

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ
ÚSTAV TELEKOMUNIKACÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF TELECOMMUNICATIONS

SEGMENTACE ULTRAZVUKOVÝCH SNÍMKŮ ZA ÚČELEM
DETEKCE ARTERIÁLNÍ STĚNY A MĚŘENÍ VRSTEV INTIMA-MEDIA

DIZERTAČNÍ PRÁCE
DOCTORAL THESIS

AUTOR PRÁCE
AUTHOR

Ing. RADEK BENEŠ

BRNO 2013



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ
ÚSTAV TELEKOMUNIKACÍ**

**FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF TELECOMMUNICATIONS**

SEGMENTACE ULTRAZVUKOVÝCH SNÍMKŮ ZA ÚČELEM DETEKCE ARTERIÁLNÍ STĚNY A MĚŘENÍ VRSTEV INTIMA-MEDIA

**THE SEGMENTATION OF ULTRASOUND IMAGES FOR ARTERY WALL DETECTION AND
INTIMA-MEDIA THICKNESS MEASUREMENT**

DOKTORSKÁ PRÁCE
DOCTORAL THESIS

AUTOR PRÁCE
AUTHOR

ING. RADEK BENEŠ

VEDOUCÍ PRÁCE
SUPERVISOR

ING. KAMIL ŘÍHA, PH.D

BRNO 2013

ABSTRAKT

Tato práce je zaměřena na problematiku měření šířky vrstev intima a media (intima media thickness), která se z medicínského pohledu ukazuje jako vhodná pro ohodnocení rizik plynoucích z různých onemocnění kardiovaskulárního systému. Šířka intima media je měřena v ultrazvukovém obraze, který zobrazuje arterii carotis communis v jejím podélném řezu, ve kterém jsou patrné měřené vrstvy intima a media. Práce zahrnuje teoretickou analýzu problematiky z technického i medicínského pohledu a shrnuje současný stav zkoumané problematiky. V práci je popsán návrh nového plně automatického systému pro měření šířky vrstev intima media. Navržený systém zahrnuje i robustní proceduru lokalizace arterie a je tak schopen bez počáteční inicializace či úpravy vstupních dat zpracovávat přímo zdrojová data získaná ultrazvukovou stanicí v B-módu.

KLÍČOVÁ SLOVA

Arterie, Intima, Media, Ultrazvukový obraz, RANSAC, SVM, Klasifikace, Lokalizace arterie

ABSTRACT

The thesis focuses on the measurement of intima media thickness, which seems to be a significant marker of the risk of cardiovascular events. Intima media thickness is measured in ultrasound image displaying the common carotid artery in its longitudinal section. In the longitudinal section the intima and media layers are visible. Thesis is discussing both technical and medical background and summarizes state of the art in this field. The main part of the thesis describes the novel automatic system for measurement of intima media thickness. Proposed system includes also robust method for artery localization and therefore is able to process raw B-mode data from ultrasound station without any initialization or manual preprocessing.

KEYWORDS

Artery, Intima, Media, Ultrasound image, RANSAC, SVM classification, Artery localization

BENEŠ, Radek *Segmentace ultrazvukových snímků za účelem detekce arteriální stěny a měření vrstev intima-media*: dizertační práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací, 2013. 114 s. Vedoucí práce byl Ing. Kamil Říha, Ph.D.

PROHLÁŠENÍ

Prohlašuji, že svou doktorskou práci na téma „Segmentace ultrazvukových snímků za účelem detekce arteriální stěny a měření vrstev intima-media“ jsem vypracoval samostatně pod vedením vedoucího doktorské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené doktorské práce dále prohlašuji, že v souvislosti s vytvořením této doktorské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

(podpis autora)

PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu diplomové práce panu Ing. Kamilu Říhovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci. Dále bych chtěl poděkovat své rodině za podporu během celého studia.

Brno

.....

(podpis autora)

OBSAH

1	Úvod	11
1.1	Měření IMT	14
1.2	Anatomické vlastnosti CCA	15
1.3	Vyšetřovací protokol IMT	16
1.4	Automatický systém pro měření IMT	17
1.5	Ultrazvukový obraz a jevy komplikující jeho zpracování	17
1.5.1	Artefakty v ultrazvukovém obraze	18
1.5.2	Šum v ultrazvukových obrazech	19
2	Cíl dizertační práce	21
2.1	Zkoumané metody pro dosažení vytyčených cílů	22
3	Současný stav poznání	23
3.1	Předzpracování obrazu	23
3.1.1	Redukce šumu v ultrazvukových obrazech	23
3.1.2	Normalizace jasu obrazu	30
3.2	Lokalizace arterie a její stěny	30
3.2.1	Lokalizace arterie založená na analýze gradientu	32
3.2.2	Lokalizace arterie založená na lokální statistice	33
3.2.3	Lokalizace arterie založená na podobnostní analýze	34
3.2.4	Lokalizace arterie založená na Houghově transformaci	35
3.2.5	Automaticky navržená metoda lokalizace arterie	35
3.3	Identifikace vrstev na tepenné stěně a měření IMT	39
3.3.1	Metody založené na aktivních konturách	41
3.3.2	Metody založené na dynamickém programování	46
3.3.3	Ostatní segmentační metody	49
3.3.4	Statistické zpracování změřených hodnot IMT podél arterie	50
4	Navržené řešení	51
4.1	Databáze obrazů arterie	51
4.1.1	Rozšíření databáze obrazů pro účely lokalizace arterie	52
4.1.2	Rozšíření databáze obrazů pro účely identifikace vrstev na povrchu arterie	52
4.2	Redukce šumu s využitím vlnkové transformace	53
4.2.1	Princip nalezení nejvhodnějších parametrů metody	53
4.3	Lokalizace arterie a její stěny	56
4.3.1	Extrakce lokálních texturních příznaků	57

4.3.2	SVM klasifikátor	58
4.3.3	Modifikovaný RANSAC algoritmus	63
4.3.4	Blok analýzy gradientu	68
4.3.5	Následné zpracování prvotních tepenných bodů	69
4.4	Identifikace vrstev na povrchu tepenné stěny a měření IMT	70
4.4.1	Identifikace míst vhodných pro měření IMT	70
4.4.2	Identifikace LI a MA rozhraní	78
4.4.3	Měření hodnoty IMT	78
5	Dosažené výsledky	80
5.1	Redukce šumu s využitím vlnkové transformace	80
5.1.1	Experimentální nastavení parametrů metody redukce šumu . .	80
5.2	Lokalizace arterie a její stěny	81
5.2.1	Porovnání SVM klasifikátoru s lineárním a nelineárním jádrem	81
5.2.2	Trénování SVM klasifikátoru a výběr nejvhodnějších příznaků	83
5.2.3	Výsledná úspěšnost SVM klasifikátoru	85
5.2.4	Úspěšnost hrubé lokalizace	85
5.2.5	Testování odolnosti metody založené na RANSAC algoritmu .	86
5.2.6	Výsledná úspěšnost přesné lokalizace tepenné stěny	89
5.3	Identifikace vrstev na povrchu tepenné stěny a měření IMT	89
5.3.1	Vyhodnocení střední absolutní chyby měření IMT	89
5.3.2	Analýza směrodatných odchylek chyb	92
6	Závěr	95
	Literatura	98
	Seznam symbolů, veličin a zkratk	109
A	Obsah CD	113

SEZNAM OBRÁZKŮ

1.1	Ultrazvukový obraz (a) podélného a (b) příčného řezu krkavicí (CCA).	14
1.2	Ultrazvukový obraz podélného řezu krkavicí (CCA) a detail tepenné stěny.	14
1.3	Blokové schéma systému pro automatické měření IMT.	18
1.4	Ultrazvukový obraz obsahující šum typu speckle.	19
3.1	Principiální zobrazení tvrdého (vlevo) respektive měkkého (vpravo) prahování. Tečkovaná křivka – originální signál, modrá křivka – po aplikaci prahovací metody.	28
3.2	Principiální zobrazení poloměkkého prahování (vlevo) respektive nezáporné garoty (vpravo). Tečkovaná křivka – originální signál, modrá křivka – po aplikaci prahovací metody.	28
3.3	Blokový diagram metody redukce šumu s využitím fúze obrazu. . . .	28
3.4	Obraz arterie v podélném směru (nahore) a příslušná projekce intenzity v podélném směru arterie (dole). Převzato z[72].	33
3.5	Řešení navržené pomocí GPDesignru – první experiment.	37
3.6	Řešení navržené pomocí GPDesignru – druhý experiment.	40
3.7	Rozdíl mezi TDP a DDP: (a) oblast měření IMT, (b) výsledek při použití TDP, (c) výsledek při využití DDP. Převzato z[88].	49
4.1	Blokové schéma systému pro automatické měření IMT s detailním rozkreslením dílčích bloků.	51
4.2	Ukázka struktury trénovacích dat: (a) originální obraz, (b) maska definovaná pro trénovací a testovací účely.	53
4.3	Princip výpočtu strmosti hrany.	55
4.4	Blokový diagram navržené metody lokalizace tepny a její stěny. . . .	57
4.5	Rozdělení separabilních dat: (vlevo) bez optimalizace polohy nadroviny, (vpravo) s optimalizací tak, aby od nejbližších krajních bodů byla nadrovina stejně vzdálena.	59
4.6	Proces mapování lineárně neseperabilních dat pomocí mapovací funkce tak, aby data byla separovatelná.	60
4.7	Ukázka principu lokalizace arterie: (a) originální obraz, (b) červeně jsou vyznačeny body klasifikovány jako body uvnitř arterie (jsou patrné chybné klasifikace), (c) zobrazení bodů po redukci odlehlých bodů, (d) výsledná aproximace arterie polynomiální křivkou.	62
4.8	Proložení polynomiální křivky třemi body.	65
4.9	Demonstrace měření vzdálenosti bodu od křivky. Na spodním obrázku je schematicky ukázáno vynesení vzdálenostní funkce a lokalizace jejího minima v bodu $\mathbf{x}_m$	66

4.10	Aproximace polynomiální křivky více než třemi body.	67
4.11	Konstrukce přímk kolmých na hrubou lokalizaci, na kterých je analyzován gradient (sada bílých přímek). Červeně jsou vyznačeny tzv. prvotní tepenné body. Žlutá (čárkovaná) křivka představuje hrubou lokalizaci.	68
4.12	Ukázka proložení prvotních tepenných bodů. (a) Fialové body zobrazují prvotní tepenné body. Žlutě je naznačena jejich interpolace metodou nejmenších čtverců. (b) Zelené body zobrazují aproximaci po aplikaci RANSAC metody, tzn. aproximaci provedené pouze z inlierů.	69
4.13	Blokový diagram navrženého algoritmu pro měření IMT.	70
4.14	Ukázka získání intenzitního profilu (zvýrazněno na příkladu červené přímky) kolmo k modelu arterie (žlutá čárkovaná křivka).	71
4.15	Ukázka situace kdy ne všechny místa podél arterie jsou vhodné pro měření IMT. V tomto ukázkovém snímku jsou vrstvy patrné pouze v levé části obrazu.	72
4.16	Ukázka tříkrokového procesu výběru vhodných míst pro měření IMT. V prvním kroku jsou červeně naznačeny body odebrané kvůli nízkému kontrastu. V druhém kroku jsou žlutě naznačeny body odebrané kvůli nedostatečně výraznému profilu. Ve třetím kroku jsou modře naznačeny body odebrané kvůli nedostatečné délce clusteru a zeleně je označen bod, který byl opětovně přidán (propojuje dva významné segmenty).	73
4.17	Ukázka výběru míst podél arterie a měření IMT. (a) Vstupní obraz, (b) místa podél arterie, kde je dostatečný gradient, (c) místa podél arterie, kde je patrná struktura vrstev, (d) nalezené segmenty po postprocesingu, (e) identifikované LI a MA rozhraní, (f) detailní zobrazení.	74
4.18	Typický profil arteriální stěny s naznačeným principem měření kontrastu.	77
4.19	Pokročilejší analýza intenzitního profilu (zaměřena na analýzu přítomnosti intima-media rozhraní).	77
4.20	Princip lokalizace rozhraní LI a rozhraní MA.	78
5.1	Vývoj fitness funkce nejlepšího chromozomu pro Daubechies rodinu vlnek (a) respektive pro Symlet rodinu vlnek (b)	82
5.2	Vývoj fitness funkce (RMSE klasifikátoru) v průběhu generací.	84
5.3	Statistické vlastnosti populace v průběhu evoluce.	84
5.4	Ukázka přidávání bodů náhodně (a), respektive do clusterů (b).	87
5.5	Závislost pravděpodobnosti selhání RANSAC metody na přidávání náhodných bodů.	88

5.6	Závislost pravděpodobnosti selhání RANSAC metody na přidávání clusterů náhodných bodů.	88
5.7	Lokalizační chyby měřené v 10 místech podél arterie v 50 obrazech testovací sady.	90
5.8	Střední lokalizační chyby v jednotlivých obrazech (zprůměrováno 10 měření v každém obraze).	90
5.9	Statistické vyjádření lokalizačních chyb v jednotlivých obrazech. . . .	91
5.10	Histogram zobrazující distribuci absolutních chyb.	93
5.11	Box plot zobrazující střední chyby.	94
5.12	Box plot porovnávající variabilitu směrodatných odchylek mezi měření provedeným operátorem a navrženým algoritmem.	94

SEZNAM TABULEK

3.1	Parametry genetického programování pro návrh metody lokalizace arterie v obraze.	38
3.2	Výsledky navržené metody lokalizace arterie v obraze.	38
3.3	Parametry genetického programování pro návrh metody lokalizace arterie ve videosekvenci.	39
3.4	Výsledky navržené metody lokalizace arterie ve videosekvenci.	40
4.1	Zvolené nastavení genetického algoritmu.	56
4.2	Shrnutí nastavení evolučního algoritmu pro hledání nejvhodnějších příznaků pro SVM.	61
5.1	Nejvhodnější nastavení nalezené evolučním algoritmem pro různé rodiny vlnek.	80
5.2	Porovnání metody založené na vlnkové transformaci s ostatními metodami.	81
5.3	Matice záměn pro standardní klasifikátor SVM.	83
5.4	Matice záměn pro klasifikátor SVM s radiálním jádrem.	83
5.5	Sada příznaků automaticky zvolených evolučním algoritmem.	85
5.6	Pravděpodobnost selhání RANSAC metody při přidávání náhodných bodů.	87
5.7	Pravděpodobnost selhání RANSAC metody při přidávání clusterů náhodných bodů.	87
5.8	Shrnutí výsledků lokalizace arteriální stěny.	89
5.9	Shrnutí výsledků přesnosti identifikace vrstev na povrchu arterie.	92

1 ÚVOD

Struktura lékařských vyšetření se v průběhu posledních desítek let výrazně proměnila. V dnešní době jsou mnohem častěji využívány neinvazivní techniky medicínského zobrazení, které umožňují lékařům analyzovat strukturu orgánů či tkání bez nutnosti provedení invazivního zákroku. Nárůst počtu takových vyšetření s sebou přináší i značný nárůst počtu obrazů, které musí lékař po provedeném vyšetření důsledně vyhodnotit. V průběhu některých vyšetření jsou nasnímány desítky až stovky obrazů (např. vyšetření počítačovou tomografií (CT), snímání ultrazvukové (UZ) sekvence obrazů), v průběhu jiných vyšetření je pořízen pouze jeden obraz, který ale musí být velmi složitě manuálně analyzován (např. detekce dysfagie[1], měření šířky intima media vrstev[2]). Při některých vyšetřeních již není v silách vyšetřujícího lékaře, aby takové množství obrazových dat manuálně zpracoval a vyhodnotil, a proto je vhodné pro některé dílčí úkony využít výpočetní techniku a specializované algoritmy (*computer aided diagnosis* – CAD). Specializované algoritmy nemají za cíl plně zastoupit lékaře při stanovování diagnózy, pouze mají usnadnit jeho práci. Algoritmy mohou například zvýraznit podezřelé regiony při hledání nádorových onemocnění, automaticky měřit obsah/objem tkání, rychlost pohybu tkání, či jen provést předzpracování obrazu (odstranit artefakty z obrazu apod.).

Automatizace některých úkonů v průběhu lékařského vyšetření popřípadě v průběhu následné analýzy pořízených dat vede k efektivnějšímu využívání lidských zdrojů i diagnostických přístrojů. Rovněž přispívá ke snížení pravděpodobnosti chyb, které by mohly vzniknout v důsledku nepozornosti při manuálním zpracování velkého objemu dat (přehlédnutí markeru, nepřesná lokalizace apod.). Pokud pomineme nepřesnosti způsobené nepozorností, může v průběhu některých vyšetření (například při měření rozměrů či objemů tkání) lidský faktor vnášet i další nepřesnosti, které mohou být způsobeny různou interpretací či subjektivním vnímáním. Polak[3] ve své studii srovnal výsledky měření šířky vrstev na povrchu arterie provedené různými specializovanými lékaři. Měření provedená některými lékaři vykazovala chybu, která při vztažení k nominální hodnotě dosahovala 23 %. Z této studie je zřejmé, že pokud je možné sestavit automatizovaný systém, který bude mít konzistentní výsledky (bude zaručena opakovatelnost algoritmu), přinese automatizace měření nejen zvýšení rychlosti, ale i zvýšení výsledné přesnosti.

Výrazný pokles časové náročnosti u automatizovaných metod by umožnil hromadné zpracování rozsáhlých obrazových databází. Bylo by tak možné automaticky zpracovat veškerá data daného pacienta, a tak kvalitněji popsat vývoj analyzovaného onemocnění. Hromadné zpracování by rovněž přispělo v oblasti vědy, kde by bylo možné na základě rozsáhlejších databází spolehlivěji hledat vzájemné korelace

mezi příznaky a diagnózou.

Jedním z mnoha případů, ve kterých je vhodné celý postup vyšetření automatizovat, je měření statických a dynamických parametrů arterií[4], jako například měření průměru arterie (*lumen diameter* – LD)[5], tuhosti tepenné stěny (*arterial stiffness* – AS)[6], či šířky specifických vrstev (*intima* a *media*) na povrchu tepenné stěny (*intima media thickness* – IMT[2]). Tato práce je zaměřena právě na problematiku měření IMT, jejíž hodnota se z medicínského pohledu jeví jako výrazný marker pro vyhodnocení rizika vzniku onemocnění kardiovaskulárního systému.

Hodnota IMT je v dnešní době hojně využívána pro vyhodnocení zvýšeného rizika vzniku kardiovaskulárních onemocnění (KVO) jako např. cévní mozkové příhody, infarktu myokardu či kardiovaskulární mortality[7]. Přítomnost plaku na stěnách arterií je navíc korelována se vznikem patologických degenerativních změn jako jsou vaskulární demence či Alzheimerova choroba[8, 9].

Měření hodnoty IMT je rutinním vyšetřením, jehož hlavní nevýhodou je značná časová náročnost, která plyne především z nutnosti provést měření manuálně (v dnešní době stále nejčastější způsob měření). Navíc je nutné provést měření opakovaně v mnoha místech podél arterie pro dosažení maximální přesnosti.

Zvýšená hodnota IMT je jedním z časných příznaků aterosklerózy[10, 11, 12]. Ateroskleróza je onemocnění velkých a středních tepen, při kterém se tukové látky, především cholesterol, usazují na stěnách tepen (vznikají aterómy). V důsledku usazování tukových látek na stěně tepny, dochází k jejímu zúžení, snížení její pružnosti a omezení průtoku krve. Omezení průchodu krve pak může způsobit zhoršené zásobení některých orgánů a vést k jejich poškození (ischemie). Ateromy navíc velmi často dystroficky kalcifikují, ve stěnách tepny se objevují tvrdé destičky[12]. Aterom může být odtržen a unášený krví pak může ucpat větev tepny, a tak způsobit embolii. V místě odtržení ateromu může dojít ke vzniku krevní sraženiny (trombus), která dále může zúžit nebo uzavřít tepnu[12].

Podle Světové zdravotnické organizace (World Health Organization – WHO) mají v dnešní době kardiovaskulární onemocnění na svědomí zhruba 30 % všech úmrtí[13]. WHO rovněž odhaduje, že v roce 2040 budou kardiovaskulární onemocnění zodpovědná dokonce za 50 % všech úmrtí, zvláště v důsledku zvyšujícího se podílu v rozvojových zemích a zemích třetího světa. Tento fakt dokazuje potřebnost vyšetřování hodnoty IMT pro zhodnocení rizika kardiovaskulárních onemocnění i u asymptomatických jedinců, a pro vyhodnocení vývoje u již probíhajících onemocnění.


Velké a středně velké tepny, mezi které vyšetřovaná krkavice (*common carotid artery* – CCA, lat. *arteria carotis communis*) spadá, lze v dnešní době kvalitně

vizualizovat mnoha dostupnými technologiemi např. intravaskulární ultrasonografií (IVUS), počítačovou tomografií (CT), magnetickou rezonancí (MRI) koronárních tepen, či B-mode ultrazvukovým zobrazením (B-mode UZ). Mnohé z těchto metod jsou velmi nákladné (CT, MRI) a mají značné nároky na technickou a odbornou vybavenost, jiné metody (IVUS) dokonce vyžadují invazivní zákrok. Nejvhodnější se z dnešního pohledu ukazuje využití B-mode sonografického zobrazení. Ultrazvukové zobrazení je výhodné zvláště pro jeho neinvazivní charakter, rychlost, cenovou dostupnost, bezpečnost pro pacienta, přenositelnost atd. Nevýhodou ultrazvukového zobrazení je poměrně nízká kvalita pořízených obrazů – především nízké rozlišení, malý kontrast analyzovaných oblastí, značné množství šumu a artefaktů v obraze apod.


Arterii lze neinvazivně vizualizovat pomocí vysoko-rozlišujícího (B-mode) ultrazvukového zobrazení. Dle natočení sondy lze arterii vizualizovat v příčném řezu (*transversal scan*) a podélném řezu (*longitudinal scan*) (viz obr. 1.1). V příčném řezu se arterie v ultrazvukovém (UZ) obraze zobrazí jako kruh, případně mírně zploštělá elipsa (viz obr. 1.1 (b)), u které lze měřit jisté statické (např. průměr tepny), či dynamické parametry (např. tuhost tepenné stěny). Pro měření šířky vrstev na povrchu arterie je vhodnější příčný řez arterií (viz obr. 1.1 (a)), kde mají stěny arterie přibližně přímkový charakter a na stěnách jsou patrné vrstvy intima a media (double-line obraz intimy a medie). V ideálním případě jsou stěny arterie zobrazeny rovnoběžně s horizontální rovinou obrazu, mají rovný (přímkový) charakter a jsou dobře patrné i u krajů obrazu. Ve skutečnosti je však běžné, že arterie je mírně prohnutá a málokdy je zachycena horizontálně. Často také u krajů přestávají být patrné vrstvy intima a media popřípadě přestává být patrná celá arterie. Tyto faktory významně komplikují měření arteriálních parametrů a musí být uvažovány již v průběhu návrhu metod měření. Metody tak musí vykazovat velmi dobrou reprodukovatelnost i pro různé geometrické variace arterie.

V podélném zobrazení arterie jsou jednotlivé vrstvy na povrchu arterie poměrně dobře patrné. Šířka vrstev intima a media je nazývána *intima media thickness* (IMT). Hodnota je měřena jako vzdálenost dvou rozhraní, z nichž jedno se nachází mezi vnitřkem tepny (*lumen*) a vrstvou intima (rozhraní *lumen intima* – LI) a druhé mezi vrstvami media a adventicia (rozhraní *media adventicia* – MA) (viz obr. 1.2).

U většiny pacientů je šířka IMT v rozmezí od 0,5 mm do 0,9 mm[14]. Prostorové rozlišení dnešních ultrazvukových stanic se obvykle pohybuje okolo 70 mikrometrů na pixel. Při takovém rozlišení jsou vrstvy na tepenné stěně v B-mode ultrazvukovém obraze tenké 7 až 15 pixelů. Segmentace takto drobných útvarů a jejich následné měření, které je navíc prováděno v poměrně nekvalitních ultrazvukových obrazech, se tak stává velmi komplikovaným úkolem.



Obr. 1.1: Ultrazvukový obraz (a) podélného a (b) příčného řezu krkavicí (CCA).



Obr. 1.2: Ultrazvukový obraz podélného řezu krkavicí (CCA) a detail tepenné stěny.

1.1 Měření IMT

V současné době je šířka IMT nejčastěji měřena vyšetřujícím lékařem manuálně. Lékař manuálně vyznačuje množinu bodů podél celé arterie v obraze. Vyznačuje jak množinu bodů na LI, tak i na MA rozhraní. Statistickým zpracováním vzdáleností vyznačených rozhraní je určena střední hodnota IMT. Manuální vyznačování bodů je značně časově náročné a navíc mohou být výsledky částečně nedůvěryhodné, protože se mohou mírně lišit v závislosti na zkušenostech a znalostech vyšetřujícího lékaře[3]. Další nevýhoda manuálního přístupu spočívá v obtížném zpracování rozsáhlé databáze dat.

Výše zmíněné nevýhody manuální metody, popřípadě nedokonalosti současných poloautomatických metod podněcují vývoj nových metod měření IMT. Většina obdobných prací se však zaměřuje především na precizní segmentaci rozhraní LI a MA. Málokterý projekt uvažuje problematiku jako komplexní celek a navrhuje takové řešení, ve kterém by vlastní segmentaci rozhraní předcházela lokalizace arterie. Tato dizertační práce má za cíl nalézt komplexní řešení, které by zastřešovalo veškeré dílčí kroky (předzpracování obrazu, lokalizace arterie v obraze, identifikace vrstev a měření IMT) a jehož vstupem by byl ultrazvukový (UZ) obraz v B-módu a výstupem hodnota IMT. Výsledné řešení je navrhováno tak, aby celá procedura měření IMT byla provedena plně automaticky. Jelikož se jedná o systém, který by měl být využí-

ván v lékařství, je nutné zaručit jeho maximální přesnost, robustnost a konzistenci výsledků.

1.2 Anatomické vlastnosti CCA

Hodnota IMT je měřena na krkavici, která je v UZ obraze zobrazena v podélném řezu (viz obr. 1.2). Krkavice na levé straně (*carotis communis sinistra*) vychází z oblouku aorty, krkavice na pravé straně (*carotis communis dextra*) vychází z hlavopážního oblouku. Obě karotidy stoupají po stranách krku a ve výšce štítné chrupavky se dělí do dvou tepen – vnitřní a zevní krkavice. Zevní krkavice (*external carotid artery* – ECA) zásobuje krví tvář a externí část hlavy. Vnitřní krkavice (*internal carotid artery* – ICA) zásobuje krví mozek a ostatní interní části lebeční dutiny. Krkavice je největší krční tepnou.

Na tepenné stěně se nachází trojice vrstev – *intima*, *media* a *adventicia*. Intima vrstva je nejbližší středu arterie a je v přímém kontaktu s proudící krví. Na povrchu intima vrstvy (blíže ke středu arterie) se nachází endotel (jednovrstevný plochý epitel), který vystýlá cévní trubici. Tato vrstva je velmi důležitá pro plynulý tok krve, neboť její hladké stěny zabraňují jejímu srážení. Endotel je pokryt elastickými vlákny. Media, tedy vlastní stěna arterie, je tvořena převážně svalovými buňkami s podélnou orientací vláken a kolagenními vlákny (kolagen typu 3). Kolagenních vláken přibývá zvláště se zvyšujícím se věkem[15]. Svalové buňky mají za úkol rozšiřovat a zužovat průsvit cévy. Adventicia vrstva je tvořena z hustého kolagenního vaziva (kolagen typu 1) a elastických vláken, která mají význam pro mechanické vlastnosti cévní stěny. Adventicia vyrovnává veškeré pohyby cévní stěny a fixuje cévu v okolní tkáni díky prorůstání některých vláken do okolí cévy[16, 15].

Šířka vrstev intima a media se u zdravých pacientů pohybuje v rozmezí 0,5 mm – 0,9 mm. Hranice mezi normální a patologickou hodnotou se liší v různých studiích (od 0,75 mm[17] až 1,0 mm[14]). Mnohé studie[18, 19] potvrzují, že nárůst IMT nad hodnotu 0,9 mm – 1,0 mm u zdravé dospělé populace již indikuje výrazný nárůst rizika kardiovaskulárních onemocnění. Šířku tepenné stěny však neovlivňuje jen riziko KVO, ale rovněž další faktory jako např. věk, pohlaví, krevní tlak, diabetes mellitus, kouření[18]. Korelace s věkem je celkem lineární – průměrný roční nárůst šíře IMT je obvykle 0,01 mm/rok až 0,015 mm/rok[20].

Měření šířky vrstev intima media lze provést na blízké (*near wall*) i na vzdálenější (*far wall*) stěně tepny. V praxi je ale prováděno většinou na vzdálenější stěně, pro její kvalitnější zobrazení v ultrazvukovém obraze. Vyšší kvalita zobrazení je zaručena vzrůstajícím charakterem akustické impedance na vzdálenější stěně tepny.

Ultrazvukové paprsky zde procházejí z prostoru méně denzního do prostoru s vyšší denzitou, což zaručí vyšší kvalitu zobrazení. Naopak v oblasti, kde se vyskytuje bližší stěna tepny, jsou v důsledku vysoko-impedančních struktur generována echa, která mohou zastínit nízko-impedanční struktury za nimi[21].

Rozhraní zachycená v ultrazvukovém obraze odpovídají vrstvám tepenné stěny (intima, media, adventicia), ale vzhledem k fyzikálním vlastnostem ultrazvukového signálu je není možné samostatně přesně kvantifikovat. Při průchodu ultrazvukového signálu hyperechogenní vrstvou (např. intima) dochází k nadhodnocení a při průchodu anechogenní vrstvou (např. media) k podhodnocení šíře; Z tohoto důvodu je měřen celý komplex intima-media.

1.3 Vyšetřovací protokol IMT

Měření IMT se v posledních letech formovalo a doposud bylo testováno množství způsobů vyšetřování. Různé studie zkoumaly například to, na kterém segmentu arterie je nejvhodnější šířku IMT měřit – zda na CCA, ICA, či na větvení (bulbus), jiné hodnotily, zda je vhodnější IMT měřit na blízké, či vzdálené stěně. Postupem času se ustálil obecný názor, že na vzdálené stěně CCA je možné opakovaně získat nejkvalitnější sonografický obraz, a proto je pro měření IMT nejvhodnější[22].

Měření je prováděno v ultrazvukovém (B-mode) obraze pořízeném lineární ultrazvukovou sondou. Pacient v průběhu vyšetření leží v uvolněné poloze na zádech, hlavu má nakloněnu na opačnou stranu, než na které je vyšetřovaná arterie. Ve chvíli, kdy je dosaženo optimálního zobrazení CCA v podélném řezu, je pořízen krátký videozáznam, který je většinou analyzován po skončení vyšetření (*off-line analýza*). Měření je provedeno opakovaně pro arterii na levé i pravé straně. Iniciální bod pro nastavení ultrazvukové sondy se nachází v místě počátku rozšiřování CCA do bulbu. Místo bulbu lze snadno nalézt, neboť poblíž něho se tepenné stěny v ultrazvukovém obraze přestávají zobrazovat jako dvojice paralelních přímk, ale začínají se na jedné straně vzájemně oddalovat. Měření je prováděno ve vzdálenosti 1 až 2 cm proximálně od tohoto místa rozšíření[23]. Měření lze provést v průběhu sonografického vyšetření přímo v ultrazvukové stanici, nebo po jeho skončení ve specializovaném programu.

Při manuálním měření přímo v UZ stanici je značnou nevýhodou nesnadné ovládání, které většinou neumožňuje rychle, pohodlně a s požadovanou přesností vyznačit dostatečný počet měřených bodů. Většina UZ stanic není uzpůsobena k tomu, aby obsluha přímo prováděla takto rozsáhlá manuální měření. Rovněž zde může být problém s nízkou přesností vyznačení měřících bodů, kde se může chyba pohybovat i v řádu desetin milimetrů.

Druhá možnost, měření až po skončení obrazového snímání za pomoci specializovaných programů, je preferována pro její přesnost, která navíc může být zvýšena provedením opakovaného měření na každé z karotid (při dodržení měřicího protokolu). Navíc některé specializované algoritmy dokáží částečně automatizovat analýzu obrazů, a tak urychlit vlastní měření. Další výhodou tohoto přístupu je skutečnost, že v době analýzy dat již ultrazvuková stanice může být využívána k dalším měřením.

V našem případě byl měřicí protokol mírně zjednodušen, stejně jak tomu bývá při návrhu obdobných metod. Z hlediska návrhu algoritmů například nebylo zapotřebí provádět měření vícenásobně na každé krkavici, jak je to prováděno v klinické praxi. Upravený měřicí protokol uvažuje off-line analýzu dat, ale v principu mu nic nebrání provádět analýzu on-line (přímo na ultrazvukové stanici).


1.4 Automatický systém pro měření IMT

Systémy (počítačové algoritmy) pro měření IMT jsou velmi komplexní řešení, která musí být schopna automaticky zpracovat vstupní obraz a v něm identifikovat a změřit šířku patřičných tepenných vrstev. Takto komplexní systém je vhodné rozdělit do několika dílčích bloků, které jsou na sobě nezávislé, avšak jejich spojením je dosaženo výsledné funkcionality. V souladu s ostatní literaturou je celý systém rozdělen do tří základních bloků (viz obr. 1.3)

- blok předzpracování obrazu,
- blok lokalizace arterie a její stěny v UZ obraze,
- blok identifikace LI a MA rozhraní na stěně arterie.

1.5 Ultrazvukový obraz a jevy komplikující jeho zpracování

Přestože se technologie ultrazvukového snímání neustále vyvíjí a vzrůstá i kvalita pořízených obrazů, stále se v obrazech setkáváme s množstvím nežádoucích jevů, které komplikují jejich zpracování. Největší komplikace způsobují obrazové artefakty, které mohou v krajním případě dokonce zastínit vyšetřovaný objekt. V jiných případech mohou naopak ultrazvukový obraz znehodnotit falešné obrazce, které nekorespondují s fyziologií vyšetřované tkáně.



Obr. 1.3: Blokové schéma systému pro automatické měření IMT.

1.5.1 Artefakty v ultrazvukovém obraze

Artefakty v UZ obraze mohou být způsobeny fyzikální podstatou ultrazvuku, konstrukcí ultrazvukových přístrojů a sond, popřípadě interakcí ultrazvukových vln a vyšetřované tkáně. Mezi nejčastější artefakty patří např. *reverbase*, při které je v obraze patrné množství pravidelných útvarů (opakovaná echa), která mohou vykreslovat falešné vnitřní struktury. Častý je rovněž vznik tzv. *akustického stínu*, který vznikne v situaci, kdy je velká část ultrazvukových vln odražena, popřípadě pohlcena tkáně. Oblast ležící v akustickém stínu nelze echograficky posoudit. Dalšími artefakty může být *zesílení* či *zeslabení* odrazivosti za jistými strukturami. K zesílení odrazivosti dochází za strukturami s malým útlumem, které výrazně neutlumí akustický signál a následné odrazy se tak zdají intenzivnější, než ve skutečnosti jsou. Naopak ke snížené odrazivosti dochází za ložiskem s větším útlumem. Některé silně odrazivé struktury mohou vytvářet tzv. *zrcadlové artefakty*. Moderní multi-elementové širokopásmové sondy a digitální technologie zpracování obrazu výrazně redukuje výskyty všech druhů artefaktů[24].


Nejčastějším artefaktem, se kterým se setkáme při vyšetřování arterií pacientů, kteří trpí aterosklerózou, bývá akustický stín. Tento artefakt je zapříčiněn akustickými parametry kalcifikovaných tepenných stěn. Na rozhraní mezi tkáně a kalcifikovanými částmi tepenné stěny, které mají značnou akustickou impedanci, je koeficient reflexe přibližně 1. Toto znemožní průchod akustického vlnění produkovaného ultra-

zvukovou sondou do další tkáně, a tím je zapříčiněn vznik zmíněného akustického stínu. V důsledku přítomnosti akustického stínu v okolí tepenné stěny mohou selhávat některé metody segmentace tepenné stěny. Pokud není obraz znehodnocen příliš, ukazují se jako nejodolnější metody založené na aktivních konturách, méně odolné pak metody založené na lokální statistice[25].

Další komplikace při vyšetřování arterií jsou zapříčiněny vlastnostmi proudící krve uvnitř arterie. Červené krvinky mají tendenci penízkovatět (vytvářet struktury o velkém objemu, ale malém povrchu)[26]. Vytvořené struktury se jeví jako hyper-echogenní. Z tohoto důvodu, se arterie vizualizovaná v UZ obrazech někdy jeví světlejší, než by ve skutečnosti měla být (za ideálních podmínek by měla mít úplně černou barvu). Tento jev může způsobit selhání mnohých metod lokalizace arterie. Selhat mohou zvláště metody analyzující pouze jas pixelů, které předpokládají, že lumen arterie je černý a je obklopen dvěma světlými tepennými stěnami. Tento nežádoucí jev lze částečně potlačit již ve fázi předzpracování obrazu využitím normalizace obrazu, popřípadě modifikací vlastního algoritmu lokalizace[25].

Způsob korekce artefaktů je závislý na jejich původu. Artefakty vzniklé na základě fyzikální podstaty fungování ultrazvuku jsou velmi obtížně odstranitelné. Odrazové artefakty mohou být korigovány správným nastavením parametrů ultrazvukové stanice jako např. kompenzace výkonu TGC (*Time Gain Compensation*) a úpravou akustického výkonu. Artefakty způsobené lomem většinou zmizí při úpravě polohy nebo úhlu natočení sondy[24].

Mezi artefakty v UZ obraze se řadí také šum, který se nazývá *speckle noise*[27] a vyznačuje se multiplikativním charakterem. Jeho redukce je velmi důležitou úlohou realizovanou v proceduře předzpracování.



Obr. 1.4: Ultrazvukový obraz obsahující šum typu speckle.

1.5.2 Šum v ultrazvukových obrazech

Šum typu speckle se běžně vyskytuje v obrazech pořízených ultrazvukovými zobrazovacími systémy. Šum vzniká v důsledku interference vln odražených od rozhraní

různých tkání a pro svůj multiplikativní charakter je patrný zvláště v obrazových partiích s vyšší intenzitou (viz obr. 1.4).

1.5.2.1 Matematický model šumu typu speckle

Speckle šum je možné matematicky vyjádřit pomocí multiplikativního modelu[28]

$$I(t) = R(t) \cdot u(t), \quad (1.1)$$

kde $t = (x, y)$ představuje prostorové souřadnice v obraze, $I(t)$ je pořízený obraz, který v sobě obsahuje speckle šum $u(t)$ se střední hodnotou $\bar{u}$ a variancí σ_u^2 . $R(t)$ reprezentuje odrazivost vyšetřovaného regionu. Kaur[29] rozšířil multiplikativní model šumu o aditivní složku $\mu(t)$

$$I(t) = R(t) \cdot u(t) + \mu(t). \quad (1.2)$$

V současné době je problematika redukce šumu intenzivně zkoumána, což je patrné při pohledu na nepřeborné množství nových metod[29, 30, 31, 32, 33, 34, 35]. Všechny metody jsou navrhovány tak, aby odstranily z obrazu maximální množství šumu a zároveň zachovaly všechny důležité obrazové detaily (jako např. významné hrany, jemné objekty apod.). Šum i jemné objekty mají podobný charakter (ve frekvenčním spektru se promítají zvláště ve vysokofrekvenčních složkách), proto jsou požadavky kladené na redukci šumu a zachování jemných objektů naprosto protichůdné. Nalezení vhodné metody redukce šumu a nastavení patřičných parametrů je tak vždy otázkou kompromisu.

2 CÍL DIZERTAČNÍ PRÁCE

Cílem dizertační práce je návrh moderního komplexního systému realizujícího kompletní proceduru měření IMT v ultrazvukových snímcích. Navrhovaný systém bude vykazovat následující rysy.

Navrhovaný systém musí být plně **automatický**. Tato vlastnost systému je velmi důležitá, neboť jen automatický systém je schopen výrazně optimalizovat a zrychlit lékařská vyšetření a rovněž umožní hromadné zpracování rozsáhlých databází. Hromadné zpracování rozsáhlých databází je důležitým aspektem vhodným jak v lékařské praxi (zpracování všech záznamů daného pacienta), tak i v oblasti výzkumu (na základě množství podkladů je snadnější hledání nových korelací). Automatický systém nevyžaduje žádnou interakci s obsluhujícím lékařem v průběhu měření. Systém graficky prezentuje výsledky obsluhujícímu lékaři, který jejich platnost potvrdí, popřípadě inicializuje algoritmus s jiným obrazem.

Navrhovaný systém musí být velmi **přesný**. Jak lokalizační procedura, tak i segmentace rozhraní na tepenné stěně musí být navrženy tak, aby byla zaručena co nejvyšší přesnost celého systému. U části realizující segmentaci rozhraní na tepenné stěně je z tohoto důvodu zaimplementována metoda selekce nejvhodnějších míst podél arterie pro měření IMT.

Navrhovaný systém musí být velmi **robustní**. Lokalizační část navrženého algoritmu i měřicí část musí být schopny pracovat i v případě, kdy není arterie zachycena v obraze ideálně. Musí si poradit s komplikujícími faktory, jako jsou nehorizontální zachycení arterie v UZ obraze, značné prohnutí arterie v obraze, ultrazvukový šum či artefakty.

Navrhovaný systém musí být dostatečně **rychlý**. Tato vlastnost je v současné době důležitá zvláště pro rychlé zpracování velkého množství obrazů. V budoucnu bude důležitá při případné integraci do ultrazvukových stanic, kde bude vyžadována činnost téměř v reálném čase (okamžité měření a následná vizualizace výsledků po přiložení sondy).

Měřicí metoda musí být navržena tak, aby byla **aplikovatelná přímo na originální ultrazvukový obraz** pořízený UZ stanicí, tzn. před vlastním zpracováním obrazu není zapotřebí provádět žádné manuální korekce obrazu (ořez, výběr oblasti zájmu, geometrické transformace, jasové transformace apod.).

Činnost měřicí metody musí být do jisté míry **nezávislá na typu a nastavení** ultrazvukové stanice. Pochopitelně musí být dodržena základní pravidla snímání ultrazvukových obrazů.

2.1 Zkoumané metody pro dosažení vytyčených cílů

Aby bylo dosaženo vytyčených cílů, byly v rámci výzkumu postupně navrhovány či modifikovány metody využitelné v dílčích částech systému dle obr. 1.3 (předzpracování, lokalizace tepenné stěny a identifikace vrstev na tepenné stěně). Na základě vzájemného porovnání navržených metod byla vždy do výsledného systému zvolena nejvhodnější z nich.

V první fázi byly zkoumány metody zaměřené na předzpracování obrazu. Byly navrženy metody, které měly za cíl zdokonalit současná řešení a adaptovat je na ultrazvukové obrazy zobrazující komplex intima-media. Z hlediska redukce šumu byly zkoumány především následující metody

- vylepšená varianta Kuan filtru (*KuanS*)[27, 36] – viz sekce 3.1.1.2,
- využití fúze obrazů pro redukci šumu – viz sekce 3.1.1.4,
- využití vlnkové transformace, jejíž parametry jsou optimalizovány s využitím evolučních přístupů[37, 38] – viz sekce 4.2.

Další výzkum v oblasti předzpracování obrazu byl zaměřen na

- normalizaci intenzity – navržena metoda[39], která vychází z metody[40], avšak normalizace intenzity obrazů je prováděna bez nutnosti interakce s uživatelem,
- stabilizaci videosekvence[41], která by mohla být v budoucnu využitelná v komplexnějším systému pro kontinuální měření arteriálních parametrů v sekvenci obrazů.

Velmi důkladně byla zkoumána problematika lokalizace arterie a její stěny jak v obrazech podélného, tak i příčného řezu CCA. Navržené metody lokalizace CCA v příčném řezu[42, 43, 44] nejsou přímo využitelné z hlediska měření IMT, ale byly zkoumány z hlediska možnosti měření dalších významných arteriálních parametrů, například pro další možnost jejich začlenění do komplexního systému. Hlavní výzkum se však zaměřoval na lokalizaci arterie v jejím podélném řezu[45, 46], kde se nabízelo využití klasifikace pixelů na základě jejich texturálních parametrů a následný post-procesing.

3 SOUČASNÝ STAV POZNÁNÍ

V této kapitole jsou shrnuty metody dnes nejčastěji využívané v systémech pro měření šířky komplexu vrstev intima-media. Kapitola je rozdělena do dílčích sekcí, které korespondují s dělením systémů pro měření IMT (viz obr. 1.3).

3.1 Předzpracování obrazu

Předzpracování obrazu je velmi důležitou procedurou v každém systému obrazového zpracování. Ještě větší význam má tato procedura při zpracování ultrazvukových obrazů, které obsahují značné množství nežádoucích artefaktů a šumu (viz obr. 1.4).

3.1.1 Redukce šumu v ultrazvukových obrazech

Metody redukce šumu obecně mohou zpracovávat jeden nebo více obrazů (např. opakované pozorování určitého objektu). Metody založené na více pozorováních určitého objektu vyžadují statické pozorovací podmínky a nulový nebo minimální pohyb objektů v obraze. Taková statická konfigurace globálně v celém obrazu je při UZ vyšetření obtížně zaručitelná, a proto nejsou tyto metody příliš obvyklé. Při některých vyšetřeních však není zapotřebí analyzovat celý obraz, ale jen jeho část, která je buď statická, nebo v ní lze objekty stabilizovat s využitím kompenzace pohybu (viz např.[47]).

Mnohem obvyklejší jsou metody redukce šumu, které využívají pouze jeden obraz dané scény[28]. Takové metody mohou být založeny např. na adaptivním principu[48, 49], parciálních diferenciálních rovnicích (*partial differential equations* – PDE)[50], zpracování obrazu v různých měřítkách (*multi-scale metody*)[30], využití transformace do jiné domény (vlnková transformace)[51].

3.1.1.1 Adaptivní filtrace

Při adaptivní filtraci jsou parametry filtru adaptivně nastavovány pro různé obrazové oblasti dle parametrů dané oblasti. Pro určení aktuálního nastavení je většinou využito statistické analýzy intenzity pixelů v definovaném okolí aktuálně zpracovávané oblasti (případně pixelu). Nejčastěji jsou v dané oblasti analyzovány momentové parametry jako jsou střední hodnota, směrodatná odchylka, rozptyl apod.[32]. Nastavení filtru se pak v průběhu filtrace daného obrazu upravuje tak, aby co možná nejlépe potlačilo šum a přitom neodstranilo z obrazu detailní objekty.

Mezi nejběžnější adaptivní metody patří *Lee*[48], *Frost*[49], *Kuan*[52] a *MAP filtr*[30].

Kuan filtr vychází z předpokladu, že multiplikativní model šumu může být transformován na signálově závislý aditivní model, na který lze následně aplikovat techniku minimální střední kvadratické chyby (MMSE)[51]. Rovnice redukce šumu (viz rovnice 3.1) popisuje váhování originálního obrazu a rozostřeného obrazu.

$$\hat{R}(t) = I(t) \cdot W(t) + \bar{I}(t) \cdot [1 - W(t)], \quad (3.1)$$

kde $\hat{R}(t)$ je obraz po redukci šumu, $I(t)$ je originální obraz obsahující speckle šum, $\bar{I}(t)$ je průměrná hodnota intenzity uvnitř okna. $W(t)$ je váhovací koeficient, který je definován

$$W(t) = \frac{1 - \frac{c_u^2}{c_I^2(t)}}{1 + c_u^2}, \quad (3.2)$$

kde c_u a $c_I(t)$ jsou variační koeficienty šumu $u(t)$ a obrazu $I(t)$.

$$c_u = \frac{\sigma_u}{\bar{u}}, c_I(t) = \frac{\sigma_I(t)}{\bar{I}(t)}. \quad (3.3)$$

Lee filtr (přesněji *Lee MMSE filtr*) je zjednodušeným případem Kuan filtru, kdy je uvažována lineární aproximace pro multiplikativní model šumu[51]. Váhovací koeficient je definován

$$W(t) = 1 - \frac{c_u^2}{c_I^2(t)}. \quad (3.4)$$

Frost filtr je adaptivním Wienerovým filtrem, jehož princip je založen na konvoluci bodů v definovaném okolí s exponenciální impulsní odezvou m danou rovnicí[51]

$$m = \exp[K c_I(t_0) \cdot |t|], \quad (3.5)$$

kde K je parametr filtru, t_0 reprezentuje polohu zpracovávaného bodu a $|t|$ je vzdálenost od bodu t_0 .

Výše zmíněné základní adaptivní metody byly v posledních letech zdokonaleny[53]. Hlavní myšlenka, kterou představil Lopes a kol.[53] spočívá v klasifikaci obrazových oblastí do některé ze tří kategorií a dle příslušnosti do těchto kategorií jsou ovlivňovány vlastnosti filtrace. Klasifikace oblastí do jednotlivých kategorií se řídí lokálními parametry v obraze. Do první kategorie jsou klasifikovány převážně homogenní oblasti, tzn. oblasti kde je směrodatná odchylka intenzit bodů v okolí nízká. V takových

oblastech je šum redukován s využitím klasické dolní propusti. Do druhé kategorie jsou klasifikovány heterogenní oblasti, ve kterých je využit klasický adaptivní princip (popsaný v Lee nebo Kuan metodě). Do poslední kategorie jsou klasifikovány obrazové oblasti, kde se vyskytují detailní objekty (oblasti s vysokou směrodatnou odchylkou pixelů). Obrazové body z takových oblastí nejsou vůbec ovlivňovány filtrační metodou z důvodu snahy o zachování detailních objektů. Tyto tři případy lze např. pro Lee filtr matematicky formulovat

$$\hat{R}(t) = \begin{cases} \bar{I}(t) & \text{pokud } c_I(t) < c_u \\ I(t) & \text{pokud } c_I(t) > c_{max} \\ I(t) \cdot W(t) + \bar{I}(t) \cdot [1 - W(t)] & \text{v ostatních případech} \end{cases} \quad (3.6)$$

3.1.1.2 Redukce šumu s využitím rozšířeného Kuan filtru (KuanS)

Modifikace Kuan filtru (*KuanS*) vychází z podobné myšlenky klasifikace obrazových oblastí do jedné ze tří tříd, obdobně jak to bylo popsáno u vylepšené varianty Lee filtru v sekci 3.1.1.1. Hlavní modifikace navržené metody spočívá ve filtrování heterogenních oblastí, kde je nově využito sigmoidální funkce pro modifikaci původní váhovací funkce $W(t)$. Modifikovaná váhovací funkce $W'(t)$ je pak vyjádřena rovnicí

$$W'(t) = \frac{1}{1 + \exp(-K \cdot (W(t) - 0,5))}. \quad (3.7)$$

Modifikace váhovacího faktoru zaručuje hladší přechody mezi krajními hodnotami uvnitř heterogenních oblastí (dle nastavení konstanty K). Filtrování homogenních oblastí a významných oblastí je shodné jako ve vylepšených Kuan a Lee metodách.

Při využití KuanS filtru bylo dosaženo kvalitnějších výsledků ve všech měřených parametrech v porovnání se standardním Kuan filtrem[52] i s jeho dříve představenou vylepšenou variantou[53]. Oproti mnohem komplexnějším filtračním metodám má KuanS filtr velmi nízkou časovou náročnost, která je srovnatelná s jednoduchými adaptivními metodami. Komplexní filtrační metody mají vyšší časovou náročnost, a tak mohou být takové metody pro některé aplikace nevhodné. Tato skutečnost potvrzuje význam i jednodušších metod, jako jsou Lee nebo Kuan a potřeba hledání jejich dalších vylepšení.

3.1.1.3 Redukce šumu s využitím vlnkové filtrace

V současné době jsou velmi populární metody založené na vlnkové transformaci[54], které jsou, dle současných porovnávacích studií[51], jedny z nejkvalitnějších. V takových metodách je šum redukován prostřednictvím prahování patřičných koeficientů získaných vlnkovou dekompozicí. Vlastní postup redukce šumu se skládá ze tří kroků

- vstupní obraz je rozložen s využitím vlnkové transformace na sadu koeficientů v různých měřítkách,
- prahování koeficientů dle konkrétní metody a dle zvolených hodnot prahů,
- zpětná rekonstrukce inverzní vlnkovou transformací (rekonstrukce na základě prahovaných koeficientů).

Vlastnosti dané metody jsou závislé na zvolené mateřské vlnce (mateřské vlnky jsou řazeny do tzv. rodin, z nichž nejznámější jsou: *Daubechies*, *Coiflet*, *Symlet*, *Haar*, *Meyer*, *Morlet*, *Mexický klobouk*, *Shannon*, *Gabor*, *Biortogonální spline*), na metodě prahování (tvrdé – obr. 3.1 vlevo, měkké – obr. 3.1 vpravo, poloměkké – obr. 3.2 vlevo, nezáporná garota – obr. 3.2 vpravo, hyperbolické apod.) a na konkrétních hodnotách prahu či prahů.

Pro určení hodnot prahů pro prahování vlnkových koeficientů existuje celá řada metod[32]. Jednou z nejjednodušších je metoda *univerzálního prahu*. Slouží především pro prvotní odhad prahu, neboť její využití vede k výraznému přehlazení obrazů[31]. Hodnota prahu λ je vypočítána dle vztahu

$$\lambda = \sigma \sqrt{2 \log(N)}, \quad (3.8)$$

kde N je délka signálu a σ je směrodatná odchylka šumu.

Metoda *VisuShrink* byla představena Donohem a kol.[55]. Metoda nemůže sloužit pro odstranění šumu typu speckle, neboť uvažuje pouze aditivní model šumu[56]. Odhad směrodatné odchylky šumu je proveden na základě koeficientů vlnkové dekompozice $g_{j-1,k}$

$$\hat{\sigma} = \frac{\text{med}(\{|g_{j-1,k}| : k = 0, 1, 2 \dots 2^{j-1} - 1\})}{0,6745}. \quad (3.9)$$

Pokročilejšími metodami jsou např. *SureShrink* a *BayesShrink*[32]. U metody *SureShrink* je volba prahu založena na kombinaci univerzálního prahu a SURE (*Stein's Unbiased Risk Estimator*) prahu[57]. V této metodě je určen práh t_j pro každou

úroveň dekompozice j . Hodnota prahu t' u *SureShrink* metody je definována jako

$$t' = \min(t, \sigma\sqrt{2\log N}), \quad (3.10)$$

kde t je hodnota univerzálního prahu, σ je směrodatná odchylka šumu a N je délka signálu.

BayesShrink metoda je také charakteristická tím, že je práh určen pro každé pásmo zvlášť uvažováním zobecněného Gaussova rozdělení GGD (Generalized Gaussian Distribution)[58].

Kromě určení hodnoty prahu je rovněž nutné zvolit vhodnou metodu prahování. Nejzákladnějšími metodami jsou tvrdé a měkké prahování. Tvrdé prahování (viz obr. 3.1 vlevo) nastaví veškeré hodnoty nižší nebo rovny prahu na nulovou hodnotu. Ostatní hodnoty zůstanou nezměněny. Tento fakt lze vyjádřit rovnicí

$$\tilde{x} = \begin{cases} 0 & \text{pro } |x| \leq x_{\text{thr}} \\ x & \text{pro } |x| > x_{\text{thr}} \end{cases}, \quad (3.11)$$

kde x je originální hodnota, $\tilde{x}$ je prahovaná hodnota a x_{thr} je hodnota prahu.


Měkké prahování (viz obr 3.1 vpravo), stejně jako tvrdé, nastaví koeficienty menší než práh x_{thr} na nulovou hodnotu. Ostatní hodnoty jsou zvýšeny, respektive poníženy o hodnotu prahu dle toho, zda se jedná o záporné, respektive kladné hodnoty. Tuto skutečnost lze vyjádřit rovnicí

$$\tilde{x} = \begin{cases} 0 & \text{pro } |x| \leq x_{\text{thr}} \\ \text{sign}(x) \cdot (|x| - x_{\text{thr}}) & \text{pro } |x| > x_{\text{thr}} \end{cases}. \quad (3.12)$$


3.1.1.4 Redukce šumu s využitím fúze obrazů

Metoda založená na fúzi obrazů byla navržena přímo pro aplikaci na ultrazvukové videosekvence zachycující arteriální stěnu. Při statických vyšetřeních, mezi která spadá i měření IMT, dostačuje jedno pozorování zkoumaného objektu. Pokud je však zachycena videosekvence a jsou splněny jisté podmínky, lze redundantní obrazy využít k redukci šumu založené na obrazové fúzi. Blokové schéma metody založené na fúzi obrazů je zobrazeno na obr. 3.3.


Metody založené na fúzi obrazů lze použít pouze v případech, kdy analyzované objekty jsou v obraze statické (nepohybují se v čase). Nežádoucí pohyb obrazu může být způsoben pohybem ultrazvukové sondy po vyšetřované oblasti v průběhu



Obr. 3.1: Principiální zobrazení tvrdého (vlevo) respektive měkkého (vpravo) prahování. Tečkovaná křivka – originální signál, modrá křivka – po aplikaci prahovací metody.



Obr. 3.2: Principiální zobrazení poloměkkého prahování (vlevo) respektive nezáporné garoty (vpravo). Tečkovaná křivka – originální signál, modrá křivka – po aplikaci prahovací metody.



Obr. 3.3: Blokový diagram metody redukce šumu s využitím fúze obrazu.

vyšetření (snímání sekvence). Z tohoto důvodu musí algoritmus provádět *eliminaci translačního pohybu*, například pomocí algoritmu založeného na pohybových vektorech[41].

Procedura *zarovnání tepny* má za úkol eliminovat pulzující pohyb tepny. Tento pohyb má jiný původ než výše popsáný translační pohyb, a proto není potlačen v předchozím kroku. Pro eliminaci pulzujícího pohybu byla navržena metoda, která vychází ze znalosti polohy LI rozhraní v prvním obraze videosekvence (v referenčním snímku). Pohyb rozhraní (přesněji pohyb významných bodů nalezených na rozhraní) v průběhu sekvence je sledován prostřednictvím optického toku a tato informace je následně využita pro přesnou a rychlou stabilizaci obrazů videosekvence.

Následuje proces *fúze obrazů*[59], který kombinuje vstupní obrazy (již bez nežádoucích pohybů) obsahující šum za účelem získání kvalitnějšího výsledného obrazu $\hat{I}$. Jedna z nejjednodušších lineárních metod fúze obrazů vychází ze superpozice obrazů s váhami, které jsou určeny metodou analýzy hlavních komponent (*principal component analysis* – PCA). Tato metoda provádí fúzi obrazů z videosekvence I_i do jednoho obrazu $\hat{I}$ jako vážený součet

$$\hat{I} = \sum_{i=1}^N I_i \cdot w_i. \quad (3.13)$$

Optimální váhovací koeficienty w_i jsou určeny z vlastního vektoru odpovídajícímu největšímu vlastnímu číslu, které je spočítáno pomocí analýzy hlavních komponent PCA v kovarianční matici počítané ze vstupních obrazů[60].

3.1.1.5 Ostatní filtrační metody

Obecně známé metody, které jsou běžně používány pro redukci Gaussovského aditivního šumu, mohou být modifikovány využitím Homomorfního přístupu[61] tak, aby byly využitelné i pro speckle šum. Homomorfní přístup spočívá ve využití logaritmické transformace (přesněji $\log(I(t) + 1)$), která je aplikovaná na originální obraz $I(t)$ před vlastní aplikací obecné metody redukce šumu.

Šum v ultrazvukových obrazech lze rovněž redukovat pomocí metod založených na anizotropní difúzi (*anisotropic diffusion*), jako například *speckle reducing anisotropic diffusion* – SRAD[62], *detail preserving anisotropic diffusion* – DPAD[63], *fuzzy anisotropic diffusion*[64] nebo *nonlinear coherent diffusion* – NCD. Metoda SRAD byla vytvořena přímo s ohledem na vlastnosti speckle šumu. Metoda využívá tzv. okamžitý koeficient (*instantaneous coefficient*), který je obdobou váhovacího koeficientu u Frost či Lee filtru a zahrnuje lokální obrazový gradient, Laplacian a

absolutní intenzitu. Yongjian ve studii[65] dokázal vyšší účinnost této metody pro obrazy znehodnocené speckle šumem v porovnání se standardními metodami anizotropické difúze.

Pro redukci šumu v UZ obrazech lze rovněž využít metod analyzujících obraz v různých měřítkách jako např. *Laplacian pyramid-based nonlinear diffusion* (LPND)[33]. Metoda se skládá ze tří hlavních kroků – transformace do tzv. Laplacian Pyramid domény, zpracování pyramidálních koeficientů s využitím nelineárních Gaussovských filtrů a zpětná transformace. Speckle šum, který má vysokofrekvenční charakter, tak lze snadněji identifikovat.

Loizou a kol.[66] provedl srovnání metod redukce šumu v obrazech zachycujících CCA. Nejhuře dopadly základní metody založené na výpočtu mediánu či na Wienerově filtraci. Tyto metody poměrně výrazně způsobovaly přehlazování hran. Filtry založené na anizotropické difúzi jsou vyhodnoceny jako velmi výpočetně náročné. Překvapivě některé pokročilé metody, např. metoda SRAD a Vlnková transformace, nedosahovaly v této porovnávací studii předpokládaných kvalit.

3.1.2 Normalizace jasu obrazu

V důsledku různého nastavení parametrů ultrazvukové stanice (zesílení, frekvence, hloubka zobrazení, křivka kompenzace zesílení – TGC (*time-gain compensation* apod.) mohou mít ultrazvukové obrazy různé jasové parametry. Někdy je tedy nutné provést normalizaci jasových hodnot v obraze tak, aby měřicí algoritmy měly analyzované objekty v daném jasovém rozsahu a mohly korektně pracovat.

Loizou a kol.[40] navrhl metodu, která lineárně transformuje jasové intenzity pixelů do požadovaného rozsahu. Navržený algoritmus předpokládá, že intenzity pixelů uvnitř arterie mají mít hodnotu v rozsahu 0 až 5 (uvažováno v 8 bitové hloubce – maximální intenzita je 255), a hodnoty pixelů ve vrstvě adventicia musí mít hodnotu v rozmezí 180 až 190. Zásadní nevýhoda metody[40] spočívá v nutnosti interakce s uživatelem, který musí vyznačit region v arterii a region ve vrstvě adventicia.

3.2 Lokalizace arterie a její stěny

Druhým postupným krokem v systémech automatického měření IMT (dle obr. 1.3) je procedura lokalizace arterie a její stěny v UZ obraze. V této proceduře je analyzován globálně celý vstupní ultrazvukový obraz, ve kterém je hledána tepna a její stěna. Na základě výsledku této procedury je inicializována následná procedura identifikace

vrstev na tepenné stěně. Pro dosažení plně automatického systému měření IMT je nutné zajistit plnou automatizaci i této procedury.

V dnešní době je v převážné většině systémů pro měření IMT využíváno buď pouze manuální lokalizace arterie, jako např. Cheng a kol.[67], kde musí obsluhující osoba (dále *operátor*) vyznačit dva body ležící na tepenné stěně, nebo v metodě navržené Selzerem a kol.[68], kde musí operátor dokonce vyznačit více bodů ležících podél celé tepenné stěny.

V mnoha případech může lokalizační procedura vykazovat jisté znaky částečné automatizace, kdy uživatel pouze specifikuje přibližné umístění arterie (tzv. *region of interest* – ROI)[69, 70]. Díky tomu nemusí lokalizační procedura analyzovat celý ultrazvukový obraz, který obsahuje mnohé „komplikované“ oblasti, které mohou lokalizační algoritmus mást (např. hrdelní žíla – *jugular vein*). Kvůli nezbytnosti lidského zásahu nejsou ani částečně automatizované metody vhodné pro plně automatické systémy.

V dnešní době již existují i jisté plně automatické lokalizační metody. Většina z nich ale není dostatečně robustní, a tak často nejsou schopny pracovat při neideálním zachycení arterie v obraze. Některé metody například pro zjednodušení předpokládají některé z následujících podmínek a mohou selhávat při jejich nesplnění

- **Předpoklad: horizontální zobrazení tepny v obraze.**
 - U většiny zdravých jedinců se tepna v B-mode UZ obraze zobrazuje horizontálně.
 - **Využití v metodách:** mnohé metody z tohoto faktu vycházejí a analyzují obraz ve vertikálních řezech.
 - **Komplikace:** tepna nemusí být vždy zobrazena horizontálně a může být v obraze natočena. Předpokládané parametry tepenné stěny se v důsledku jejího natočení mohou výrazně změnit, a tak zkreslit intenzitní profily vertikálních řezů.
 - **Možná východiska:** nejprve provést odhad směru arterie a namísto vertikálních řezů využívat řezů kolmých na přibližný směr arterie.
- **Předpoklad: tepenné stěny mají přímkový charakter a jsou rovnoběžné.**
 - U většiny vyšetřovaných pacientů má tepna (resp. tepenné stěny) při podélné B-mode projekci přímkový charakter, není to ale pravidlem a lokalizační metody by tohoto neměly explicitně využívat.
 - **Využití v metodách:** některé metody provádí aproximaci tepenné stěny přímkou (snadná implementace s využitím např. Houghovy transformace).

- **Komplikace:** u některých jedinců nemusí být tepenná stěna zobrazena jako přímka, ale může být prohnutá (a to i celkem výrazně). Poté jednoduché metody založené na Houghově transformaci mohou selhávat.
- **Možná východiska:** aproximace tepenné stěny více přímkami (vícenásobné využití Houghovy transformace v jednom obraze), popř. aproximace tepenné stěny křivkou (např. využití obecné Houghovy transformace).
- **Předpoklad: tepna vykazuje očekávané texturální parametry.**
 - U většiny jedinců se lumen tepny zobrazuje sytě černou barvou.
 - **Využití v metodách:** analýza texturálních parametrů pro přibližnou lokalizaci tepny a následná lokalizace tepenných stěn, např. s využitím analýzy gradientu.
 - **Komplikace:** v důsledku artefaktů, popřípadě chybného nastavení ultrazvukové stanice, může mít tepna obecně jiné než předpokládané texturální parametry.
 - **Možná východiska:** analýza možných texturálních vlastností (tzv. lokálních příznaků) a rozhodnutí, které jsou pro lokalizaci tepny důležité, a které jsou ve značném rozsahu invariantní pro různá nastavení ultrazvukové stanice.


Výše zmíněné komplikující faktory ukazují, že u vizualizované tepny se nemůžeme spolehnout ani na její geometrické, ani na texturální vlastnosti, a musíme tak lokalizační metodu navrhovat velmi robustně s přihlédnutím ke všem možným komplikacím.

3.2.1 Lokalizace arterie založená na analýze gradientu

Lokalizace arterie může být založena pouze na základě analýzy gradientu. Prvotní metody byly založené na velmi zjednodušeném předpokladu, že lumen tepny je relativně tmavý a je obklopován výrazně světlejšími tepennými stěnami. Pignoli[71] byl jedním z prvních autorů, který se zabýval měřením šířky vrstev na tepenné stěně a navrhl metodu, ve které využívá analýzy gradientů ve vertikálních řezech obrazem k lokalizaci tepenné stěny i k následné identifikaci rozhraní mezi vrstvami. Metody využívající takto jednoduché analýzy gradientu jsou obecně náchylné ke všem výše vyjmenovaným nežádoucím jevům při zobrazení.

3.2.2 Lokalizace arterie založená na lokální statistice

Existují metody, které lokalizují tepnu na základě statistické analýzy jasů jednotlivých pixelů v obraze. Fan a kol.[72] navrhnul metodu, ve které je prováděna analýza intenzity a směrodatné odchylky jednotlivých pixelů obrazu vždy v definovaném okolí bodu. Metoda je založena na předpokladu, že pixely tepny jsou tmavší a mají menší variabilitu intenzity v definovaném okolí, zatímco okolní tkáň jsou naopak světlejší a variabilita intenzity v jejich okolí je větší. Metoda provádí analýzu průmětu intenzity do směru podélného s tepnou, jak je vidět na obr. 3.4. Navržená metoda může selhávat v případech, kdy tepna není zobrazena v požadovaném směru nebo je mírně prohnutá.



Obr. 3.4: Obraz arterie v podélném směru (nahore) a příslušná projekce intenzity v podélném směru arterie (dole). Převzato z[72].

Ve studii[21] bylo dokázáno, že střední hodnota jasu pixelů a směrodatná odchylka počítaná v definovaném okolí (v dané studii byla uvažována velikost 10 px) jsou významnými příznaky pro rozlišení mezi pixely uvnitř arterie a pro pixely okolní tkáň. Postup představený v[21] začíná předzpracováním obrazu a jeho podvzorkováním. Obrazová informace je dále uvažována jen jako množina sloupcových řezů. V řezech je vyhledána potenciální pozice vrstvy adventicia, jako nejsvětlejší místo v aktuálně analyzovaném řezu. Poté je v okolí tohoto bodu vyhledáno nejtmavší místo a to je považováno za tepnu. Tento postup se iterativně opakuje pro všechny sloupcové řezy. Následuje procedura, která vyhledá maximální gradient v daném sloupci a s jeho pomocí upřesní polohu LI rozhraní. Procedura upřesnění polohy LI rozhraní již pracuje s originálním obrazem.

Rovněž existují lokalizační procedury založené na *k-means clusteringu*[73] nebo na *fuzzy C-means clusteringu*[74]. Tyto metody začínají extrakcí příznaků pro každý pixel v obraze. Příznaky bývají odvozeny například z intenzity, střední hodnoty nebo směrodatné odchylky, vždy v okolí definovaného bodu. Na základě takových příznaků jsou v[73] jednotlivé pixely klasifikovány do jedné ze tří tříd – oblast uvnitř arterie, tepenná stěna a okolní tkáň. Nakonec jsou analyzovány hranice segmentovaných regionů, a tak je lokalizována i poloha tepny a její stěny.

Většina z metod, které jsou založeny na lokální statistice pixelů v jistém okolí, uvažují jako jeden z důležitých příznaků intenzitu daného pixelu. V důsledku artefaktů či nastavení UZ stanice však arterie nemusí být ideálně tmavá, intenzita pixelů pak může značně kolísat a metody tak přestávají být robustní. Částečně lze robustnost metod lokalizace arterie zachovat, pokud jim je předřazena jistá forma předzpracování obrazu, zvláště pak proces normalizace jasových hodnot. Postupy navržené pro normalizaci obrazu[22] jsou však manuální, a tak nevhodné pro automatické systémy.

3.2.3 Lokalizace arterie založená na podobnostní analýze

Lokalizační metody spadající do této kategorie jsou založené na analýze podobnosti zachycené tepny s očekávaným (ideálním) profilem tepny. Metody většinou provádějí analýzu obrazu ve vertikálních řezech, čímž se však opět omezují na lokalizaci tepen, které jsou v obraze zachyceny přibližně horizontálně. Pro jiný směr tepny v obraze či její prohnutí nemusí být tyto metody dostatečně odolné, neboť takovéto geometrické změny mohou výrazně ovlivnit i vertikální průmět tepny.

Lokalizační metoda založená na podobnosti byla využita např. v[75]. V této metodě jsou porovnávány intenzitní profily tepny ve vertikálních řezech obrazu s ideálním profilem tepny. Průběh vertikálních řezů je nejprve decimován pro zvýšení odolnosti vůči šumu. Podobnostní princip je aplikován zvláště na profily obou tepenných stěn (bližší i vzdálenější k sondě), přičemž vzdálenost mezi nimi je omezena na základě znalosti parametrů hledané arterie. Touto jednoduchou metodou bylo dosaženo úspěšnosti pouze 60-80 %, a proto byl algoritmus rozšířen o zapracování informací o souvislostech mezi sousedícími řezy arterií. V algoritmu jsou jako sousedící řezy uvažovány jak sousedící řezy podél arterie, tak řezy zachycené v průběhu času (vstupem algoritmu je videosekvence). Díky zahrnutí těchto informací byla zvýšena výsledná úspěšnost systému na 98 %. Metoda však není schopna pracovat s tepnou, která se od horizontálního směru liší o více jak 3 %, což je značné omezení. Rovněž je metoda omezena tím, že do ní musí vstupovat videosekvence, což není vždy úplně vhodné.

3.2.4 Lokalizace arterie založená na Houghově transformaci

V různých publikacích bylo zkoumáno využití *Houghovy transformace* (HT)[76] pro lokalizaci arterie v obrazech, které ji zachycují jak v příčném (viz obr. 1.1 (b)), tak i podélném řezu (viz obr. 1.1 (a)). Pro lokalizaci v příčném řezu je využívána varianta HT, která je navržena pro hledání kruhovitých vzorů v obraze (tzv. *circular Hough transform* – CHT). Pro lokalizaci v podélném řezu, který je pro měření IMT vhodnější, je využito Houghovy transformace hledající přímky v obraze (tzv. *linear Hough transform*). Využití této metody pro lokalizaci tepny v celém obraze je velmi časté, neboť je velmi snadno implementovatelné. Taková aplikace HT ale není příliš vhodná, protože není dostatečně robustní pro mírně prohnuté arterie. Molinary a kol.[77] navrhl vylepšení, které rovněž využívá HT, ale omezení dříve navržených metod mírně potlačuje za cenu značného zvýšení složitosti algoritmu. Ve své studii navrhuje vícenásobné využití Houghovy transformace pro dílčí segmenty arterie, která tak již jako celek nemusí vykazovat přímkový charakter. Komplikace algoritmu spočívá v následném zpracování nalezených přímek tak, aby ve výsledku spojitě reprezentovaly tepennou stěnu.

3.2.5 Automaticky navržená metoda lokalizace arterie

V rámci plnění cílů dizertační práce byl navržen obecný systém založený na genetickém programování (dále jen GPDesigner)[42], který by bez zásahu operátora navrhl nejvhodnější metodu pro dané zadání obrazového zpracování. V tomto případě byl algoritmus experimentálně ověřen návrhem metody lokalizace arterie.

GPDesigner využívá genetického programování, pomocí kterého optimalizuje vzájemné propojení a nastavení dílčích bloků obrazového zpracování tak, aby ve výsledku co nejlépe řešily požadované zadání. GPDesigner lze využít pro návrh různých metod obrazového zpracování. Pro různé metody se však GPDesigneru musí poskytnout následující podklady

- **Sada terminálních operátorů.**

Jedná se o operátory, které vstupují do navrženého řešení. Obecně se může jednat o konstanty, číselné hodnoty, obrazy, videosekvence apod.

- **Sada neterminálních operátorů.**

Jedná se o jednoduché operátory, ze kterých je sestavováno výsledné řešení. V implementacích zabývajících se počítačovým viděním se převážně jedná o dílčí jednoduché bloky obrazového zpracování. Příkladem mohou být hranové operátory, morfologické operátory apod.

- **Fitness funkce**

Fitness funkce je využívána pro ohodnocení navrženého řešení.

- **Parametry popisující možnosti vzájemného propojení neterminálních operátorů (gramatika).**

Je využívána z důvodu nutnosti zúžit stavový prostor, a tak urychlit konvergenci ke kvalitnějším řešením. Zároveň je tak zamezeno nesmyslným kombinacím obrazových bloků.

- **Ukončovací kritérium.**

Řídí ukončení genetického programování.

GPDesigner je implementován jako nadstavba nad Java evolution framework JEF[78], který byl vyvinut týmem SPLab. JEF byl rozšířen obrazovými komponentami tak, aby byl schopen provést automatický návrh obrazového zpracování.

GPDesigner byl experimentálně využit k návrhu metody lokalizace arterie v jejím příčném řezu. Díky obecnosti GPDesigneru by však mohla být využita pro lokalizaci arterie i v obrazech zachycujících podélný řez CCA. Pro takový úkol by musely být definovány další neterminální operátory (další dílčí bloky obrazového zpracování), musela by být upravena gramatika a navržen výpočet fitness funkce.

S daným frameworkem byly provedeny dva experimenty. V prvním experimentu (viz sekce 3.2.5.1) byl požadavek, aby výsledná lokalizace arterie v příčném řezu zpracovávala jeden UZ snímek (množina terminálních symbolů byla omezena pouze na konstanty, numerické hodnoty a obrazy). V druhém experimentu byla sada neterminálních operátorů rozšířena o takové, které jsou schopny zpracovávat i sadu UZ obrazů (viz sekce 3.2.5.2).

Každé řešení nalezení GPDesignerem je vytvořeno jako stromová struktura dílčích operátorů. Kořen stromu (*root*) představuje výstup navrženého algoritmu. Koncové objekty (*leaf nodes*) představují terminální operátory – tzn. vstupy algoritmu.

3.2.5.1 Lokalizace arterie v obraze


Pro tento experiment byly definovány veškeré požadované podklady (viz kap 3.2.5)

- **sada terminálních operátorů:** konstanta, numerická hodnota, obraz,
- **sada neterminálních operátorů:** Houghova transformace, morfologické operace (eroze, dilatace, otevření, uzavření), prahování, entropické prahování, ekvalizace histogramu, segmentace rozvodím, hessian, rozmazání, jasové transformace obrazu, Algoritmy detekce hran,
- **fitness funkce:** počítána na základě přesnosti jednotlivých lokalizací ve všech obrazech trénovací sady,
- **gramatika:** arterie má v příčném řezu kruhovitý průřez, proto byla grama-

tika navrhována tak, aby jedním z kroků bylo využití Houghovy transformace. Hlavní volnost gramatiky byla definována před vlastní aplikací HT a v jejím nastavení,

- **ukončovací kritérium:** bylo definováno maximálním počtem evolucí a rovněž včasným ukončením.

Nejkvalitnější proces lokalizace byl nalezen evolučním frameworkem po 40 evolucích a zhruba 12,25 h výpočtu (Intel i5-2540M 2,6 GHz). Nalezený proces byl tvořen velmi nekonvenčním vzájemným propojením dílčích bloků, jak tomu u genetického programování obvykle bývá. Výsledné řešení je pak ve formě stromové struktury zobrazeno na obr. 3.5, parametry genetického programování jsou shrnuty v tab. 3.1.



Obr. 3.5: Řešení navržené pomocí GPDesigneru – první experiment.

Postup lokalizace arterie byl navržen včetně nejvhodnější metody předzpracování obrazu pro daný účel. Právě toto nalezení ideální metody předzpracování a optimalizace jejích parametrů je další nespornou výhodou této metody. V jiných řešeních jsou totiž metody předzpracování navrhovány a testovány převážně odděleně od systému, ve kterém jsou následně použity. Při tomto návrhu je však i část předzpracování adaptována v průběhu návrhu a promítá se do ohodnocení daného řešení a následného vývoje genetického programování.

Testovací sada obrazů čítala 147 různých obrazů CCA. Přestože nebylo pro tento experiment definováno dostatečné množství dílčích komponent, byla dosažena úspěšnost 75 %. Veškeré výsledky jsou shrnuty v tab. 3.2. Genetický algoritmus by bylo

možné dále rozšířit například využitím Kartézského genetického programování. Detailnější informace o evolučním frameworku i jeho úpravě lze nalézt v[44].

Tab. 3.1: Parametry genetického programování pro návrh metody lokalizace arterie v obraze.

Parametr	Hodnota
Velikost populace	100
Pravděpodobnost mutace	30 %
Pravděpodobnost křížení	60 %
Počet obrazů v trénovací sadě	9
Počet generací	40
Doba trvání evoluce	12,25 h
Průměrná čas. náročnost testování jednoho řešení	1,5 s

Tab. 3.2: Výsledky navržené metody lokalizace arterie v obraze.

Parametr	Hodnota
Počet obrazů v testovací sadě	147
Úspěšnost napříč testovací sadou	75 %

3.2.5.2 Lokalizace arterie ve videosekvenci

V tomto experimentu bylo plánováno využití pulzujícího pohybu tepny v průběhu srdečního cyklu, který je pochopitelně značně patrný ve videosekvenci. Pro návrh lokalizační metody byl opět využit GPDesigner, kterému musely být poskytnuty potřebné podklady, aby byl schopen automaticky navrhnout nejvhodnější možné řešení.

- **sada terminálních operátorů:** Oproti prvnímu experimentu rozšířena o možnost zpracovat videosekvenci,
- **sada neterminálních operátorů:** Oproti minulému experimentu rozšířena o množství dílčích bloků, převážně pak bloky zpracovávající videosekvence,
- **fitness funkce:** počítána opět na základě přesnosti jednotlivých lokalizací ve všech obrazech trénovací sady,
- **gramatika:** arterie má v příčném řezu kruhovitý průřez, který v průběhu videosekvence zřetelně pulzuje. Hlavní myšlenka byla pokusit se tohoto pulzujícího pohybu co nejvýhodněji využít (např. některá z metod optického toku)

např. v kombinaci s Houghovou transformací pro lokalizaci tepny.

- **ukončovací kritérium:** bylo definováno opět maximálním počtem evolucí a rovněž včasným ukončením.

Automatický návrh lokalizační metody trval 96 hodin (Intel i5-2540M 2,6 GHz) a jeho výsledek je zobrazen na obr. 3.6. Parametry genetického programování jsou shrnuty v tab. 3.3. Navržená lokalizační procedura na testovací databázi dosahovala úspěšnosti 82 %. Ve zbylých 18 % případech byla buď nalezena tepna chybně (7,69 %), nebo algoritmus tepnu žádnou tepnu nenalezl (9,61 %). Druhá situace, kdy algoritmus nenalezne tepnu místo toho, aby za tepnu označil špatnou oblast (podmínky pro prohlášení objektu za tepnu jsou striktní), výrazně zvyšuje robustnost algoritmu, neboť následné zpracování může na tuto situaci adekvátně zareagovat a pokusit se tepnu lokalizovat např. s jinou částí videosekvence.


Průměrná nepřesnost lokalizace středu tepny byla 6,31 px a byla porovnávána s nepřesnostmi, které se dopouštějí znalí uživatelé (*operátoři*) při vyznačování středu tepny. Jejich průměrná nepřesnost na shodné testovací množině byla 5,45 px. Dosazené výsledky jsou shrnuty v tab. 3.4.

Tab. 3.3: Parametry genetického programování pro návrh metody lokalizace arterie ve videosekvenci.

Parametr	Hodnota
Velkost populace	15
Pravděpodobnost mutace	10 %
Pravděpodobnost křížení	25 %
Počet videosekvencí v trénovací sadě	16
Počet generací	10
Doba trvání evoluce	96 h
Průměrná čas. náročnost na testování jednoho řešení	9,6 s

3.3 Identifikace vrstev na tepenné stěně a měření IMT

Identifikace vrstev na tepenné stěně je proces, při kterém jsou vyhledány přesné polohy LI a MA rozhraní podél arterie. Identifikace LI a MA rozhraní lze realizovat různými segmentačními technikami. Obecně je segmentace obrazu procesem, při kterém je vstupní obraz dělen na množství menších oblastí s definovanými vlastnostmi,



Obr. 3.6: Řešení navržené pomocí GPDesigneru – druhý experiment.

Tab. 3.4: Výsledky navržené metody lokalizace arterie ve videosekvenci.

Parametr	Hodnota
Počet videosekvencí v testovací sadě	52
Úspěšnost napříč testovací sadou	82 %
Chybné nalezení tepny	7,69 %
Nenalezení žádné tepny	9,61 %
Průměrná nepřesnost nalezení tepny (algoritmem)	6,31 px
Průměrná nepřesnost nalezení tepny (operátorem – pro porovnání)	5,45 px

což umožňuje snadnější analýzu obsahu obrazu. Segmentační metody lze rozdělit do dvou skupin – metody založené na regionech a metody založené na hranách. Cheng ve své studii[79] ukázal, že pro segmentaci vrstev na tepenné stěně jsou vhodnější metody založené na detekci hran, a proto bude zbytek této sekce věnován převážně těmto metodám.

Identifikace vrstev na tepenné stěně je, díky kvalitnějšímu zobrazení, vhodnější provádět na vzdálené stěně[2]. Důvod kvalitnějšího zobrazení spočívá v menší náchylnosti ke vzniku artefaktů a detailněji je popsán v sekci 1.5.1.

Prvotní metody[71] představené pro identifikaci LI a MA rozhraní byly většinou velmi jednoduché a vycházely ze základní analýzy gradientu v obraze. V poslední době se ale výzkum v této oblasti ubírá k návrhu komplexnějších metod, které jsou založeny nejčastěji na jednom ze dvou základních principů. První z principů využívá aktivní konturu a druhý využívá techniku dynamického programování. Tyto techniky jsou prezentovány jako výhodné i v případech, kdy je určitá část tepenné stěny zastíněna v důsledku artefaktů, neboť v těchto místech jsou metody schopny tepennou stěnu aproximovat. Zmíněná aproximace však není příliš přesná, neboť rozhraní jsou pochopitelně v takových místech aproximována převážně na základě parametrů křivky a méně pak na základě parametrů obrazu.

3.3.1 Metody založené na aktivních konturách

Metody založené na principu aktivních kontur se v dnešní době využívají v analýze biomedicínských obrazů velmi často. Jsou využívány např. pro segmentaci různých tkání nebo nálezů a není divu, že tyto metody našly uplatnění i pro identifikaci LI a MA rozhraní na povrchu tepenné stěny. Obliba těchto metod iniciovala množství modifikací základního principu, ale i různé přístupy k definici externích sil, které formují aktivní konturu. V této sekci bude nejprve obecně popsána základní metoda aktivních kontur a následně budou popsány její modifikace.

Aktivní kontura je modelována množinou vzájemně propojených bodů, které ve výsledku těsně obepínají segmentovanou oblast. Segmentace pomocí aktivních kontur je iteračním procesem, který začíná z počáteční inicializace (musí být určena počáteční poloha bodů kontury) a v jednotlivých iteracích je poloha bodů postupně upravována tak, aby ve výsledku obklopovala segmentovanou oblast. Pohyb bodů v jednotlivých krocích je řízen snahou minimalizovat energii podél křivky (viz rovnice 3.14). Z průběhu minimalizace energie je většinou odvozeno ukončovací kritérium iteračního procesu.

Obecná metoda, představená Kass a kol.[80], vychází z křivky, kterou lze para-

metricky popsat rovnici $v(s) = [x(s), y(s)]^T$, kde $s \in \langle 0, 1 \rangle$. Takto definovaná křivka má přiřazenu energii $E_{\text{snake}}(v(s))$, která je dána součtem interní a externí energie

$$E_{\text{snake}}(v) = E_{\text{int}}(v) + E_{\text{ext}}(v), \quad (3.14)$$

kde $E_{\text{int}}(v)$ představuje interní energii a $E_{\text{ext}}(v)$ externí energii. Interní energie $E_{\text{int}}(v)$ je vyjádřena pomocí vlastností dané kontury rovnici

$$E_{\text{int}}(v) = \int_0^1 [w_1(s) |v'(s)|^2 + w_2(s) |v''(s)|^2] ds, \quad (3.15)$$

kde $w_1(s)$ respektive $w_2(s)$ jsou koeficienty elasticity respektive tuhosti. Nastavením těchto koeficientů lze výrazně změnit vlastnosti aktivní kontury. Například aktivní kontura s vysokým koeficientem tuhosti velmi obtížně aproximuje objekty s členitou hranicí.

Metody aktivních kontur jsou velmi často začleněny v různých algoritmech pro naprosto různá zadání. V různých algoritmech se často liší pouze vhodným nastavením interních parametrů. Značnou nevýhodou takových metod je skutečnost, že mnohdy je nutné provést drobné korekce parametrů i v rámci dané metody, např. pokud dojde ke změnám parametrů obrazu při přenastavení snímacích vlastností UZ stanice či využití jiného UZ přístroje.

Externí energie $E_{\text{ext}}(v)$ je v různých modifikacích základní metody definována různě, ale většinou bývá odvozena z parametrického obrazu vypočítaného z originálního obrazu. V mnoha publikacích je externí energie počítána přímo z absolutní hodnoty gradientu, v jiných je externí síla vypočítána pomocí jistých operátorů. Určení externí energie je blíže popsáno v sekci 3.3.1.5.

Proces minimalizace energie z rovnice 3.14 lze, s ohledem na v , zapsat pomocí Euler-Lagrangeovy rovnice[67]

$$\frac{\partial v}{\partial t} - \frac{\partial}{\partial s} [w_1(s) v'(s)] + \frac{\partial^2}{\partial s^2} [w_2(s) v''(s)] - F[v(s)] = 0, \quad (3.16)$$

kde $\frac{\partial v}{\partial t}$ se po několika iteracích blíží k nule. Rovnice 3.16 může být zapsána v diskrétní podobě, kde je využíváno vzorkovacího intervalu, jehož hodnota je volena jako kompromis mezi dvěma extrémními stavy. Volba příliš nízké hodnoty τ způsobí pomalou konvergenci a naopak příliš vysoká hodnota působí problémy s oscilací.

V následujících sekcích jsou představeny modifikace základní metody, které byly aplikovány na segmentaci tepenných vrstev. Protože se metody aktivních kontur v anglicky psané literatuře nazývají *snake based methods*, bude i zde využívána tato terminologie.

3.3.1.1 Cohenova aktivní kontura (Cohen snake)

Cohen[81] provedl významnou modifikaci klasického přístupu, která je známa pod názvem *balloon snake model*. Navržená metoda je rozšířena přidáním externí síly, která působí rozpínavě na aktivní konturu (analogie se silou při „nafukování“ balónu). Zároveň byla v procesu minimalizace energie využita metoda konečných prvků.

Využití pro segmentaci LI a MA rozhraní – Cheng a kol.[67] využil tuto metodou k identifikaci LI a MA rozhraní. Bylo dosaženo přesnosti $62,3 \pm 60,5 \mu\text{m}$ u LI rozhraní, respektive $38,4 \pm 68,3 \mu\text{m}$ u MA rozhraní.

3.3.1.2 Ziplock aktivní kontura

Ziplock snake[82] je modelován jako kontura, která expanduje z koncových bodů směrem do středu kontury. Tato modifikace aktivní kontury nevyžaduje počáteční inicializaci v podobě množiny bodů po celé její délce, jak je tomu u standardní metody aktivních kontur. Inicializace spočívá pouze ve vyznačení dvou koncových bodů, které jsou umístěny blízko segmentovaného rozhraní. Algoritmus navíc v prvním kroku upraví polohu koncových bodů tak, aby opravdu ležely na segmentovaném rozhraní.

Využití pro segmentaci LI a MA rozhraní – studie[67] porovnává ziplock snake metody s modifikovaným Cohen snakem[81] z pohledu použití pro měření IMT. Je zřejmé, že modifikovaný Cohen snake je mnohem přesnější pro identifikaci LI i MA rozhraní[67].

3.3.1.3 Technika využívající tzv. hladový minimalizační algoritmus

Tato modifikace základní metody je motivována snahou o redukci výpočetní náročnosti iteračního procesu[83]. Proces minimalizace energie aktivní kontury je inspirován tzv. hladovým minimalizačním algoritmem *greedy minimization algorithm*[84], který je řešen v diskrétní podobě. Každý bod kontury může být posunut v definovaném okně $M \times N$, aby bylo dosaženo snížení energie. Hladový minimalizační algoritmus volí ideální posun pro každý bod lokálně a předpokládá, že tato volba bude ideální i z globálního pohledu.

V každém kroku iterativního postupu je prováděna analýza nazývaná *corner elimination*. Díky této analýze může kontura aproximovat i objekty s rohy. S rohy kontury je zacházeno tak, že pokud je podél kontury nalezeno výrazné zakřivení, je nastaven koeficient tuhosti v daném bodu na 0, aby mohl být v kontuře vytvořen zlom.

Iterativní proces je ukončen v okamžiku, kdy se výrazně nezmění poloha žádného bodu. Rovněž je vhodné definovat ukončení pomocí maximálního počtu iterací, aby byla eliminována možnost zacyklení.

Využití pro segmentaci LI a MA rozhraní – Loizou a kol.[85] využil greedy modifikaci klasické aktivní kontury. Zde se chyba mezi manuální identifikací rozhraní a identifikací navrženým algoritmem pohybuje okolo 40 μm .

3.3.1.4 Kombinace mnoha-měřítkové analýzy a aktivních kontur

Gutierrez a kol.[86] představil techniku aktivních kontur doplněnu o mnoha-měřítkový přístup. Mnoha-měřítková analýza zaručuje snížení výpočetní náročnosti, protože nejprve je analyzován obraz v hrubém rozlišení a následně je v kvalitnějších obrazech poloha aktivní kontury upravována.

Využití pro segmentaci LI a MA rozhraní – v[86] je tato technika využita pro měření IMT a průměru tepny. Přesnost této metody pro identifikaci LI a MA rozhraní však dosahovala pouze $90,0 \pm 60,0 \mu\text{m}$.

3.3.1.5 Definice externích sil

Odlíšnost jednotlivých přístupů využívajících aktivní kontury nespočívá pouze v modifikaci vlastního algoritmu, ale také v modifikaci externích sil, které formují výsledný tvar křivky. Základní metody využívají parametrický obraz vytvořen na základě absolutní hodnoty gradientu (jako např.[87]). V dalších přístupech, které se týkají identifikace LI a MA rozhraní, se objevují komplexnější výpočty externí síly, například s využitím tzv. *MacLeod operátoru*[79, 67]. Tento operátor se skládá ze dvou překrývajících se Gaussovských křivek, které jsou modulovány třetí Gaussovskou křivkou zaručující radiální útlum

$$f_M(x, y) = \exp\left(-\frac{x^2 + y^2}{d_c^2}\right) \cdot \left[\exp\left(-\left(\frac{d_{xy} + d_{pk}}{d_{pk}}\right)^2\right) - \exp\left(-\left(\frac{d_{xy} - d_{pk}}{d_{pk}}\right)^2\right) \right], \quad (3.17)$$

Jednotlivé parametry v rovnici 3.17 definují parametry modulovaných Gaussovských křivek[79, 67]. Parametr d_c je konstanta popisující útlum v radiálním směru, parametr d_{pk} , je vzdálenost vrcholů dvojice Gaussovských rozložení od os. Hodnota d_{xy} je počítána dle vztahu $d_{xy} = x \cdot \sin(\Theta) - y \cdot \cos(\Theta)$, kde Θ definuje natočení osy mezi vrcholy Gaussovských distribucí. Konvolucí vstupního obrazu a MacLeod

operátoru je získán parametrický obraz, který je využit pro definici externích sil (např. viz rovnice 3.28).

V obecných přístupech se setkáváme s komplexní definicí externích sil, která se snaží podchytit energii přímek (*lines*), hran (*edge*) či ukončení (*terminations*). V takovém případě je externí energie dána součtem

$$E_{\text{ext}}(v) = w_{\text{line}} \cdot E_{\text{line}}(v) + w_{\text{edge}} \cdot E_{\text{edge}}(v) + w_{\text{term}} \cdot E_{\text{term}}(v), \quad (3.18)$$

kde w_{line} , w_{edge} a w_{term} jsou váhovací koeficienty. Energie přímek specifikuje, jak moc bude kontura přitahována světlými/tmavými pixely. Je definována jednoduše jako intenzita obrazu

$$E_{\text{line}}(v) = I(x, y). \quad (3.19)$$

Energie hran definuje, jak moc je kontura přitahována k oblastem s vysokou změnou gradientu

$$E_{\text{edge}}(v) = -|\nabla I(x, y)|. \quad (3.20)$$

Energie ukončení $E_{\text{term}}(v)$ zaručuje započítání případných rohů a zakončení v obraze do výsledné externí síly. Energie je počítána z mírně rozostřeného obrazu $C(x, y) = G_{\sigma} * I(x, y)$,

kde G_{σ} je Gaussián se směrodatnou odchylkou σ . Energie zakončení je počítána dle vztahu

$$E_{\text{term}}(v) = \frac{\partial \Theta}{\partial \mathbf{n}_{\perp}}, \quad (3.21)$$

kde Θ je směr gradient

$$\Theta = \tan^{-1} \frac{c_y}{c_x}, \quad (3.22)$$

a $\mathbf{n}_{\perp} = (-\sin\Theta, \cos\Theta)$ je jednotkový vektor kolmý ke gradientu.

Do externích sil se někdy započítává i tzv. energie omezení (*constraint energy*), která umožňuje uživateli aktivně zasahovat do vývoje kontury. Díky této energii je možné explicitně definovat, ke kterým oblastem se má kontura přitahovat či oddalovat.

3.3.1.6 Přidání dodatečných sil

V mnohých publikacích bylo představeno rozšíření standardní rovnice aktivní kontury (viz rovnice 3.14) o další síly formující konturu. V kapitole 3.3.1.1 byla představena tzv. Cohenova aktivní kontura, která přidává rozpínavou sílu.

Gutierrez a kol.[86] ve své práci využil další síly, které napomáhaly stabilizovat konturu a zaručovat její větší hladkost. Nově přidaná síla byla úměrná rychlosti každého vrcholu kontury, ale byla aplikovaná v opačném směru.

3.3.2 Metody založené na dynamickém programování

Metody založené na dynamickém programování (DP) jsou spolu s metodami založenými na aktivních konturách v současné době nejpoužívanějšími technikami pro identifikaci vrstev na povrchu tepenné stěny. Cheng a kol.[88] dokázal, že tyto metody jsou schopny nalézt optimální řešení. Techniky založené na dynamickém programování operují s obrazovou informací obsaženou v analyzovaném obraze a zároveň s parametry hledaného řešení (modelovaného lomenou čarou). V současné době je navíc základní princip různě modifikován, například zahrnutím anatomických znalostí o segmentované oblasti nebo zpracováním vstupního obrazu v různých rozlišeních.

3.3.2.1 Tradiční dynamické programování

Techniky DP hledají vždy optimální řešení uvnitř definované oblasti zájmu (region of interest – ROI) o velikosti $N \times M$. Řešení je modelováno pomocí lomené čáry B , která je reprezentována prostřednictvím posloupnosti N bodů $\mathbf{p}_j = (j, y_j)$, kde j je sloupcová souřadnice v obraze a y_j je odpovídající řádková souřadnice

$$B = \{\mathbf{p}_1, \mathbf{p}_2, \mathbf{p}_3, \dots, \mathbf{p}_N\}. \quad (3.23)$$

Z důvodu nalezení ideálního řešení je definována tzv. účelová funkce *cost funkce* $C(B_i)$ [89, 90], která se skládá ze součtu lokálních vah po celé délce lomené čáry B_i

$$C(B_i) = c_f(\mathbf{p}_{i,1}) + \sum_{y=2}^N \left(w_1 c_f(\mathbf{p}_{i,y}) + w_2 c_g(\mathbf{p}_{i,y}, \mathbf{p}_{i,y-1}) \right). \quad (3.24)$$

Účelová funkce i -té křivky je dle rovnice 3.24 dána součtem dvou členů. Jeden je definován obrazovými vlastnostmi $c_f(\cdot)$ a druhý geometrickými vlastnostmi $c_g(\cdot)$. Definice těchto členů se liší v různých implementacích. Obrazový člen bývá určen na základě informací získaných ze vstupního obrazu buď přímo (např. intenzita,

gradient, statistické vlastnosti) nebo aplikací jistých filtrů (např. Haarových filtrů viz[89]).

Při výpočtu výsledné účelové funkce je každý z členů násoben patřičným váhovacím faktorem w_1 a w_2 ($w_1 + w_2 = 1$). Správné nastavení těchto faktorů je důležité pro chování navrženého algoritmu a je provedeno v průběhu návrhu algoritmu.

Výsledné řešení je představováno lomenou křivkou B s minimální hodnotou účelové funkce $C(B)$. Hodnoty váhovacích koeficientů, stejně tak jako koeficientů elasticity a tuhosti u aktivních kontur, jsou závislé jak na konkrétní implementaci, tak na použitém UZ zobrazovacím systému.

Dynamické programování, které je využíváno jako prostředek pro řešení optimačních problémů, našlo své uplatnění i při hledání minimální hodnoty účelové funkce. Cost funkce (dle rovnice 3.24) v bodu (i, y_i) může být přepsána v rekurzivní formě v souladu s dynamickým programováním[89, 90] (geometrický člen je zjednodušen proměnnou k):

$$C(1, y_1) = c_f(1, y_1), \quad (3.25)$$

$$C(i, y_i) = \min_{k \in \{-1, 0, 1\}} (C(i-1, y_{i-1} + k) + w_1 c_f(i, y_i) + w_2 |k|) \quad \text{pro} \quad 2 \leq i \leq N. \quad (3.26)$$

Tím je získána akumulční matice účelové funkce (cost accumulation matrix – CAM), kde je zanesena informace o tom, s jakou nejnížší akumulovanou váhou lze daného bodu matice dosáhnout. Výsledné řešení je nalezeno jako nejnížší hodnota v pravém sloupci a řešení se odtud dále zpětně trasuje přes celou matici[90].

Pro identifikaci obou rozhraní LI a MA musí být DP aplikováno dvakrát po sobě s různými inicializacemi. Protože jsou hledaná rozhraní umístěna velmi blízko sebe, může nastat situace, kdy se jednotlivé nezávislé lomené čáry (představující řešení jednotlivých aplikací dynamického programování) protnou, a tím znehodnotí nalezené řešení (viz obr. 3.7 (b)). Takové nepřesnosti lze předejít díky využití jistých modifikací dynamického programování.

Modifikace dynamického programování mohou být obecné (využitelné i v jiných algoritmech založených na dynamickém programování), ale i specifické pro danou úlohu. Například zmíněnému zkřížení hledaných LI a MA rozhraní se dá zabránit přidáním konkrétní podmínky vycházející z anatomických vlastností. Takto upravené DP se pak nazývá *dual dynamic programming* – DDP. V případě segmentace LI a MA rozhraní bývá zohledněna jejich vzájemná minimální a maximální vzdálenost (viz obr. 3.7 (c)).

3.3.2.2 Dynamické programování prováděné v různých měřítkách

Liang a kol.[91] představil modifikaci tradičního dynamického programování, která spočívá ve zpracování vstupního obrazu v různých rozlišeních. V prvním kroku je stěna tepny určena přibližně aplikací DP na podvzorkovaný vstupní obraz. Prvotní zpracování podvzorkovaného obrazu je výhodné, neboť jsou v něm potlačeny vysokofrekvenční složky včetně šumu. Takto získaný prvotní odhad polohy tepenné stěny je následně zpřesněn při použití obrazu v plném rozlišení (bez rozostření, tedy se zachovanými vysokofrekvenčními složkami). Při porovnání s tradičním přístupem je mnoha-měřítkový (*multiscale*) přístup odolnější vůči šumu[91].


Metoda představená Liang a kol.[91] dosahuje přesnosti $42,0 \pm 20,0 \mu\text{m}$.

3.3.2.3 Duální programování (DDP)

Při aplikaci tradičního DP zvláště na segmentaci LI a MA rozhraní se vyskytují komplikace s možným protnutím jednotlivých rozhraní. Pro řešení tohoto problému byla navržena technika duálního dynamického programování (*dual dynamic programming* – DDP[88]), která je schopna v jednom algoritmu detekovat zároveň obě rozhraní. Činnost algoritmu je zpřesňována informací o minimální a maximální vzdálenosti rozhraní, které vycházejí z anatomických vlastností. Dále algoritmus může brát v úvahu omezení na částečnou rovnoběžnost segmentovaných rozhraní.

Zapojením vzájemné souvislosti mezi hledanými rozhraními rovněž dojde ke zvýšení odolnosti navrženého algoritmu proti šumu. Stejně jako v TDP je i v DDP hledáno minimum cost funkce, která je v DDP funkcí tří proměnných $C(i, y_{i,1}, y_{i,2})$. Cost funkce musí reflektovat obrazové parametry, vzájemnou polohu bodů na obou rozhraních $((i, y_{i,1})$ a $(i, y_{i,2}))$ a hladkost jednotlivých nalezených rozhraní. Algoritmus také musí zahrnovat podmínku minimální a maximální vzdálenosti mezi oběma rozhraními.

Cheng a kol.[88] dokázal, že výsledky získané pomocí techniky DDP jsou tak kvalitní, že jsou plně srovnatelné s těmi, kterých bylo dosaženo při standardním vyšetření lékařem. V té samé studii bylo provedeno srovnání DDP s TDP. Z těchto výsledků je zřejmá vyšší přesnost a spolehlivost DDP oproti aplikaci TDP zvláště na každé rozhraní. TDP v některých případech absolutně selhalo v důsledku spojení nebo překřížení jednotlivých rozhraní, jak ukazuje obr. 3.7.



Obr. 3.7: Rozdíl mezi TDP a DDP: (a) oblast měření IMT, (b) výsledek při použití TDP, (c) výsledek při využití DDP. Převzato z[88].

3.3.2.4 Obrazová informace v algoritmu dynamického programování

Člen účelové funkce (rovnice 3.24), který je odvozen z obrazové informace, může být definován přímo absolutní hodnotou gradientu nebo prostřednictvím některého operátoru, stejně jako tomu bylo u metod založených na aktivních konturách. Například v[92] je využit MacLeod operátor f_M (viz rovnice 3.17) v kombinaci s gradientním operátorem ve směru y , který je vyjádřen maskou f_s

$$f_s = \begin{bmatrix} 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix}. \quad (3.27)$$

Výsledný člen založený na obrazové informaci h' je pak definován konvolucí původního obrazu I a masek operátorů

$$h' = |I * f_M| + I * f_s. \quad (3.28)$$

3.3.3 Ostatní segmentační metody

Metody založené na jiném principu než na aktivních konturách nebo na dynamickém programování dnes nejsou tak časté[93]. Jedna z metod lokalizace rozhraní byla založena na hledání maxima gradientu v řezech kolmých k ose prvotní lokalizace

arterie (ta byla vyznačena uživatelem v průběhu inicializační fáze). V dalších metodách bylo zkoumáno využití např. *matched filtrů* pro přesnou lokalizaci LI. Jejich činnost je založena na křížové korelaci a na následném vyhledání maxima.

Zajímavých výsledků bylo dosaženo využitím tzv. FOAM operátoru (first-order absolute moment edge operator). Metoda představená Faitou a kol.[94] se skládá ze 4 postupných kroků. Nejprve je aplikován hranový operátor FOAM. Následně jsou heuristicky hledána maxima ve výsledném obraze, která jsou ve třetím kroku následně upravována tak, aby neobsahovala statisticky vychýlená data. V posledním kroku jsou již pouze vyhodnoceny hodnoty IMT (označováno jako CIMT – carotid IMT).

V metodě představené Ligouri a kol.[69] byl obraz nejprve prahován a upraven, aby byly eliminovány možné artefakty uvnitř arterie. Následně je provedena analýza gradientu v jednotlivých sloupcích. Výsledkem algoritmu není jen hodnota IMT, ale také LD.


Destrempes a kol.[95] představil metodu založenou čistě na analýze vlastností tkání. Echogenicita regionu zájmu, který zahrnuje jednotlivé tkáně (lumen, intima-media komplex, adventicia), je modelována kombinací tří Nakagamiho rozložení. Lumen tepny je reprezentován distribucí s nízkou střední hodnotou, adventicia je představována distribucí s vyšší střední hodnotou, a komplex intima media je smíšený. Obraz je zkoumán v úzkých vertikálních pruzích zobrazujících tepnu a její stěnu. Nejprve je určen model na základě EM algoritmu (expectation maximization). Optimální segmentace je pak určena na základě odhadnutých distribucí v kombinaci se znalostí klasifikace od uživatele.

3.3.4 Statistické zpracování změřených hodnot IMT podél arterie

Všechny výše zmíněné metody provádějí identifikaci vrstev na stěně arterie po celé její délce nebo alespoň v několika místech podél arterie, a tak je možné změřit více hodnot IMT. Většinou je měření prováděno v ekvidistantních vzdálenostech podél tepny (je-li to možné), a tak je získán soubor hodnot IMT, který lze následně statisticky zpracovávat. Kromě nejdůležitější střední hodnoty $l_{\text{IMT_mean}}$, lze dále určovat další statistické hodnoty jako například minimum, maximum nebo medián ($l_{\text{IMT_max}}$, $l_{\text{IMT_min}}$, $l_{\text{IMT_median}}$).

4 NAVRŽENÉ ŘEŠENÍ

Navržené řešení je fyzicky rozděleno do tří hlavních bloků, které jsou dále členěny (viz obr. 4.1). Jednotlivé bloky jsou detailně popsány v následujících sekcích. Nejprve je představena databáze vytvořená speciálně pro účely návrhu a testování výsledného řešení.



Obr. 4.1: Blokové schéma systému pro automatické měření IMT s detailním rozkreslením dílčích bloků.

4.1 Databáze obrazů arterie

Pro účely návrhu a testování výsledného řešení byla vytvořena rozsáhlá databáze ultrazvukových obrazů, které zachycují podélné řezy CCA arterie (např. obr. 4.7 (a)) různých dobrovolníků. Obrazy byly snímány dle základních požadavků definovaných v sekci 1.3. Pro zachycení co možná největšího množství variací obrazů, které se mohou vyskytnout v praxi, byla jednotlivá snímání prováděna s různým nastavením ultrazvukové stanice (např. frekvence, hloubka zobrazení, zesílení, křivka TGC).

Obrazy byly snímány dvěma ultrazvukovými stanicemi – *Ultrasonix OP* a *Toshiba Nemio XG* na dvou různých pracovištích. Byly využity tři různé ultrazvukové sondy

s frekvencemi 7,5 MHz, 10,0 MHz a 14,0 MHz. Po nasnímání byla z obrazů odstraněna oblast, která obsahovala popisné údaje, ale dále nebyly obrazy upravovány (ořez, přiblížení, předzpracování, transformace jasu či geometrie).

Databáze nasnímaných obrazů byla rozdělena na dvě disjunktní sady – trénovací a testovací sada. Testovací sada byla využita pro ověření přesnosti navrženého řešení. Trénovací sada byla využita v průběhu hledání nejvhodnějšího nastavení dílčích metod (např. trénování klasifikátoru).

4.1.1 Rozšíření databáze obrazů pro účely lokalizace arterie


Každý obraz v databázi byl doplněn dodatečnými meta-informacemi. Meta informace byly doplněny k obrazům v trénovací i testovací části databáze, a tak sloužily jak k účelům trénování metody (labelovaná databáze pro trénování SVM klasifikátoru), tak i pro vyhodnocování přesnosti lokalizační metody.

Ke každému obrazu v databázi byla vytvořena binární maska, kterou lze vizualizovat pomocí černobílého obrazu (např. obr. 4.2 (b)). Bílou barvou v masce byl operátorem vyplněn lumen arterie, ostatní oblasti byly vyplněny černou barvou. V procesu trénování SVM klasifikátoru byla maska využita velmi přímočaře – hodnota pixelu v masce definovala požadovanou klasifikaci (uvnitř arterie vs. vně arterie). Testovací část množiny bylo možné využít rovněž přímo pro výpočet přesnosti natrénování klasifikátoru.

V testovací databázi byla pro usnadnění vyhodnocení přesnosti lokalizace arterie vyznačována rovněž poloha tepenné stěny. Poloha tepenné stěny byla vyznačena v několika bodech podél arterie třemi proškolenými operátory. Z polohy těchto bodů byla provedena aproximace polynomiální křivkou pro přesnější popis polohy tepenné stěny. Aproximace tepenné stěny byly zprůměrovány a považovány za přesnou polohu tepenné stěny a byly uloženy do odděleného popisného souboru.

4.1.2 Rozšíření databáze obrazů pro účely identifikace vrstev na povrchu arterie

Pro účely vyhodnocení přesnosti identifikace vrstev na povrchu arterie byla databáze rozšířena o informace o poloze rozhraní LI a MA, které vyznačili odborníci (operátoři) proškoleni lékařem. Poloha obou rozhraní byla vyznačena dvěma operátory a následně zprůměrována. Aproximace obou rozhraní byly uloženy do odděleného popisného textového souboru v podobě dvojice množin bodů (jedna množina pro LI a druhá pro MA rozhraní).



Obr. 4.2: Ukázka struktury trénovacích dat: (a) originální obraz, (b) maska definovaná pro trénovací a testovací účely.

4.2 Redukce šumu s využitím vlnkové transformace

Ve výsledném navrženém systému byla pro redukci šumu ve vstupních obrazech využita metoda založená na prahování koeficientů vlnkové transformace (princip metody je detailně popsán v sekci 3.1.1.3). Nevýhodou takových metod je komplikované nastavení jejich parametrů, jako jsou hodnoty prahů, volba prahovací metody či volba vhodné vlnky. V této dizertační práci byl navržen nový způsob nalezení nejvhodnějšího nastavení veškerých parametrů metody využívající evolučních principů.

4.2.1 Princip nalezení nejvhodnějších parametrů metody

Pro nalezení nejvhodnějšího nastavení metody bylo využito evoluční optimalizační strategie. Ta optimalizuje nastavení metody s ohledem na dosažení co nejvyšší kvality redukce šumu. Kvalita redukce šumu je vyhodnocována pomocí předem definovaných objektivních kritérií, jež byla vybrána v souladu se současnou literaturou (např.[96]). Hodnoty všech těchto kritérií byly shrnuty do jedné výsledné hodnoty, která byla využita jako fitness funkce pro evoluční strategii. Kvalita redukce šumu byla hodnocena následujícími kritérii: střední kvadratická odchylka (MSE – mean squared error), strmost hrany, relativní kontrast a směrodatná odchylka.

4.2.1.1 Objektivní kritéria využitá pro vyhodnocení kvality redukce šumu

a) **Střední kvadratická odchylka** (MSE) je definována vztahem

$$MSE = \frac{1}{M \cdot N} \cdot \sum_{i=1}^M \sum_{j=1}^N (x(i, j) - \tilde{x}(i, j))^2, \quad (4.1)$$

kde $x(i, j)$ a $\tilde{x}(i, j)$ jsou obrazy, mezi kterými má být MSE určeno (originální obraz a obraz po redukci šumu). Hodnoty M respektive N reprezentují šířku, respektive výšku obrazů.

b) **Relativní kontrast** v obraze je důležitým parametrem zvláště v obrazech vyznačujících se nízkým SNR[96]. Kontrast lze vypočítat dle vztahu

$$c_{AB} = |I_A - I_B|, \quad (4.2)$$

kde I_A a I_B jsou střední hodnoty intenzity ve zvolených oblastech A a B. Relativní kontrast lze určit tak, že hodnota c_{AB} je vztažena k referenční intenzitě I_r vypočtené dle vztahu

$$I_r = \frac{I_A + I_B}{2}. \quad (4.3)$$

Relativní kontrast pak lze vypočítat dle vztahu

$$\frac{c_{AB}}{I_r} = 2 \cdot \frac{|I_A - I_B|}{I_A + I_B}. \quad (4.4)$$


c) **Strmost hrany** m je určována na výrazných hranách dle vztahu

$$m = \frac{\Delta y}{\Delta x}, \quad (4.5)$$

kde parametr Δy je představován rozdílem intenzity na vzdálenosti Δx (viz obr. 4.3).

d) **Směrodatná odchylka v homogenních oblastech** σ je počítána v oblastech, které by se měly vyznačovat velmi nízkou variabilitou intenzity. Výpočet je prováděn dle vztahu

$$\sigma_A = \sqrt{\frac{1}{K \cdot L} \cdot \sum_{i=1}^K \sum_{j=1}^L (x(i, j) - \bar{x})^2}, \quad (4.6)$$



Obr. 4.3: Princip výpočtu strmosti hrany.

kde K a L reprezentují velikost oblasti A , $\bar{x}$ představuje střední hodnotu intenzity v této oblasti a $x(i, j)$ je jasová hodnota obrazu na souřadnicích i, j .

4.2.1.2 Princip evoluční strategie

Všechny výše zmíněné parametry jsou určeny v množině zvolených míst v každém obraze trénovací sady a jsou společně zahrnuty do fitness funkce, která objektivně vyhodnocuje kvalitu redukce šumu a je rozhodující pro optimalizační činnost evolučního přístupu. Evoluční strategie, která hledá nejvhodnější nastavení parametrů redukce šumu, se pak řídí následujícím algoritmem

1. Vygeneruj počáteční populaci.
Počáteční populací se rozumí sada jedinců, kterými je inicializován evoluční postup. V této metodě se jedincem rozumí konkrétní nastavení metody redukce šumu. Počáteční populace je tedy sada různých nastavení metody redukce šumu. Počáteční populace je vygenerována náhodně. V ideálním případě by měla co nejlépe pokrývat celý stavový prostor, což by teoreticky mělo zajistit rychlejší konvergenci a minimalizovat pravděpodobnost uvíznutí v lokálním extrému.
2. Všechny jedince z počáteční populace ohodnot fitness funkcí.
Fitness funkce numericky reflektuje vhodnost daného nastavení parametrů metody redukce šumu. Fitness funkce je vypočítána na základě určení výše popsaných parametrů měření kvality ve všech obrazech testovací sady.
3. Odstraň jedince s nízkou hodnotou fitness funkce.

Jsou odebrána taková nastavení, která dle objektivních kritérií nejsou příliš vhodná. Takoví jedinci nejsou vhodní ani jako výsledná řešení a pravděpodobně by ani v dalších evolucích nepřispěli ke zvýšení kvality nových jedinců.

4. Aplikuj genetické operátory.

Vybraní jedinci z populace jsou modifikováni využitím genetických operátorů. Bylo využito operátorů mutace a křížení. Při mutaci byla náhodně změněna část jedince, při křížení došlo k záměně dvou částí dvou jedinců.

5. Ohodnoť nové jedince v populaci pomocí fitness funkce.

Aplikace nových nastavení a zhodnocení filtrace s tímto nastavením.

6. Otestuj splnění ukončovacího kritéria. V případě že není splněno, algoritmus pokračuje z bodu 3.

7. Ukončení algoritmu a vyhlášení výsledného řešení.

Prohlášení jedince s nejvyšší hodnotou fitness funkce za nejvhodnější řešení – tzn. nejvhodnější nastavení metody redukce šumu.

Ukončovací kritérium bylo v našem případě definováno pomocí metody včasného zastavení (*early stop*) i pomocí maximálního počtu iterací. Mechanismus včasného zastavení ukončí iterace evolučního algoritmu v okamžiku, kdy se kvalita nejlepšího jedince (vyjádřena fitness funkcí) nezvýší po definovaný počet iterací. Nastavení genetického algoritmu je shrnuto v tabulce 4.1

Tab. 4.1: Zvolené nastavení genetického algoritmu.

Parametr	Hodnota
Využití včasného zastavení	Ano
Velikost počáteční populace	500
Využitá metoda mutace	Gaussovská mutace
Metoda výběru	Ruletová selekce
Pravděpodobnost křížení	10 %
Podíl jedinců vstupujících do tzv. turnajové selekce	10 %

4.3 Lokalizace arterie a její stěny

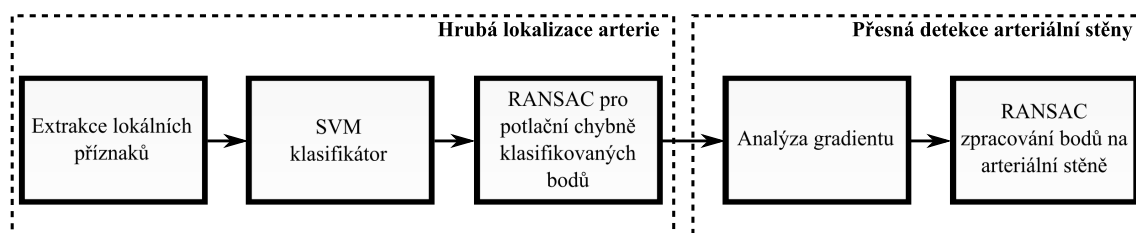
Navržená metoda lokalizace arterie a její stěny se skládá ze dvou základních částí, kterými jsou

- hrubá lokalizace arterie,
- přesná lokalizace arteriální stěny.

Tyto hlavní bloky jsou dále rozděleny na dílčí bloky (blokové schéma viz obr. 4.4). Metoda hrubé lokalizace arterie má za úkol nalézt přibližnou polohu arterie v obraze a tu aproximovat polynomiální křivkou (polynomiální křivka prochází středem arterie). Navazující blok přesné lokalizace tepenné stěny vyhledá tepennou stěnu s využitím analýzy gradientu. Pro aproximaci tepenné stěny v obraze je opět využito polynomiální křivky.

Při návrhu metod bylo postupováno tak, aby byla minimalizována veškerá omezení, která limitují použitelnost současných metod. Současné metody mnohdy selhávají např. při lokalizaci arterií, které nejsou zachyceny horizontálně nebo jsou v obraze mírně prohnuty.

Metoda **hrubé lokalizace arterie** začíná extrakcí lokálních texturních příznaků pixelů v obraze. Na základě extrahovaných příznaků je SVM klasifikátorem rozhodnuto, zda daný pixel leží uvnitř nebo vně tepny. V dalším postupu jsou zpracovávány pouze body, které klasifikátor považuje za body uvnitř arterie. Tyto body jsou analyzovány blokem založeným na RANSAC algoritmu, který je schopen nalézt proložení těchto bodů, při kterém je potlačen vliv chybně klasifikovaných bodů. Výsledkem tak je aproximace tepny pomocí polynomiální křivky (model tepny).



Obr. 4.4: Blokový diagram navržené metody lokalizace tepny a její stěny.

Úkolem bloku **přesné lokalizace tepenné stěny** je nalezení parametrů polynomiální křivky, která je využita pro modelování tepenné stěny. Principiálně je tento blok složen ze dvou dílčích kroků (viz obr. 4.4). Nejprve je analyzován gradient ve směru kolmém k tepně a jsou nalezeny tzv. prvotní tepenné body (zobrazeny na obr. 4.11 jako červené body, popř. na obr. 4.12 jako fialové body). Následně jsou tyto body zpracovány RANSAC algoritmem, aby byly potlačeny případné nepřesnosti.

4.3.1 Extrakce lokálních texturních příznaků

Extrakcí lokálních texturních příznaků v jednotlivých místech vstupního obrazu se rozumí výpočet parametrů, které popisují vlastnosti bodu a jeho blízkého okolí. Extrahované lokální příznaky v bodech vstupního obrazu jsou v následném postupu využívány pro klasifikaci jednotlivých bodů (viz sekce 4.3.2).

Jedním z nejzákladnějších lokálních příznaků je například střední hodnota intenzity vypočítána v určitém okolí daného bodu. Lokálních příznaků existuje nespočet, např. mediánová hodnota, homogenita, Haarovy příznaky[97], hodnota autokovariance, momentové parametry, poměr tmavých pixelů vůči světlým (*area fraction*), histogram hran apod. Všechny tyto příznaky lze navíc počítat pro různé velikosti okolí bodu. Pro použitý klasifikátor není vhodné využívat velké množství příznaků, proto je nutné vybrat podmnožinu příznaků, které budou nejvhodnější pro danou klasifikaci. Experimentální výběr nejvhodnějších příznaků je poměrně složitý, a proto byl implementován evoluční mechanismus, který automaticky provede výběr nejvhodnějších příznaků (viz sekce 4.3.2.2).

Pro optimalizaci činnosti algoritmu je extrakce lokálních příznaků (a tedy i následná klasifikace) prováděna pouze pro vybrané obrazové body. Body, u kterých má být provedena klasifikace, se volí z množiny všech obrazových bodů náhodně s pravděpodobností 20 %. To znamená, že bude ke klasifikaci vybrán přibližně každý pátý pixel. Tento fakt je zřejmý i na obr. 4.7 (b), kde červeně vyznačené pixely uvnitř arterie nepokrývají celou arterii.

4.3.2 SVM klasifikátor

SVM klasifikátor byl využit pro binární klasifikaci jednotlivých pixelů do jedné ze dvou kategorií

- „body uvnitř arterie“ (např. na obr. 4.7 (b) jsou zobrazeny jako červené body),
- „body mimo arterii“ (okolní tkáň).


Klasifikace jednotlivých pixelů je prováděna na základě lokálních příznaků, které jsou vypočteny předchozím blokem. SVM klasifikátor obecně vyžaduje nízký počet vzájemně nekorelovaných příznaků pro co nejpřesnější klasifikaci, což kontrastuje s vysokým množstvím možných příznaků vypočítaných předchozím blokem. Z tohoto důvodu je nutné sadu všech možných příznaků (bude označována jako *plný příznakový vektor*) redukovat jen na nejvhodnější příznaky. Soupis využitelných příznaků spolu s procedurou výběru nejvhodnějších příznaků jsou detailně popsány v sekci 4.3.2.2. Využitý evoluční přístup zaručuje výběr nejvhodnějších lokálních příznaků a tím je dosahováno maximální přesnosti klasifikátoru.

4.3.2.1 Princip support vector machine (SVM) klasifikátoru

SVM klasifikace[98] je proces, při kterém je příznakový prostor dělen nadrovinou (respektive nadrovinami) za účelem separace prostoru do dvou (respektive více) tříd tak, aby dělicí rovina byla stejně vzdálena od okrajů tříd (viz 4.5 vpravo).

Právě optimalizace umístění nadroviny s ohledem na co největší odstup od obou tříd odlišuje tuto metodu od ostatních (např. u perceptronové metody je dělicí nadrovina hledána bez optimalizačního kritéria a její přesná poloha je závislá na průběhu učení – viz 4.5 vlevo).

V průběhu procesu trénování jsou uvažovány jen body, které leží nejbližší hraně mezi třídami. Těmto bodům se říká *support vectors*. Ostatní body nemají žádný vliv na geometrické vlastnosti konstruovaných nadrovin[99].




Obr. 4.5: Rozdělení separabilních dat: (vlevo) bez optimalizace polohy nadroviny, (vpravo) s optimalizací tak, aby od nejbližších krajních bodů byla nadrovina stejně vzdálena.

Základní lineární SVM klasifikátor[98] může být rozšířen i na případy, kde data nejsou lineárně separabilní. V takovém případě jsou data mapována do prostoru vyšší dimenze, kde mohou být nadroviny použity efektivněji pro separaci dat. Mezi nejčastější mapovací funkce SVM klasifikátoru může být zařazena polynomiální (homogenní i nehomogenní), radiální báze (*radial basis function*) či hyperbolická funkce. Potom můžeme mluvit o nelineárním SVM klasifikátoru (viz obr 4.6).

4.3.2.2 Trénování SVM klasifikátoru a výběr nejvhodnějších příznaků

Plný příznakový vektor je v našem případě tvořen nespočetným množstvím příznaků (některé byly zmíněny v sekci 4.3.1). Mnohé z příznaků v příznakovém prostoru jsou redundantní či vzájemně korelované, a tudíž přebytečné. SVM klasifikátor vyžaduje nízký počet vzájemně nekorelovaných příznaků, a proto byla navržena metoda pro redukci příznaků (nalezení nejvhodnější podmnožiny příznaků). Metoda využívá evoluční strategii, která umožňuje prohledávat velký stavový prostor i při relativně nízké výpočetní náročnosti (v porovnání s prohledáváním celého stavového



Obr. 4.6: Proces mapování lineárně neseparabilních dat pomocí mapovací funkce tak, aby data byla separovatelná.

prostoru). Z evolučního pohledu jsou jedinci reprezentováni jako sada lokálních obrazových příznaků (podmnožina plného příznakového vektoru). Evoluční princip lze shrnout následujícími body

1. Vygeneruj počáteční populaci.
Populací se rozumí sada jedinců = sada podmnožin plného příznakového vektoru (viz 4.3.2).
2. Proveď genetické operace, jako jsou mutace či křížení za účelem úpravy jedinců. Tyto operace zapříčiní vlastní změnu v podmnožině vybraných příznaků.
3. Ohodnot dané jedince pomocí fitness funkce (viz sekce 4.3.2.3).
 - Proveď trénování klasifikátoru s danou volbou příznaků a s využitím trénovací množiny.
 - Proveď testování daného nastavení s testovací množinou – testovací množina je rovněž labelována, a tak je možné výsledek automaticky kvantifikovat do podoby fitness funkce.
4. Vyber množinu vhodných jedinců (odstraň nekvalitní jedince).
Dále nebudou uvažováni jedinci, kteří nedosahují dostatečných kvalit.
5. Pokud nebyla splněna podmínka ukončovacího kritéria, pokračuj znovu od bodu 2.
6. Propaguj řešení s nejvyšší fitness funkcí jako výsledné nastavení klasifikátoru.

Vyhodnocení vhodnosti daných příznaků bylo prováděno v každé iteraci pro všechny jedince. Klasifikátor byl vždy nejprve natrénován s příslušnou sadou příznaků (reprezentována daným jedincem) a vyhodnocen nad disjunktní testovací množinou obrazů.

Evoluční algoritmus byl inicializován sadou 100 jedinců. Nastavení důležitých parametrů evolučního algoritmu je shrnuto v tabulce 4.2.

Tab. 4.2: Shrnutí nastavení evolučního algoritmu pro hledání nejvhodnějších příznaků pro SVM.

Parametr	Hodnota
Velkost populace	100
Pravděpodobnost mutace	10 %
Pravděpodobnost křížení	25 %
Typ selekce	Turnajová selekce
Ukončovací kritérium	Včasné ukončení


Bylo otestováno využití standardního SVM klasifikátoru i rozšířené varianty, která využívá nelineární mapovací funkci (v tomto případě *radial basis funkci* – RBF). Metody byly otestovány a vzájemně porovnány. Mnohem vhodnější se ukazuje využití nelineární mapovací funkce. Veškeré výsledky jsou shrnuty v sekci 5.2.

4.3.2.3 Výpočet fitness funkce


Fitness funkce, vyjadřující kvalitu natrénování klasifikátoru, byla počítána z výsledku klasifikací při reálné aplikaci klasifikátoru na testovací labelovanou databázi. Díky tomu, že je testovací databáze labelována, lze vyhodnotit chybu klasifikace a tu přímo využít jako fitness funkci.

Ve skutečnosti nebyla data rozdělena striktně na trénovací a testovací databázi, ale bylo využito sofistikovanějšího způsobu křížové validace (*cross validation*). Při křížové validaci jsou data průběžně dělena na trénovací a testovací části až za běhu algoritmu. Tak je vyzkoušeno více možností dělení vstupních dat. Výsledná úspěšnost je pak dána průměrem ze všech použitých kombinací dělení vstupní množiny.


Většinou je využito k -složkové validace (*k-fold cross validation*), kdy jsou vstupní data rozdělena do k stejně velkých podmnožin (dílů). Jeden díl je využit k testování úspěšnosti a zbylých $k-1$ je využito k trénování. Je tak vygenerováno k kombinací. Pokud je $k = 2$, jedná se o speciální případ nazývaný *dvousložková validace*, kdy je sada rozdělena na dvě části a ve dvou krocích je postupně každá z nich použita jak v procesu trénování, tak i testování. Pokud je naopak k rovno počtu vzorků, jedná se o metodu *leave one out cross validation* (LOOCV). U takové metody je pouze jeden vzorek ponechán v testovací množině, zatímco veškeré ostatní vzorky jsou využity v procesu trénování. Další používanou variací je *opakované náhodné dělení* (repeating random sub-sampling validation). Při této metodě je v každé iteraci




(a)



(b)



(c)



(d)

Obr. 4.7: Ukázka principu lokalizace arterie: (a) originální obraz, (b) červeně jsou vyznačeny body klasifikovány jako body uvnitř arterie (jsou patrné chybné klasifikace), (c) zobrazení bodů po redukci odlehlých bodů, (d) výsledná aproximace arterie polynomiální křivkou.

prováděno dělení náhodně. Výhoda tohoto přístupu spočívá v tom, že poměr mezi trénovacími a testovacími daty není závislý na počtu iterací (jak je tomu u k -složkové validace).

Díky využití metody křížové validace je zaručeno

- automatické dělení vstupní množiny na trénovací a testovací části (přesný způsob dělení je dán typem metody),
- trénovací a testovací množiny jsou disjunktní v každém kroku dělení,
- potlačení možnosti výběru korelovaných dat do trénovací či testovací množiny,
- potlačení možnosti přetrénování modelu.

V našem případě bylo využito k -složkové validace, kde $k = 10$. Databáze tak byla rozdělena na deset stejně velkých částí a v deseti iteracích byla každá z nich použita pro testovací účely a zbytek pro trénovací účely.

4.3.3 Modifikovaný RANSAC algoritmus

V této sekci je popsána jedna ze stěžejních komponent navrženého řešení, která má za úkol dříve klasifikované body zpracovat a rozhodnout, kde leží arterie. Tato navržená komponenta je založena na principech RANSAC[100] algoritmu, který je v dané implementaci schopen nalézt nejvhodnější proložení bodů „uvnitř arterie“ modelem arterie (modelem arterie rozumíme aproximaci středu tepny přímkou popřípadě křivkou). Oproti jednoduchým aproximacím (např. metodou nejmenších čtverců) má RANSAC algoritmus jednoznačnou výhodu ve schopnosti aproximovat střed tepny, aniž by byl ovlivněn chybně klasifikovanými body.

Klasický RANSAC algoritmus využívá lineární model. Jeho využitím by byla použitelnost daného algoritmu značně omezena pouze na arterie zobrazené bez prohnutí. S ohledem na možný mírně prohnutý charakter tepny v podélném řezu byl RANSAC algoritmus modifikován tak, aby byl schopen poradit si i s takovou úlohou. Navržené vylepšení spočívá ve využití polynomiálního modelu arterie (aproximace středu arterie polynomiální křivkou s parametry p_0 , p_1 a p_2), který lze zapsat pomocí rovnice

$$y = p_2 \cdot x^2 + p_1 \cdot x + p_0. \quad (4.7)$$

Navržený RANSAC algoritmus je využit pro proložení bodů klasifikovaných jako body uvnitř arterie polynomiálním modelem, přičemž je zaručena minimalizace vlivu chybně klasifikovaných bodů. Tyto body se v terminologii používané v RANSAC[100] algoritmu nazývají jako tzv. *outliers*. V naší implementaci, kdy je předřazený kla-

sifikátor velmi přesný, jsou chybně klasifikované body většinou izolované nebo tvoří malé shluky, ale nikdy netvoří tak komplexí shluk jako ten, který je vytvořen správně klasifikovanými „body uvnitř arterie“ a který je podstatný pro aproximaci. Zmíněné vlastnosti shlukování bodů klasifikovaných jako „body uvnitř arterie“ jsou ideální pro nasazení navrženého RANSAC algoritmu.

RANSAC algoritmus má iterativní charakter. Výsledkem RANSAC algoritmu je model arterie a dvě skupiny bodů – body, které odpovídají hledanému modelu (inliers) a body, které neodpovídají (outliers). Všechny body, které se skutečně nacházejí uvnitř arterie, by v ideálním případě měly odpovídat hledanému modelu a měly by být tedy označeny jako inliers. Všechny ostatní body by naopak měly být označeny jako outliers a neměly by se v průběhu RANSAC algoritmu promítat do hledané aproximace.

Činnost navrženého modifikovaného RANSAC algoritmu lze shrnout v následujících krocích

1. Nahodile vyber tři body (hypotetické inlier body). Vytvoř model tak, že těmito body je proložena křivka $\mathbf{p}$ (detailně popsáno v sekci 4.3.3.1).
2. Otestuj ostatní body proti tomuto modelu.
 - (a) Vypočti vzdálenosti $d(\mathbf{x}_i)$ od křivky $\mathbf{p}$ pro všechny body $\mathbf{x}_i$ (detailně popsáno v sekci 4.3.3.2).
 - (b) Body, které vyhovují kritériu $d(\mathbf{x}_i) < t$, jsou považovány za inliers (t je experimentálně zvolená prahová hodnota).
3. Pokud je počet inliers vyšší než pro doposud nej kvalitnější model, je tento kvalitnější model uložen i s nejvyšším počtem inliers.
4. Pokud není dosaženo ukončovací kritérium (dostatečný počet iterací), algoritmus pokračuje od bodu 1.
5. Interpoluj křivku všemi body inliers, které byly určeny nej kvalitnějším modelem (detailně popsáno v sekci 4.3.3.3).

4.3.3.1 Proložení křivky třemi body


Polynomiální křivku druhého řádu viz rovnice 4.7 lze zapsat v maticovém tvaru

$$y = \begin{bmatrix} x^2 & x & 1 \end{bmatrix} \cdot \begin{bmatrix} p_2 \\ p_1 \\ p_0 \end{bmatrix}. \quad (4.8)$$

K nalezení parametrů této křivky (viz obr. 4.8) je nutná znalost polohy tří bodů

$\mathbf{x}_i = [x_i, y_i], i = 0, 1, 2$. Tento fakt lze zapsat v maticovém tvaru

$$\begin{bmatrix} y_0 \\ y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} x_0^2 & x_0 & 1 \\ x_1^2 & x_1 & 1 \\ x_2^2 & x_2 & 1 \end{bmatrix} \cdot \begin{bmatrix} p_2 \\ p_1 \\ p_0 \end{bmatrix}. \quad (4.9)$$



Obr. 4.8: Proložení polynomiální křivky třemi body.

Řešením této soustavy rovnic je vektor parametrů hledané křivky $\mathbf{p} = [p_2 \ p_1 \ p_0]^T$.

4.3.3.2 Výpočet vzdálenosti mezi bodem a polynomiální křivkou

Vzdálenost mezi obecným bodem $\mathbf{x}_0$ a polynomiální křivkou je definována jako vzdálenost mezi bodem $\mathbf{x}_0 = (x_0, y_0)$ a bodem $\mathbf{x}_m = (x_m, y_m)$, který leží na křivce a je nejbližší bodu $\mathbf{x}_0$ (viz obr. 4.9).

Obecně je Euklidovská vzdálenost mezi bodem $\mathbf{x}_0$ a libovolným bodem $\mathbf{x} = (x, y)$ definována jako


$$l = \sqrt{(x - x_0)^2 + (y - y_0)^2}. \quad (4.10)$$

Body na křivce definované rovnicí 4.7 mají souřadnice $\mathbf{x} = (x, y) = (x, p_2 x^2 + p_1 x + p_0)$. Vzdálenost mezi bodem na křivce a libovolným bodem $\mathbf{x}_0 = (x_0, y_0)$ může být vyjádřeno jako funkce s parametrem x

$$l(x) = \sqrt{(x - x_0)^2 + (p_2 x^2 + p_1 x + p_0 - y_0)^2}. \quad (4.11)$$

Tuto závislost můžeme nazývat vzdálenostní funkcí. Vzdálenostní funkce $l(x)$ nabývá minima právě v bodu, který zároveň leží na křivce a je nejbližší k bodu $\mathbf{x}_0$. Toto minimum lze nalézt pomocí analýzy průběhu křivky

$$\frac{dl(x)}{dx} = 0, \quad (4.12)$$



Obr. 4.9: Demonstrace měření vzdálenosti bodu od křivky. Na spodním obrázku je schematicky ukázáno vynesení vzdálenostní funkce a lokalizace jejího minima v bodu $\mathbf{x}_m$.

$$4p_2x^3 + 6p_1p_2x^2 + 2(1 + 2p_2(p_0 - y_0) + p_1^2)x + 2(p_1(-y_0 + p_0) - x_0) = 0. \quad (4.13)$$


Reálný kořen x_m kubické rovnice 4.13 představuje x -ovou souřadnici bodu nejblíže bodu na křivce.

Výpočet y -ové souřadnice y_m lze provést dle rovnice 4.7. Hledaný bod $\mathbf{x}_m = (x_m, y_m)$ je hledaný bod na křivce nejblíže bodu $\mathbf{x}_0$ a jejich vzdálenost pak je definována pomocí rovnice

$$l(x_m) = \sqrt{(x_m - x_0)^2 + (p_2x_m^2 + p_1x_m + p_0 - y_0)^2}. \quad (4.14)$$

4.3.3.3 Aproximace mnoha bodů polynomiální křivkou

Navržený RANSAC algoritmus nalezne mnoho bodů vyhovujících modelu ($N \gg 3$). Posledním krokem je určit nejlepší model arterie tak, aby byl vypočten na základě všech inlierů a ne jen ze tří bodů, jak je tomu doposud. Z tohoto důvodu musí navržená metoda obsahovat mechanismus aproximace polynomiální křivky více než třemi body (jak je to vidět na obr. 4.10).



Obr. 4.10: Aproximace polynomiální křivky více než třemi body.

Aproximace je procesem hledání nejlepšího modelu, který reprezentuje všechny body s minimální aproximační chybou. K řešení takové úlohy musí být do matematického modelu přidána chybovost e_i

$$y_i + e_i = p_2 x_i^2 + p_1 x_i + p_0. \quad (4.15)$$

Sada rovnic pro N aproximovaných bodů může být zapsána v maticové podobě

$$\begin{bmatrix} y_0 \\ \vdots \\ y_{N-1} \end{bmatrix} + \begin{bmatrix} e_0 \\ \vdots \\ e_{N-1} \end{bmatrix} = \begin{bmatrix} x_0^2 + x_0 + 1 \\ \vdots \\ x_{N-1}^2 + x_{N-1} + 1 \end{bmatrix} \cdot \begin{bmatrix} p_2 \\ p_1 \\ p_0 \end{bmatrix}. \quad (4.16)$$

Protože je počet bodů větší než 3 ($N \gg 3$), je soustava rovnic přeúčtená. Taková úloha může být vyřešena pomocí metody nejmenších čtverců. V naší implementaci je tato úloha řešena SVD dekompozicí[101].

4.3.3.4 Ukončovací kritérium

Obecně je ukončovací kritérium RANSAC algoritmu definováno velmi jednoduše. Algoritmus je iterován bez ohledu na kvalitu doposud nalezeného řešení po předem zvolený počet iterací. Využitím pravděpodobnostní analýzy lze počet iterací optimalizovat pro dané zadání[102]. V této modifikaci není počet iterací N konstantní, ale je nastaven dle vztahu

$$N = \frac{\log(1 - p)}{\log(1 - (1 - \varepsilon)^s)}, \quad (4.17)$$

kde pravděpodobnostní konstanta p [102] bývá obvykle zvolena 0,99. Parametr s představuje počet náhodně zvolených bodů, v naší implementaci $s = 3$. Parametr ε vyjadřuje pravděpodobnost, že zvolený bod je outlier


$$\varepsilon = 1 - \frac{n_i}{n_a}, \quad (4.18)$$

kde n_i je počet inliers a n_a je počet veškerých bodů.

4.3.4 Blok analýzy gradientu

V tomto bloku je prováděna analýza gradientu podél arterie v ekvidistantních vzdálenostech. Podél arterie je zkonstruováno množství ekvidistantních přímek (viz bílé přímky v obr. 4.11) tak, aby jejich směr byl kolmý na lokalizaci arterie (viz žlutá čárkovaná křivka v obr. 4.11). Na těchto přímkách je měřen gradient g_i v každém bodu i . Gradient g_i , který je nejbližší středu tepny a dosahuje hodnoty vyšší než experimentálně zvolená prahová hodnota g_t , je zařazen do sady prvotních tepenných bodů (viz červené body v obr. 4.11). Tato sada bodů obsahuje potenciální body na arteriální stěně a bude označována P (v obr. 4.12 jsou tyto body vyznačeny fialovou barvou).

Některé body zahrnuté do sady P mohou být detekovány nepřesně například kvůli nízké kvalitě ultrazvukových obrazů, přítomnosti šumu či artefaktů (jako jsou útlum, akustický stín apod.). Příklad takové situace je zobrazen na obr. 4.12, kde jsou chybně detekovány body především v levé části obrazu. Tyto nepřesnosti ukazují nutnost dalšího zpracování výsledků.




Obr. 4.11: Konstrukce přímek kolmých na hrubou lokalizaci, na kterých je analyzován gradient (sada bílých přímek). Červeně jsou vyznačeny tzv. prvotní tepenné body. Žlutá (čárkovaná) křivka představuje hrubou lokalizaci.

4.3.5 Následné zpracování prvotních tepenných bodů

Následné zpracování prvotních tepenných bodů nemůže být úplně přímočaré, např. pokud bychom sadu bodů P proložili křivkou dle kritéria minimální kvadratické chyby, bylo by proložení výrazně ovlivněno všemi chybně lokalizovanými prvotními tepennými body (viz obr. 4.12 (a) – žluté proložení).

Při návrhu byl na počátku brán v úvahu předpoklad, že sada prvotních tepenných bodů obsahuje i nepřesně určené body, avšak interpolaci je nutné provádět pouze na základě přesných bodů. Tento problém je velmi podobný aproximaci, která byla prováděna v proceduře hrubé lokalizace arterie. Protože se osvědčilo využití navržené modifikace RANSAC metody, byl tento postup využit i v tomto případě.

Modifikovaná RANSAC metoda je schopna nalézt ideální proložení bodů polynomiální křivkou (modelem tepenné stěny) tak, aby byl minimalizován vliv chybných bodů (outliers). Metoda se řídí obdobným postupem, jaký je popsán v sekci 4.3.3, liší se pouze nastavením prahové vzdálenosti t . Oproti hrubé lokalizaci tepny je prahová hodnota t volena nižší, protože arteriální stěna je užší. Kritérium pro označení bodu jako inlier je tak mnohem striktnější. Díky navržené RANSAC metodě je výsledné proložení bodů provedeno pouze na základě inliers, tedy přesně lokalizovaných prvotních tepenných bodů, a dosahuje kvalitních výsledků. Výsledek proložení při využití RANSAC algoritmu je zobrazen zelenými body na obr. 4.12 (b). Výsledná aproximace metodou RANSAC je přímo výsledkem metody přesné lokalizace tepenné stěny.




Obr. 4.12: Ukázka proložení prvotních tepenných bodů. (a) Fialové body zobrazují prvotní tepenné body. Žlutě je naznačena jejich interpolace metodou nejmenších čtverců. (b) Zelené body zobrazují aproximaci po aplikaci RANSAC metody, tzn. aproximaci provedené pouze z inlierů.

4.4 Identifikace vrstev na povrchu tepenné stěny a měření IMT

Pro identifikaci vrstev na povrchu tepenné stěny byla navržena nová metoda založená na detailní analýze gradientu kolmo na počáteční hrubou lokalizaci. Hlavní výhoda navržené metody spočívá v tom, že měření šířky vrstev na povrchu arterie je prováděno jen ve vybraných místech, která jsou vyhodnocena jako nejvhodnější pro takové měření. Navržená metoda není nucena segmentovat vrstvy podél celé arterie, jak je tomu v převážné většině současných metod (např.[67, 68, 79, 88]). Díky této skutečnosti je navržená metoda využitelná i v případech, kdy jsou měřené vrstvy, popřípadě celá arterie, patrné jen v části obrazu, což se v praxi mnohdy stává. Dalšími výhodami navržené metody jsou nízká výpočetní náročnost a vysoká odolnost vůči nepřesné inicializaci (nepřesnému určení polohy tepenné stěny).

Navržená metoda se skládá ze tří částí (viz obr. 4.13). První z nich identifikuje segmenty arterie, ve kterých bude vhodné provést identifikaci vrstev LI a MA. Místa, která jsou vyhodnocena jako nevhodná, ať už v nich není vůbec patrna arterie nebo nejsou dostatečně rozlišitelné vrstvy na jejím povrchu, nejsou uvažovány při vlastním měření. Navazující část (druhý blok v obr. 4.13) pak provádí vlastní identifikaci vrstev pouze v místech k tomu vhodných. Poslední blok algoritmu provede měření vzdálenosti LI a MA rozhraní, a tak určí hodnotu IMT.



Obr. 4.13: Blokový diagram navrženého algoritmu pro měření IMT.


4.4.1 Identifikace míst vhodných pro měření IMT

Tento blok je automaticky inicializován modelem tepenné stěny, který je získán z bloku lokalizace tepenné stěny (viz obr. 4.1). Lokalizace tepenné stěny je reprezentována polynomiální křivkou (model tepenné stěny). Polynomiální křivka je pro tento účel navzorkována, a tak je získána množina bodů $m \in M$. Hlavním úkolem tohoto kroku je nalézt jen takové body, které jsou vhodné pro měření IMT – tzn. je nutné nalézt vhodnou množinu bodů S ($S \subset M$).

Navržená metoda je schopna identifikovat LI a MA rozhraní, pokud se nacházejí ve vzdálenosti menší než 30 px od modelu tepenné stěny. Tato prahová hodnota

byla experimentálně zvolena jako kompromis mezi dvěma extrémními stavy. Vyšší hodnoty mohou vést k chybným detekcím, neboť LI a MA rozhraní jsou hledána ve větším rozsahu, a v důsledku artefaktů či struktury okolní tkáně se při analýze mohou objevit podobné obrazce. Naopak příliš nízká hodnota by bránila správnému nalezení LI a MA rozhraní, pokud by tepenná stěna nebyla přesně lokalizována.


Identifikace vhodných míst pro měření IMT je založena na analýze gradientu kolmo k tepenné stěně ve všech bodech podél arterie. Jedná se o analýzu jednorozměrného signálu $l_m(x)$ (budeme nazývat **intenzitním profilem** v bodu m), který je získán z průběhu intenzity na přímce kolmé k modelu arteriální stěny v bodu m (viz obr. 4.14).



Obr. 4.14: Ukázka získání intenzitního profilu (zvýrazněno na příkladu červené přímky) kolmo k modelu arterie (žlutá čárkovaná křivka).

Jak již bylo naznačeno, ne každý bod na arteriální stěně (bod v množině M) je vhodný k měření IMT. V obraze se často nachází značné množství oblastí (např. viz obr. 4.15 v pravé polovině), kde je velmi obtížné arterii identifikovat, natož pak měřit IMT. Proto je nutné vybrat do množiny S jen takové body, které budou pro měření IMT vhodné.

Podmnožina S je postupně vytvářena zejména odebíráním bodů nevhodných pro měření IMT z počáteční sady M . Vytváření podmnožiny S je tří-krokový proces. První dva kroky jsou zodpovědné za odebírání bodů z množiny M na základě nesplnění základních podmínek kladených na kvalitu zobrazení arteriální stěny a vrstev na jejím povrchu. První dva kroky analyzují intenzitní profily jednotlivých bodů odděleně (neuvažují vzájemné souvislosti sousedních intenzitních profilů). Odebírání realizované prvními dvěma kroky je navrženo velmi „přísně“, a tak mohou být některé body odstraněny neoprávněně. Proto je do navrženého řešení zařazen třetí krok, který provádí hlubší analýzu, do které jsou zahrnuty vzájemné informace



Obr. 4.15: Ukázka situace kdy ne všechna místa podél arterie jsou vhodné pro měření IMT. V tomto ukázkovém snímku jsou vrstvy patrné pouze v levé části obrazu.

získané z okolních intenzitních profilů. Třetí blok je tak schopen do množiny přidat body, které byly prvními dvěma kroky pravděpodobně chybně odebrány. Princip metody je patrný z obr. 4.16 a jednotlivé kroky jsou detailněji popsány v následujících sekcích.

4.4.1.1 Odebrání bodů, které mají nízký celkový kontrast

Prakticky v každém obraze zachycujícím podélný řez arterie se nacházejí oblasti, kde je arteriální stěna zachycena s nedostatečným kontrastem (např. pravá část arterie v obr. 4.15). Taková chyba zobrazení je způsobena již při samotném obrazovém snímání např. v důsledku nedostatečného tlaku části sondy na vyšetřovanou oblast. V takových oblastech, které nemají dostatečný kontrast, pochopitelně není možné věrohodně identifikovat LI a MA rozhraní, a proto musí být body v těchto oblastech odstraněny z počáteční sady M (viz obr. 4.16 červené body).


Kontrast měřený v daném intenzitním profilu $l_m(x)$ je definován jako rozdíl mezi extrémními hodnotami (viz obr. 4.18)

$$h = \max(l_m(x)) - \min(l_m(x)), \quad (4.19)$$


kde $\max(l_m(x))$ je maximální a $\min(l_m(x))$ je minimální hodnota podél intenzitního profilu. Body, jejichž intenzitní profil má nižší kontrast, než je prahová hodnota l_{thr}

$$h < l_{\text{thr}}, \quad (4.20)$$

jsou odstraněny ze sady bodů M . Prahová hodnota l_{thr} je určena jako sedmdesátiprocentní kvantil v množině všech kontrastů získaných podél arterie (ve všech bodech M) v daném obraze. Výpočet prahové hodnoty byl zvolen experimentálně analýzou intenzitních profilů v dostupné obrazové sadě. Předpokladem pro tento výběr byla



Obr. 4.16: Ukázka tříkrokového procesu výběru vhodných míst pro měření IMT. V prvním kroku jsou červeně naznačeny body odebrané kvůli nízkému kontrastu. V druhém kroku jsou žlutě naznačeny body odebrané kvůli nedostatečně výraznému profilu. Ve třetím kroku jsou modře naznačeny body odebrané kvůli nedostatečné délce clusteru a zeleně je označen bod, který byl opětovně přidán (propojuje dva významné segmenty).



Obr. 4.17: Ukázka výběru míst podél arterie a měření IMT. (a) Vstupní obraz, (b) místa podél arterie, kde je dostatečný gradient, (c) místa podél arterie, kde je patrná struktura vrstev, (d) nalezené segmenty po post-procesingu, (e) identifikované LI a MA rozhraní, (f) detailní zobrazení.

skutečnost, že oblasti s nízkým kontrastem většinou pokrývají maximálně 30 % obrazu.

Současné metody většinou problém špatné segmentovatelnosti arterie přímo neřeší. Často plně spoléhají na manuální vstup od uživatele, který v inicializačním kroku vyznačí v obraze oblast zájmu (ROI — region of interest), ve kterém jsou následně algoritmem rozhraní identifikována. Algoritmus plně spoléhá na to, že uživatel vyznačí výhradně nejvhodnější oblast.

4.4.1.2 Odebrání bodů, ve kterých intenzitní profil nezobrazuje výrazně LI a MA rozhraní

V obraze se rovněž mohou objevit oblasti, kde sice je arterie a její stěna zachycena s dostatečným kontrastem, ale v důsledku přítomnosti šumu nebo dalších artefaktů nejsou rozhraní identifikovatelná. Tento jev se většinou objevuje nezávisle ve více izolovaných místech podél arterie. Měření IMT by v takových místech bylo značně nepřesné, a proto navržená metoda provádí striktní odebírání těchto bodů z počáteční množiny bodů M (viz obr. 4.16 žluté body). Tím bude zaručeno, že algoritmus v těchto „nevhodných“ bodech nebude IMT měřit.

Současné algoritmy (např. metoda aktivních kontur nebo dynamického programování) neřeší tento problém přímo. Tyto algoritmy plně spoléhají na svoji schopnost aproximovat segmentovaná rozhraní pomocí geometrických vlastností křivky i v místech, kde rozhraní nejsou patrná. Tento přístup na první pohled (zvláště při vizualizaci výsledků) vypadá ideálně – rozhraní je segmentováno po celé délce arterie. Je nutné ale brát v potaz skutečnost, že v místech, kde nejsou LI a MA rozhraní ideálně patrná, mohou naměřené hodnoty vykazovat poměrně značnou chybu, kterou stávající metody minimalizují pouze pomocí průměrování výsledků. Metoda navržená v rámci řešení této dizertační práce však řeší selekci pouze bodů, ve kterých je možné potřebná rozhraní přímo změřit tak, jak se tomu děje i při manuálním měření.

Princip bloku detekce přítomnosti LI a MA rozhraní je založen na hloubkové analýze intenzitního profilu $l_m(x)$. Typický intenzitní profil (viz obr. 4.19) je charakterizován stabilním nárůstem intenzity s jedním výrazným poklesem.

Oblasti „vhodné“ pro měření IMT (pojem vhodný bod značí, že v daném bodu jsou vrstvy viditelné a detekční algoritmus je schopen je korektně identifikovat) nebudou odstraněny z množiny M . Jako vhodné jsou vyhodnoceny takové intenzitní profily $l_m(x)$, ve kterých se nachází pouze jeden významný pokles. Pokud v intenzitním profilu není žádný pokles (intenzitní profil je monotónně rostoucí funkcí), není

možné identifikovat jednotlivá rozhraní. Rovněž nelze přesně lokalizovat LI a MA rozhraní, pokud je v intenzitním profilu více než jeden pokles. Zmíněný pokles musí mít navíc určitou minimální délku t , aby byl uvažován jako intima-media rozhraní. Matematicky lze tuto skutečnost popsat tak, že musí existovat právě jeden interval x (ohraničený body x_a a x_b)

$$x \in \langle x_a, x_b \rangle, \text{ kde } \frac{dl_m(x)}{dx} < 0 \text{ a } |x_a - x_b| > t, \quad (4.21)$$


kde t je prahová hodnota definována fyziologicky (minimální šířka vrstev) – viz obr. 4.19.

4.4.1.3 Následné zpracování bodů v množině S


Výše uvedené dva kroky odstraňují body nevhodné pro měření IMT z počáteční sady M . Protože jsou intenzitní profily analyzovány izolovaně a podmínky odstranění jsou poměrně striktní, může dojít k situaci, že některé body byly neprávem odebrány (viz obr. 4.16 zelený bod). Jiné body naopak stále neoprávněně zůstávají v množině (viz obr. 4.16 modré body). Proto byl navržen tento třetí krok, který analyzuje sousedství bodů. Hlavní myšlenka této fáze algoritmu spočívá v tom, že je nejvhodnější měřit IMT na delších úsecích arterie, kratší úseky mohou být pouze falešné detekce zapříčiněné např. šumem nebo jinými artefakty.

Množina M , ze které byly v prvních dvou krocích odebírány nevhodné body a která je následně modifikována tímto krokem, je poté prohlášena za výslednou množinu S . Ve všech bodech množiny S je následně provedeno měření IMT. Při reálním nasazení bylo z množiny M obvykle odstraněno 50 % bodů (množina S má zhruba poloviční velikost), což je stále dostatečný počet pro měření. Počet odebraných bodů samozřejmě záleží na kvalitě zpracovávaného obrazu. Metoda vychází z předpokladu, že je vhodnější provádět měření v menším počtu bodů, ale zato přesněji. Současné metody naopak spoléhají na měření IMT podél celé arterie a následné zakrytí chybně měřených hodnot při výpočtu průměrné hodnoty IMT.

Analýza vzájemných sousedství bodů spočívá ve vytváření tzv. clusterů, do kterých jsou seskupeny sousedící body. Následné měření IMT je prováděno pouze v clusterech, které jsou tvořeny alespoň pěti sousedícími body. Clustery jsou navíc považovány za použitelné pro měření IMT, i pokud jsou přerušeny jedním dříve odebraným bodem (viz obr. 4.16 zelený bod). Body, které se nacházejí v nevyužitelných clusterech (clustery, které nedosahují požadované délky), jsou odstraněny z množiny M , a tak nejsou využity pro měření IMT.



Obr. 4.18: Typický profil arteriální stěny s naznačeným principem měření kontrastu.



Obr. 4.19: Pokročilejší analýza intenzitního profilu (zaměřena na analýzu přítomnosti intima-media rozhraní).


4.4.2 Identifikace LI a MA rozhraní

Algoritmus identifikuje LI a MA rozhraní (v důsledku tak měří šířku vrstev intima media) pouze v bodech, které byly identifikovány jako vhodné v průběhu předchozích kroků. V tomto kroku je opět analyzován intenzitní profil $l_m(x)$ za účelem přesné identifikace lumen-intima (LI) a media-adventicia (MA) rozhraní. Intenzitní profily jsou pro tento krok nejprve nadvzorkovány pro dosažení sub-pixelové přesnosti.

Rozhraní LI je definováno jako bod nejbližší k lumen, ve kterém začne intenzitní profil vzrůstat v intima vrstvě. Lumen tepny je vizualizován pixely s nízkou intenzitou, která ovšem v důsledku šumu může mírně kolísat. Za bod na LI rozhraní proto byla experimentálně zvolena hodnota o $h \cdot 0,1$ vyšší než $\min(l_m(x))$ (viz obr. 4.20)

$$l_{m,LI} = \min(l_m(x)) + h \cdot 0,1, \quad (4.22)$$

kde h je kontrast definovaný v rovnici 4.19. Rozhraní mezi vrstvami media a adventicia je definováno jako bod situovaný uprostřed mezi x_1 a $x_{\max}$, kde bod x_1 představuje bod nejnižší hodnoty v zmíněném poklesu v intenzitním profilu a $x_{\max}$ je bod, kde intenzita dosahuje maximální hodnoty (viz obr. 4.20).



Obr. 4.20: Princip lokalizace rozhraní LI a rozhraní MA.

4.4.3 Měření hodnoty IMT

Tato část algoritmu má za úkol finálně zpracovat výsledky předchozího měření (popř. sady měření) a prezentovat je obsluze (vyšetřujícímu lékaři). Vzdálenosti mezi LI

a MA rozhraními byly předchozími bloky navrženého algoritmu změřeny ve všech bodech $s \in S$ podél arterie. Tento blok tedy provádí statistickou analýzu naměřených hodnot. V naší implementaci je výsledná hodnota IMT v n -tém obraze testovací sady vypočtena jako průměrná vzdálenost mezi LI a MA rozhraními ve všech bodech $s \in S$

$$\text{IMT}_n = \frac{1}{S} \sum_{s=1}^S \text{IMT}_n(s). \quad (4.23)$$

Aby navržená měřicí metoda přesně kopírovala stávající vyšetřovací protokoly (viz sekce 1.3), bylo by nutné provedení měření na obou karotidách a výsledná hodnota IMT by byla počítána obdobným statistickým zpracováním, avšak byly by uvažovány i ostatní snímky daného pacienta.

5 DOSAŽENÉ VÝSLEDKY

V této kapitole jsou shrnuty veškeré dosažené výsledky a je provedeno srovnání s obdobnými metodami. Nadále bude dodržováno členění do sekcí v souladu s dělením algoritmu.

5.1 Redukce šumu s využitím vlnkové transformace

V průběhu hledání nejvhodnějšího nastavení navržené metody redukce šumu s využitím vlnkové transformace byly postupně provedeny tři experimenty. Během nich byla provedena optimalizace parametrů postupně pro tři různé rodiny vlněk

- Daubechies (zahrnující vlnky db2, db5 a db8),
- Symlets (sym2, sym5 a sym8),
- Coiflets (coif1, coif3 a coif5).

Dosažené výsledky jsou shrnuty v tabulce 5.1 a tabulce 5.2.

Tab. 5.1: Nejvhodnější nastavení nalezené evolučním algoritmem pro různé rodiny vlněk.

Rodina vlněk	Daubechies	Symlets	Coiflets
Typ vlnky	db2	sym5	coif3
Typ prahování	měkké	měkké	měkké
Práh 1	61,45	61,45	64,13
Práh 2	47,69	48,55	55,27
Práh 3	16,77	16,71	71,55
Práh 4	75,66	75,62	–
Práh 5	25,10	24,97	–
Fitness funkce	3,31	3,34	3,11

5.1.1 Experimentální nastavení parametrů metody redukce šumu

Optimalizační procedura (vývoj fitness funkce je patrný z obr. 5.1) vyhodnotila měkké prahování jako nejvhodnější prahovací metodu pro všechny tři experimenty. Optimální řešení nalezené pro rodinu Daubechies dosahovalo hodnoty fitness funkce

Tab. 5.2: Porovnání metody založené na vlnkové transformaci s ostatními metodami.

Metoda	Fitness funkce
WT-coif3	3,31
Anisotropic[103]	16,59
B-filtr[104]	4,19
Gaussian	7,97
NLMS[105]	3,55
ROF[106]	6,43
Wiener	4,04

3,31 při využití vlnky db2 a koeficientů shrnutých v tabulce 5.1. Optimální řešení nalezené pro rodinu Symlet bylo dosaženo při využití vlnky sym5 a koeficientů z tabulky 5.1. Fitness funkce při takovém řešení nabývala hodnoty 3,34. Pro první dva experimenty bylo nalezeno řešení, které využívalo hloubku dekompozice 5. Pro rodinu Coiflet byla jako nejvhodnější vyhodnocena vlnka coif3 s hodnotami koeficientů z tabulky 5.1.


Na základě provedených experimentů byla pro navrhovaný systém zvolena dekompozice s mateřskou vlnkou coif3 s prahovacími parametry shrnutými v tabulce 5.1.

Nejvhodnější nalezené řešení bylo porovnáno s ostatními v současnosti používanými metodami (např. NLMS, B-filtr, ROF, Wiener). Pro objektivní porovnání byla využita metrika identická s tou, která byla využita v předchozích experimentech jako fitness funkce. Výsledky tohoto porovnání jsou shrnuty v tabulce 5.2. Ve výsledcích je zřejmá kvalita navržené metody, NLMS filtru, Wienerovy filtrace a B-filtru. Využitím ostatních metod nebylo dosaženo natolik kvalitních výsledků.


5.2 Lokalizace arterie a její stěny

5.2.1 Porovnání SVM klasifikátoru s lineárním a nelineárním jádrem

V rámci návrhu klasifikační části metody hrubé lokalizace bylo otestováno využití různých typů jader u SVM klasifikátoru – lineárního jádra a jádra využívajícího nelineární mapování pomocí RBF funkce. Úspěšnost základní verze SVM klasifikátoru byla pouhých 80,73 %. U rozšířené varianty bylo dosaženo výrazně vyšší úspěšnosti – 91,23 %. Kvality jednotlivých klasifikátorů lze ještě lépe vyhodnotit na základě matic záměn v tabulce 5.3 a tabulce 5.4.



(a)



(b)

Obr. 5.1: Vývoj fitness funkce nejlepšího chromozomu pro Daubechies rodinu vlnek (a) respektive pro Symlet rodinu vlnek (b)

Tab. 5.3: Matice záměn pro standardní klasifikátor SVM.

	Klasifikace negativní	Klasifikace pozitivní
Predikce negativní	86,8 %	13,2 %
Predikce Pozitivní	25,1 %	74,9 %

Tab. 5.4: Matice záměn pro klasifikátor SVM s radiálním jádrem.


	Klasifikace negativní	Klasifikace pozitivní
Predikce negativní	89,2 %	10,9 %
Predikce pozitivní	5,6 %	94,3 %

Vzhledem k dosaženým výsledkům byl již v dalším postupu používán výhradně klasifikátor s nelineárním typem jádra. U zvoleného klasifikátoru následně proběhla optimalizace výběru příznaků, jejíž výsledky jsou shrnuty v následující sekci.


5.2.2 Trénování SVM klasifikátoru a výběr nejvhodnějších příznaků

Pro dosažení maximální přesnosti klasifikace byl výběr nejvhodnějších příznaků pro klasifikaci proveden s využitím evoluční strategie (viz sekce 4.3.2.2). Vývoj evoluční strategie výběru nejvhodnějších příznaků lze sledovat z trendu fitness funkce (její výpočet je detailně popsán v sekci 4.3.2.3), která vyjadřuje kvalitu nejlepšího jedince v průběhu jednotlivých generací.

Ukončovacího kritéria evolučního algoritmu bylo dosaženo po 72 generacích, kdy přestalo docházet ke zvyšování kvality nejlepšího řešení, tzn. již nebyla snižována hodnota fitness funkce představující chybu klasifikátoru. Vývoj fitness funkce nejlepšího jedince je patrný z obr. 5.2. V obr. 5.3 je zobrazen vývoj statistických parametrů celé populace (kvantily, mediánová hodnota, extrémy) v průběhu evoluce. Výsledná volba příznaků je shrnuta v tabulce 5.5.



Obr. 5.2: Vývoj fitness funkce (RMSE klasifikátoru) v průběhu generací.



Obr. 5.3: Statistické vlastnosti populace v průběhu evoluce.

Tab. 5.5: Sada příznaků automaticky zvolených evolučním algoritmem.

Velikost okna	Sada zvolených lokálních příznaků
5x5	Kurtosis, medián, minimální hodnota intenzity, koeficient šikmosti, umístění těžiště
15x15	Hranatost, směrodatná odchylka, autokovariance
25x25	Směrodatná odchylka, umístění těžiště, maximální hodnota intenzity

5.2.3 Výsledná úspěšnost SVM klasifikátoru

Po provedení optimalizace nastavení příznaků a parametrů SVM klasifikátoru byla výsledná úspěšnost klasifikátoru 92,85 %. Oproti metodě[45], kde byly příznaky vybírány osobou provádějící návrh metody na základě experimentálních výsledků a zkušeností, došlo k mírnému zvýšení přesnosti z původní úspěšnosti 91,23 %.

Zvýšení úspěšnosti klasifikátoru, i když velmi malé, je ve skutečnosti dosti důležité. Díky tomu mají navazující metody (založené na RANSAC algoritmu) nižší počet nepřesných dat (outliers), a tak je minimalizováno riziko jejich selhání. Tím se zvyšuje robustnost hrubé lokalizace arterie, a tak i celého systému měření IMT.

5.2.4 Úspěšnost hrubé lokalizace

Pro vyhodnocení úspěšnosti bloku hrubé lokalizace bylo zvoleno kritérium, kdy hrubá lokalizace arterie byla považována za přesnou, pokud se nalezené řešení, modelované polynomiální křivkou procházející středem arterie, v žádném jejím bodu nevychýlilo z oblasti lumen. Toto kritérium plyne z požadavků dalších bloků v systému automatického měření IMT.

Při aplikaci navržené metody hrubé lokalizace na daná data nastala pouze jediná situace, kdy byla hrubá lokalizace nepřesná. Výsledná úspěšnost navrženého bloku hrubé lokalizace tak byla 98 %. Chyba hrubé lokalizace nastala v situaci, kdy bylo v obraze velké množství oblastí chybně klasifikovaných jako body uvnitř tepny. To ukazuje na důležitost správné konfigurace SVM klasifikátoru (důležitost výběru vhodného nastavení a jádra viz kap 5.2.1) a důležitost volby správných příznaků viz sekce 5.2.3.

Současné metody dosahují úspěšnosti 92 % [107] – 95 % [77]. Některé přístupy dosahují vyšších úspěšností, např. Rossi a kol. [75], avšak tato metoda nedokáže lokalizovat prohnuté či nehorizontálně zachycené arterie.

5.2.5 Testování odolnosti metody založené na RANSAC algoritmu

V reálném použití vykazovala navržená metoda SVM klasifikace velmi dobrých výsledků, a tak navazující metoda založená na RANSAC algoritmu měla při reálném nasazení téměř ideální podklady pro svoji práci. Vzhledem k nutnosti ověření robustnosti navrženého RANSAC algoritmu i mimo tyto celkem ideální podmínky byly provedeny dva experimenty, které tuto metodu ověřily v simulovaném prostředí. Při experimentech byly do množiny bodů klasifikovaných jako body arterie vloženy náhodné body, které simulovaly chybně klasifikované body (outliers). V obou experimentech byla měřena pravděpodobnost selhání metody (selhání hrubé lokalizace) v závislosti na zvyšujícím se počtu vkládaných outliers.

V prvním experimentu byly outliers vkládány na náhodné pozice do sady původních bodů (viz obr. 5.4 (a)). V rámci druhého experimentu byly outliers vkládány ve shlucích. Náhodné body v prvním experimentu simulují chybnou klasifikaci na základě šumu či rozsahově malých artefaktů. Shluky bodů použité v druhém experimentu simulují situaci, která může nastat při chybné klasifikaci například důsledkem podobnosti struktury tkání v UZ obraze.

V prvním experimentu byla míra znehodnocení vstupních dat vyjádřena poměrem mezi přidanými a původními body. Obrázek. 5.5 a tab. 5.6 zobrazují závislost pravděpodobnosti selhání RANSAC metody na poměru přidaných a původních bodů. Tento experiment ukazuje dobrou odolnost RANSAC algoritmu na přítomnost náhodných bodů outliers.

V druhém experimentu byly přidávány sady bodů, které byly seskupeny do clusterů. Za tímto účelem byl vytvořen náhodný generátor, který nejprve přidával body do jednotlivých clusterů, které následně vložil na určitou pozici do počáteční sady (viz obr. 5.4 (b)). Počet bodů v každém clusteru byl stanoven na 20 % z původního počtu bodů. Druhý experiment tak byl zaměřen na ověření odolnosti RANSAC metody v závislosti na přidávání shlukovaných bodů. Výsledky jsou shrnuty v obr. 5.6 a tabulce 5.7.

Z prvního experimentu je zřejmé, že RANSAC metoda je velmi odolná vůči náhodně přidaným bodům (v reálném použití – nekorelované chybně klasifikované body). Při druhém experimentu se ukazovalo, že přidávání korelovaných outliers má výraznější vliv na přesnost. Přesto však metoda i při vložení vyššího počtu clusterů dosahovala velmi dobrých výsledků. Testy ukázaly velkou odolnost navržené RANSAC metody a prokázaly její využitelnost pro hrubou lokalizaci arterie.


Tab. 5.6: Pravděpodobnost selhání RANSAC metody při přidávání náhodných bodů.

Poměr mezi body přidanými a původními	1	2	3	4	5	6	7	8
Pravděpodobnost selhání RANSAC metody	0 %	3 %	6 %	16 %	26 %	26 %	56 %	66 %


Tab. 5.7: Pravděpodobnost selhání RANSAC metody při přidávání clusterů náhodných bodů.

Počet clusterů ^a	6 (1,2)	8 (1,6)	10 (2,0)	12 (2,4)	14 (2,8)	16 (3,2)	18 (3,6)	20 (4,0)
Pravděpodobnost selhání RANSAC metody	0 %	3 %	0 %	6 %	10 %	16 %	16 %	26 %


^av závorce je uveden poměr mezi body přidanými a původními pro orientační srovnání



Obr. 5.4: Ukázka přidávání bodů náhodně (a), respektive do clusterů (b).



Obr. 5.5: Závislost pravděpodobnosti selhání RANSAC metody na přidávání náhodných bodů.



Obr. 5.6: Závislost pravděpodobnosti selhání RANSAC metody na přidávání clusterů náhodných bodů.

5.2.6 Výsledná úspěšnost přesné lokalizace tepenné stěny

Přesnost lokalizace tepenné stěny navrženým algoritmem byla vztahována vůči manuální lokalizaci provedené třemi operátory (viz sekce 4.1.1). Chyba lokalizace byla měřena v každém obraze v deseti ekvidistantních bodech podél arterie jako absolutní hodnota rozdílu mezi hodnotou určenou navrženým algoritmem a průměrnou hodnotou manuálního označení operátory (viz sekce 4.1.1). Dosažené výsledky jsou shrnuty v tabulce 5.8.

Všechny absolutní chyby lokalizace arteriální stěny jsou zobrazeny v 3D grafu viz obr. 5.7. V každém obraze bylo všech deset měření podél arterie zprůměrováno a průměrná chyba v jednotlivých obrazech je graficky znázorněna v obr. 5.8. Výsledky deseti měření v každém obraze byly statisticky zpracovány a jsou zobrazeny ve formě krabicového grafu v obr. 5.9. Průměrná chyba v obrazech, kde byla hrubá lokalizace úspěšná je 4,62 px (0,354 mm).

Tab. 5.8: Shrnutí výsledků lokalizace arteriální stěny.

Parametr	Hodnota
Počet obrazů v testovací sadě	50
Počet úspěšných hrubých lokalizací	49 (98 %)
Střední chyba lokalizace (px)	4,62 px
Střední chyba lokalizace (mm)	0,354 mm


5.3 Identifikace vrstev na povrchu tepenné stěny a měření IMT

Veškeré získané výsledky byly srovnávány s přesnou hodnotou, která byla vyznačena u každého testovaného obrazu (viz sekce 4.1.2).


5.3.1 Vyhodnocení střední absolutní chyby měření IMT

Uvažujme střední hodnoty IMT ve všech obrazech obrazové sady ($n \in \langle 0, N - 1 \rangle$) měřené operátory $IMT_{n, \text{human}}$ (průměrná hodnota z měření dvou operátorů) a měřené navrženým algoritmem $IMT_{n, \text{alg}}$. Chyba v n -tém obraze lze vyjádřit vztahem


$$ERR_n = |IMT_{n, \text{human}} - IMT_{n, \text{alg}}|. \quad (5.1)$$



Obr. 5.7: Lokalizační chyby měřené v 10 místech podél arterie v 50 obrazech testovací sady.



Obr. 5.8: Střední lokalizační chyby v jednotlivých obrazech (zprůměrováno 10 měření v každém obraze).



Obr. 5.9: Statistické vyjádření lokalizačních chyb v jednotlivých obrazech.

Na obr. 5.10 je zobrazen histogram středních absolutních chyb navrženého algoritmu (ERR_n). Střední hodnota vypočítána ze všech středních absolutních chyb navrženého algoritmu je $0,82 \text{ px} \pm 0,70 \text{ px}$. Statistické hodnoty (medián, kvantily i tzv. extrémní pozorování) v souboru středních absolutních chyb lze odečíst z tzv. box plotu v obr. 5.11.

Vzhledem ke známému měřítku ($\mu\text{m}/\text{px}$) pro dané nastavení ultrazvukové stanice lze hodnoty transformovat do absolutní míry (v μm), a tak je lépe porovnat s obdobnými metodami. Po provedení této konverze dosahuje střední hodnota průměrné absolutní chyby navrženého algoritmu hodnoty $63 \mu\text{m} \pm 54 \mu\text{m}$. Dosažená hodnota střední absolutní chyby navrženého algoritmu je srovnatelná s mnohem komplexnějšími metodami, např. metoda představená Delsanto a kol.[2] dosahovala chyby $63 \mu\text{m} \pm 49 \mu\text{m}$, popř. metoda představená Molinari a kol.[77] dosahovala chyby $54 \mu\text{m} \pm 35 \mu\text{m}$. Dosažené výsledky a jejich srovnání s dalšími metodami je shrnuto v tabulce 5.9. Přímočaré porovnání dosažených výsledků s ostatními metodami (viz tabulka 5.9) je však poměrně komplikované. Mnohé metody dosahují mírně kvalitnějších výsledků, ale takové metody jsou často experimentálně zkoušeny pouze na úzkých výřezích arterie, kde jsou podmínky pro měření IMT naprosto ideální. Navíc jsou tyto metody testovány mimo reálný systém měření IMT, a tak jsou často absolutně přesně inicializovány (pokud vyžadují manuální inicializaci).

Při takových podmínkách mohou metody dosahovat kvalitnějších výsledků, avšak vyžadují množství zásahů operátora či zjednodušené podmínky.

Další značnou výhodou navržené metody je její velmi nízká výpočetní náročnost (0,2 s na Intel i5-2540M 2,6 GHz). Ostatní metody mají výpočetní náročnost řádově vyšší (viz tab. 5.9). Nejvyšší výpočetní náročnost mívají zpravidla metody založené na aktivních konturách.

Další výhoda navržené metody spočívá v její robustnosti. Navržená metoda je schopna měřit IMT i v případech, kdy není arterie vizualizována v celém obraze či je v důsledku šumu obraz velmi nekvalitní. V mnohých bodech podél arterie, které nejsou ideálně vizualizovány, není měření prováděno, a tak není výsledná průměrná hodnota IMT ovlivňována takovými hodnotami.

Tab. 5.9: Shrnutí výsledků přesnosti identifikace vrstev na povrchu arterie.

Metoda	Střední absolutní chyba (μm)	Výpočetní náročnost (s)
Navržený algoritmus	$63 \mu\text{m} \pm 54 \mu\text{m}$	0,2 s
Delsanto a kol. (μm)[2]	$63 \mu\text{m} \pm 49 \mu\text{m}$	32,0 s
Molinari a kol. (μm)[77]	$54 \mu\text{m} \pm 35 \mu\text{m}$	3,0 s
Gutierrez a kol. (μm)[86]	$90 \mu\text{m} \pm 60 \mu\text{m}$	neurčeno
Liang a kol. (μm)[91]	$42 \mu\text{m} \pm 20 \mu\text{m}$	42,0 s


5.3.2 Analýza směrodatných odchylek chyb

V této analýze jsou uvažovány všechny hodnoty IMT měřené ve všech obrazech ($n \in \langle 0, N - 1 \rangle$) a ve všech bodech podél arterie ($s \in S$). Směrodatná odchylka chyb měřená v n -tém obraze může být počítána dle vztahu


$$v_n = \sqrt{\frac{1}{S} \sum_{s=1}^S (\text{IMT}_n(s) - \overline{\text{IMT}}_n)^2}. \quad (5.2)$$

Velikost hodnoty v_n charakterizuje variabilitu změřených hodnot IMT podél arterie v n -tém obraze. Všechny směrodatné odchylky ze všech provedených měření byly analyzovány za účelem porovnat je vůči směrodatným odchylkám, kterých je dosahováno při manuálním měření. Hodnoty IMT změřené podél vizualizované části arterie by měly být konstantní, a tak by v ideálním případě měla být hodnota směrodatné odchylky nulová, popřípadě velmi nízká. Na obr. 5.12 jsou zobrazeny výsledky tohoto experimentu. Z grafu je patrné, že variabilita a její statistické hodnoty (medián, kvantily) nabývají obdobných hodnot pro manuální i automatické měření.


Velmi nízká hodnota dosažené variability svědčí o tom, že algoritmus měří hodnoty IMT podél arterie velmi přesně, především díky pečlivému výběru vhodných míst.



Obr. 5.10: Histogram zobrazující distribuci absolutních chyb.



Obr. 5.11: Box plot zobrazující střední chyby.



Obr. 5.12: Box plot porovnávající variabilitu směrodatných odchylek mezi měření provedeným operátorem a navrženým algoritmem.

6 ZÁVĚR

V rámci této dizertační práce byl navržen nový moderní systém pro měření šířky vrstev intima-media. Navržený systém je plně automatický, má velmi nízkou časovou náročnost a přitom se vyznačuje velmi dobrou přesností. Oproti ostatním současným metodám vykazuje velmi vysokou robustnost, díky které je schopen provést přesnou detekci tepny a následné měření IMT i v situacích, kdy nejsou vstupní obrazy nasnímány dostatečně kvalitně.

Důležitost automatizovaného systému je zřejmá především při pohledu na pracnost manuálního měření IMT, který je stále nejčastějším způsobem měření v současné lékařské praxi. Tato vyšetření jsou stále čtenější, neboť jsou schopny napomoci při predikci kardiovaskulárních onemocnění[20, 18, 19].

Měření hodnoty IMT je prováděno v ultrazvukových obrazech s CCA vizualizovanou v podélném řezu. Přesné měření IMT je poměrně náročná úloha, především kvůli nízkému prostorovému rozlišení ultrazvukových sond a přítomnosti artefaktů v obrazech. Vrstvy intima a media jsou velmi tenké, a proto i malá chyba při měření výrazně ovlivní výslednou šířku IMT, což může mít výrazný vliv na její medicínskou interpretaci. Proto je při měření hodnoty IMT v ultrazvukových obrazech kladen hlavní důraz na maximální přesnost měření. Dále je kladen velký důraz na spolehlivost a opakovatelnost celého měření. Současné metody jsou schopny IMT změřit v kvalitních datech, avšak často selhávají při zpracování neideálně nasnímaných obrazových materiálů.

V poslední době je důraz kladen také na maximální stupeň automatizace celého procesu měření. Automatizací měření by bylo možné odbourat tzv. inter-observer chybu (chybu měření různými operátory) a také výrazně uspořit čas a zpřístupnit tato vyšetření širšímu spektru pacientů. Díky automatické činnosti by rovněž bylo umožněno zpracování rozsáhlých databází, které je nezbytné ve vědecké oblasti pro nalezení nových souvislostí IMT a dalších onemocnění.

Celý systém pro měření šířky vrstev intima-media je velmi rozsáhlý, proto byla jeho implementace rozdělena do několika dílčích částí (dle obr. 1.3). V rámci každé dílčí části byla provedena analýza současných metod a byly implementovány nové metody, z nichž ta nejvhodnější byla využita ve výsledném řešení. V současné literatuře se můžeme setkat s množstvím metod, které se zaměřují vždy na určitou dílčí část systému a také jsou dle toho testovány. Málokteré metody jsou však fyzicky začleněny do komplexního systému tak, aby provedly kompletní proces měření IMT. Nejčastěji je v dnešní době zkoumána především oblast identifikace LI a MA rozhraní.

Prvním blokem v systému měření IMT je blok předzpracování obrazu. Jako nejvhodnější se ukázalo využití vlnkové transformace, pro jejíž přesné nastavení byl navržen postup založený na evolučních přístupech. Díky navrženému evolučnímu přístupu je zaručena optimalizace volby parametrů metody na základě objektivních parametrů extrahovaných z obrazů v testovací sadě.

Druhým blokem v systému je blok lokalizace arterie a její stěny. Byla navržena nová metoda založená na klasifikaci pixelů na základě jejich texturálních parametrů a následný post-procesing modifikovanou metodou RANSAC. Díky navržené RANSAC metodě bylo dosaženo velmi dobré robustnosti celé metody. Navržená modifikace RANSAC metody je schopna aproximovat tepnu v mnoha situacích (různá natočení v obraze, různá prohnutí), které mohou v klinické praxi nastat a se kterými mívají současné metody problémy. Následná detekce tepenné stěny opět s výhodou využívá RANSAC metody, která zde nalezne nejvhodnější proložení bodů na tepenné stěně.

Navržený systém dosahoval 98 % úspěšnosti hrubé lokalizace. Průměrná chyba aproximace arteriální stěny byla 4,62 px (0,354 mm). Dosažená přesnost lokalizace tepenné stěny je naprosto dostačující pro inicializaci navazujícího bloku detekce LI a MA rozhraní a měření IMT.

Pro identifikaci LI a MA rozhraní byla navržena nová metoda založená na pokročilé analýze gradientu. Jako velmi důležitý se v navržené metodě ukázal blok předřazený měřicímu bloku, který provádí selekci míst vhodných k měření IMT. Hlavní myšlenka selekčního bloku spočívá v předpokladu, že je výhodnější provést velmi přesná měření v méně místech podél arterie. Díky navržené selekci tedy není IMT měřena podél celé arterie v obraze, ale jsou vybrána jen nejvhodnější místa. V tomto bloku spočívá značná výhoda oproti současným metodám, které provádí měření i v místech, kde není arterie ideálně patrná a vzniklou chybu minimalizují pouze pomocí průměrování výsledné hodnoty IMT.

Blok provádějící selekci je navíc schopen vyloučit místa, kde arterie není patrná, například v důsledku nízkého přtlaku sondy při snímání. Tím se využitelnost algoritmu výrazně rozšiřuje i pro obrazy, které nejsou pořízeny dostatečně kvalitně v celé ploše obrazu. Díky navrženému bloku selekce je možné měření provést na celém pořízeném obraze (dané měřené oblasti jsou vybrány automaticky), což je značná výhoda oproti současným metodám, které často provádějí měření pouze na určitém výřezu arterie, který musí být mnohdy manuálně vybrán operátorem.

Střední hodnota průměrné absolutní chyby dosahuje hodnoty $63 \mu\text{m} \pm 54 \mu\text{m}$. Přesnost navržené metody je srovnatelná s mnohem komplexnějšími metodami, např. metoda představená Delsanto a kol.[2], respektive Molinari a kol.[77] (chyby

$63\text{ }\mu\text{m} \pm 49\text{ }\mu\text{m}$, respektive $54\text{ }\mu\text{m} \pm 35\text{ }\mu\text{m}$). Přímé srovnání s obdobnými metodami je však obtížné, neboť mnohé současné metody jsou testovány pouze na výřezech z ultrazvukových obrazů, na kterých je tepna ideálně vizualizována. Měření v takto idealizovaných podmínkách, které nekorespondují s lékařskou praxí, může dosahovat vyšší přesnosti.

Oproti současným metodám má navržená metoda i další výhody – má řádově nižší výpočetní náročnost, díky selekci vhodných míst je schopna pracovat i v neideálně nasnímaných obrazech, nevyžaduje absolutně přesnou inicializaci (nižší nároky na lokalizační proceduru).

Celý navržený systém je určen pro PC s operačním systémem Windows. Omezení na operační systém Windows nelimituje ani možnosti budoucího využití systému, neboť i kdyby se uvažovalo o případném zaimplementování navržené metody přímo do UZ stanice, nebyl by s tím žádný problém. Jednotlivé metody využívané v celém systému byly implementovány jako vzájemně spolupracující autonomní bloky. Tím bylo umožněno implementovat dílčí metody v různých programovacích jazycích (C++, Matlab a Java) dle konkrétní potřeby. Všechny dílčí metody byly otestovány a dosažené výsledky byly porovnány s jinými současnými metodami. Dílčí metody jsou přiloženy na CD.

LITERATURA

- [1] MILLER, J. L., WATKIN, K. L. Lateral pharyngeal wall motion during swallowing using real time ultrasound. *Dysphagia*, sv. 12, č. 3, s. 125–132, 1997.
- [2] DELSANTO, S., MOLINARI, F., GIUSTETTO, P., LIBONI, W., BADALAMENTI, S., SURI, J. Characterization of a completely user-independent algorithm for carotid artery segmentation in 2-d ultrasound images. *IEEE Transactions on Instrumentation and Measurement*, sv. 56, č. 4, s. 1265 –1274, Srpen 2007.
- [3] POLAK, J. F., FUNK, L. C., O’LEARY, D. H. Inter-reader differences in common carotid artery intima-media thickness: implications for cardiovascular risk assessment and vascular age determination. *Journal of ultrasound in medicine: official journal of the American Institute of Ultrasound in Medicine*, sv. 30, č. 7, s. 915–920, Červenec 2011 PMID: 21705724.
- [4] STOITSIS, J., GOLEMATI, S., KENDROS, S., NIKITA, K. S. Automated detection of the carotid artery wall in b-mode ultrasound images using active contours initialized by the hough transform. In *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, s. 3146 –3149, srpen 2008.
- [5] GRAF, S., GARIEPY, J., MASSONNEAU, M., ARMENTANO, R. L., MAN-SOUR, S., BARRA, J. G., SIMON, A., LEVENSON, J. Experimental and clinical validation of arterial diameter waveform and intimal media thickness obtained from b-mode ultrasound image processing. *Ultrasound in Medicine & Biology*, sv. 25, č. 9, s. 1353–1363, Listopad 1999.
- [6] SELZER, R. H., MACK, W. J., LEE, P. L., KWONG-FU, H., HODIS, H. N. Improved common carotid elasticity and intima-media thickness measurements from computer analysis of sequential ultrasound frames. *Atherosclerosis*, sv. 154, č. 1, s. 185–193, Leden 2001.
- [7] HODIS, H. N., MACK, W. J., LABREE, L., SELZER, R. H., LIU, C.-R., LIU, C.-H., AZEN, S. P. The role of carotid arterial intima-media thickness in predicting clinical coronary events. *Annals of Internal Medicine*, sv. 128, č. 4, s. 262–269, 1998.
- [8] DELSANTO, S., MOLINARI, F., LIBONI, W., GIUSTETTO, P., BADALAMENTI, S., SURI, J. User-independent plaque characterization and accurate

- IMT measurement of carotid artery wall using ultrasound. In *28th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2006. EMBS '06*, s. 2404–2407, Zář 2006.
- [9] WATANABE, T., KOBAYASHI, S., KAWAMURA, M., ITOKAWA, M., IDEI, T., NAKAGAWA, Y., IGUCHI, T., KATAGIRI, T. Small dense low-density lipoprotein and carotid atherosclerosis in relation to vascular dementia. *Metabolism*, sv. 53, č. 4, s. 476–482, Duben 2004.
 - [10] LORENZ, M. W., MARKUS, H. S., BOTS, M. L., ROSVALL, M., SITZER, M. Prediction of clinical cardiovascular events with carotid intima-media thickness: a systematic review and meta-analysis. *Circulation*, sv. 115, č. 4, s. 459–467, Leden 2007 PMID: 17242284.
 - [11] SILBERNAGL, S., LANG, F., AL, E. *Atlas patofyziologie člověka*. Grada Publishing, 2001.
 - [12] STRÍTESKÝ, J. *Patologie*. Epava, 2001.
 - [13] WHO / *Cardiovascular diseases (CVDs)*., 2012.
 - [14] SALONEN, R., SALONEN, J. T. Determinants of carotid intima-media thickness: a population-based ultrasonography study in eastern finnish men. *Journal of Internal Medicine*, sv. 229, č. 3, s. 225–231, Březen 1991 PMID: 2007840.
 - [15] TROJAN, S. *Lékařská fyziologie*. Grada Publishing a.s., 2003.
 - [16] KÜNZEL, D. *Lidský organismus ve zdraví a nemoci*. Avicenum, 1990.
 - [17] BONITHON-KOPP, C., SCARABIN, P. Y., TAQUET, A., TOUBOUL, P. J., MALMEJAC, A., GUIZE, L. Risk factors for early carotid atherosclerosis in middle-aged french women.. *Arteriosclerosis, Thrombosis, and Vascular Biology*, sv. 11, č. 4, s. 966–972, Červenec 1991.
 - [18] BOTS, M. L., HOES, A. W., KOUDESTAAL, P. J., HOFMAN, A., GROBBEE, D. E. Common carotid intima-media thickness and risk of stroke and myocardial infarction: the rotterdam study.. *Circulation*, sv. 96, č. 5, s. 1432–7, 1997.
 - [19] LAMONT, D., PARKER, L., WHITE, M., UNWIN, N., BENNETT, S. M. A., COHEN, M., RICHARDSON, D., DICKINSON, H. O., ADAMSON, A., ALBERTI, K. G. M. M., CRAFT, A. W. Risk of cardiovascular disease measured by carotid intima-media thickness at age 49-51: lifecourse study.

- [20] TOUBOUL, P. J., CROUSE, J. R. *Intima-Media Thickness and Atherosclerosis: Predicting the Risk?*. Parthenon Publishing Group, Duben 1997.
- [21] DELSANTO, S., MOLINARI, F., GIUSTETTO, P., LIBONI, W., BADALAMENTI, S., SURI, J. Characterization of a completely user-independent algorithm for carotid artery segmentation in 2-d ultrasound images. *IEEE Transactions on Instrumentation and Measurement*, sv. 56, č. 4, s. 1265–1274, září 2007.
- [22] KANTERS, S. D. J. M., ALGRA, A., LEEUWEN, M. S. v., BANGA, J.-D. Reproducibility of in vivo carotid intima-media thickness measurements a review. *Stroke*, sv. 28, č. 3, s. 665–671, Březen 1997.
- [23] CASELLA, I. B., PRESTI, C., PORTA, R. M. P., SABBAG, C. R. D., BOSCH, M. A., YAMAZAKI, Y. A practical protocol to measure common carotid artery intima-media thickness. *Clinics*, sv. 63, č. 4, s. 515–520, Srpen 2008 PMID: 18719764 PMCID: PMC2664129.
- [24] HRAZDIRA, I. *Úvod do ultrasonografie v otázkách a odpovědích pro studenty lékařské fakulty*. Klinika zobrazovacích metod LF MU v Brně, 2008.
- [25] MOLINARI, F., ZENG, G., SURI, J. S. A state of the art review on intima-media thickness (IMT) measurement and wall segmentation techniques for carotid ultrasound. *Computer methods and programs in biomedicine*, sv. 100, č. 3, s. 201–221, Prosinec 2010 PMID: 20478640.
- [26] STOLTZ, J. F., DONNER, M. New trends in clinical hemorheology: an introduction to the concept of the hemorheological profile. *Schweiz Med Wochenschr Suppl*, sv. 43, s. 41–49, 1991.
- [27] BENEŠ, R., ŘÍHA, K. Speckle noise suppression in ultrasound medical images. In *The 10th International Conference on Knowledge in Telecommunication Technologies and Optics*, vol. 10, s. 199–205, prosinec 2010.
- [28] SHI, Z., FUNG, K. A comparison of digital speckle filters. In *Geoscience and Remote Sensing Symposium, 1994. IGARSS '94. Surface and Atmospheric Remote Sensing: Technologies, Data Analysis and Interpretation., International*, vol. 4, s. 2129–2133 vol.4, Srpen 1994.
- [29] KAUR, A., SINGH, K. Speckle noise reduction by using wavelets. In *NCCI 2010-National Conference on Computational Instrumentation CSIO, Chandigarh, INDIA*, s. 198–203, 2010.

- [30] FOUCHER, S., BENIE, G., BOUCHER, J.-M. Multiscale MAP filtering of SAR images. *IEEE Transactions on Image Processing*, sv. 10, č. 1, s. 49–60, Leden 2001.
- [31] JANSEN, M. *Noise reduction by wavelet thresholding.*, vol. 161 Springer USA, 2001.
- [32] SUDHA, S., SURESH, G., SUKANESH, R. Speckle noise reduction in ultrasound images using context-based adaptive wavelet thresholding. *IETE Journal of Research*, sv. 55, č. 3, s. 135, 2009.
- [33] RAMACHANDRAN, S., NAIR, M. Ultrasound speckle reduction using nonlinear gaussian filters in laplacian pyramid domain. In *2010 3rd International Congress on Image and Signal Processing (CISP)*, vol. 2, s. 771–776, Říjen 2010.
- [34] RAHMAN, M. M., AZIZ, A., PK, M. K., RAJIV, M. A. N. U., UDDIN, M. S. An optimized speckle noise reduction filter for ultrasound images using anisotropic diffusion technique. *International Journal of Imaging & Robotics*, sv. 8, č. 2, s. 55–60, 2012.
- [35] LIU, S., WEI, J., FENG, B., LU, W., DENBY, B., FANG, Q., DANG, J. An anisotropic diffusion filter for reducing speckle noise of ultrasound images based on separability. In *Signal & Information Processing Association Annual Summit and Conference (APSIPA ASC), 2012 Asia-Pacific*, s. 1–4, 2012.
- [36] BENEŠ, R., ŘÍHA, K. Medical image denoising by improved kuan filter. *Advances in Electrical and Electronic Engineering*, sv. 10, č. 1, s. 43–49, 2012.
- [37] BENEŠ, R., VALOUCH, L. Biologically inspired approach for determination of set-up of wavelet based de-noising method. *Elektrorevue - Internetový časopis (<http://www.elektrorevue.cz>)*, sv. 3, č. 1, s. 20–25, 2012.
- [38] BENEŠ, R., VALOUCH, L. Evolutionary strategy for threshold estimation. *Proceedings of the 13th International Conference on Research in Telecommunication Technologies*, sv. 13, s. 174–178, 2011.
- [39] OMRAN, Y., BENEŠ, R., ŘÍHA, K. Suitable image intensity normalization for arterial visualization. *International Journal of Advances in Telecommunications, Electrotechnics, Signals and Systems*, sv. 1, č. 2-3, 2012.
- [40] LOIZOU, C. P., PATTICHIS, C. S., PANTZIARIS, M., TYLLIS, T., NICOLAIDES, A. Quality evaluation of ultrasound imaging in the carotid artery

- based on normalization and speckle reduction filtering. *Medical and Biological Engineering and Computing*, sv. 44, č. 5, s. 414–426, 2006.
- [41] BENEŠ, R., ŘÍHA. Real-time motion compensation using optical flow. In *33rd International Conference on Telecommunications and Signal Processing*, vol. 1, s. 166–170, 2010.
 - [42] BENEŠ, R., KARÁSEK, J., BURGET, R., ŘÍHA, K. Automatically designed machine vision system for the localization of CCA transverse section in ultrasound images. *Computer Methods and Programs in Biomedicine*, 2012.
 - [43] KARÁSEK, J., BENEŠ, R. Image filter design based on evolution. In *16th Conference Student EEICT 2010*, vol. 5, s. 251–255, 2010.
 - [44] KARÁSEK, J., BURGET, R., BENEŠ, R.; NAGY, L. Grammar guided genetic programming for automatic image filter design. In *The 10th International Conference on Knowledge in Telecommunication Technologies and Optics*, no. 10, s. 205–210. Ostrava: VSB- Technical University of Ostrava, 2010.
 - [45] BENEŠ, R., HASMANDA, M., ŘÍHA, K. Non- linear RANSAC method and its utilization. *Elektrorevue - Internetový časopis (<http://www.elektrorevue.cz>)*, sv. 2, č. 4, s. 7–14, 2011.
 - [46] BENEŠ, R., HASMANDA, M. Automatic artery localisation in US images. *Proceedings of the 17th Conference Student EEICT 2011 Volume 3*, č. 1, s. 88–92, Duben 2011.
 - [47] BENEŠ, R., ŘÍHA, K. Real-time motion compensation using optical flow. In *In 33rd International Conference Proceeding on Telecommunications and Signal Processing - TSP' 2010*, s. 166–170, Budapest, 2010. Asszisztencia Szervezo Kft.
 - [48] LEE, J.-S. Digital image enhancement and noise filtering by use of local statistics. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, sv. 2, s. 165–168, Březen 1980.
 - [49] FROST, V. S., STILES, J. A., SHANMUGAN, K. S., HOLTZMAN, J. C. A model for radar images and its application to adaptive digital filtering of multiplicative noise. *IEEE transactions on pattern analysis and machine intelligence*, sv. 4, č. 2, s. 157–166, Únor 1982 PMID: 21869022.
 - [50] ZHANG, F., LIU, W., WANG, J., ZHU, Y., XIA, L. Anisotropic partial differential equation noise-reduction algorithm based on fringe feature for ESPI. *Optics Communications*, sv. 282, č. 12, s. 2318–2326, Červen 2009.

- [51] GAGNON, L., JOUAN, A. Speckle filtering of SAR images: a comparative study between complex-wavelet-based and standard filters. In *Optical Science, Engineering and Instrumentation'97*, s. 80–91, 1997.
- [52] KUAN, D. T., SAWCHUK, A. A., STRAND, T. C., CHAVEL, P. Adaptive noise smoothing filter for images with signal-dependent noise. *IEEE Trans. Pattern Anal. Mach. Intell.*, sv. 7, č. 2, s. 165–177, Únor 1985.
- [53] LOPES, A., TOUZI, R., NEZRY, E. Adaptive speckle filters and scene heterogeneity. *IEEE Transactions on Geoscience and Remote Sensing*, sv. 28, č. 6, s. 992–1000, Listopad 1990.
- [54] SUDHA, S., SURESH, G., SUKANESH, R. Speckle Noise Reduction in Ultrasound Images Using Context-based Adaptive Wavelet Thresholding. *IETE Journal of Research*, sv. 55, č. 3, s. 135–143, 2009.
- [55] DONOHO, D. De-noising by soft-thresholding. *IEEE Transactions on Information Theory*, sv. 41, č. 3, s. 613–627, 1995.
- [56] RUIKAR, S. D., DOYE, D. D. Wavelet based image denoising technique. *International Journal of Advanced Computer Science and Applications*, sv. 2, č. 3, s. 49–53, 2011.
- [57] LUISIER, F., BLU, T., UNSER, M. A new SURE approach to image denoising: Interscale orthonormal wavelet thresholding. *Image Processing, IEEE Transactions on*, sv. 16, č. 3, s. 593–606, 2007.
- [58] CHANG, S. G., YU, B., VETTERLI, M. Adaptive wavelet thresholding for image denoising and compression. *Image Processing, IEEE Transactions on*, sv. 9, č. 9, s. 1532–1546, 2000.
- [59] ROCKING, O. *Image Fusion*. Online.
- [60] NIROSHA JOSHITHA, J., SELIN, R. M. Image fusion using PCA in multifeature based palmprint recognition. *International Journal of Soft Computing and Engineering*, sv. 2, č. 2, s. P2, 2012.
- [61] JAIN, A. K. *Fundamentals of Digital Image Processing*. Prentice Hall, 1 edition, Říjen 1988.
- [62] YU, Y., ACTON, S. Speckle reducing anisotropic diffusion. *IEEE Transactions on Image Processing*, sv. 11, č. 11, s. 1260 – 1270, listopad 2002.

- [63] AJA-FERNANDEZ, S., ALBEROLA-LOPEZ, C. On the estimation of the coefficient of variation for anisotropic diffusion speckle filtering. *IEEE Transactions on Image Processing*, sv. 15, č. 9, s. 2694–2701, 2006.
- [64] ZHANG, Y., CHENG, D., H., TIAN, J., HUANG, J. A novel speckle reduction and contrast enhancement method based on fuzzy anisotropic diffusion. In *Proc. 17th IEEE Int Image Processing (ICIP) Conf*, s. 4161–4164, 2010.
- [65] YU, Y., ACTON, S. Speckle reducing anisotropic diffusion. *IEEE Transactions on Image Processing*, sv. 11, č. 11, s. 1260 – 1270, Listopad 2002.
- [66] LOIZOU, C. P., PATTICHIS, C. S., CHRISTODOULOU, C. I., ISTEPANIAN, R. S. H., PANTZIARIS, M., NICOLAIDES, A. Comparative evaluation of despeckle filtering in ultrasound imaging of the carotid artery. *Ultrasonics, Ferroelectrics and Frequency Control, IEEE Transactions on*, sv. 52, č. 10, s. 1653–1669, 2005.
- [67] CHENG, D.-C., SCHMIDT-TRUCKSASS, A., SHENG CHENG, K., BURKHARDT, H. Using snakes to detect the intimal and adventitial layers of the common carotid artery wall in sonographic images. *Computer Methods and Programs in Biomedicine*, sv. 67, č. 1, s. 27 – 37, 2002.
- [68] SELZER, R. H., HODIS, H. N., KWONG-FU, H., MACK, W. J., LEE, P. L., RAN LIU, C., HUA LIU, C. Evaluation of computerized edge tracking for quantifying intima-media thickness of the common carotid artery from b-mode ultrasound images. *Atherosclerosis*, sv. 111, č. 1, s. 1 – 11, 1994.
- [69] LIGUORI, C., PAOLILLO, A., PIETROSANTO, A. An automatic measurement system for the evaluation of carotid intima-media thickness. *IEEE Transactions on Instrumentation and Measurement*, sv. 50, č. 6, s. 1684 –1691, 2001.
- [70] CHENG, D. C., PU, Q., SCHMIDT-TRUCKSAESS, A., LIU, C. H. A novel method in detecting cca lumen diameter and imt in dynamic b-mode sonography. In MAGJAREVIC, R., LIM, C. T., GOH, J. C. H., editors, *13th International Conference on Biomedical Engineering*, vol. 23 of *IFMBE Proceedings*, s. 734–737. Springer Berlin Heidelberg, 2009.
- [71] PIGNOLI, P., LONGO, T. Evaluation of atherosclerosis with b-mode ultrasound imaging. *The Journal of nuclear medicine and allied sciences*, sv. 32, č. 3, s. 166–173, Zář 1988 PMID: 3066862.

- [72] FAN, L., SANTAGO, P., JIANG, H., HERRINGTON, D. Ultrasound measurement of brachial flow-mediated vasodilator response. *IEEE Transactions on Medical Imaging*, sv. 19, č. 6, s. 621 –631, červen 2000.
- [73] WAN, J., RUAN, Q., LI, W. Using two methods for recognition common carotid artery of b-mode longitudinal ultrasound image. In *Signal Processing (ICSP), 2010 IEEE 10th International Conference on*, s. 1 –4, září 2010.
- [74] ABDEL-DAYEM, A., EL-SAKKA, M. Fuzzy c-means clustering for segmenting carotid artery ultrasound images. In KAMEL, M., CAMPILHO, A., editors, *Image Analysis and Recognition*, vol. 4633 of *Lecture Notes in Computer Science*, s. 935–948. Springer Berlin / Heidelberg, 2007.
- [75] ROSSI, A. C., BRANDS, P. J., HOEKS, A. P. Automatic recognition of the common carotid artery in longitudinal ultrasound b-mode scans. *Medical Image Analysis*, sv. 12, č. 6, s. 653 – 665, 2008 Special issue on information processing in medical imaging 2007.
- [76] GOLEMATI, S., STOITSIS, J., SIFAKIS, E. G., BALKIZAS, T., NIKITA, K. S. Using the hough transform to segment ultrasound images of longitudinal and transverse sections of the carotid artery. *Ultrasound in Medicine & Biology*, sv. 33, č. 12, s. 1918 – 1932, 2007.
- [77] MOLINARI, F., ZENG, G., SURI, J. S. An integrated approach to computer-based automated tracing and its validation for 200 common carotid arterial wall ultrasound images: a new technique. *Journal of ultrasound in medicine: official journal of the American Institute of Ultrasound in Medicine*, sv. 29, č. 3, s. 399–418, Březen 2010 PMID: 20194936.
- [78] KARASEK, J., BENEŠ, R., BURGET, R., NAGY, L. Grammar guided genetic programming for automatic image filter design. In *The 10th International Conference on Knowledge in Telecommunication Technologies and Optics.*, s. 205–210, Ostrava, 2010. VSB- Technical University of Ostrava.
- [79] CHENG, D.-C., CHENG, K.-S., SCHMIDT-TRUCKSÄSS, A., SANDROCK, M., PU, Q., BURKHARDT, H. Automatic detection of the intimal and the adventitial layers of the common carotid artery wall in ultrasound b-mode images using snakes. In *Proceedings of the 10th International Conference on Image Analysis and Processing, ICIAP '99*, s. 452–, Washington, DC, USA, 1999. IEEE Computer Society.
- [80] KASS, M., WITKIN, A., TERZOPOULOS, D. Snakes: Active contour models. *International Journal of Computer Vision*, sv. 1, s. 321–331, 1988.

- [81] COHEN, L. D. On active contour models and balloons. *CVGIP: Image Understanding*, sv. 53, s. 211–218, březn 1991.
- [82] NEUENSCHWANDER, W. M., FUA, P., IVERSON, L., SZEKELY, G., KUBLER, O. Ziplock snakes. *International Journal of Computer Vision*, sv. 25, s. 191–201, 1997.
- [83] NIXON, M., AGUADO, A. S. *Feature Extraction & Image Processing, Second Edition*. Academic Press, 2nd edition, 2008.
- [84] WILLIAMS, D. J., SHAH, M. A fast algorithm for active contours and curvature estimation. *CVGIP: Image Understanding*, sv. 55, č. 1, s. 14 – 26, 1992.
- [85] LOIZOU, C. P., PATTICHIS, C. S., ISTEPANIAN, R. S. H., PANTZIARIS, M., TYLLIS, T., NICOLAIDES, A. Intima media segmentation of the carotid artery. In *IEEE Int X Mediterr Conf Medicon Med Biol Eng POS-03*, vol. 499, s. 1–4, 2004.
- [86] GUTIERREZ, M., PILON, P., LAGE, S., KOPEL, L., CARVALHO, R., FURUE, S. Automatic measurement of carotid diameter and wall thickness in ultrasound images. In *Computers in Cardiology, 2002*, s. 359 – 362, Zář 2002.
- [87] GUTIERREZ, M., PILON, P., LAGE, S., KOPEL, L., CARVALHO, R., FURUE, S. Automatic measurement of carotid diameter and wall thickness in ultrasound images. In *Computers in Cardiology, 2002*, s. 359 – 362, zář 2002.
- [88] CHENG, D.-C., JIANG, X. Detections of arterial wall in sonographic artery images using dual dynamic programming. *IEEE Transactions on Information Technology in Biomedicine*, sv. 12, č. 6, s. 792 –799, leden 2008.
- [89] LEE, Y.-B., CHOI, Y.-J., KIM, M.-H. Boundary detection in carotid ultrasound images using dynamic programming and a directional haar-like filter. *Comput. Biol. Med.*, sv. 40, s. 687–697, zář 2010.
- [90] HOLDFELDT, P., VIBERG, M., GUSTAVSSON, T. A new method based on dynamic programming for boundary detection in ultrasound image sequences. In *30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2008. EMBS 2008*, s. 3072–3074, 2008.
- [91] LIANG, Q., WENDELHAG, I., WIKSTRAND, J., GUSTAVSSON, T. A multiscale dynamic programming procedure for boundary detection in ultrasonic artery images. *IEEE Transactions on Medical Imaging*, sv. 19, č. 2, s. 127 –142, únor 2000.

- [92] RUBBA, P., MERCURI, M., FACCENDA, F., IANNUZZI, A., IRACE, C., STRISCIUGLIO, P., GNASSO, A., TANG, R., ANDRIA, G AND BOND, M. Premature carotid atherosclerosis: does it occur in both familial hypercholesterolemia and homocystinuria? ultrasound assessment of arterial intima-media thickness and blood flow velocity. *Stroke*, sv. 25, č. 5, s. 943–950, 1994.
- [93] GUSTAVSSON, T., ABU-GHARBIEH, R., HAMARNEH, G., LIANG, Q. Implementation and comparison of four different boundary detection algorithms for quantitative ultrasonic measurements of the human carotid artery. In *Computers in Cardiology 1997*, s. 69 –72, září 1997.
- [94] FAITA, F., GEMIGNANI, V., BIANCHINI, E., GIANNARELLI, C., GHIADONI, L., DEMI, M. Real-time measurement system for evaluation of the carotid intima-media thickness with a robust edge operator. *Journal of Ultrasound in Medicine*, sv. 27, č. 9, s. 1353–1361, Zář 2008 PMID: 18716145.
- [95] DESTREMPES, F., MEUNIER, J., GIROUX, M., SOULEZ, G., CLOUTIER, G. Segmentation in ultrasonic b-mode images of healthy carotid arteries using mixtures of nakagami distributions and stochastic optimization. *IEEE Transactions on Medical Imaging*, sv. 28, č. 2, s. 215–229, 2009.
- [96] PRINOSIL, J., SMEKAL, Z., BARTUSEK, K. Wavelet thresholding techniques in MRI domain. In *2010 International Conference on Biosciences (BIOSCIENCESWORLD)*, s. 58 –63, Březen 2010.
- [97] LIENHART, R., MAYDT, J. An extended set of haar-like features for rapid object detection. In *Image Processing. 2002. Proceedings. 2002 International Conference on*, vol. 1, s. I–900, 2002.
- [98] VAPNIK, V. Pattern recognition using generalized portrait method. *Automation and Remote Control*, sv. 24, s. 774–780, 1963.
- [99] BELOUSOV, A. I., VERZAKOV, S. A., VON FRESE, J. Applicational aspects of support vector machines. *Journal of Chemometrics*, sv. 16, č. 8-10, s. 482–489, 2002.
- [100] HARTLEY, R., ZISSERMAN, A. *Multiple View Geometry in Computer Vision*. Cambridge University Press, New York, NY, USA, 2 edition, 2003.
- [101] TREFETHEN, L. N., III, D. B. *Numerical Linear Algebra*. SIAM, Červen 1997.
- [102] HARTLEY, R., ZISSERMAN, A. *Multiple View Geometry in Computer Vision*. Cambridge University Press, Březen 2004.

- [103] PERONA, P., MALIK, J. Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, sv. 12, č. 7, s. 629–639, Červenec 1990.
- [104] TOMASI, C., MANDUCHI, R. Bilateral filtering for gray and color images. In *Computer Vision, 1998. Sixth International Conference on*, s. 839–846, 1998.
- [105] BUADES, A., COLL, B., MOREL, J. M. A non-local algorithm for image denoising. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, vol. 2, s. 60–65, 2005.
- [106] RUDIN, L. I., OSHER, S., FATEMI, E. Nonlinear total variation based noise removal algorithms. *Physica D: Nonlinear Phenomena*, sv. 60, č. 1, s. 259–268, 1992.
- [107] MOLINARI, F., ZENG, G., SURI, J. S. Intima-media thickness: setting a standard for a completely automated method of ultrasound measurement. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, sv. 57, č. 5, s. 1112–1124, Květen 2010 PMID: 20442021.

SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK

AS	Artery stiffness, tuhost tepny
CAD	Computer aided diagnosis, počítačem podporované vyšetření
CAM	Cost accumulation matrix, akumulární matice účelové funkce
CCA	Common carotid artery, krkavice
CIMT	Carotid intima media thickness, šířka intima-media měřená na krkavici
CT	Computer tomography, počítačová tomografie
CVD	Cardiovascular diseases, kardiovaskulární onemocnění
DDP	Dual dynamic programing, duální dynamické programování
DP	Dynamic programming, dynamické programování
DPAD	Detail preserving anisotropic diffusion
DWT	Discrete wavelets transform, diskrétní vlnková transformace
EA	Evolutionary algorithm, evoluční algoritmus
ECA	External carotid artery, zevní krkavice
FOAM	First-order absolute moment edge operator
GGD	Generalized normal distribution, zobecněné Gaussovo rozdělení
GGGP	Grammar guided genetic programming, gramatikou řízené genetické programování
HT	Hough transform, Houghova transformace
CHT	Circulat Hough transform, Houghova transformace pro detekci kruhů
ICA	Internal carotid artery, vnitřní krkavice
IDWT	Inverse discrete wavelets transform, inverzní diskrétní vlnková transformace
IMT	Intima-media thickness, šířka intima-media vrstev
IVUS	Intravascular ultrasound, intravaskulární ultrazvuk

JEF Java evolution framework
 KVO Kardiovaskulární onemocnění
 LD Lumen diameter, průměr tepny
 LI Lumen-intima interface, lumen-intima rozhraní
 LOOCV Leave one out cross validation
 LPND Laplacian pyramid-based nonlinear diffusion
 MA Media-adventitia interface, media-adventicia rozhraní
 MMSE Minimum mean square error
 MRI Magnetic resonance imaging, magnetická rezonance
 NCD Nonlinear coherent diffusion
 NLMS Normalised least mean squares filter
 PCA Principal component analysis, analýza hlavních komponent
 PDE Partial differential equations, parciální diferenciální rovnice
 PSNR Peak signal-to-noise ratio, špičkový poměr signálu k šumu
 RANSAC Random sample consensus
 RBF Radial basis function
 ROI Region of interest, oblast zájmu
 SNR Signal-to-noise ratio, poměr signálu k šumu
 SRAD Speckle reduction anisotropic diffusion
 SURE Stein's unbiased risk estimate
 SVM Support vector machine
 TDP Traditional dynamic programming, tradiční dynamické programování
 TGC Time Gain Compensation, časová kompenzace zisku
 UZ Ultrazvuk
 WHO World health organization, světová zdravotnická organizace

B	Lomená čára představující řešení dynamického programování
c_{AB}	Kontrast v obraze
$C(B)$	Účelová funkce
E_{edge}	Energie hran
E_{snake}	Energie aktivní kontury
E_{int}	Interní energie aktivní kontury
E_{line}	Energie přímek
E_{ext}	Externí energie aktivní kontury
E_{term}	Energie zakončení
ERR_n	Průměrná chyba v n -tém obraze
f_M	MacLeod operátor
I	Vstupní obraz
I_r	Referenční intenzita
IMT_n	Průměrná hodnota IMT v n -tém obraze
$\text{IMT}_{n,\text{human}}$	Průměrná hodnota IMT v n -tém obraze změřená operátorem
$\text{IMT}_{n,\text{alg}}$	Průměrná hodnota IMT v n -tém obraze změřená algoritmem
$l_{\text{IMT_mean}}$	Střední hodnota IMT
$l_m(x)$	Intenzitní profil
$l_{m,\text{LI}}$	Intenzita odpovídající LI rozhraní
m	Strmost hrany
N	Délka signálu
$\mathbf{p}$	Model křivky
s_n	Směrodatná odchylka chyb v n -tém obraze
τ	Vzorkovací interval
$W(t)$	Váhovací funkce využitá u Kuan filtru

$W'(t)$ Modifikovaná váhová funkce využitá u Kuan filtru

$w_1(s)$ Koeficient elasticity

$w_2(s)$ Koeficient tuhosti

A OBSAH CD

Přiložené CD obsahuje

- text dizertační práce,
- zdrojové kódy,
 - navržené filtry pro prostředí RapidMiner,
 - navržené scénáře pro prostředí RapidMiner,
 - navržené zdrojové kódy v matlabu,
- RapidMiner.

Radek Beneš

KONTAKT

Lhota 291, Červený Kostelec
radek.benes@phd.feec.vutbr.cz
723847171

VZDĚLÁNÍ

2009 - 2013	Ústav telekomunikací, Vysoké učení technické v Brně, Doktorský studijní program
2007 - 2009	Ústav telekomunikací, Vysoké učení technické v Brně, Magisterský studijní program
2004 - 2007	Ústav telekomunikací, Vysoké učení technické v Brně, Bakalářský studijní program

PROJEKTY

2012	FRVŠ (2567/2012/G1) – Inovace výuky počítačových cvičení a příslušných podkladů k předmětu Pokročilé techniky zpracování obrazu.
2012	FRVŠ (1347/2012/F1/a) – Inovace náplně a vybavení výuky zpracování obrazu
2011	FRVŠ (2502/2011/G1) – Rozšíření studijních podkladů k předmětu Pokročilé techniky zpracování obrazu
2010 – 2011	MSM (2B06111) – Nové diagnostické metody zjišťování parametrů oběhového systému založené na infračerveném snímání obrazu krevního řečiště

CELKOVÉ VÝSLEDKY

Počet publikací (z toho s IF)	Vydané: 25 (2) V tisku: 1 (1)
Počet patentů	2
Počet užitečných vzorů	1
Počet produktů	8

OCENĚNÍ

2007	Cena děkana
2009	Cena děkana
2009	Cena rektora
2009	EEICT – 1. místo v kategorii zpracování obrazu
2011	EEICT – 2. místo v kategorii zpracování obrazu