledično skrajša čakalno dobo za resnično bolne paciente.

Za primerjavo uspešnosti večeresolucijskega pristopa najprej pogledajmo rezultate s parametri, ki jih izračuna osnovni algoritem ArTex, brez večeresolucijskega pristopa. Rezultati so prikazani v tabeli 6.2. Tukaj ugotovimo, da klasifikacijska točnost doseže značilno boljše rezultate, tako pri uporabi vseh slikovnih in osnovnih atributov, kot tudi pri uporabi le 200 najboljših med njimi po metodi ReliefF. Pri obeh naborih atributov dosežemo tudi značilno boljšo senzitivnost in značilno slabšo specifičnost. Značilnih razlik med obema naboroma ne ugotovimo, kar pomeni da izbira atributov ni ničesar spremenila.

Sedaj pa pogledajmo rezultate z uporabo večeresolucijske parametrizacije. Iz tabele 6.3 lahko vidimo, da imajo klasifikatorji nekaj težav z obravnavo velikega števila vhodnih atributov (2700) s samo 278 učnimi primeri. To lahko povzroči preveliko prilagajanje učnim primerom, kar lahko zmanjša diagnostično moč klasifikatorjem. Samo naivni Bayes je pri uporabi vseh 2700 atributov značilno boljši od zdravnikov. Ko pa poleg slikovnih atributov uporabimo še osnovne attribute, ki so jih določili zdravniki, dobimo v vseh primerih boljše rezultate, v dveh od treh primerov celo značilno boljše od zdravnikov.

Iz tabele 6.4 lahko vidimo, da klasifikatorji, za razliko od ne-resolucijske obravnave, veliko pridobijo z zmanjšanjem atributnega prostora. V vseh primerih lahko opazimo značilno izboljšanje rezultatov glede na rezultate zdravnikov speciali-

Tabela 6.4: Eksperimentalni rezultati klasifikatorjev na parametriziranih scintigramih, opisanih le z 200 najboljšimi atributi večresolucijske parametrizacije. Rezultati, ki se značilno ($\alpha < 0.05$) razlikujejo od kliničnih, so odebeljeni (boljši zeleno in slabši rdeče)

	200 najboljših slikovnih in osnovni atributi			200 najboljših slikovnih atributov		
	točnost	specifičnost	senzitivnost	točnost	specifičnost	senzitivnost
Naivni Bayes	74,10	79,80	69,10	72,30	79,80	65,80
SVM	69,42	65,90	72,50	70,14	72,90	67,80
C4.5	67,62	63,60	71,10	68,34	63,60	72,50

Tabela 6.5: Primerjava klasifikacijske točnosti naivnega Bayesa na parametriziranih scintigramih, opisanih le z 200 najboljšimi atributi večresolucijske parametrizacije in opisanih s pomočjo ostalih algoritmov za parametrizacijo slik.

algoritem	100% res.	en. 3	ARes 3	SIFT 3
ArTex	70,65	72,31	74,10	71,94
Haar	66,66	69,10	68,76	67,97
Laws	60,39	66,66	67,71	69,80
Gabor	57,30	55,22	55,62	56,96
IP	65,32	67,50	68,12	67,82

stov. Še posebej vzpodbudni so rezultati naivnega Bayesa, ki doseže značilno izboljšanje tako klasifikacijske točnosti kot tudi izboljšanje senzitivnosti in specifičnosti.

V tabeli 6.5 so podani rezultati dobljeni z ostalimi algoritmi, ki pa so vsi značilno slabši od algoritma ArTex v kombinaciji z algoritmom ARes. Tudi resolucije, določene z algoritmom SIFT, ne prispevajo značilnih izboljšav.

Doseženi eksperimentalni rezultati kažejo, da lahko z uporabo dodatnih slikovnih atributov povečamo število zanesljivih pozitivnih in negativnih diagnoz za skoraj deset odstotkov. Hkrati pa dosežemo nižje število nepravilnih diagnoz kot zdravniki v klinični praksi.

6.2 Scintigrafija okostja

Ko določimo vse referenčne točke, z njihovo pomočjo izrežemo dele okostja, ki jih nato diagnosticiramo. Najprej moramo te izrezane slike parametrizirati, kar smo poskusili s petimi različnimi algoritmi (ArTex, Haarova in Gaborjeva transformacija ter Image processor), ki so opisani v razdelku 5.1. Najboljše rezultate smo dobili z uporabo algoritma ArTex v kombinaciji z algoritmom ARes.

Algoritem ArTex, opisan v razdelku 4.2, opiše slike z več sto avtomatsko generiranimi atributi. Na teh atributih smo uporabili metodo naivnega Bayes-a, ki je implementiran znotraj paketa Weka (Witten in Frank, 1999). Pri testiranju nismo ločevali vseh vrst patologij, saj so posamezne vrste zelo redko zastopane (manj kot pet) in tako ne moremo izvajati zanesljivih statističnih testov. Za študijo diagnosticiranja vseh patologij bi potrebovali nekaj tisoč scintigrafij, kar pa časovno in tehnično ni bilo izvedljivo. Zato smo se omejili le na dvorazredni problem (sum na patologijo in brez patologije). Pri 19% slik zdravniki specialisti niso ugotovili patoloških dogajanj ali artefaktov, kar je bilo prisotno pri ostalih 81% scintigramov.

Zdravniki radiologi so pregledali in diagnostično ocenili le 268 slik pacientov od skupno uporabljenih 467. Zato smo za testiranje z metodami strojnega učenja uporabili le teh 268 slik. Scintigrame smo s postopkom, opisanim v razdelku 3.1, razdelili na 10 regij, ki smo jih ločeno obravnavali kot binarne klasifikacijske probleme. Za sestavo učne in testne množice smo uporabili vse patološko ocenjene regije posameznih območij in naključno izbrane nepatološke regije, v razmerju 30% patoloških in 70% nepatoloških. Rezultate klasifikacijske točnosti smo ocenili z 10-kratnim prečnim preverjanjem, ki so prikazani v tabeli 6.6, njihova senzitivnost in specifičnost pa v tabeli 6.7. Algoritem SIFT dosega značilno slabše rezultate, pa tudi ni bilo mogoče narediti testov pri vseh predlaganih resolucijah, tako da so rezultati algoritma SIFT dopolnjeni na enak način, kot je opisano v razdelku 5.3. To pomeni, da v primeru, ko je algoritem SIFT predlagal resolucijo, ki je premajhna, da bi jo algoritem za parametrizacijo lahko upošteval, namesto rezultata z uporabo algoritma SIFT, uporabimo kar rezultat ustrezne enakomerne resolucije (namesto *SIFT 4* je uporabljen *en. 4*), s čimer omogočimo primerjavo skupnih povprečij.

Tabela 6.6: Dosežene klasifikacijske točnosti dvorazrednih problemov pri različnih resolucijah. Za parametrizacijo je uporabljen algoritem ArTex, razširjen z J-mero

del okostja	100% res.	en. 4	ARes 4	SIFT 4
Cervikalni del hrbtenice	76,00	72,00	75,00	72,00*
Stopala	84,44	84,44	85,56	83,33
Lobanja posteriorno	70,00	80,00	80,00	75,00
Kolčnica	88,48	90,30	90,30	88,41
Lumbalni del hrbtenice	69,10	74,42	71,41	71,47
Stegnenica in golenica	84,15	84,15	86,41	82,35
Medenica	88,57	91,43	94,29	90,00
Rebra	94,31	95,42	95,42	95,42*
Lopatica	95,00	95,00	95,00	90,00
Torakalni del hrbtenice	71,67	71,67	81,12	71,67*
<i>povprečje</i>	82,17	83,88	85,45	81,97*

V tabeli specifičnosti in senzitivnosti 6.7 vidimo, da ArTex v kombinaciji z ARes-om doseže značilno boljšo senzitivnost in drugo najboljšo specifičnost, ki se značilno ne razlikuje.

Tabela 6.7: Specifičnost in senzitivnost klasifikacije z algoritmom ArTex

del okostja	100% res.		en. 4		ARes 4	
	sp.%	sen.%	sp.%	sen.%	sp.%	sen.%
Cervikalni del hrbtenice	88,89	42,86	88,89	28,57	86,10	56,08
Stopala	93,75	61,54	93,75	61,54	93,75	65,38
Lobanja posteriorno	84,62	0,00	100,00	0,00	100,00	0,00
Kolčnica	91,36	81,82	93,83	81,82	93,83	81,82
Lumbalni del hrbtenice	80,68	43,90	88,64	43,90	81,82	48,78
Stegnenica in golenica	91,20	67,31	95,20	57,69	94,40	73,08
Medenica	94,00	75,00	96,00	80,00	98,00	85,00
Rebra	95,16	92,00	98,39	88,00	98,39	88,00
Lopatica	100,00	81,82	100,00	81,82	100,00	81,82
Torakalni del hrbtenice	82,93	43,75	85,37	37,50	85,37	61,20
<i>povprečje</i>	90,26	59,00	94,01	56,08	93,16	64,12

V tabeli 6.8 so primerjani rezultati algoritma ArTex z ostalimi algoritmi za parametrizacijo slik. Najboljše rezultate dosežemo z uporabo algoritma ArTex za parametrizacijo tekstur, kar smo preverili s Friedmanovim ne-parametričnim testom. Test nam pokaže, da je algoritem ArTex v kombinaciji z ARes-om statistično značilno ($\alpha = 0,05$) boljši od algoritmov Laws, Haar in Gabor, ni pa značilno boljši od Image procesorja.

Friedmanov ne-parametrični test nam tudi pokaže značilno ($\alpha = 0,05$) prednost senzitivnosti algoritma ArTex, pred Haarovimi valčki, Lawsovimi in Gaborjevimi filtri, ne pa tudi pred Image procesorjem. Specifičnost algoritma ArTex ni značilno odstopala od nobenega od primerjanih algoritmov.

Tabela 6.8: Dosežene povprečne klasifikacijske točnosti naivnega Bayesa na dvo-razrednih problemih pri različnih resolucijah in različnih algoritmih za parametrizacijo slik

algoritem	100% res.	en. 4	ARes 4	SIFT 4
ArTex (z J-mero)	82,17	83,88	85,45	<i>81,97</i>
ArTex (brez J-mere)	83,25	83,00	84,91	<i>82,63</i>
Gabor	83,61	84,41	84,12	<i>84,12</i>
Haar	80,16	79,80	81,82	<i>81,12</i>
Laws	82,60	83,00	83,39	<i>84,38</i>
IP	81,47	83,59	84,46	<i>82,89</i>

Poglavje 7

Zaključki

7.1 Večresolucijska parametrizacija tekstur

Pri obravnavi večresolucijskega pristopa za parametrizacijo tekstur smo pokazali, da obstaja določena povezava med vsebino slike določene resolucije in kvaliteto parametrizacije, še posebej pri algoritmu ArTex. Vsi testirani algoritmi (geometrijski, transformacijski ali statistični) so dosegli boljše rezultate pri uporabi več resolucij, kar potrjuje ugotovitev, da je pri parametrizaciji slik zelo pomembna tudi izbira resolucij. Za pomoč pri določanju bolj informativnih resolucij smo razvili algoritem ARes, ki dosega značilno boljše rezultate v kombinaciji z ArTex-om tudi v primerjavi z uporabo enakomerno porazdeljenega prostora resolucij. ARes tudi pri drugih algoritmih za parametrizacijo v primerjavi z osnovno resolucijo dosega v veliki večini značilno boljše rezultate, sicer pa vsaj brez značilnih razlik. V primerjavi z enakomernimi resolucijami pa redko poslabša rezultate, v nekaj primerih pa tudi izboljša, v ostalih primerih pa ni značilnih razlik.

Za enakomerno porazdeljen prostor resolucij smo tudi ugotovili, da je boljši od eksponentne oblike resolucij.

Ugotovimo lahko, da je uporaba več kot treh eksponentno razdeljenih resolucij mogoča le v primeru, ko imamo dovolj velike slike. Ostaja pa vprašanje, kako se te resolucije obnašajo pri drugih algoritmih, saj teh testov nismo naredili in ne moremo trditi, da je enakomerna razdelitev vedno boljša izbira.

Vsekakor ne moremo za nek algoritem trditi, da je najboljši, saj smo ugotovili, da je uspešnost algoritma odvisna od več dejavnikov. Ti dejavniki predstavljajo posebnosti domen in željena izboljšanja, bodisi klasifikacijske točnosti, specifičnosti ali senzitivnosti. V našem primeru je npr. algoritem ArTex v kombinaciji z ARes-om na osmih resolucijah dosegel absolutno najboljši rezultat klasifi-

kacije na dveh domenah (brodatz A in B) v primerjavi z vsemi ostalimi algoritmi in kombinacijami resolucij.

Zanimivo je tudi da je za isti parametrizacijski algoritem potrebno izbrati različne metode strojnega učenja za klasifikacijo za različne domene. V naši študiji smo ugotovili podoben fenomen, kot že nekateri avtorji (Kononenko, 2001), da se pri več medicinskih domenah bolje izkaže uporaba naivnega Bayes-a, kot pa metode podpornih vektorjev in ostalih. Pri obeh obravnavanih medicinskih domenah se je algoritem ArTex v kombinaciji z ARes-om in naivnim Bayes-om izkazal za značilno boljšega od vseh ostalih primerjanih algoritmov. Iz teh rezultatov pa ne gre sklepati na neko pravilo, saj so običajni atributi pri medicinskih domenah določeni s strani zdravnikov specialistov, ki naj bi po večini bili medsebojno neodvisni, naši atributi pa so sestavljeni iz zaupanj in podpor povezovalnih pravil, za katere pa neodvisnosti ne moremo pričakovati.

7.2 Scintigrafija srčne mišice

Predstavljeni postopek diagnosticiranja srčne mišice z uporabo večresolucijskega pristopa, opisom scintigrafije s povezovalnimi pravili in uporabo metod strojnega učenja predstavlja novo alternativo kliničnemu diagnosticiranju. Rezultati kažejo, da kvaliteta parametrov, pridobljenih z večresolucijskim pristopom parametrizacije, dosega enake ali boljše rezultate kot ročno določeni atributi zdravnikov specialistov. S kombinacijo obeh vrst parametrov, večresolucijskih in kliničnih, pa dobimo v primerjavi s klinično prakso precej boljše rezultate.

Čeprav je opisana študija še v začetnih korakih, lahko ugotovimo, da nudi zelo dobre rezultate. Pokazali smo, da lahko z uporabo večresolucijske parametrizacije z algoritmom ArTex in metodami strojnega učenja uspešno sestavimo ekspertni sistem za oceno scintigrafij, ki lahko izboljša sekvenčni diagnostični postopek ishemične bolezni srca. Metode strojnega učenja lahko pripomorejo manj izkušenim zdravnikom pri ocenjevanju scintigramov in tako izboljšajo njihovo učinkovitost v smislu točnosti, senzitivnosti in specifičnosti.

Praktična uporaba predlaganega postopka se lahko odraža v dveh izboljšavah. Zaradi večje specifičnosti testov dosežemo manjše število pacientov, ki bi morali na dodatno preiskavo koronarne angiografije, ki je invazivna in zato tudi nevarna. Zaradi večje senzitivnosti, pa lahko tudi prihranimo denar in skrajšamo čakalne dobe resnično bolnih pacientov.

Najpomembnejši rezultat predlaganega postopka pa je verjetno v izboljšavi napovedne moči sekvenčnega diagnostičnega postopka. Skoraj deset odstotno izboljšanje diagnosticiranja nepatoloških in patoloških pacientov, ki jim ne bi bilo potrebno še naprej na zahtevnejše in dražje teste, predstavlja občutno racionalizacijo in izboljšavo obstoječega postopka, brez nevarnosti nepravilnega diagnosti-

ciranja večjega števila pacientov, kot v obstoječi praksi. Vseeno pa je potrebno omeniti, da so rezultati naše študije pridobljeni na zelo omejeni populaciji in tako niso splošno uporabni za normalno populacijo, ki prihaja na Kliniko za nuklearno medicino.

7.3 Scintigrafija okostja

Predlagana metoda za iskanje referenčnih točk dosega dobre rezultate za vse opazovane sklope kosti. Malo slabše rezultate dobimo pri detekciji reber in okončin. Rezultati kažejo, da je najtežje iskati kosti reber, saj niso bila pravilno detektirana na 15% scintigrafij. Te napake večinoma pomenijo, da je algoritem zgrešil eno ali dve rebri, ali pa rebru ni sledil čisto do konca. Pri rebrih je problematična neizrazita sled kosti na scintigramih, ki ji zaradi raznolikosti okostij težko sledimo. Okončine pa so na veliko scintigramih vidne le delno, bodisi zaradi delnega slikanja, ali pa zaradi omejitev zornega kota gama kamere. Okončine niso bile pravilno zaznane predvsem na slikah, kjer se je kost nadlahtnica videla le delno. Zaradi možnih napak detekcije referenčnih točk sistem "Skelet" omogoča ročne premike najdenih točk in tako omogoči nadaljnji postopek segmentacije in odkrivanja patologij. Med obravnavanimi scintigrami smo imeli 18% delnih okostij, ki so lahko posledica amputacij, ali pa le delnega slikanja pacienta. Algoritem za segmentacijo je prilagojen tudi za iskanje referenčnih točk na delnih okostjih, tako da rezultati segmentacije delnih okostij ne odstopajo od rezultatov celotnih okostij.

Predstavljeni ekspertni sistem za obdelavo scintigrafije celotnega okostja predstavlja korak naprej v avtomatizaciji rutinskih kliničnih postopkov. Razviti postopek se lahko uporabi kot dodatna pomoč radiologu, saj lahko opozori na morebitno spregledane patologije ali pa celo odpre kakšen nov pogled na možno oceno stanja. Pri segmentaciji smo uvedli uporabo enoznačno določljivih referenčnih točk, do katerih pridemo s kombinacijo prilagojenih standardnih orodij računalniškega vida. Z razvito kombinacijo dosežemo zadovoljivo točnost detekcije referenčnih točk na scintigrafskih slikah, ki imajo značilno nizko ločljivost. Zaradi nizke ločljivosti v primerjavi z rentgenskim slikanjem, prisotnosti artefaktov in patologij mora postopek uporabiti vso možno predznanje o človeški anatomiji v smislu lokacije posameznih kosti in prostorskih razmerjih med njimi, da lahko doseže zadovoljive rezultate. Opisani postopek dosega dobre rezultate in v nadaljevanju pričakujemo, da bodo študije s segmentacijo na osnovi referenčnih točk dale še bolj točne in zanesljivejše rezultate v primerjavi s študijami, ki segmentacije ne uporabljajo.

Avtomatsko določene referenčne točke z uporabo triangulacijske mreže omogočajo prileganje poljubnih oblik na posamezne scintigrame, kar je po našem

mnenju najboljši način izreza območij na scintigramih, saj je posameznim kostem zaradi neizrazite oblike težko slediti. Sistem tako omogoča nadaljnje študije posameznih delov okostja z drugimi algoritmi (npr. poljubnimi algoritmi za parametrizacijo ali novimi algoritmi, ki jih želimo testirati), saj lahko izlušči poljuben del okostja, ki ga preučujemo.

Opisani pristop s segmentacijo odpira nov pogled na avtomatsko diagnosticiranje scintigramov celotnega okostja, saj omogoča poleg iskanja točkovnih lezij še dodatne možnosti:

- točnejše in zanesljivejše opazovanje simetrije posameznih kosti pri opazovanju strukturnih nepravilnosti - mnoge nepravilnosti lahko opazimo le z opazovanjem razlik v dolžini, obsegu ali ukrivljenosti kosti,
- detekcijo lezij z nizkim izsevom ali manjšo aktivnostjo zaradi umetnih vsadkov (npr. umetni kolk),
- možnost primerjanja skupnega izseva med različnimi deli okostja, ki lahko odločujoče vpliva na oceno patologije,
- zahtevnejše ocene patologij, ki se določajo na osnovi kombinacije patologij večih delov okostja (npr. sklepni artritis),
- bolj specifično avtomatsko generiranje poročil o stopnji in lokaciji patologije v pisani besedi za izobraževalne potrebe študentov ali radiologov specializantov.

O sami kvaliteti diagnosticiranja scintigramov še težko govorimo, saj bi za objektivno oceno uspešnosti potrebovali še več primerov in več zdravnikov, ki bi patologije ocenili, sicer se lahko zgodi, da se s strojnim učenjem preveč prilagodimo enemu zdravniku, ki pa ni nujno popolnoma zanesljiv (Kukar, 2001).

Opisani postopek strojnega učenja je še v začetni fazi razvoja, vendar so rezultati vzpodbudni in uporaba večrazrednega strojnega učenja v nadaljnjem delu lahko približa sistem uporabi v klinični praksi.

7.4 Nadaljnje delo

Predstavljeni algoritmi in njihove aplikacije omogočajo še veliko raziskovanja v smeri izboljšav, prav tako pa bi jih lahko uporabili še v mnogih realnih domenah. Pri večeresolucijskem pristopu bi lahko analizirali še drugačne metode za iskanje primernih resolucij, kot so npr. entropija slike, variacije Laplaceovih filtrov ali gostota izstopajočih vrhov. Omenjene metode bi lahko raziskali ločeno za posamezne razrede algoritmov za parametrizacijo tekstur.

Ugotavljali bi lahko tudi uspešnosti različnih metod strojnega učenja pri različnih razredih parametrizacijskih algoritmov in postopkih za določanje primernih resolucij. Pri parametrizacijskih algoritmih z velikim številom atributov, bi bilo primerno tudi analizirati vpliv različnih metod za izbiro podmnožic atributov in vpliv različnih metod diskretizacije atributov.

Ugotovitve predlaganega nadaljnjega dela bi morda lahko pripomogle k razvoju novih algoritmov za parametrizacijo tekstur.

Pri uporabljenih medicinskih domenah je prav tako potrebnega še veliko dela za njihovo uspešno vpeljavo v klinično prakso, kar pa je povezano predvsem z interesom in pripravljenostjo zdravnikov specialistov. Za širšo uporabo ekspertnih sistemov za scintigrafijo okostja in srčne mišice je potrebna tudi prilagoditev parametrov predstavitve medicinskega znanja, saj se enaki tipi scintigrafij v različnih državah zaradi različne opreme in klinične prakse razlikujejo.

Literatura

National library of medicine. <http://www.nlm.nih.gov/>.

- P.S.U. Adiga, B.B. Chaudhuri. Region based techniques for segmentation of volumetric histo-pathological images. *Comput. Methods and Programs in Biomed.*, 61(1):23–47, 2000.
- C. Anderson, S. Crawford-Hines. Semi-automated boundary tracing of medical images for three-dimensional model development. URL citeseer.nj.nec.com/5784.html. Colorado State University, Fort Collins, 1998.
- R. Bajcsy, S. Kovačič. Multiresolution elastic matching. *Computer vision, graphics and image processing*, 46:1–21, 1989.
- E. Bardinet, L.D. Cohen, N. Ayache. Tracking and motion analysis of the left ventricle with deformable superquadrics. *Medical Image Analysis*, 1(2):129–149, 1996.
- V. Barra. Robust segmentation and analysis of dna microarray spots using an adaptative split and merge algorithm. *Comput. Methods and Programs in Biomed.*, 81(2):174–180, 2006.
- A. Benneke. Konzeption und Realisierung Eines Semi-Automatischen Befundungssystems in Java und Anbindung an ein Formalisiertes Begriffssystem am Beispiel der Skelett-Szintigraphie. Diplom arbeit, Institut für Medizinische Informatik, Universität Hildesheim, mentor Prof. Dr. D.P. Pretschner, 1997.
- R. Bernard. *Razgradnja medicinskih slik s statističnimi modeli slikovnih vzorcev anatomije*. PhD thesis, Univerza v Ljubljani, Fakulteta za elektrotehniko, 2001.
- J. Bernauer. Zur Semantischen Rekonstruktion Medizinischer Begriffssysteme. Habilitationsschrift, Institut für Medizinische Informatik, Univ. Hildesheim, 1995.
- K.C. Berning. *Zur Automatischen Befundung und Interpretation von Ganzkörper-Skelettszintigrammen*. PhD thesis, Institut für Medizinische Informatik, Universität Hildesheim, 1996.

- M. Bevk. *Izpeljava značilk tekstur z uporabo povezovalnih pravil*. PhD thesis, Univeza v Ljubljani, Fakulteta za Računalništvo in Informatiko, 2005.
- M. Bevk, I. Kononenko. A statistical approach to texture description of medical images: A preliminary study. V *The Nineteenth International Conference on Machine Learning ICML'02 Workshops*, Sydney, 2002.
- M. Bevk, I. Kononenko. Towards symbolic mining of images with association rules : preliminary results on textures. *Intelligent data analysis*, 10(4):379–393, 2006.
- H. Blum. *Models for the Perception of Speech and Visual Form*. MIT Press, 1967.
- P. Brodatz. *Textures - A Photographic Album for Artists and Designers*. Reinhold, Dover, New York, 1966.
- M.E. Brummer, R.M. Mersereau, R.L. Eisner, R.R.J. Lewine. Automatic detection of brain contours in mri data sets. V *IEEE Transactions on Medical Imaging*, volume 12, str. 153–166, 1993.
- N. Budihna, M. Milčinski, B. Bratanič, uredniki. *Nuklearna medicina v pediatriji*. Ljubljana: Sledi, 1994. monografija.
- J.M. Carstensen. Cooccurrence feature performance in texture classification. V *The 8th Scandinavian Conference on Image Analysis, Tromsø, Norway*, str. 831–838, 5 1993. URL <http://www.imm.dtu.dk/pubdb/p.php?985>.
- C.K. Chui. *An Introduction to Wavelets*. Academic Press, San Diego, 1992.
- M.L. Comer, E.J. Delp. Segmentation of textured images using a multiresolution gaussian autoregressive model. *Image Processing, IEEE Transactions on image processing*, 8 (3):408–420, 3 1999.
- T.F. Cootes, A. Hill, C.J. Taylor, J. Haslam. The use of active shape models for locating structures in medical images. V *IPMI*, str. 33–47, 1993. URL citeseer.nj.nec.com/cootes94use.html.
- N. Cristianini, J. Shawe-Taylor. *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. Cambridge University Press, 2000.
- J. Demšar. Statistical comparisons of classifiers over multiple data sets. *Journal of Machine Learning Research*, 7:1–30, 1 2006a. URL <http://jmlr.csail.mit.edu/papers/v7/demsar06a.html>.
- J. Demšar. Statistical comparisons of classifiers over multiple data sets. *Journal of Machine Learning Research*, 7:1–30, 2006b.
- J. Demšar, B. Zupan, G. Leban. Orange: From experimental machine learning to interactive data mining, white paper, 2004. www.aillab.si/orange.

- J.S. Duncan, N. Ayache. Medical image analysis: Progress over two decades and the challenges ahead. *PAMI*, 22(1):85–106, 1 2000.
- O.J. Dunn. Multiple comparisons among means. *Journal of the American Statistical Association*, 56:52–64, 1961.
- D. Eberly. Information about ellipses. URL <http://www.magic-software.com>. Magic Software, Inc., 12 2003.
- U.M. Fayyad. Multi-interval discretization of continuous-valued attributes for classification learning. V *IJCAI 1993*, str. 1022–1027. Morgan Kaufmann, 1993.
- C. Bastos Rocha Ferreira, D. Leandro Borges. Automated mammogram classification using a multi-resolution pattern recognition approach. *SIBGRAPI01*, 00:76, 2001.
- P.A. Freeborough, N.C. Fox, R.I. Kitney. Interactive algorithms for the segmentation and quantitation of 3-d mri brain scans. *Comput. Methods and Programs in Biomed.*, 53:15–25, 1997.
- M. Friedman. A comparison of alternative tests of significance for the problem of m rankings. *Annals of Mathematical Statistics*, 11:86–92, 1940.
- GeneralElectric. Ectoolbox protocol operator’s guide, 2001.
- S.E. Grigorescu, N. Petkov, P. Kruizinga. Comparison of texture features based on gabor filters. *IEEE Trans. on Image Processing*, 11(10):1160–1167, 2002.
- C. Grošelj. *Sistem nevronske mreže v diagnostiki ishemične bolezni srca*. PhD thesis, Univerza v Ljubljani, Medicinska fakulteta, Ljubljana, 1999.
- C. Grošelj, M. Kukar, J. Fettich, I. Kononenko. Impact of machine learning to the diagnostic certainty of the patient’s group with low coronary artery disease probability. V *Computer-Aided Data Analysis in Medicine*, str. 68–74, Bled, Slovenia, 1997.
- I.B. Gurevich, I.V. Koryabkina. Comparative analysis and classification of features for image models. *Pattern Recognition and Image Analysis*, 16(3):265–297, 7 2006.
- G.M. Haley, B.S. Manjunath. Rotation-invariant texture classification using a complete space-frequency model. *IEEE Tr. Im. Proc.*, 8(2):255–269, 2 1999.
- R.M. Haralick, K. Shanmugam, I. Dinstein. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, 3(11):610–621, 1973.
- T. Heinonen, H. Eskola, P. Dastidar, P. Laarne, J. Malmivuo. Segmentation of T1 MR scans for reconstruction of resistive head models. *Comput. Methods and Programs in Biomed.*, 54(3):173–181, 1997.
- A. Hendler, M. Hershkop. When to Use Bone Scintigraphy. It Can Reveal Things Other Studies Cannot. *Postgraduate Medicine*, 104(5):54–66, 11 1998.

- S. Herlidou, I. Idy-Peretti, R. Grebe, F. Grados, N. Lecuyer, P. Fardellone. Quantitative evaluation of trabecular bone structure by calcaneus mr images texture analysis of healthy volunteers and osteoporotic subjects. V *23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, str. 24–29, Istanbul, 10 2001.
- G. Holmaas, D. Frederiksen, A. Ulvik, S.O. Vingsnes, G. Ostgaard, H. Nordli. Identification of thoracic intervertebral spaces by means of surface anatomy: a magnetic resonance imaging study. *Acta Anaesthesiologica Scandinavica*, 50(3):368–373(6), 2006.
- P.V.C. Hough. Machine analysis of bubble chamber pictures. International Conference on High Energy Accelerators and Instrumentation, CERN, 1959.
- G. Jammal, A. Bijaoui. DeQuant: a Flexible Multiresolution Restoration Framework. *Signal Processing*, 84(7):1049–1069, 7 2004.
- Y. Jin, H.M. Ladak. Software for interactive segmentation of the carotid artery from 3d black blood magnetic resonance images. *Comput. Methods and Programs in Biomed.*, 75(1):31–43, 2004.
- T. Kadir, M. Brady. Scale, saliency and image description. *International Journal of Computer Vision*, 45(2):83–105, 11 2001.
- T. Kapur, W. Eric L. Grimson, W.M. Wells, R. Kikinis. Segmentation of brain tissue from magnetic resonance images. *Medical Image Analysis*, 1(2):109–127, 1996.
- V. Kindratenko. *Development and Application of Image Analysis Techniques for Identification and Classification of Microscopic Particles*. PhD thesis, Universitaire Instelling Antwerpen, Departement Scheikunde, 1997.
- K. Kira, L. Rendell. A practical approach to feature selection. V D. Sleeman, P. Edwards, uredniki, *Proc. Intern. Conf. on Machine Learning*, str. 249–256, Aberdeen, UK, 1992. Morgan Kaufmann.
- I. Kononenko. Machine learning for medical diagnosis: History, state of the art and perspective. *Artificial Intelligence in Medicine*, 23(1):89–109, 2001.
- J. Krivic, F. Solina. Part-level object recognition using superquadrics. *Computer Vision and Image Understanding*, 95(1):105–126, 2004.
- M. Kukar. *Ocenjevanje zanesljivosti klasifikacij in cenovno občutljivo kombiniranje metod strojnega učenja*. PhD thesis, Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, 2001.
- M. Kukar, C. Grošelj. Machine learning in stepwise diagnostic process. V *Joint European Conference on Artificial Intelligence in Medicine and Medical Decision Making*, str. 315–325, Aalborg, Denmark, 1999.

- M. Kukar, I. Kononenko, C. Grošelj, K. Kralj, J. Fettich. Analysing and Improving the Diagnosis of Ischaemic Heart Disease with Machine Learning. *Artificial Intelligence in Medicine*, 16:25–50, 1999.
- M. Kukar, I. Kononenko, T. Silvester. Machine learning in prognosis of the femoral neck fracture recovery. *Artificial Intelligence in Medicine*, 8:431–451, 1996.
- M. Kukar, L. Šajn, C. Grošelj, J. Grošelj. Multi-resolution image parametrization in sequential diagnostics of coronary artery disease. V *Artificial intelligence in medicine : proceedings*. Springer, 2007. v tisku.
- K. Laws. *Textured Image Segmentation*. PhD thesis, University of Southern California, 1 1980.
- D. Lindahl, J. Palmer, J. Pettersson, T. White, A. Lundin, L. Edenbrandt. Scintigraphic diagnosis of coronary artery disease: myocardial bull's-eye images contain the important information. *Clinical Physiology*, 6(18), 1998.
- J. Lötjönen. Construction of patient-specific surface models from mr images: application to bioelectromagnetism. *Comput. Methods and Programs in Biomed.*, 72(2):167–178, 2003.
- D.G. Lowe. Distinctive image features from scale-invariant keypoints. *Int. J. Comput. Vision*, 60(2):91–110, 2004. ISSN 0920-5691.
- S. Mahmoodi, B.S. Sharif, E.G. Chester, J.P. Owen, R.E.J. Lee. Bayesian estimation of growth age using shape and texture descriptors. V *IEEE - Image processing and its applications*, number 465, str. 489–493, 1999. Conference Publication.
- M.N. Maissey, T.K. Natarajan, P.J. Hurley, H.N.Jr Wagner. Validation of a Rapid Computerized Method of Measuring ^{99m}Tc Pertechnetate Uptake for Routine Assessment of Thyroid Structure and Function. *J Clin Endocrinol Metab*, 36:317–322, 1973.
- J. Markwardt. Metastasen-suche in maskierten standardskeletten. *Spektrum, Akademie der Wissenschaften, Berlin*, 90(12), 1990.
- K. Mele. *Vizualno učenje kategorij z lokalnimi deskriptorji*. PhD thesis, Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, 2005.
- A.J. Méndez, P.G. Tahoces, M.J. Lado, M. Souto, J. Correa, J.J. Vidal. Automatic detection of breast border and nipple in digital mammograms. *Comput. Methods and Programs in Biomed.*, 49(3):253–262, 1996.
- K. Mikolajczyk, T. Tuytelaars, C. Schmid, A. Zisserman, J. Matas, F. Schaffalitzky, T. Kadir, L. Van Gool. A comparison of affine region detectors. *International Journal of Computer Vision*, 65(1-2):43–72, 2005.
- H. Moravec. Rover visual obstacle avoidance. V *proceedings of the seventh International Joint Conference on Artificial Intelligence*, str. 785–790, 8 1981.

- V. Müller, J. Steinhagen, M. deWit, H. K. Bohuslavizki. Bone Scintigraphy in Clinical Routine. *Radiol Oncol*, 35(1):21–30, 2001.
- H. Murase, S. Nayar. Visual learning and recognition of 3-d objects from appearance. *IJCV*, 14(1):5–24, 1 1995.
- M. Noguchi, H. Kikuchi, M. Ishibashi, S. Noda. Percentage of the Positive Area of Bone Metastasis is an Independent Predictor of Disease Death in Advanced Prostate Cancer. *British Journal of Cancer*, (88):195–201, 2003.
- T. Ojala, T. Mäenpää, M. Pietikäinen, J. Viertola, J. Kyllönen, S. Huovinen. Outex-new framework for empirical evaluation of texture analysis algorithms. V *ICPR (1)*, str. 701–706, 2002.
- T. Ojala, M. Pietikainen, T. Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7):971–987, 2002. ISSN 0162-8828.
- D.L. Pham, C. Xu, J.L. Prince. Current methods in medical image segmentation. *Annual Review of Biomedical Engineering*, 2:315–337, 2000.
- C.S. Poon, M. Braun, R. Fahrig, A. Ginige, A. Dorrell. Segmentation of medical images using an active contour model incorporating region-based image features. V Robb R. A., urednik, *Visualisation in Biomedical Computing*, number 2359, str. 90–97, Rochester, USA. SPIE., 1994.
- M. Robnik-Šikonja, I. Kononenko. Theoretical and empirical analysis of ReliefF and RReliefF. *Machine Learning*, 53:23–69, 2003.
- R. Rodríguez. A strategy for blood vessels segmentation based on the threshold which combines statistical and scale space filter: application to the study of angiogenesis. *Comput. Methods and Programs in Biomed.*, 82(1):1–9, 2006.
- J.A. Rushing, H.S. Ranganath, T.H. Hinke, S.J. Graves. Using association rules as texture features. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(8):845–858, 2001. ISSN 0162-8828.
- F. Solina, A. Leonardis. Proper scale for modeling visual data. *Image and Vision Computing*, 16(2):89–98, 1998.
- M. Subašić, S. Lončarić, E. Sorantin. Model-based quantitative aaa image analysis using a priori knowledge. *Comput. Methods and Programs in Biomed.*, 80(2):103–114, 2005.
- M. Syn, J. Gosling, R. Prager, L. Berman, J. Crowley. Tracking the inter-frame deformation of structures in 3d ultrasound imaging. V Robb R., urednik, *Visualization in Biomedical Computing*, number 2359, str. 170–179, Rochester, USA. SPIE., 1994.
- J.Y. Boire V. Barra. Segmentation of fat and muscle from mr images of the thigh by a possibilistic clustering algorithm. *Comput. Methods and Programs in Biomed.*, 68(3): 185–193, 2002.

- K. Valkealahti, E. Oja. Reduced multidimensional cooccurrence histograms in texture classification. *PAMI*, 20(1):90–94, 1 1998.
- L. Šajn. Izvorna koda programa, 2007. lkm.fri.uni-lj.si/skelet/skelet.zip.
- L. Šajn, I. Kononenko, J. Fettich, M. Milčinski. Automatic Segmentation of Whole-Body Bone Scintigrams. Technical report, Faculty of Computer and Information Science, University of Ljubljana, 11 2004. URL <http://lkm.fri.uni-lj.si/papers/Skelet.pdf>.
- L. Šajn, I. Kononenko, M. Milčinski. Computerized segmentation and diagnostics of whole-body bone scintigrams. *Computerized Medical Imaging and Graphics*, 2007. (v tisku).
- L. Šajn, M. Kukar, I. Kononenko, M. Milčinski. Automatic segmentation of whole-body bone scintigrams as a preprocessing step for computer assisted diagnostics. V Miksch S., Hunter J., Keravnou E., uredniki, *Artificial intelligence in medicine : proceedings*, str. 361–372. Springer, 2005a.
- L. Šajn, M. Kukar, I. Kononenko, M. Milčinski. Computerized segmentation of whole-body bone scintigrams and its use in automated diagnostics. *Computer Methods and Programs in Biomedicine*, 80(1):47–55, 10 2005b.
- M.G. Weiner, L. Jenicke, V. Mller, H. K. Bohuslavizki. Artifacts and Non-Osseous Uptake in Bone Scintigraphy. Imaging Reports of 20 Cases. *Radiol Oncol*, 35(3):185–91, 2001.
- I.H. Witten, E. Frank. *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*. Morgan Kaufmann, 1999. ISBN 1558605525.
- T.K. Yin, N.T. Chiu. A Computer-Aided Diagnosis for Locating Abnormalities in Bone Scintigraphy by a Fuzzy System With a Three-Step Minimization Approach. *IEEE Transactions on Medical Imaging*, 23(5):639–654, 5 2004.

Dodatek

Rangi generičnih baz podatkov

V tabelah 1-4 so navedeni rezultati doseženih rangov klasifikacijskih točnosti ostalih algoritmov po posameznih uporabljenih domenah. Za posamezne domene lahko opazujemo pri kakšni izbiri resolucije dosežemo boljše rezultate in ugotovimo da se najprimernejša izbira resolucijskega prostora med domenami razlikuje.

Tabela 1: Primerjava rangov klasifikacijskih točnosti algoritma Gabor pri uporabi različnih resolucij

domena	100% res.	en. 4	ARes 4	SIFT 4	en. 8	ARes 8	SIFT 8
brodatz A	5	4	2	6	3	1	7
brodatz B	7	3,5	5	6	1	2	3,5
brodatz C	7	3,5	6	3,5	1,5	5	1,5
outex 0	3,5	5	1,5	7	1,5	3,5	6
outex 1	5	3	1	6	3	3	7
outex 10	7	3	5	6	1	2	4
outex 11	5,5	3,5	3,5	7	2	1	5,5
outex 12	7	3	5	6	1	2	4
outex 2	5	4	3	7	1	2	6
povpr.rang	5,78	3,61	3,56	6,06	1,67	2,39	4,94

Tabela 2: Primerjava rangov klasifikacijskih točnosti algoritma Haar pri uporabi različnih resolucij

domena	100% res.	en. 4	ARes 4	SIFT 4	en. 8	ARes 8	SIFT 8
brodatz A	7	4	3	6	2	1	5
brodatz B	7	3	4,5	6	1,5	1,5	4,5
brodatz C	7	5,5	1	5,5	3,5	2	3,5
outex 0	7	1,5	4	6	1,5	3	5
outex 1	6	3	4	7	1	2	5
outex 10	7	3	4	6	2	1	5
outex 11	7	4	3	6	2	1	5
outex 12	7	3	4	6	2	1	5
outex 2	5	4	3	7	1	2	6
povpr.rang	6,67	3,44	3,39	6,17	1,83	1,61	4,89

Tabela 3: Primerjava rangov klasifikacijskih točnosti algoritma Image Processor pri uporabi različnih resolucij

domena	100% res.	en. 4	ARes 4	SIFT 4	en. 8	ARes 8	SIFT 8
brodatz A	7	3	5	6	1	2	4
brodatz B	7	4	5	6	1	3	2
brodatz C	7	5,5	4	5,5	1,5	3	1,5
outex 0	7	5	6	4	1	3	2
outex 1	7	3	4	6	1	2	5
outex 10	7	2	5	6	1	3	4
outex 11	7	3	5	6	1	2	4
outex 12	7	2	6	5	1	3	4
outex 2	6	2	4	7	1	3	5
povpr.rang	6,89	3,28	4,89	5,72	1,06	2,67	3,50

Tabela 4: Primerjava rangov klasifikacijskih točnosti algoritma Laws pri uporabi različnih resolucij

domena	100% res.	en. 4	ARes 4	SIFT 4	en. 8	ARes 8	SIFT 8
brodatz A	7	3	4,5	6	1	2	4,5
brodatz B	7	2	6	5	1	4	3
brodatz C	7	3,5	6	3,5	1,5	5	1,5
outex 0	7	1	6	4	2	4	4
outex 1	7	3,5	3,5	6	2	1	5
outex 10	7	2	6	5	1	4	3
outex 11	7	5	6	3	1	3	3
outex 12	7	2	6	4	1	5	3
outex 2	7	2	4	6	1	3	5
povpr.rang	7,00	2,67	5,33	4,72	1,28	3,44	3,56

Scintigrafija okostja

V tem razdelku so v tabelah 5-9 predstavljeni še rezultati klasifikacijskih točnosti različnih algoritmov na posameznih delih okostja, ki so povzeti v razdelku 6.2. V tabeli 10 je podan slovar uporabljenih izrazov za kosti in dele okostja.

Na sliki 1 je za lažjo predstavo prikazan še shematični prikaz okostja in slovenskih imen kosti.

Tabela 5: Dosežene klasifikacijske točnosti dvorazrednih problemov pri različnih resolucijah. Za parametrizacijo je uporabljen algoritem ArTex brez J-mere, za klasifikacijo pa naivni Bayes

del okostja	100% res.	en. 4	ARes 4	SIFT 4
Cervikalni del hrbtenice	74,00	74,00	75,00	<i>74,00</i>
Stopala	83,33	75,56	81,11	83,33
Lobanja posteriorno	75,00	80,00	85,00	75,00
Kolčnica	88,56	87,58	91,97	83,94
Lumbalni del hrbtenice	71,35	78,33	74,36	69,87
Stegnenica in golenica	83,01	84,77	88,14	80,72
Medenica	88,57	84,29	88,57	91,43
Rebra	93,06	96,53	90,97	<i>96,53</i>
Lopatica	95,00	90,00	95,00	92,50
Torakalni del hrbtenice	80,67	79,00	79,00	<i>79,00</i>
povprečje	83,25	83,00	84,91	<i>82,63</i>

Tabela 6: Dosežene klasifikacijske točnosti dvorazrednih problemov pri različnih resolucijah. Za parametrizacijo je uporabljen algoritem Gabor, za klasifikacijo pa naivni Bayes

del okostja	100% res.	en. 4	ARes 4	SIFT 4
Cervikalni del hrbtenice	76,00	78,00	81,33	<i>78,00</i>
Stopala	78,67	80,89	82,00	82,00
Lobanja posteriorno	86,67	86,67	86,67	86,67
Kolčnica	85,00	84,17	84,17	83,33
Lumbalni del hrbtenice	75,00	74,12	73,46	74,12
Stegnenica in golenica	85,73	86,29	86,29	86,87
Medenica	85,71	85,71	85,71	85,89
Rebra	96,67	96,78	95,67	<i>96,78</i>
Lopatica	95,50	95,50	93,00	93,00
Torakalni del hrbtenice	71,19	75,95	72,86	74,52
povprečje	83,61	84,41	84,12	<i>84,12</i>

Tabela 7: Dosežene klasifikacijske točnosti dvorazrednih problemov pri različnih resolucijah. Za parametrizacijo je uporabljen algoritem Haar, za klasifikacijo pa naivni Bayes

del okostja	100% res.	en. 4	ARes 4	SIFT 4
Cervikalni del hrbtenice	71,00	67,33	74,33	<i>67,33</i>
Stopala	79,78	78,67	78,67	78,67
Lobanja posteriorno	71,67	76,67	81,67	86,67
Kolčnica	82,50	82,50	81,67	80,00
Lumbalni del hrbtenice	73,46	74,89	75,60	74,23
Stegnenica in golenica	82,51	82,51	85,79	85,79
Medenica	83,21	83,21	81,96	84,64
Rebra	94,78	92,67	94,78	<i>92,67</i>
Lopatica	91,00	91,00	93,50	91,00
Torakalni del hrbtenice	71,67	68,57	70,24	70,24
povprečje	80,16	79,80	81,82	<i>81,12</i>

Tabela 8: Dosežene klasifikacijske točnosti dvorazrednih problemov pri različnih resolucijah. Za parametrizacijo je uporabljen algoritem Laws, za klasifikacijo pa naivni Bayes


del okostja	100% res.	en. 4	ARes 4	SIFT 4
Cervikalni del hrbtenice	77,67	78,00	80,00	<i>78,00</i>
Stopala	77,78	75,67	76,67	77,78
Lobanja posteriorno	86,67	76,67	86,67	86,67
Kolčnica	86,67	90,83	87,50	90,00
Lumbalni del hrbtenice	75,66	76,37	76,37	77,14
Stegnenica in golenica	81,46	83,60	81,43	85,20
Medenica	83,04	85,71	84,29	88,39
Rebra	94,56	96,67	96,78	<i>96,67</i>
Lopatica	93,00	95,50	93,00	93,00
Torakalni del hrbtenice	69,52	70,95	71,19	70,95
povprečje	82,60	83,00	83,39	<i>84,38</i>

Tabela 9: Dosežene klasifikacijske točnosti dvorazrednih problemov pri različnih resolucijah. Za parametrizacijo je uporabljen algoritem Image Processor, za klasifikacijo pa naivni Bayes

del okostja	100% res.	en. 4	ARes 4	SIFT 4
Cervikalni del hrbtenice	65,00	75,33	78,00	<i>75,33</i>
Stopala	81,89	81,89	80,78	82,00
Lobanja posteriorno	86,67	86,67	86,67	78,33
Kolčnica	83,33	83,33	82,50	83,33
Lumbalni del hrbtenice	70,49	70,44	71,21	69,67
Stegnenica in golenica	87,37	87,37	87,37	87,37
Medenica	80,54	83,04	84,46	83,04
Rebra	100,00	100,00	100,00	<i>100,00</i>
Lopatica	95,50	95,50	95,50	95,50
Torakalni del hrbtenice	63,86	72,38	78,10	74,29
povprečje	81,47	83,59	84,46	<i>82,89</i>

Tabela 10: Slovar uporabljenih izrazov za kosti in dele okostja

Slovensko	Angleško / Latinsko
cervikalni del hrbtenice	cervical spine
stopala	feet
lobanja posteriorno	skull posterior
kolčnica	ilium bone
lumbalni del hrbtenice	lumbal spine
stegnenica in golenica	femur and tibia
medenica	pelvic region
rebra	ribs
lopatica	scapula
torakalni del hrbtenice	thoracic spine
sramnica	pubis
nadlahtnica	humerus
križnica	sacrum



Slika 1: Shematični prikaz skeleta in slovenskih imen kosti