

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

**FAKULTA ELEKTROTECHNIKY
A KOMUNIKAČNÍCH TECHNOLOGIÍ**

ÚSTAV TELEKOMUNIKACÍ

Ing. Radek Beneš

**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**

ZKRÁCENÁ VERZE PH.D. THESIS

Obor: Teleinformatika

Školitel: Ing. Kamil Říha, Ph.D.

Oponenti:

Datum obhajoby:

KLÍČOVÁ SLOVA

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

KEYWORDS

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

Dizertační práce je k dispozici na Vědeckém oddělení děkanátu FEKT VUT v Brně, Technická 10, Brno, 616 00

OBSAH

1	Šířka vrstev intima-media	5
1.1	Anatomické vlastnosti CCA	5
1.2	Automatický systém pro měření IMT	6
2	Cíl dizertační práce	6
2.1	Zkoumané metody pro dosažení vytyčených cílů	7
3	Současný stav poznání	7
3.1	Lokalizace arterie a její stěny	7
3.1.1	Lokalizace arterie založená na analýze gradientu	8
3.1.2	Lokalizace arterie založená na lokální statistice	8
3.1.3	Lokalizace arterie založená na podobnostní analýze	8
3.1.4	Lokalizace arterie založená na Houghově transformaci	8
3.2	Identifikace vrstev na tepenné stěně a měření IMT	9
3.2.1	Metody založené na aktivních konturách	9
3.2.2	Metody založené na dynamickém programování	9
4	Navržené řešení	9
4.1	Redukce šumu s využitím vlnkové transformace	9
4.1.1	Princip nalezení nejvhodnějších parametrů metody	10
4.2	Lokalizace arterie a její stěny	11
4.2.1	Extrakce lokálních texturních příznaků	11
4.2.2	SVM klasifikátor	11
4.2.3	Modifikovaný RANSAC algoritmus	12
4.2.4	Blok analýzy gradientu	15
4.2.5	Následné zpracování prvotních tepenných bodů	15
4.3	Identifikace vrstev na povrchu tepenné stěny a měření IMT	17
4.3.1	Identifikace míst vhodných pro měření IMT	17
4.3.2	Identifikace LI a MA rozhraní	18
4.3.3	Měření hodnoty IMT	19
5	Dosažené výsledky	19
5.1	Redukce šumu s využitím vlnkové transformace	19
5.2	Lokalizace arterie a její stěny	20
5.2.1	Porovnání SVM klasifikátoru s lineárním a nelineárním jádrem	20
5.2.2	Trénování SVM klasifikátoru a výběr nejvhodnějších příznaků	20
5.2.3	Výsledná úspěšnost SVM klasifikátoru	21
5.2.4	Úspěšnost hrubé lokalizace	21
5.2.5	Testování odolnosti metody založené na RANSAC algoritmu	21
5.2.6	Výsledná úspěšnost přesné lokalizace tepenné stěny	22
5.3	Identifikace vrstev na povrchu tepenné stěny a měření IMT	22
5.3.1	Vyhodnocení střední absolutní chyby měření IMT	24
5.3.2	Analýza směrodatných odchylek chyb	24
6	Závěr	25
	Literatura	27

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. 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.).

Jedním z mnoha případů, ve kterých je vhodné celý postup vyšetření automatizovat, je měření statických a dynamických parametrů arterií[1], jako například měření průměru arterie (*lumen diameter* – LD)[2], tuhosti tepenné stěny (*arterial stiffness* – AS)[3], či šířky specifických vrstev (*intima* a *media*) na povrchu tepenné stěny (*intima media thickness* – IMT[4]). 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[5]. Přítomnost plaku na stěnách arterií je navíc korelována se vznikem patologických degenerativních změn jako jsou vaskulární demence či Alzheimerova choroba[6, 7].


Arterii lze neinvazivně vizualizovat pomocí vysoko-rozlišujícího (B-mode) ultrazvukového zobrazení v příčném řezu (*transversal scan*) a podélném řezu (*longitudinal scan*). Pro měření šířky vrstev na povrchu arterie je vhodnější příčný řez arterií, kde mají stěny arterie přibližně přímkový charakter a na stěnách jsou patrné vrstvy intima a media. 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). Vrstvy na tepenné stěně v B-mode ultrazvukovém obraze jsou tenké 7 až 15 pixelů. Segmentace takto drobných útvarů je velmi komplikovaným úkolem.

1 ŠÍŘKA VRSTEV INTIMA-MEDIA

V současné době je šířka IMT nejčastěji měřena vyšetřujícím lékařem manuálně vyznačením bodů podél arterie v obraze. 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[8]. Další nevýhoda manuálního přístupu spočívá v obtížném zpracování rozsáhlé databáze dat. Nevýhody manuální metody, popřípadě nedokonalosti současných poloautomatických metod podněcují vývoj nových metod měření IMT.

1.1 Anatomické vlastnosti CCA

Na tepenné stěně se nachází trojice vrstev – *intima*, *media* a *adventicia*. 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[9] až 1,0 mm[10]). Mnohé studie[11, 12] 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 pouze riziko KVO, ale rovněž další faktory jako např. věk, pohlaví, krevní tlak, diabetes mellitus, kouření[11]. Korelace s věkem je celkem lineární – průměrný roční nárůst šíře IMT je obvykle 0,01 mm/rok až 0,015 mm/rok[13].




Obr. 1: Ultrazvukový obraz podélného řezu krkavicí (CCA) a detail tepenné stěny.

1.2 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. 1.1)

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



Obr. 1.1: Blokové schéma systému pro automatické měření IMT.

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).

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.

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 se všemi komplikujícími faktory.

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.

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. 1.1. 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

- vylepšená varianta Kuan filtru (*KuanS*)[41, 42],
- využití fúze obrazů pro redukci šumu,
- využití vlnkové transformace, jejíž parametry jsou optimalizovány s využitím evolučních přístupů[43, 44].

Další výzkum v oblasti předzpracování obrazu byl zaměřen na

- normalizaci intenzity obrazů arterií – navržena metoda[45], která vychází z metody[14], avšak normalizace intenzity je prováděna bez nutnosti interakce s uživatelem,
- stabilizaci videosekvence[46], 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[47, 48, 49] 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.

3 SOUČASNÝ STAV POZNÁNÍ

V této kapitole jsou shrnuty metody dnes nejčastěji využívané v systémech pro měření šířky komplexu vrstev intima-media. Členění koresponduje s dělením systémů pro měření IMT (viz obr. 1.1).

3.1 Lokalizace arterie a její stěny

V dnešní době je v převážné většině systémů pro měření IMT využíváno buď pouze manuální lokalizace arterie, jako např. Cheng a kol.[15], kde musí obsluhující osoba (dále *operátor*) vyznačit dva body ležící na tepenné stěně, nebo v metodě navržené Selzerem a kol.[16], kde musí operátor dokonce vyznačit více bodů ležících podél celé tepenné stěny.

Lokalizační procedura může vykazovat jisté znaky částečné automatizace, např. pokud uživatel pouze specifikuje přibližné umístění arterie (tzv. *region of interest* – ROI)[17, 18]. 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, že je tepna zachycena horizontálně, že není prohnutá, či předpokládají její přesné texturní parametry. Při nesplnění těchto omezujících podmínek metody selhávají.

3.1.1 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 [19]. Metody využívající takto jednoduché analýzy gradientu jsou obecně náchylné ke všem výše vyjmenovaným nežádoucím jevům při zobrazení.

3.1.2 Lokalizace arterie založená na lokální statistice

Fan a kol.[20] 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.

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[21] jsou však manuální, a tak nevhodné pro automatické systémy.

3.1.3 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. Lokalizační metoda založená na podobnosti byla využita např. v[22].

3.1.4 Lokalizace arterie založená na Houghově transformaci

V různých publikacích bylo zkoumáno využití *Houghovy transformace* (HT)[23] pro lokalizaci arterie v obrazech, které ji zachycují v příčném i podélném řezu. Pro lokalizaci v příčném řezu je využívána varianta, která je navržena pro hledání kruhovitých vzorů v obraze (tzv. *circular Hough transform* – CHT). Pro lokalizaci v podélném řezu je využito standardní HT.

Molinary a kol.[24] navrhl vylepšení, které mírně potlačuje omezení dříve navržených metod. Navrhl vícenásobné využití HT pro dílčí segmenty arterie, která tak již jako celek nemusí vykazovat přímkový charakter. Komplikace algoritmu spočívá v následném zpracování nalezených přímk tak, aby ve výsledku spojitě reprezentovaly tepennou stěnu.

3.2 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. Na základě znalosti polohy LI a MA rozhraní lze následně provést měření IMT.

3.2.1 Metody založené na aktivních konturách

Aktivní kontura je modelována množinou vzájemně propojených bodů. 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 3.1).

Obecná metoda, představená Kass a kol.[25], vychází z křivky, kterou lze parametricky popsat rovnicí $v(s) = [x(s), y(s)]^T$, 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

$$E_{\text{snake}}(v) = E_{\text{int}}(v) + E_{\text{ext}}(v), \quad (3.1)$$

kde $E_{\text{int}}(v)$ představuje interní energii a $E_{\text{ext}}(v)$ externí energii.

Díky oblibě metod aktivních kontur vzniklo množství modifikací základního principu, jako jsou

- **Cohenova aktivní kontura**, která přidává mezi externí energie rozpínavou sílu,
- **Ziplock aktivní kontura**, která expanduje z krajních iniciálních bodů, a tak snižuje nároky na počáteční inicializaci,
- kontura využívající **tzv. hladový minimalizační algoritmus**, která redukuje výpočetní náročnost zjednodušujícími předpoklady,
- **aktivní kontura v kombinaci s mnoha-měřítkovým přístupem**, která umožňuje rychlejší konvergenci a větší robustnost vůči šumu.

3.2.2 Metody založené na dynamickém programování

Techniky založené na dynamickém programování (DP) operují s obrazovou informací obsaženou v analyzovaném obraze a zároveň s parametry hledaného řešení (modelovaného lomenou čarou)[26]. 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.

Řešení je hledáno s využitím akumulací matice účelové funkce (cost accumulation matrix – CAM), kde je zanesena informace o tom, s jakou nejmenší akumulovanou vahou lze daného bodu matice dosáhnout. Výsledné řešení je nalezeno jako nejmenší hodnota v pravém sloupci a řešení se odtud dále zpětně trasuje přes celou matici[27].


V současné době je navíc základní princip různě modifikován, například zahrnutím anatomických znalostí o segmentované oblasti (**duální dynamické programování**) nebo **zpracováním vstupního obrazu v různých rozlišeních**.

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.

4.1 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. Nevýhodou takových metod je komplikované nastavení jejich



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

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.

4.1.1 Princip nalezení nejvhodnějších parametrů metody

Bylo využito evoluční strategie, která optimalizuje nastavení metody s ohledem na dosažení co nejvyšší kvality redukce šumu. Kvalita redukce šumu je vyhodnocována pomocí hodnot střední kvadratické odchylky (MSE – mean squared error), strmosti hrany, relativního kontrastu a směrodatné odchylky[28]. Všechny hodnoty byly určeny v množině zvolených míst v každém obraze trénovací sady a byly shrnuty do jedné výsledné hodnoty, která byla využita jako fitness funkce v evoluční strategii.

Princip evoluční strategie

Evoluční strategie, která hledá nejvhodnější nastavení parametrů redukce šumu, se pak řídí následujícím algoritmem

1. Vygeneruj počáteční populaci.

Počáteční populaci 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.

2. Všechny jedince z počáteční populace ohodnoť 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.

4. Aplikuj genetické operátory.

Vybrání jedinci z populace jsou modifikovány využitím genetických operátorů. Bylo využito operátorů mutace a křížení.

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.

Ukončovací kritérium bylo v našem případě definováno pomocí metody včasného zastavení (*early stop*) i pomocí maximálního počtu iterací.

4.2 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. 4.1). 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 a tu opět aproximuje polynomiální křivkou.

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 vhodné proložení těchto bodů. Výsledkem tak je aproximace tepny pomocí polynomiální křivky (model tepny).

Úkolem bloku **přesné lokalizace tepenné stěny** je nalezení parametrů polynomiální křivky, která aproximuje tepennou stěnu. Principiálně je tento blok složen ze dvou dílčích kroků. Nejprve je analyzován gradient ve směru kolmém k tepně a jsou nalezeny tzv. prvotní tepenné body (zobrazeny na obr. 4.4 jako červené body, popř. na obr. 4.5 jako fialové body). Následně jsou tyto body zpracovány RANSAC algoritmem, aby byly potlačeny případné nepřesnosti.

4.2.1 Extrakce lokálních texturních příznaků

Extrakci lokálních texturních příznaků v jednotlivých místech vstupního obrazu se rozumí výpočet parametrů, které popisují vlastnosti bodu a jeho blízkého okolí. Lokálních příznaků existuje nespočet, např. střední hodnota, mediánová hodnota, homogenita, Haarovy příznaky[29], 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. Byl implementován evoluční mechanismus, který automaticky provede výběr nejvhodnějších příznaků (viz sekce 4.2.2).

4.2.2 SVM klasifikátor

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

- „body uvnitř arterie“ (např. na obr. 4.2 (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 nejpresnější klasifikaci. Z tohoto důvodu je nutné sadu všech možných příznaků (bude označována jako *plný příznakový vektor*) redukovat. Využitý evoluční přístup zaručuje výběr nejvhodnějších lokálních příznaků a tím je dosaženo maximální přesnosti klasifikátoru. Základní lineární SVM klasifikátor[30] může být rozšířen i na případy, kde data nejsou lineárně separabilní. V takovém případě jsou data mapována do prostoru vyšší dimenze, kde mohou být data lépe separována.

Trénování SVM klasifikátoru a výběr nejvhodnějších příznaků

Klasifikátor SVM vyžaduje nízký počet vzájemně nekorelovaných příznaků, a proto byla navržena evoluční metoda pro redukcii příznaků (nalezení nejvhodnější množiny příznaků). 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.

Populaci se rozumí sada jedinců = sada podmnožin plného příznakového vektoru (viz 4.2.2).

2. Proveď genetické operace, jako jsou mutace či křížení za účelem úpravy jedinců.

Tyto operace zapříčiní vlastní změnu v podmnožině vybraných příznaků.

3. Ohodnoť dané jedince pomocí fitness funkce (viz sekce 4.2.2).

- 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.

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.

4.2.3 Modifikovaný RANSAC algoritmus

V této sekci je popsána jedna ze stěžejních komponent navrženého řešení, která má za úkol dříve klasifikované body zpracovat a proložit modelem arterie. Tato navržená komponenta je založena na principech RANSAC[31] algoritmu, který je v dané implementaci schopen nalézt nejvhodnější proložení bodů „uvnitř arterie“ modelem arterie (modelem arterie rozumíme aproximaci středu tepny 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.

S ohledem na možný mírně prohnutý charakter tepny v podélném řezu byl standardní RANSAC algoritmus modifikován. Navržená modifikace spočívá ve využití polynomiálního modelu arterie, který lze zapsat pomocí rovnice

$$y = p_2 \cdot x^2 + p_1 \cdot x + p_0. \quad (4.1)$$



Obr. 4.2: 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.

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[31] algoritmu nazývají jako tzv. *outliers*. V naší implementaci, kdy je předřazený klasifikátor velmi přesný, jsou chybně klasifikované body většinou izolované nebo tvoří malé shluky, ale nikdy netvoří tak komplexní shluky 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.

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 dále).
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 dále).
 - (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 nejkvalitnější 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 nejkvalitnějším modelem (detailně popsáno dále).

Proložení křivky třemi body


K nalezení parametrů křivky je nutná znalost polohy tří bodů $\mathbf{x}_i = [x_i, y_i]$, $i = 0, 1, 2$. Tento fakt lze zapsat v maticovém tvaru

$$\begin{bmatrix} y_0 \\ y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} x_0^2 & x_0 & 1 \\ x_1^2 & x_1 & 1 \\ x_2^2 & x_2 & 1 \end{bmatrix} \cdot \begin{bmatrix} p_2 \\ p_1 \\ p_0 \end{bmatrix}. \quad (4.2)$$

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

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. 4.3).



Obr. 4.3: Demonstrace měření vzdálenosti bodu od křivky. Na spodním obrázku je schematicky ukázáno vynešení vzdálenostní funkce a lokalizace jejího minima v bodu $\mathbf{x}_m$.

Body na křivce definované rovnicí 4.1 mají souřadnice $\mathbf{x} = (x, y) = (x, p_2x^2 + p_1x + p_0)$. Vzdálenost mezi bodem na křivce a libovolným bodem $\mathbf{x}_0 = (x_0, y_0)$ může být vyjádřeno jako funkce s parametrem x

$$l(x) = \sqrt{(x - x_0)^2 + (p_2x^2 + p_1x + p_0 - y_0)^2}. \quad (4.3)$$

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

$$\frac{dl(x)}{dx} = 0, \quad (4.4)$$

$$4p_2x^3 + 6p_1p_2x^2 + 2(1 + 2p_2(p_0 - y_0) + p_1^2)x + 2(p_1(-y_0 + p_0) - x_0) = 0. \quad (4.5)$$

Reálný kořen x_m kubické rovnice 4.5 představuje x -ovou souřadnici bodu nejbližšího bodu na křivce.

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. Navržená metoda tak musí obsahovat mechanismus 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

$$y_i + e_i = p_2 x_i^2 + p_1 x_i + p_0. \quad (4.6)$$

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

$$\begin{bmatrix} y_0 \\ \vdots \\ y_{N-1} \end{bmatrix} + \begin{bmatrix} e_0 \\ \vdots \\ e_{N-1} \end{bmatrix} = \begin{bmatrix} x_0^2 + x_0 + 1 \\ \vdots \\ x_{N-1}^2 + x_{N-1} + 1 \end{bmatrix} \cdot \begin{bmatrix} p_2 \\ p_1 \\ p_0 \end{bmatrix}. \quad (4.7)$$

Protože je počet bodů větší než 3 ($N \gg 3$), je soustava rovnic přeurčená. Taková úloha může být vyřešena pomocí metody nejmenších čtverců. V naší implementaci je tato úloha řešena SVD dekompozicí[32].

Ukončovací kritérium

Využitím pravděpodobnostní analýzy nemusí být počet iterací konstantní, ale lze optimalizovat pro dané zadání[33]. V této modifikaci není počet iterací N konstantní, ale je nastaven dle vztahu

$$N = \frac{\log(1-p)}{\log(1-(1-\varepsilon)^s)}, \quad (4.8)$$

kde pravděpodobnostní konstanta p [33] 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

$$\varepsilon = 1 - \frac{n_i}{n_a}, \quad (4.9)$$

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

4.2.4 Blok analýzy gradientu


Podél arterie je zkonstruováno množství ekvidistantních přímek (viz bílé přímky v obr. 4.4) tak, aby jejich směr byl kolmý na lokalizaci arterie (viz žlutá čárkovaná křivka v obr. 4.4). 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. 4.4). Tato sada bodů obsahuje potenciální body na arteriální stěně a bude označována P (v obr. 4.5 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. 4.5, kde jsou chybně detekovány body především v levé části obrazu. Tyto nepřesnosti ukazují nutnost dalšího zpracování výsledků.


4.2.5 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. 4.5 (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. Výsledek proložení (lokalizace tepenné stěny) je zobrazen zelenými body na obr. 4.5 (b).



Obr. 4.4: Konstrukce přímk kolmých na hrubou lokalizaci, na kterých je analyzován gradient (sada bílých přímk). Červeně jsou vyznačeny tzv. prvotní tepenné body. Žlutá (čárkovaná) křivka představuje hrubou lokalizaci.



Obr. 4.5: 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.

4.3 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. [15, 16, 26]). 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. 1.1). První z nich identifikuje segmenty arterie, ve kterých bude vhodné provést identifikaci vrstev LI a MA. Navazující část 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.

4.3.1 Identifikace míst vhodných pro měření IMT

Polynomiální křivka reprezentující tepennou stěnu je 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 množinu bodů S ($S \subset M$).

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. 4.6).



Obr. 4.6: Ukázka získání intenzitního profilu (zvýrazněno na příkladu červené přímky) kolmo k modelu arterie (žlutá čárkovaná křivka).

V obraze se často nachází značné množství oblastí, 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 odebráním bodů nevhodných pro měření IMT z počáteční sady M . Vytváření podmnožiny S je tří-krokový proces. První dva kroky jsou zodpovědné za odebrání 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 získané z okolních intenzitních profilů. Třetí blok je tak schopen do množiny přidat body, které byly prvními dvěma kroky pravděpodobně chybně odebrány.

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. V takových oblastech pochopitelně není možné věrohodně identifikovat LI a MA rozhraní, a proto musí být body v těchto oblastech odstraněny z počáteční sady M .

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

$$h = \max(l_m(x)) - \min(l_m(x)), \quad (4.10)$$

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 $h < l_{\text{thr}}$, jsou odstraněny ze sady bodů M . Prahová hodnota l_{thr} je určena jako sedmdesáti-procentní 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 skutečnost, že oblasti s nízkým kontrastem většinou pokrývají maximálně 30 % obrazu.

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

V obraze se rovněž mohou objevit oblasti, kde v důsledku přítomnosti šumu nebo dalších artefaktů nejsou rozhraní identifikovatelná. Měření IMT by v takových místech bylo značně nepřesné, a proto navržená metoda provádí striktní odebrání těchto bodů z počáteční množiny bodů M .

Typický intenzitní profil je charakterizován stabilním nárůstem intenzity s jedním výrazným poklesem. Zmíněný pokles musí mít navíc určitou minimální délku t (definována fyziologicky minimální šířkou vrstev), 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)

$$x \in \langle x_a, x_b \rangle, \text{ kde } \frac{dl_m(x)}{dx} < 0 \text{ a } |x_a - x_b| > t, \quad (4.11)$$

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 a jiné body naopak stále neoprávněně zůstávají v množině. 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 šumem nebo jinými artefakty.


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. Body, které se nacházejí v nevyužitelných clusterech (clustery, které nedosahují požadované délky), jsou odstraněny z množiny M , a tak nejsou využity pro měření IMT.

4.3.2 Identifikace LI a MA rozhraní

V tomto kroku je opět analyzován intenzitní profil $l_m(x)$ za účelem přesné identifikace lumen-intima (LI) a media-adventicia (MA) rozhraní. 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 $\min(l_m(x))$

$$l_{m,LI} = \min(l_m(x)) + h \cdot 0,1, \quad (4.12)$$

kde h je kontrast definovaný v rovnici 4.10. 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. 4.7).



Obr. 4.7: Princip lokalizace rozhraní LI a rozhraní MA.

4.3.3 Měření hodnoty IMT

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 $s \in S$

$$\text{IMT}_n = \frac{1}{S} \sum_{s=1}^S \text{IMT}_n(s). \quad (4.13)$$

5 DOSAŽENÉ VÝSLEDKY

V této kapitole jsou shrnuty veškeré dosažené výsledky a je provedeno srovnání s obdobnými metodami.

5.1 Redukce šumu s využitím vlnkové transformace

Byla provedena optimalizace parametrů postupně pro tři různé rodiny vlnek

- 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. Optimální řešení nalezená pro jednotlivé rodiny vlnek jsou shrnuta v tab. 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). Výsledky tohoto porovnání jsou shrnuty v tabulce 5.2. Je zřejmá kvalita navržené metody, NLMS filtru, Wienerovy filtrace a B-filtru. Využitím ostatních metod nebylo dosaženo natolik kvalitních výsledků.

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

Rodina vlnek	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

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

Metoda	Fitness funkce
WT-coif3	3,31
Anisotropic[34]	16,59
B-filtr[35]	4,19
Gaussian	7,97
NLMS[36]	3,55
ROF[37]	6,43
Wiener	4,04

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 dvou jader – lineárního jádra a jádra využívajícího nelineární mapování pomocí RBF funkce. Úspěšnost základní verze klasifikátoru byla 80,73 %. U rozšířené varianty bylo dosaženo výrazně vyšší úspěšnosti – 91,23 %.


Vzhledem k dosaženým výsledkům byl již v dalším postupu používán výhradně klasifikátor s nelineárním typem jádra. U zvoleného klasifikátoru následně proběhla optimalizace výběru příznaků.

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 4.2.2). 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. 5.1. Výsledná volba příznaků je shrnuta v tabulce 5.3.

Tab. 5.3: 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



Obr. 5.1: Vývoj fitness funkce (RMSE klasifikátoru) v průběhu generací.

5.2.3 Výsledná úspěšnost SVM klasifikátoru

Po provedení optimalizace nastavení příznaků a parametrů SVM klasifikátoru byla výsledná úspěšnost klasifikátoru 92,85 % (oproti 91,23 % dosažených metodou[50] bez optimalizace příznaků). I malé zvýšení úspěšnosti klasifikátoru je ve skutečnosti 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.

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 % [38] – 95 % [24]. Některé přístupy dosahují vyšších úspěšností, např. Rossi a kol. [22], 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.

Z prvního experimentu (přidávání náhodných bodů) je zřejmé, že RANSAC metoda je velmi odolná vůči náhodně přidaným bodům (v reálném použití – nekorelované chybně klasifikované body). Při druhém experimentu (přidávání náhodných bodů sdružených do clusterů) 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. 5.4: 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. 5.5: 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

5.2.6 Výsledná úspěšnost přesné lokalizace tepenné stěny

Přesnost lokalizace tepenné stěny navrženým algoritmem byla vztahována vůči manuální lokalizaci provedené třemi operátory. 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. Dosažené výsledky jsou shrnuty v tabulce 5.6.


V každém obraze bylo všech deset měření podél arterie zprůměrováno a průměrná chyba v jednotlivých obrazech je graficky znázorněna v obr. 5.2. Výsledky deseti měření v každém obraze byly statisticky zpracovány a jsou zobrazeny ve formě krabicového grafu v obr. 5.3. Průměrná chyba v obrazech, kde byla hrubá lokalizace úspěšná je 4,62 px (0,354 mm).

Tab. 5.6: 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.



Obr. 5.2: Střední lokalizační chyby v jednotlivých obrazech (zprůměrováno 10 měření v každém obraze).



Obr. 5.3: Statistické vyjádření lokalizačních chyb v jednotlivých obrazech.

5.3.1 Vyhodnocení střední absolutní chyby měření IMT

Uvažujme pouze 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

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

Na obr. 5.4 je zobrazen histogram středních absolutních chyb navrženého algoritmu (ERR_n). Střední hodnota vypočítána ze všech středních absolutních chyb navrženého algoritmu je $0,82 \text{ px} \pm 0,70 \text{ px}$ ($63 \mu\text{m} \pm 54 \mu\text{m}$). Dosažená hodnota střední absolutní chyby navrženého algoritmu je srovnatelná s mnohem komplexnějšími metodami, např. metoda představená Delsanto a kol.[4] dosahovala chyby $63 \mu\text{m} \pm 49 \mu\text{m}$, popř. metoda představená Molinari a kol.[24] dosahovala chyby $54 \mu\text{m} \pm 35 \mu\text{m}$. Přímočaré porovnání dosažených výsledků s ostatními metodami (viz tabulka 5.7) 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 ($0,2 \text{ s}$ na Intel i5-2540M $2,6 \text{ GHz}$). Ostatní metody mají výpočetní náročnost řádově vyšší (viz tab. 5.7). Nejvyšší výpočetní náročnost mívají zpravidla metody založené na aktivních konturách.

Další výhoda navržené metody spočívá v její robustnosti, kdy je schopna měřit IMT i v případech, kdy není arterie vizualizována v celém obraze či je v důsledku šumu obraz velmi nekvalitní.

Tab. 5.7: Shrnutí výsledků přesnosti identifikace vrstev na povrchu arterie.


Metoda	Střední absolutní chyba (μm)	Výpočetní náročnost (s)
Navržený algoritmus	$63 \mu\text{m} \pm 54 \mu\text{m}$	$0,2 \text{ s}$
Delsanto a kol. (μm)[4]	$63 \mu\text{m} \pm 49 \mu\text{m}$	$32,0 \text{ s}$
Molinari a kol. (μm)[24]	$54 \mu\text{m} \pm 35 \mu\text{m}$	$3,0 \text{ s}$
Gutierrez a kol. (μm)[39]	$90 \mu\text{m} \pm 60 \mu\text{m}$	neurčeno
Liang a kol. (μm)[40]	$42 \mu\text{m} \pm 20 \mu\text{m}$	$42,0 \text{ s}$

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

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

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 dosažováno 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. 5.5 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. 5.4: Histogram zobrazující distribuci absolutních chyb.



Obr. 5.5: Box plot porovnávající variabilitu směrodatných odchylek mezi měřením 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.

Celý systém pro měření šířky vrstev intima-media je velmi rozsáhlý, proto byla jeho implementace rozdělena do několika dílčích částí (dle obr. 1.1). V rámci každé dílčí části byla provedena analýza současných metod a byly implementovány nové metody, z nichž ta nejvhodnější byla využita ve výsledném řešení.

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-processing 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. 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 přítlaku 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.[4], respektive Molinari a kol.[24] (chyby $63 \mu\text{m} \pm 49 \mu\text{m}$, respektive $54 \mu\text{m} \pm 35 \mu\text{m}$). Přímé srovnání s obdobnými metodami je však obtížné, neboť mnohé současné metody jsou testovány pouze na výřezích 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).

LITERATURA

- [1] 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.
- [2] GRAF, S., GARIEPY, J., MASSONNEAU, M., ARMENTANO, R. L., MANSOUR, 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.
- [3] 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.
- [4] 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.
- [5] 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.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] 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.

- [13] TOUBOUL, P. J., CROUSE, J. R. *Intima-Media Thickness and Atherosclerosis: Predicting the Risk?*. Parthenon Publishing Group, Duben 1997.
- [14] 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.
- [15] 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.
- [16] 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.
- [17] 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.
- [18] 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.
- [19] 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.
- [20] 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.
- [21] 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.
- [22] 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.
- [23] 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.
- [24] 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.
- [25] KASS, M., WITKIN, A., TERZOPOULOS, D. Snakes: Active contour models. *International Journal of Computer Vision*, sv. 1, s. 321–331, 1988.
- [26] 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.

- [27] 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.
- [28] PRINOSIL, J., SMEKAL, Z., BARTUSEK, K. Wavelet thresholding techniques in MRI domain. In *2010 International Conference on Biosciences (BIOSCIENCESWORLD)*, s. 58 –63, Březen 2010.
- [29] 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.
- [30] VAPNIK, V. Pattern recognition using generalized portrait method. *Automation and Remote Control*, sv. 24, s. 774–780, 1963.
- [31] HARTLEY, R., ZISSERMAN, A. *Multiple View Geometry in Computer Vision*. Cambridge University Press, New York, NY, USA, 2 edition, 2003.
- [32] TREFETHEN, L. N., III, D. B. *Numerical Linear Algebra*. SIAM, Červen 1997.
- [33] HARTLEY, R., ZISSERMAN, A. *Multiple View Geometry in Computer Vision*. Cambridge University Press, Březen 2004.
- [34] 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.
- [35] TOMASI, C., MANDUCHI, R. Bilateral filtering for gray and color images. In *Computer Vision, 1998. Sixth International Conference on*, s. 839–846, 1998.
- [36] 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.
- [37] 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.
- [38] 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.
- [39] GUTIERREZ, M., PILON, P., LAGE, S., KOPEL, L., CARVALHO, R., FURUIE, S. Automatic measurement of carotid diameter and wall thickness in ultrasound images. In *Computers in Cardiology, 2002*, s. 359 – 362, Zář 2002.
- [40] 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.

Vybrané publikace autora

- [41] 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.
- [42] 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.

- [43] 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.
- [44] 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.
- [45] 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.
- [46] BENEŠ, R., ŘÍHA, K. Real-time motion compensation using optical flow. In *33rd International Conference on Telecommunications and Signal Processing*, vol. 1, s. 166–170, 2010.
- [47] BENEŠ, R., KARASEK, 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.
- [48] KARÁSEK, J., BENEŠ, R. Image filter design based on evolution. In *16th Conference Student EEICT 2010*, vol. 5, s. 251–255, 2010.
- [49] 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.
- [50] 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.
- [51] 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.
- [52] 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.
- [53] 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.

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

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.

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.