


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

DLOUHODOBÁ ANALÝZA ULTRAZVUKOVÝCH VIDEOSEKVENCÍ S VYUŽITÍM METOD DETEKCE VÝZNAMNÝCH BODŮ

LONG-TERM ANALYSIS OF ULTRASOUND VIDEO SEQUENCES USING
INTEREST POINT DETECTORS

ZKRÁCENÁ VERZE PHD THESIS

OBOR

Teleinformatika

AUTOR PRÁCE
ŠKOLITEL

Ing. MARTIN ZUKAL
doc. Ing. KAMIL ŘÍHA, Ph.D.

OPONENTI

DATUM OBHAJOBY

KLÍČOVÁ SLOVA

Krkavice, karotida, ultrazvukový obraz, sekvence ultrazvukových snímků, příčný řez, lokalizace artérie, významný bod, detektor významných bodů, dlouhodobé sledování.

KEYWORDS

Common carotid artery, ultrasound image, ultrasound video sequence, transversal section, artery localization, interest point, interest point detector, long-term tracking.

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

© Zukal Martin, 2015

ISBN 80-214-

ISSN 1213-4198

OBSAH

Úvod	5
1 Současný stav poznání	6
1.1 Lokalizace artérie v UZ snímku	6
1.2 Sledování artérie ve videosekvenci	6
1.3 Model pohybu arteriální stěny způsobený pulzací	7
1.4 Model pohybu arteriální stěny vlivem dýchání	9
2 Cíle dizertace	10
3 Vlastní řešení	11
3.1 Algoritmus pro dlouhodobé kontinuální sledování artérie	11
3.1.1 Lokalizace artérie	11
3.1.2 Detekce významných bodů	13
3.1.3 Aktualizace sledovaných bodů	14
3.1.4 Reinicializace	15
3.2 Model pohybu upravený pro příčný řez	16
3.2.1 Zahrnutí modelu dýchání	18
3.3 Příprava testovacích sekvencí	18
3.3.1 Sekvence z reálného UZ snímku	19
3.3.2 Sekvence s globálním pohybem	20
3.3.3 Sekvence se šumem	20
3.3.4 Sekvence vytvořené pomocí FIELD II	21
4 Experimentální výsledky	22
4.1 Metodika vyhodnocování přesnosti měření	22
4.1.1 Testování na sekvenci z reálného UZ snímku	24
4.1.2 Testování na sekvenci s globálním pohybem	24
4.1.3 Testování na sekvencích se šumem	24
4.1.4 Testování na sekvencích vytvořených pomocí FIELD II	26
4.2 Vyhodnocení výpočetní náročnosti	26
4.3 Shrnutí výsledků	28
5 Závěr	30
Literatura	32
Curriculum Vitæ	35

ÚVOD

Lékařská sonografie je založena na ultrazvukovém vlnění, které je generováno piezoelektrickým krystalem zabudovaným do sonografické sondy. Toto vlnění prochází tělem pacienta. Na rozhraní tkání s různou akustickou impedancí dochází k odrazu ultrazvukového vlnění, které sonda zachytí a předá ke zpracování sonografu, který na základě odražených vln zobrazí patřičný výstup. [12]

Jedním z nástrojů, který lze použít pro včasnou detekci kardiovaskulárního onemocnění, je klinické vyšetření *arteria carotis communis* (česky krkavice nebo karotida, anglicky common carotid artery – CCA) pomocí ultrazvukového zobrazení v B-módu. V této práci je řešena úloha vyšetření dynamických vlastností karotidy, konkrétně měření změny poloměru karotidy během srdečního cyklu, které se používá například při výpočtu poddajnosti (compliance) [4]. Pro tento výpočet je nutné odečíst hodnoty poloměru karotidy v době systoly a v době diastoly, což nelze ručně spolehlivě provést během měření, neboť pohyb arteriální stěny je poměrně rychlý. Spolehlivé ruční měření je tedy možné provést až ve snímcích, které pro tento účel uložíme (tj. měření se provádí dodatečně na uložených datech). Konkrétní hodnoty analyzovaných parametrů se odečítají v režimu měření, kdy operátor vybere ručně vhodné body na arteriální stěně a UZ stanice na základě aktuálního nastavení vypočte příslušné hodnoty poloměru artérie.

Konkrétně se budeme zabývat kontinuální interaktivní analýzou videosekvencí. Pojmeme interaktivní máme na mysli, že jednotlivé snímky jsou zpracovávány v reálném čase a výsledky měření je možné zobrazovat okamžitě v průběhu vyšetření. Kontinuální analýza pak spočívá ve zpracování sekvence obsahující jediné (libovolně dlouhé) vyšetření karotidy.

Automatická metoda pro interaktivní kontinuální měření parametrů artérie umožní tyto parametry vyhodnotit přímo během vyšetření bez nutnosti záznamu snímků. Navíc je možné zaznamenat pouze změřené hodnoty, což je výrazně méně paměťově náročné. Výsledky je možné zobrazit v podobě grafu pro mnoho srdečních cyklů a jednorozměrné závislosti dále zpracovávat, tedy stanovovat parametry související s 1D křivkou srdečního cyklu. Měřené hodnoty taková metoda samozřejmě umožní zobrazovat i v průběhu vyšetření, takže vyšetřující lékař může ihned vyhodnocovat automaticky stanovené parametry. Měření parametrů není omezeno pouze na karotidu, ale bylo by jej možné použít pro měření parametrů jakékoli jiné tepny v lidském těle. Avšak karotida je pro vyšetření upřednostňována z důvodu její snadné přístupnosti. V následujícím textu budou tedy označení karotida (či krkavice) a artérie (či tepna) používány záměně.

1 SOUČASNÝ STAV POZNÁNÍ

1.1 Lokalizace artérie v UZ snímku

Pro detekci objektů v obraze je s oblibou používán detektor popsany P. Violou a M. Jonesem v [29]. Mezi hlavní výhody tohoto detektoru patří zejména rychlost (což umožňuje použití v aplikacích pracujících v reálném čase) a vysoká úspěšnost detekce. O vhodnosti použití tohoto algoritmu pro detekci artérie v UZ snímku je možné se přesvědčit např. v [22, 2, 19].

Detektor je nejprve nutné natrénovat na základě množiny negativních a pozitivních vzorů. Pro trénování se používá metoda AdaBoost, která vytváří z jednoduchých klasifikátorů kaskádu, kde každý stupeň kaskády je silný monolitický nelineární klasifikátor.

Pro nalezení kružnice v obraze je možné využít Houghovu transformaci [6]. Houghova transformace převádí obraz do n -rozměrného prostoru parametrů (v případě detekce kružnice je $n = 3$), který odpovídá n -rozměrnému akumulátorovému prostoru. Pro každý pixel reprezentující hranu se pak zkoumá, zda leží na kružnici vyhovující zadaným parametrům (např. že poloměr kružnice leží v intervalu $\langle r_{\min}; r_{\max} \rangle$) a pokud ano, je příslušný prvek akumulátorového prostoru inkrementován o jedna. Výsledkem tohoto postupu je velké množství nalezených kružnic. Jako kružnice reprezentující *lumen* artérie je poté vybrána ta kružnice, jejíž hodnota v akumulátorovém prostoru byla nejvyšší. Houghova transformace pro nalezení artérie v příčném řezu byla popsána například v [8] a [20].

1.2 Sledování artérie ve videosekvenci

Máme-li k dispozici videosekvenci, můžeme v ní analyzovat pohyb objektu(ů) a rozšířit tak zpracování obrazu o časovou souřadnici. Pohyb v UZ snímku je způsoben dvěma základními faktory: pohybem objektů uvnitř snímku a pohybem UZ sondy. V případě videosekvence UZ snímků zachycující artérii v příčném řezu je možné sledovat pohyb arteriální stěny a měřit její parametry, například poloměr [23, 21]. Pro sledování artérie (ať už v příčném nebo podélném řezu) byla navržena celá řada metod. Většina z nich pracuje s malou oblastí zájmu (ROI – Region of Interest), která je umístěna do místa s jasně patrným jasovým vzorem. Tato oblast zájmu je pak sledována v průběhu celé videosekvence. Golemati et al. v [7] porovnali různé algoritmy pro analýzu pohybu v UZ snímcích. Konkrétně byly porovnány tyto metody: optický tok dle Horna a Shuncka [13], optický tok dle Lucase Kanadeho s metodou váhovaných nejmenších čtverců, block matching a již dříve zmíněnou diferenciální

metodu, která umožňuje zahrnout i deformaci sledovaného bloku (tato metoda je v jejich práci označena affine block motion model (ABMM)). Nejlepších výsledků dosáhla metoda výpočtu optického toku dle Lucase a Kanadeho [18], a proto bude dále popsána.

Jedná se o diferenciální metodu výpočtu optického toku založenou na prostorových a časových parciálních derivacích. Tato metoda je schopna vypočítat pohybový vektor pro konkrétní bod(y) v obraze. Výhodou této techniky je její rychlost (v porovnání s technikami, které počítají husté pole) a odolnost vůči šumu.

Z předchozího textu vyplývá, že velice vhodnou metodou pro sledování artérie v sekvenci UZ snímků je metoda dle Lucase a Kanadeho. Tato metoda je schopna určit vektory pohybu pro konkrétní bod obrazu, ale nic neříká o tom, jakým způsobem mají být tyto body vybrány. Výběrem takových bodů se zabývají algoritmy, které se nazývají detektory významných bodů (interest point detectors). Za poslední čtyři desetky let bylo navrženo velké množství detektorů významných bodů. Mezi velmi často používané detektory patří Harrisův detektor rohů [11], detektor typu Good Features To Track [25], či poměrně nedávno publikované metody SIFT (Scale Invariant Feature Transform) [17] a SURF (Speeded Up Robust Features) [1]. Ucelený přehled obsahující popis více než deseti detektorů významných bodů publikovali T. Tuytelaars a K. Mikolajczyk v [28].

Většina algoritmů pro sledování bodů (či objektů) funguje velice dobře v případě krátkých videosekvencí. Ovšem v případě dlouhodobého kontinuálního sledování významných bodů dochází k jevu, který je anglicky označován jako feature drift („odplouvání“ významných bodů) [3, 30]. Výsledkem tohoto jevu je, že se sledované body vlivem malých chyb v odhadu jejich nové pozice, posouvají dál od sledovaného objektu (tzv. „odplouvají“). V případě, že sledované body používáme pro měření parametrů určitého objektu (zde např. poloměru artérie), dochází postupně k nežádoucímu zkreslení výsledků, až po jejich úplné znehodnocení.

Zinsser et al. [30] považují za zdroj chyb způsobující odplouvání tyto důvody: šum v obraze, geometrické deformace, změny jasu, vzorkovací artefakty snímače. Díky těmto důvodům nebude nově odhadnutá pozice sledovaného bodu nikdy zcela přesná a postupným kumulováním těchto chyb dojde k tomu, že se pozice sledovaného bodu vychýlí od správné pozice.

1.3 Model pohybu arteriální stěny způsobený pulzací

Pro popis toho, jak se deformuje arteriální stěna v průběhu jednoho srdečního cyklu, byl vytvořen matematický model, který byl popsán v [26]. Autoři vycházejí z [15],

kde je takto popsán pohyb levé srdeční komory. Stoitsis et al. model zobecnili za použití šesti parametrů (viz níže) a použili jej pro modelování deformace stěny artérie v podélném řezu. Stěny artérie se pohybují dvěma směry: ve směru kolmém ke stěně artérie (radiální směr pohybu) a ve směru rovnoběžném s arteriální stěnou (longitudinální směr pohybu). V podélném řezu je možné pozorovat (a měřit) oba dva směry pohybu.

Dále byl model rozšířen o prostorovou závislost a to v [27]. Výslednou výchylku $d(\mathbf{x}, t)$ arteriální stěny v čase t lze podle výše zmíněné studie popsat pomocí následující rovnice

$$d(\mathbf{x}, t) = \begin{bmatrix} r(\mathbf{x}, t) \\ l(\mathbf{x}, t) \end{bmatrix} = \begin{bmatrix} r_s(\mathbf{x}) \cdot r_t(t) \\ l_s(\mathbf{x}) \cdot l_t(t) \end{bmatrix}, \quad (1.1)$$

kde $r(\mathbf{x}, t)$ označuje výchylku v radiálním směru a $l(\mathbf{x}, t)$ výchylku v longitudinálním směru. Model je popsán tak, že složky pohybu závislé na čase t (tj. členy $r_t(t)$ a $l_t(t)$) jsou oddělitelné od složek pohybu závislých na prostoru (členy $r_s(\mathbf{x})$ a $l_s(\mathbf{x})$) a výsledná výchylka je dána součinem jednotlivých složek [27, 24]. Prostorově závislé složky pohybu určují, jak se mění míra pohybu se vzdáleností od arteriální stěny, což bude podrobně vysvětleno dále.

Radiální část pohybu (výchylka ve směru kolmém k arteriální stěně) závislá na čase $r_t(t)$ je definována pomocí parametrů $a, b, c, d, t_0, t_1, t_2$ a T takto

$$r_t(t) = \Gamma(t_0, t_1, t) \cdot \sin^2 \frac{\pi t}{cT} + \Gamma(t_1, t_2, t) \cdot (a + bt), \quad (1.2)$$

kde $\Gamma(t_i, t_{i+1}, t)$ je tzv. pulzní funkce popsaná následující rovnicí

$$\Gamma(t_i, t_{i+1}, t) = \frac{1}{4}(1 + \tanh(d(t - t_i)))(1 + \tanh(d(t_{i+1} - t))). \quad (1.3)$$

Parametry a, t_0, t_1, t_2 a T jsou popsány v tabulce 1.1, kde je naznačeno i to, jak ovlivňují výslednou křivku. Vliv ostatních parametrů (b, c a d) na výslednou křivku je podstatně složitější a není možné jej jednoduše popsat.

Tab. 1.1: Popis některých parametrů modelu

Parametr	Význam
a	ovlivňuje amplitudu křivky
t_0	čas začátku srdečního cyklu
t_1	ovlivňuje dobu trvání systolické části srdečního cyklu
t_2	ovlivňuje dobu trvání diastolické části srdečního cyklu
T	doba trvání celého srdečního cyklu

Longitudinální část pohybu (výchylka ve směru rovnoběžném s arteriální stěnou) závislá na čase je popsána pomocí rovnice

$$l_t(t) = \sin\left(\pi \cdot \frac{t}{T}\right). \quad (1.4)$$

Prostorově závislá složka pohybu v radiálním směru je definována jako

$$r_s(\mathbf{x}) = a_1 \cdot e^{b_1|y-y_i|}, \quad (1.5)$$

kde a_1 je maximální výchylka tepenné stěny v radiálním směru a b_1 ovlivňuje útlum výchylky v závislosti na vzdálenosti od stěny artérie, jejíž radiální vzdálenost od středu *lumen* je označena jako y_i .

Prostorově závislá složka pohybu v longitudinálním směru je definována jako

$$l_s(\mathbf{x}) = a_2 \cdot e^{b_2|y-y_i|}, \quad (1.6)$$

kde a_2 je maximální výchylka tepenné stěny v longitudinálním směru a b_2 ovlivňuje útlum výchylky v závislosti na vzdálenosti od arteriální stěny. Z pohledu na rovnice 1.5 a 1.6 je zřejmé, že výchylka exponenciálně klesá se vzdáleností od stěny artérie y_i . Strmost tohoto poklesu je dána parametry b_1 a b_2 .

Parametrům ve výše uvedených rovnicích je nutné nastavit správné hodnoty tak, aby výsledná výchylka $d(\mathbf{x}, t)$ co nejlépe odpovídala tomu, jak se pohybuje arteriální stěna během srdečního cyklu.

1.4 Model pohybu arteriální stěny vlivem dýchání

Pohyb způsobený dýcháním je výrazně pomalejší proces než pohyb způsobený pulzací arteriální stěny. Simulaci srdečního cyklu včetně dýchacích artefaktů se věnuje práce [24]. V ní je popsán konkrétní případ, kdy byla srdeční frekvence 60 úderů za minutu a frekvence dýchání 13 dechů za minutu (tedy perioda dýchání T_r je zhruba 4,6 krát delší než perioda srdečního tepu).

Výchylka bodu na arteriální stěně způsobená dýcháním je zde popisována takto

$$d_r(t) = - \left| a_r \cdot \sin\left(2 \cdot \pi \cdot \frac{t}{T_r}\right) \right|. \quad (1.7)$$

Amplituda výchylky a_r je shodná s amplitudou výchylky způsobenou pulzací arteriální stěny. I v tomto případě je pohyb tlumen v závislosti na vzdálenosti od středu artérie. Funkci popisující útlum autoři neuvádějí, pouze zmiňují, že obě funkce jsou na sobě nezávislé a výsledný pohyb je dán součinem funkce popsané rovnicí 1.7 a funkcí popisující útlum (podobně jako součin $r_t(t)$ a $r_s(\mathbf{x})$ v předchozí kapitole).

Na pravé straně rovnice 1.7 je záporné znaménko, protože pohyb působí v opačném směru, než je směr kladné axiální osy (jinými slovy proti UZ sondě).

2 CÍLE DIZERTACE

Cílem dizertační práce je navrhnout a poté i implementovat komplexní systém pro automatické interaktivní kontinuální sledování artérie a měření jejích parametrů v sekvenci UZ snímků zachycených v příčném řezu. Požadavky na tento systém je možné shrnout takto:

- Systém musí být zcela **automatický**. To znamená, že od spuštění měření až do jeho skončení není nutný žádný zásah operátora (kromě spuštění a zastavení měření). Jednou z klíčových vlastností tedy musí být schopnost systému nalézt artérii v prvním UZ snímku, určit její střed a poloměr a sledovat ji i v případě prudkého pohybu sondy.
- Navrhovaný systém musí být schopen provádět **spolehlivé a přesné měření i pro nepřetržitý tok obrazových dat, tj. pro velmi dlouhé sekvence** (v délce řádově minut).
- Systém musí být **robustní vůči běžným jevům v UZ sekvencích** jako je pohyb sondy, polykání, dýchání pacienta apod.
- Navrhovaný systém musí být **odolný vůči šumu**. Jak již bylo zmíněno dříve pro UZ snímky je typický šum typu speckle. Navrhovaný systém by tedy měl být odolný zejména vůči tomuto šumu, ale i vůči aditivnímu šumu, který se může v UZ obraze vyskytnout.
- Algoritmus musí **pracovat v reálném čase**. Tento požadavek je důležitý, aby bylo možné algoritmus nasadit přímo do UZ stanice, kde by měření a zobrazení výsledků (např. v podobě grafu) probíhalo přímo během snímání dat a nebylo nutné data po měření zpracovávat v dalším kroku.
- Naměřené **hodnoty musí být možné uložit pro další zpracování**. Kromě možnosti sledování výsledků měření v reálném čase by mělo být možné naměřená data také uložit pro dodatečné zpracování.
- Systém musí být jednoduše **rozšiřitelný a upravitelný**. Jednotlivé moduly celého systému by měly být jednoduše nahraditelné jinými implementacemi či algoritmy.
- Data zaznamenaná během měření by mělo být možné **uložit do různých formátů**.

Aby bylo možné spolehlivě vyhodnotit přesnost navrženého systému, je nutné vytvořit umělé sekvence UZ snímků s definovaným pohybem artérie. Vytvoření těchto testovacích simulovaných sekvencí je dalším z cílů dizertační práce.

Je třeba zdůraznit, že navrhovaný systém nemá za cíl nahradit lékaře při stanovení diagnózy, ale zefektivnit jeho práci odstraněním opakujících se časově náročných úkonů, ke kterým, v případě vyšetření CCA, patří například lokalizace artérie a měření jejích geometrických parametrů.

3 VLASTNÍ ŘEŠENÍ

Z podrobného zkoumání několika desítek videosekvencí a z konzultací s odborníky vyplynulo několik problémových situací, které komplikují dlouhodobé kontinuální měření parametrů artérie. Jedná se o tyto situace:

- během vyšetření dochází ke globálnímu pohybu ve scéně (což se může v extrémním případě projevit tak, že během vyšetření artérie z obrazu zcela zmizí a poté se znovu objeví),
- vlivem jevu feature drift dochází k postupné degradaci přesnosti měření,
- vlivem špatného nastavení parametrů UZ sondy může být obraz zašuměný či málo kontrastní.

Dále je nutné, aby byl systém schopen správně měřit parametry artérie i v případě, kdy pacient během vyšetření dýchá. Vliv dechu se projevuje pomalou změnou poloměru artérie. Kromě toho je nutné, aby byl systém odolný také vůči změnám scény způsobeným mikropohybem.


Tato kapitola popisuje systém pro dlouhodobé kontinuální měření parametrů artérie, který si se všemi výše uvedenými problémy umí poradit. Některé existující algoritmy při měření vyžadují zásah operátora. Ten buď vyznačí na obrazovce přímo stěnu artérie nebo určí počáteční bod (většinou uvnitř *lumen* artérie) a algoritmus pak nalezne stěnu artérie, kterou dále sleduje. Při výrazném pohybu artérie od původní pozice dojde k tomu, že algoritmus ztratí původní pozici a bez zásahu operátora není schopen artérii nalézt v její nové pozici. Zde popsaný systém je plně automatický. Je schopen artérii sám nalézt na začátku měření stejně jako v případě, kdy artérie ze scény zcela zmizí a poté se objeví.

3.1 Algoritmus pro dlouhodobé kontinuální sledování artérie

Vývojový diagram tohoto algoritmu je zachycen na obrázku 3.1. Jako vstup přichází do algoritmu videosekvence UZ snímků (tak, jak ji uloží UZ stanice, tedy bez dalších úprav). Z této sekvence jsou načítány jednotlivé snímky, které pak postupují celým procesem. V případě prvního snímku ze sekvence je okamžitě vyhodnocena první podmínka („Inicializace?“) kladně a je tedy spuštěn proces lokalizace artérie.

3.1.1 Lokalizace artérie

Uvažujeme-li o artérii v příčném řezu jako o kruhovém objektu, pak je možné ji jednoznačně popsat pomocí středu a poloměru. Proces lokalizace artérie pak znamená



Obr. 3.1: Vývojový diagram algoritmu pro dlouhodobé sledování artérie

nalezení těchto dvou parametrů.

Proces sloužící k přesnému nalezení artérie se skládá z těchto kroků:

1. Určení oblasti zájmu (ROI) pomocí detektoru Viola-Jones.
2. Nalezení středu a přibližného poloměru artérie pomocí Houghovy transformace.
3. Přesné určení poloměru artérie.

Pro účely nalezení oblasti zájmu v celém UZ snímku byl využit detektor Viola-Jones s kaskádou klasifikátorů, kterou vytvořili Říha, Mašek, Burget aj. v [22]. Autoři uvádějí úspěšnost detekce 97%.

Výsledkem detekce pomocí detektoru Viola-Jones je obdélníková oblast zájmu,

kteřá obsahuje hledanou artérii, avšak přesnou pozici středu stejně jako její přesný poloměr nelze z výsledné oblasti zájmu určit. Z tohoto důvodu jsou do procesu lokalizace artérie zařazeny další kroky, jejichž účelem je přesněji určit střed a poloměr arteriální kružnice. V těchto krocích se již pracuje pouze s oblastí určenou pomocí detektoru Viola-Jones.

Nejdříve je zpřesněna pozice středu a poloměru pomocí Houghovy transformace. Před samotnou aplikací Houghovy transformace je obraz upraven tak, aby byla kružnice reprezentující arteriální stěnu lépe patrná. V tomto kroku jsou postupně aplikovány procedury gaussovského rozostření s jádrem o velikosti 3×3 pixely a $\sigma = 2$, dále ekvalizace histogramu a poté operace morfologického uzavření. Operace morfologického uzavření spočívá v aplikaci dilatace a poté eroze na UZ snímek.

V takto upraveném obraze jsou pomocí Houghovy transformace hledány kružnice. Vzhledem k tomu, že je v Houghově parametrickém prostoru obtížné vybrat optimální výsledek jako jednu nejpravděpodobnější kružnici, ukázal se jako vhodný způsob určení středu a poloměru vypočítat průměrný střed a průměrný poloměr ze všech nalezených kružnic. Tento postup poměrně přesně určí střed artérie, avšak ne vždy je úspěšný při určování poloměru, ale nalezení pozice středu je velmi přesné.


Z toho důvodu byl na konec procesu lokalizace zařazen ještě krok přesného určení poloměru, který byl popsán Říhou a Benešem v [20]. Pro účely tohoto kroku se pracuje se snímkem, který byl podroben gaussovskému rozostření a operaci morfologického uzavření, ale nebyla provedena operace ekvalizace histogramu.

3.1.2 Detekce významných bodů

Jakmile známe přesnou pozici středu a poloměr artérie v UZ snímku, můžeme přistoupit k detekci významných bodů. Body nejsou detekovány v celém obraze, ale jen v oblasti, která odpovídá stěně artérie. Tato oblast je určena pomocí masky, která má podobu mezikruží se středem nalezeným v předchozím kroku. Poloměr menší kružnice je o jeden pixel menší než poloměr nalezený v předchozím kroku. Šířku mezikruží je možné měnit (parametr `maskWidth`), experimentálně však bylo ověřeno, že dobrých výsledků algoritmus dosahuje při šířce masky 4 pixely. Na obrázku 3.2 je zobrazen reálný UZ snímek se správně zkonstruovanou maskou vyznačenou červeným, částečně průhledným mezikružím.

V takto vymezeném prostoru jsou detekovány významné body pomocí některého z detektorů významných bodů. Předtím, než je nový bod (označme jej \mathbf{p}_c) zařazen do množiny sledovaných bodů P , se testují dvě podmínky.

Při vyhodnocování první podmínky se kontroluje, kolik bodů již v množině sledovaných bodů je a je přidáno pouze takové množství bodů, aby jejich celkový počet byl roven nejvyšší hodnotě `maxCount` (parametr algoritmu).



Obr. 3.2: Detekovaná arteriální stěna s vyznačenou maskou

Při vyhodnocování druhé podmínky se zjišťuje, zda bod \mathbf{p}_c neleží příliš blízko jiného bodu, který je již v množině sledovaných bodů zařazen. Pro stanovení vzdálenosti dvou bodů se používá eukleidovská vzdálenost D_e . Bod \mathbf{p}_c je do množiny sledovaných bodů zařazen pouze v případě, že jeho eukleidovská vzdálenost od libovolného bodu v množině sledovaných bodů je větší než ϵ_{md} (parametr algoritmu). Stále tedy musí platit, že vzdálenost mezi libovolnými dvěma body \mathbf{a} a \mathbf{b} z množiny P je větší než stanovená hodnota ϵ_{md} :

$$D_e(\mathbf{a}, \mathbf{b}) > \epsilon_{\text{md}}. \quad (3.1)$$

Experimentálně bylo zjištěno, že vhodnou volbou je $\epsilon_{\text{md}} = 4$. Toto opatření zamezuje tomu, aby byly sledované body nahromaděné na několika (např. výrazně světlejších) místech.

3.1.3 Aktualizace sledovaných bodů

Při dlouhodobém sledování bodů pomocí optického toku dochází k jevu zvanému feature drift [3, 30]. Aby body, které se vzdálily od sledované arteriální stěny, neznehodnocovaly měření, je nutné v průběhu měření body aktualizovat (některé body jsou odebrány a naopak jsou přidány nové body). V této práci byl navržen původní rozhodovací postup pro určení, zda bude sledovaný bod ponechán v množině sledovaných bodů, nebo zda bude vyřazen.

Nejprve jsou z množiny sledovaných bodů odstraněny všechny body, které algoritmus pro výpočet optického toku nedokázal v aktuálním snímku nalézt. V další fázi jsou tedy odstraněny všechny body, u nichž byla chyba sledování e , kterou vypočte sledovací algoritmus, vyšší než nastavený práh ϵ_e .

Zbýlými body je poté proložena elipsa, jejíž obě poloosy mají však téměř shodnou velikost. Elipsa je pro účely algoritmu popsána obdélníkem, do kterého je vepsána. U obdélníku lze jednoduše určit jeho střed (těžiště) \mathbf{c} , který je považován za střed artérie. Poté je opět spuštěn proces přesného určení poloměru, jehož výsledek je

označen r_{act} . Poté se opět prochází množina sledovaných bodů P a zkoumá se, jak daleko leží jednotlivé body od nově určeného středu \mathbf{c} . Pokud je vzdálenost bodu větší než $r_{\text{act}} \cdot \epsilon_{\text{aw}}$ nebo menší než $r_{\text{act}}/\epsilon_{\text{aw}}$, pak je bod z množiny sledovaných bodů odebrán. Po skončení fáze aktualizace musí platit:

$$\forall \mathbf{p}_i, \mathbf{p}_i \in P : \{D_e(\mathbf{c}, \mathbf{p}_i) > r_{\text{act}}/\epsilon_{\text{aw}} \wedge D_e(\mathbf{c}, \mathbf{p}_i) < r_{\text{act}} \cdot \epsilon_{\text{aw}}\}, \quad (3.2)$$

kde D_e značí eukleidovskou vzdálenost bodů a ϵ_{aw} je práh, který je v algoritmu nastavitelný pomocí parametru (jeho typická hodnota je 1,1).

Vzhledem k tomu, že výše uvedeným postupem může dojít k odebrání poměrně značného množství bodů, je nutné opět detekovat nové významné body a ty přidat do množiny sledovaných bodů. Za tímto účelem je aktualizována maska pro detekci významných bodů. Ta je zkonstruována stejným způsobem, jak bylo popsáno v kapitole 3.1.2 s tím, že její střed leží v bodě \mathbf{c} a jako poloměr r je vzata hodnota r_{act} . Šířka mezikruží je nadále určena parametrem `maskWidth`. Při detekci je opět brána v potaz podmínka minimální vzdálenosti od aktuálně sledovaných bodů a také podmínka celkového maximálního počtu sledovaných bodů.

3.1.4 Reinizializace

V případě, že se artérie výrazně posune od svého předchozího umístění, může se stát, že algoritmus ztratí sledované body. Abychom zabránili tomu, že algoritmus zcela ztratí sledovaný objekt, spouští se v pravidelných intervalech nový proces lokalizace artérie a zjišťuje se, zda se artérie posunula od své poslední známé pozice. Frekvence, s jakou se proces lokalizace spouští, je ovlivněna parametrem `framesPerPulse`, který udává, kolik snímků odpovídá jednomu celému srdečnímu cyklu. Lokalizace artérie se spouští vždy po zpracování $5 \cdot \text{framesPerPulse}$ snímků od snímku, kdy byla lokalizace naposledy provedena.

O spuštění procesu lokalizace se rozhoduje v bloku „Došlo k pohybu?“ ve vývojovém diagramu na obrázku 3.1. Pokud platí alespoň jedna z následujících podmínek:

- střed nově lokalizované artérie je vzdálen od poslední známé pozice středu artérie o více než definovaný práh `motionThreshold`,
- poloměr nově lokalizované artérie je výrazně větší než maximální zaznamenaný poloměr,
- poloměr nově lokalizované artérie je výrazně menší než minimální zaznamenaný poloměr,

pak jsou všechny body z množiny sledovaných bodů odstraněny a je spuštěna nová detekce významných bodů a množina sledovaných bodů je naplněna nově detekovanými body. Detekce bodů se samozřejmě provádí opět v oblasti vymezené maskou, která je zkonstruována na základě parametrů nově lokalizované artérie. Práh

`motionThreshold` je dalším z parametrů navrženého algoritmu a bylo experimentálně zjištěno, že je vhodné jej nastavit jako polovinu aktuálního poloměru artérie.

3.2 Model pohybu upravený pro příčný řez

Aby bylo možné testovat vlastnosti navrženého algoritmu pro dlouhodobé sledování tepenné stěny, bylo nutné vytvořit přesné syntetické modelové sekvence, simulující pulzační pohyb arterie v příčném řezu. Tyto sekvence musí mít dostatečně dlouhý časový rozsah a musejí mít pro každý bod přesně definovaný model pohybu v časové sekvenci. Počet snímků v jednotlivých sekvencích je roven 1320. Poznatky v této části práce (tj. modelování pohybu arteriální stěny) jsou výsledkem výzkumu, který proběhl ve spolupráci s Eng. Yara Omran.

Existuje matematický model pohybu arteriální stěny v podélném řezu, který popsali Stoitsis et al. v [27]. Pohyb je popsán jak pro složku radiální (ve směru kolmém na stěnu artérie), tak pro složku podélnou – longitudinální (ve směru rovnoběžném se stěnou artérie). Protože dynamické parametry artérie se lépe měří v příčném řezu, je naším cílem je vytvořit model, který bude popisovat pohyb arteriální stěny v příčném řezu. Výsledný model tedy bude popisovat pouze pohyb v radiálním směru, který jediný je v příčném řezu patrný.

Abychom mohli aplikovat model pohybu na stěnu artérie v příčném řezu předpokládáme, že:

- artérie má přibližně kruhovitý tvar a je možné ji tedy popsat pomocí kružnice, což dokazují práce Golemati et al. [8], Guerrero et al. [10] a Liu et al. [16],
- arteriální stěna je izotropní a vlivem pulzu dochází k izovolumickým změnám, jak popisuje Gosling et al. v [9].

Vydeme z rovnice 1.7, která popisuje celkovou výchylku arteriální stěny v podélném řezu. Celková výchylka je dána součinem složky závislé na čase $r_t(t)$ a prostorově závislé složky $r_s(\mathbf{x})$. Převédeme kartézské souřadnice do souřadnic polárních s tím, že počátek polárního souřadného systému je umístěn do středu *lumen* artérie. Úhel ϕ v dalším postupu neuvažujeme, neboť předpokládáme, že každý bod ležící na stěně artérie se pohybuje stejně. V následujících rovnicích tedy místo souřadnic $\mathbf{x} = (x, y)^\top$ budeme pracovat pouze se vzdáleností f od počátku (středu *lumen* artérie). Výchylku arteriální stěny v konkrétním bodě f a čase t označíme $d_p(f, t)$ a vypočteme ji jako

$$d_p(f, t) = r_s(f) \cdot r_t(t). \quad (3.3)$$

Funkce $r_t(t)$ označující radiální výchylku bodu závislou na čase je shodná s rovnicí 1.2. $r_s(f)$ je člen ovlivňující výchylku pixelu v závislosti na jeho prostorové

souřadnici f . Složka výchylky závislá na pozici v obrazové rovině $r_s(f)$ je tedy popsána následující rovnicí

$$r_s(f) = a_1 \cdot e^{b_1|f-f_i|}, \quad (3.4)$$

kde a_1 udává maximální výchylku arteriální stěny a parametr b_1 popisuje, jak strmě amplituda výchylky klesá se vzdáleností od středu artérie f_i .

Podobně jako navrhli Stoitsis et al. v [26], přizpůsobili jsme parametry výše popsaného teoretického modelu klinickým datům získaným pomocí měření pohybu v reálné sekvenci zachycující artérii v příčném řezu.

Ve výše zmíněné reálné sekvenci byl částečně automaticky (pomocí detektoru Good features to track) a částečně manuálně (z množiny detekovaných bodů) vybrán kvalitní význačný bod ležící na arteriální stěně, který byl sledován metodou optického toku dle Lucase a Kanadeho a jeho pozice (tj. x, y souřadnice v obraze) byla v průběhu měření zaznamenávána. Ze zaznamenaných pozic pak byla vypočítána výchylka v radiálním směru od původní pozice. Z celého měření byl vybrán typický úsek odpovídající jednomu srdečnímu cyklu bez výskytu parazitního jevu feature drift. Tímto postupem jsme získali 22 hodnot udávajících výchylku (v pixelech) bodu na arteriální stěně. Získané hodnoty byly poté znormalizovány tak, aby ležely v intervalu $\langle 0; 1 \rangle$. Normalizace hodnot je důležitá pro další postup, kdy budeme chtít v modelu pohybu arteriální stěny zohlednit také vliv dýchání, což bude vysvětleno v následující kapitole.

Vektor hodnot relativní změny výchylky byl spolu s funkcí popisující složku pohybu závislou na čase (rovnice 1.2) předložen nelineární optimalizační metodě. Použitá optimalizační metoda, jejímiž autory jsou Coleman a Li [5]. Cílem tohoto postupu je nalezení konkrétních hodnot parametrů vystupujících v rovnici 1.2 tak, aby s jejich použitím byl výsledný průběh výchylky co nejbližší změřenému. Výsledné parametry modelu pohybu nalezené nelineární optimalizační metodou jsou uvedeny v tabulce 3.1.

Tab. 3.1: Hodnoty parametrů modelu

Parametr	Hodnota
t_1	7,2932
t_2	7,2502
a	2,2738
b	$-1 \cdot 10^{-5}$
c	0,0215
d	0,1157
T	22 sn.

3.2.1 Zahnutí modelu dýchání

Výsledný pohyb arteriální stěny ovlivňuje jak pulzace stěny samotná, tak dýchání. Jednotlivé příspěvky k výslednému pohybu jsou na sobě nezávislé a výsledný pohyb je možné určit jako součet těchto příspěvků:

$$d(f, t) = d_p(f, t) + d_r(t) = r_s(f) \cdot r_t(t) + d_r(t), \quad (3.5)$$

kde $d_r(t)$ je vliv dechu popsáný rovnicí 1.7 a členy $d_p(f, t)$, $r_s(f)$ a $r_t(t)$ byly popsány v předchozí kapitole. Zdůrazněme, že parametry popisující časově závislou složku pohybu $r_t(t)$ byly hledány až po provedení normalizace, z čehož plyne, že hodnoty námi uvažované funkce $r_t(t)$ leží v intervalu $\langle 0; 1 \rangle$. V rovnici 1.7 jsme zvolili amplitudu výchylky $a_r = 1$, což má za následek, že hodnoty funkce $d_r(t)$ leží v intervalu $\langle -1; 0 \rangle$. Pro zjednodušení dalšího textu zavedeme funkci $s(t)$ vztahem

$$s(t) = r_t(t) + d_r(t). \quad (3.6)$$

Z výše uvedených vlastností funkcí $r_t(t)$ a $d_r(t)$ plyne, že obor hodnot funkce $s(t)$ je $\langle -1; 1 \rangle$. Vidíme, že $s(t)$ nezávisí na prostorových souřadnicích a ovlivňuje výchylku pouze relativně (výchylka od střední hodnoty může být jak kladná. Vynásobením funkcí $s(t)$ a $r_s(f)$ získáme hodnotu odpovídající výchylce daného bodu v závislosti na jeho prostorové souřadnici f a časové souřadnici t .

Protože Schlaikjer et al. v [24] neuvádějí funkci útlumu pohybu způsobeného dýcháním s rostoucí vzdáleností od arteriální stěny, budeme pro jednoduchost předpokládat, že pokles je exponenciální a má stejnou strmost jako v rovnici 3.4. Poté můžeme prostorově závislý člen $r_s(f)$ vytknout před součet funkcí $r_t(t)$ a $d_r(t)$ a pro výslednou výchylku $d(f, t)$ bodu na arteriální stěně můžeme psát:

$$d(f, t) = r_s(f) \cdot (r_t(t) + d_r(t)). \quad (3.7)$$

Nová pozice pixelu f' je dána původní vzdáleností od počátku souřadného systému f , ke které je přičtena výchylka $d(f, t)$ a poté jsou souřadnice f' a ϕ převedeny zpět do kartézských souřadnic. Perioda dýchání byla $T_r = 11,25T$.

Všechny body na arteriální stěně se pohybují stejně, proto se výchylka těchto bodů projeví tak, že dojde ke změně poloměru artérie od jeho počáteční hodnoty právě o velikost výchylky. Přičtením počátečního poloměru artérie k aktuální hodnotě výchylky v každém časovém okamžiku tedy dostaneme průběh poloměru artérie v celé sekvenci.


3.3 Příprava testovacích sekvencí

V této části bude popsáno, jakým způsobem byly vytvořeny všechny umělé sekvence UZ snímků, které byly poté použity pro vyhodnocení přesnosti, s jakou jednotlivé

algoritmy sledují artérii. Pro účely této práce bylo nutné vytvořit sekvence s velkým počtem snímků, aby bylo možné ověřit, že algoritmy pracují správně i po delší době.

3.3.1 Sekvence z reálného UZ snímku

Nejprve byla vytvořena sekvence, která je pokud možno co nejvíce podobná sekvenci, která je běžným výstupem z UZ stanice. Tato sekvence bude v následujícím textu označována jako S_0 . Za účelem vytvoření této sekvence byl vybrán vzorový snímek, který zachycuje artérii na konci diastoly, tedy v závěrečné fázi srdečního cyklu (viz obr. 3.3). Tento snímek byl pořízen u pacienta mužského pohlaví (věk: 32 let, hmotnost: 83kg) pomocí UZ stanice Ultrasonix OP s lineární sondou L14-5/38 (výrobce Ultrasonix Medical Corporation, Richmond, Kanada). Rozlišení uvedeného snímku je 370×370 pixelů.



Obr. 3.3: Vzorový UZ snímek z konce diastoly

V tomto snímku byla manuálně identifikována artérie a byla změřena x, y pozice jejího středu a její poloměr r_0 . Tyto parametry pak vstoupily do procesu, který měnil pozici jednotlivých pixelů na základě modelu popsaneho v kapitole 3.2. Změnu pozice jednotlivých pixelů lze docílit pomocí geometrické transformace. Tento proces byl implementován v jazyce C++ s využitím knihovny OpenCV. Pro aplikaci geometrických transformací na obrazy je v OpenCV dostupná metoda `remap`¹.

Výsledná sekvence velice věrně napodobuje reálné sekvence, ale neobsahuje časově proměnlivý šum (pracuje pouze s tím, který byl přítomen v prvním vzorovém snímku) ani žádný rušivý pohyb během sekvence (dýchání nebo pohyb sondy). Z tohoto důvodu byly vytvořeny další sekvence, které simulují další rušivé vlivy při snímání UZ obrazů a které budou popsány v dalších kapitolách.

¹http://docs.opencv.org/modules/imgproc/doc/geometric_transformations.html#remap

3.3.2 Sekvence s globálním pohybem

Důvodem k vytvoření této sekvence byla nutnost ověřit, zda je navržený algoritmus schopen se zotavit ze situace, kdy se artérie během měření dostane mimo záběr UZ sondy a po nějaké době se opět v záběru objeví. Tuto sekvenci budeme dále označovat symbolem S_P . Sekvence S_P byla vytvořena podobným způsobem, jako předchozí sekvence S_0 (tj. s využitím OpenCV a funkce `remap`). Proces tvorby prvních 663 snímků (tj. první polovina sekvence) se neliší od popisu uvedeného v předchozí kapitole. Po snímku s pořadovým číslem 663 se artérie začne pohybovat k pravému okraji snímku až téměř celá zmizí. V dalším snímku byl obrazový obsah manuálně upraven tak, aby tepna na chvíli zcela zmizela. Takto upravený snímek byl do sekvence vložen pětkrát po sobě. Poté následují snímky, kdy se artérie opět vrací od pravého okraje směrem ke středu snímku.

Při pohybu zpět se artérie nevrací přesně na původní pozici, ale přibližně o 50 pixelů vpravo od původní pozice. Toto opatření by mělo být dostatečně „matoucí“ i pro algoritmy, které pro lokalizaci artérie používají poslední známou polohu. Sekvence pak dále pokračuje bez dalšího globálního pohybu, dokud není vytvořeno požadovaných 1320 snímků. Je samozřejmé, že ve snímcích po dokončení globálního pohybu artérie dochází k pulzaci arteriální stěny podle definovaného matematického modelu.

3.3.3 Sekvence se šumem

Kromě sekvence snímků S_0 , která vznikla přímou úpravou snímku z obrázku 3.3, byly vytvořeny další dvě sekvence, které vznikly přidáním šumu různého typu a s různou intenzitou ke každému snímku ze sekvence S_0 . Konkrétně byl uvažován šum typu speckle a druhým typem šumu byl aditivní gaussovský šum. V této práci byl použit obecný model speckle šumu. Zašuměný obraz $f(\mathbf{x})$ lze ze vzorového obrazu $g(\mathbf{x})$ získat pomocí rovnice

$$f(\mathbf{x}) = g(\mathbf{x}) + g(\mathbf{x}) \cdot u(\mathbf{x}), \quad (3.8)$$

kde $u(\mathbf{x})$ popisuje šum s uniformním rozdělením pravděpodobnosti a nulovou střední hodnotou. Rozptyl σ_u^2 šumu $u(\mathbf{x})$ byl nastaven tak, aby výsledný odstup signál šum (Signal to Noise Ratio – SNR) byl 15 dB (sekvence označena S_{SP15}) a 25 dB (sekvence označena S_{SP25}). Jako vzorový obraz $g(\mathbf{x})$ byl postupně použit každý snímek ze sekvence S_0 .

Přidání aditivního gaussovského šumu $\eta(\mathbf{x})$ k obrazu $g(\mathbf{x})$ ze sekvence S_0 lze vyjádřit takto

$$f(\mathbf{x}) = g(\mathbf{x}) + \eta(\mathbf{x}). \quad (3.9)$$

Šum $\eta(\mathbf{x})$ měl nulovou střední hodnotu a rozptyl byl opět nastaven tak, aby výsledné SNR bylo 15 dB (sekvence označena S_{G15}) a 25 dB (sekvence označena S_{G25}).

3.3.4 Sekvence vytvořené pomocí FIELD II

Aby bylo možné ověřit robustnost navrženého řešení z hlediska odolnosti vůči mikropohybu, bylo pomocí nástroje FIELD II [14] vytvořeno několik sekvencí, které vznikly softwarovým „snímáním“ vytvořeného fantomu.

Pro účely této práce byl vytvořen fantom o velikosti $60 \times 60 \times 10$ mm. V tomto prostoru byly náhodně rozmístěny bodové odražeče jimž byla přiřazena amplituda echogenity na základě mapy echogenity, která byla vytvořena manuálně úpravou reálného UZ snímku (viz obr. 3.3). Tento UZ snímek byl nejprve rozostřen pomocí gaussovského rozostření s poloměrem 3 obrazové body. Poté byl snímek podroben procesu posterizace, čímž vznikl snímek s pěti odstíny šedé barvy. Nakonec byl k takto upravenému snímku přidán monochromatický gaussovský šum s mírou 1,2%. Amplituda echogenity jednotlivých bodových odražečů je váhována koeficientem, který odpovídá tomu, jak světlá je oblast v mapě echogenity, do které bodový odražeč na základě své pozice patří. Čím světlejší je oblast v mapě odrazivosti, tím vyšší je amplituda echogenity bodového odražeče. Maximální hodnota amplitudy byla 167 a minimální hodnota 0.

Parametry modelu pohybu byly nastaveny v souladu s tabulkou 3.1. Hodnoty parametrů a_1 a b_1 byly $a_1 = 0,4$ mm a $b_1 = -0,1722$. Na rozdíl od sekvence vzniklé z reálného snímku se zde model pohybu aplikuje na bodové odražeče a nikoli na pixely výsledného obrazu, čímž odpadá nutnost interpolace. Takto vytvořená sekvence byla označena jako S_{F0} .

Kromě sekvence S_{F0} byly vytvořeny ještě dvě další sekvence (S_{F2} a S_{F5}), které vznikly tak, že náhodně vybraná část bodových odražečů byla nahrazena novými. Nové bodové odražeče byly umístěny na náhodné pozice v okolí maximálně jednoho milimetru od původní pozice a jejich amplituda byla nastavena také náhodně tak, aby byla maximálně desetkrát větší nebo desetkrát menší než amplituda původních bodových odražečů. V sekvenci S_{F2} byly tímto způsobem nahrazeny 2% bodových odražečů a v sekvenci S_{F5} bylo nahrazeno 5% bodových odražečů.

4 EXPERIMENTÁLNÍ VÝSLEDKY

Abychom objektivně ověřili vlastnosti navrženého systému, byl tento podroben komplexnímu testování na uměle vytvořených sekvencích. Experiment, během kterého byly získány výsledky, probíhal následovně: nejprve byla načtena zdrojová sekvence snímků, poté byly nastaveny všechny parametry algoritmu. Poté bylo spuštěno samotné měření, kdy byly měřeny a do paměti zaznamenávány geometrické parametry artérie (konkrétně její poloměr a plocha). Tato data byla na konci měření uložena do CSV souboru. Tento experiment byl pro každou zdrojovou sekvenci opakován osmkrát a v každém opakování byl použit jiný detektor významných bodů. Kromě měření parametrů artérie byly do dalšího CSV souboru zaznamenávány také doby, které jednotlivé části procesu potřebují pro výpočet.

Jako zdrojová data byly postupně použity všechny dříve popsané sekvence. Pro každou kombinaci testovací sekvence a detektoru významných bodů tedy vznikly dva soubory. Jeden z nich obsahoval časové údaje a druhý obsahoval zaznamenané hodnoty geometrických parametrů artérie. Tyto dva CSV soubory byly dále zpracovány tak, aby bylo možné vyhodnotit přesnost měření a výpočetní náročnost algoritmu, což je popsáno v následujícím textu.

4.1 Metodika vyhodnocování přesnosti měření

Pro vyhodnocení přesnosti měření bylo použito obecně známé měřítko Root Mean Square Error (RMSE) definované pomocí následující rovnice

$$\text{RMSE} = \sqrt{\mathbb{E}((\mathbf{w}'_0 - \mathbf{w}')^2)} = \sqrt{\frac{1}{M} \sum_{i=1}^M (w'_0(t_i) - w'(t_i))^2}, \quad (4.1)$$

kde \mathbf{w}' označuje vektor změřených výchylek, \mathbf{w}'_0 je vektor správných výchylek M udává celkový počet snímků v sekvenci. Hodnota RMSE tedy udává míru, jak se liší změřené a správné hodnoty.

Vektor hodnot změřených poloměrů pro všechny časové okamžiky označíme jako $\mathbf{R} = [R(t_1), R(t_2), \dots, R(t_M)]$, kde M je počet prvků tohoto vektoru, který odpovídá počtu snímků v jednotlivých sekvencích. Předpokládejme, že se všechny body na arteriální stěně pohybují stejně, pak se musí výchylka těchto bodů projevit tak, že dojde ke změně poloměru od jeho počáteční hodnoty právě o velikost výchylky. Odečtením počátečního poloměru artérie r_0 od hodnoty poloměru v daném časovém okamžiku (snímku) tedy dostaneme výslednou hodnotu výchylky w' . Vektor těchto výchylek pro všechny časové okamžiky označíme \mathbf{w}' . Můžeme jej vypočítat jako

$$\mathbf{w}' = \mathbf{R} - r_0, \quad (4.2)$$

kde jako poloměr r_0 budeme uvažovat poloměr změřený v prvním snímku sekvence.

Konstrukce vektoru správných výchylek \mathbf{w}'_0 je podstatně jednodušší. Víme, že výchylka bodů obrazu v simulovaných sekvencích je dána funkcí $d(f, t)$ popsanou rovnicí 3.7. Body ležící přesně na arteriální stěně nejsou ovlivněny členem, který exponenciálně tlumí amplitudu výchylky, a můžeme tedy jejich výchylku v radiálním směru d_w závislou na čase t popsat takto

$$d_w(t) = a_1 \cdot r_t(t), \quad (4.3)$$

kde a_1 udává maximální výchylku arteriální stěny a $r_t(t)$ je člen ovlivňující výchylku v závislosti na časové souřadnici a je popsán rovnicí 1.2.

Na základě předpokladu, že všechny body na arteriální stěně se pohybují stejně, získáme vektor \mathbf{w}'_0 tak, že za sebe seřadíme hodnoty $d_w(t)$ pro jednotlivé časové okamžiky:

$$\mathbf{w}'_0 = [d_w(t_1), d_w(t_2), \dots, d_w(t_M)]. \quad (4.4)$$

Pro komplexní vyhodnocení vlastností nového algoritmu uzpůsobeného pro dlouhodobé měření byla přesnost stanovena i u verze sledovacího algoritmu, který nebyl uzpůsoben pro zamezení odplování bodů ani pro detekci pohybu artérie. Tento algoritmus bude v dalším textu označován jako referenční metoda.

V tabulkách uvedených v následujících kapitolách budou uváděny hodnoty RMSE navrženého řešení a pro srovnání také hodnoty RMSE získané měřením pomocí referenční metody.

Tab. 4.1: Výsledky pro sekvenci S_0

detektor	RMSE [px]	
	Vlastní řešení	Referenční metoda
FAST	0,9579	0,5331
GFTT	0,4644	0,4846
Harris	0,7738	0,4713
PyramidFAST	0,6649	0,5518
PyramidGFTT	0,4640	0,4846
PyramidHarris	0,5431	0,4713
SIFT*	3,6188	0,4827
SIFT*	4,9433	0,8401

*Nevhodné nastavení parametrů `maskWidth` a `εaw`

4.1.1 Testování na sekvenci z reálného UZ snímku

Jako první uvádíme výsledky získané testováním navrženého systému na sekvenci S_0 , která vznikla přímou úpravou reálného UZ snímku. Tabulka 4.1 ukazuje, že v naměřených datech není výrazný rozdíl mezi navrženým řešením a referenční metodou.

4.1.2 Testování na sekvenci s globálním pohybem

Výsledky testování na této sekvenci jsou uvedeny v tabulce 4.2.

Tab. 4.2: Výsledky pro sekvenci s globálním pohybem S_P

detektor	RMSE [px]	
	Vlastní řešení	Referenční metoda
FAST	4,0597	96,4852
GFTT	4,2533	23,9098
Harris	3,9332	42,6431
PyramidFAST	4,4994	24,0958
PyramidGFTT	3,5356	23,9079
PyramidHarris	3,8311	24,0248
SIFT*	6,3556	26,0650
SURF*	4,8807	24,3141

*Nevhodné nastavení parametrů `maskWidth` a ϵ_{aw}

Zde je na první pohled patrné, že referenční metoda zcela selhává, což je předvídatelný výsledek, neboť tento algoritmus není připraven na situaci, kdy artérie ze snímku zmizí a poté se opět objeví.

4.1.3 Testování na sekvencích se šumem

Výsledky testování na sekvencích s přidaným šumem (viz kapitola 3.3.3) jsou shrnuty v tabulce 4.3. Na sekvencích se speckle šumem je vidět, že referenční metoda nedosahuje zdaleka tak dobrých výsledků a v případě SNR 15 dB selhává úplně. Lze tedy konstatovat, že navržené řešení je vysoce odolné vůči šumu typu speckle. Na sekvencích s aditivním gaussovským šumem dosáhlo navržené řešení srovnatelných výsledků jako referenční metoda za použití Harrisova detektoru (ostatní detektory si vedly hůře).

Tab. 4.3: Výsledky testování na sekvencích se šumem

detektor	RMSE [px]							
	Sekvence S_{G25}		Sekvence S_{G15}		Sekvence S_{SP25}		Sekvence S_{SP15}	
	Vlastní řešení	Referenční metoda	Vlastní řešení	Referenční metoda	Vlastní řešení	Referenční metoda	Vlastní řešení	Referenční metoda
FAST	0,7294	0,4589	130,7459	87,4540	1,3140	2,0677	71,0773	27,7223
GFTT	0,5009	0,4467	3,5075	2,3608	0,5284	2,0766	1,8481	111,5661
Harris	0,5507	0,4466	2,7701	2,6365	0,5182	0,8722	2,9193	138,6851
PyramidFAST	0,7363	0,4419	7,2317	317,1422	0,6538	1,7567	1,3670	57,0142
PyramidGFTT	1,8534	0,4467	3,7247	3,0969	0,9464	1,6672	3,7871	111,5661
PyramidHarris	0,8455	0,4466	3,6748	2,6365	0,5463	0,8722	6,7516	79,9053
SIFT*	2,5185	0,6359	2,4984	3,4048	3,0416	1,5040	2,7530	36,2255
SURF*	7,9336	0,7283	7,3784	5,8053	2,9812	1,4324	3,4052	119,2418

*Nevhodné nastavení parametrů $maskWidth$ a ϵ_{av}

Tab. 4.4: Výsledky pro simulované sekvence

detektor	RMSE [px]					
	Sekvence S_{F0}		Sekvence S_{F2}		Sekvence S_{F5}	
	Vlastní řešení	Referenční metoda	Vlastní řešení	Referenční metoda	Vlastní řešení	Referenční metoda
FAST	5,4155	4,7228	3,4047	2,2439	2,6877	8,5352
GFTT	3,2930	4,6989	3,4846	3,0030	1,8297	8,2929
Harris	3,1549	12,3438	2,6611	3,1298	2,1330	10,8453
PyramidFAST	4,6271	4,5415	3,4589	2,8418	3,0496	8,4503
PyramidGFTT	3,1285	4,6989	3,7575	3,0030	3,0792	8,2929
PyramidHarris	2,2129	12,2012	2,8523	3,2625	2,1592	10,8453
SIFT*	2,6675	3,5862	7,7134	2,8584	3,7332	8,9161
SURF*	2,5806	4,7200	5,0508	3,4516	3,7584	6,6658

*Nevhodné nastavení parametrů $maskWidth$ a ϵ_{av}

4.1.4 Testování na sekvencích vytvořených pomocí FIELD II

Na sekvencích softwarově simulovaných pomocí nástroje FIELD II je velmi dobře vidět zlepšení, kterého je dosaženo při použití metody navržené v této práci. Na těchto sekvencích se totiž velmi výrazným způsobem projevil jev feature drift. Negativní důsledky tohoto jevu však byly v navrženém řešení výrazným způsobem potlačeny. Tabulka 4.4 jasně ukazuje, že navržené řešení ve všech případech dosahuje lepších výsledků než referenční metoda.

4.2 Vyhodnocení výpočetní náročnosti

Jedním z důležitých požadavků na navržený systém je, aby byl schopen pracovat v reálném čase. Proto byla změřena výpočetní náročnost jednotlivých kroků algoritmu. Pro tento účel byly do zdrojového kódu doplněny příkazy měřící uplynulý čas mezi dvěma částmi kódu a tento čas byl poté spolu s názvem činnosti zapsán na standardní výstup. Tímto způsobem byly zaznamenány doby trvání následujících kroků algoritmu pro dlouhodobé sledování artérie:

- **lokalizace artérie**, která dále zahrnuje tyto kroky: detekce pomocí detektoru Viola-Jones, úprava obrazu, nalezení středu artérie pomocí Houghovy transformace a přesné určení poloměru analýzou průměrného jasu,
- **výpočet optického toku**, tj. určení vektorů pohybu pro všechny sledované body pomocí algoritmu Lucas-Kanade,
- **aktualizace sledovaných bodů**, tj. odstranění bodů nevyhovujících některé z podmínek popsanych v kapitole 3.1,
- **detekce významných bodů**, tj. samotná detekce významných bodů v oblasti vymezené binární maskou pomocí zvoleného detektoru významných bodů.

V tabulkách dále v této kapitole jsou uváděny průměrné doby a za znakem \pm je uváděna směrodatná odchylka.

Měření bylo provedeno na PC s procesorem Intel Core i5-2320 @3,00GHz a 16GB operační paměti. Na PC byl nainstalován 64-bitový operační systém Windows 7 se Service Pack 1. Kromě samotné aplikace na počítači neběžel žádný další program.

Při pohledu do tabulky 4.5 je zjevné, že časově nejnáročnějším krokem je lokalizace artérie, která trvá zhruba 32 až 37 ms. Tento proces je také nejvíce závislý na míře šumu v datech (v případě sekvence S_{G15} trvá lokalizace artérie téměř dvojnásobnou dobu než v případě nezašuměné sekvence). Zbylé dva kroky algoritmu trvají v porovnání s lokalizací artérie zanedbatelnou dobu (řádově jednotky ms) a jsou nezávislé na míře šumu obsaženého v datech.

Tab. 4.5: Časová náročnost jednotlivých kroků algoritmu v sekvencích vytvořených z reálného UZ snímku

sekvence činnost	S_0 doba [ms]	S_P doba [ms]	S_{G25} doba [ms]	S_{G15} doba [ms]	S_{SP25} doba [ms]	S_{SP15} doba [ms]
lokalizace artérie	$32,1817 \pm 5,6196$	$27,7233 \pm 10,4150$	$33,8281 \pm 7,5466$	$69,5630 \pm 17,3460$	$36,6865 \pm 6,7562$	$49,1673 \pm 11,4628$
výpočet optického toku	$1,2365 \pm 0,1886$	$1,2121 \pm 0,1548$	$1,2019 \pm 0,0310$	$1,2703 \pm 0,0869$	$1,2305 \pm 0,0679$	$1,2575 \pm 0,0555$
aktualizace bodů	$1,9607 \pm 0,5038$	$1,9280 \pm 0,5389$	$1,8252 \pm 0,3446$	$1,8616 \pm 1,1737$	$1,9116 \pm 0,4169$	$1,8581 \pm 0,4104$

Tab. 4.6: Časová náročnost jednotlivých detektorů významných bodů v sekvencích vytvořených z reálného UZ snímku

sekvence detektor	S_0 doba detekce [ms]	S_P doba detekce [ms]	S_{G25} doba detekce [ms]	S_{G15} doba detekce [ms]	S_{SP25} doba detekce [ms]	S_{SP15} doba detekce [ms]
FAST	$0,8396 \pm 0,2698$	$0,7858 \pm 0,2509$	$0,7134 \pm 0,0147$	$2,3667 \pm 0,0662$	$0,7887 \pm 0,1175$	$1,0316 \pm 0,0169$
GFTT	$3,9280 \pm 0,0267$	$3,9578 \pm 0,0481$	$4,0403 \pm 0,0615$	$3,8846 \pm 0,0790$	$3,9694 \pm 0,0465$	$4,0304 \pm 0,0613$
Harris	$3,8376 \pm 0,0226$	$3,8494 \pm 0,0272$	$3,8319 \pm 0,0253$	$4,1257 \pm 0,0276$	$3,8731 \pm 0,0403$	$3,9060 \pm 0,0466$
PyramidFAST	$1,8930 \pm 0,0968$	$1,8941 \pm 0,0398$	$1,9499 \pm 0,0277$	$3,7527 \pm 22,3128$	$2,0231 \pm 0,0432$	$2,3066 \pm 0,0970$
PyramidGFTT	$7,9298 \pm 0,0497$	$7,9119 \pm 0,2172$	$7,9344 \pm 0,2158$	$7,8872 \pm 0,0304$	$7,9340 \pm 0,0655$	$7,9871 \pm 0,0766$
PyramidHarris	$7,7800 \pm 0,0511$	$7,8161 \pm 0,0633$	$7,7683 \pm 0,0605$	$8,0720 \pm 0,1124$	$7,8227 \pm 0,0608$	$7,8046 \pm 0,0654$
SIFT	$50,4512 \pm 0,8582$	$50,7482 \pm 0,5237$	$48,2937 \pm 0,4488$	$56,4971 \pm 0,0300$	$51,5447 \pm 0,4684$	$51,7546 \pm 0,4675$
SURF	$4,8920 \pm 0,0347$	$4,8789 \pm 0,0428$	$5,1709 \pm 0,0336$	$5,1958 \pm 0,0670$	$4,8976 \pm 0,0301$	$4,9451 \pm 0,0461$

Tabulka 4.6 popisuje, jak dlouho trvá pro jednotlivé detektory proces detekce významných bodů. Jednoznačně nejrychlejším detektorem je detektor typu FAST (doba detekce pod 1 ms), naopak jednoznačně nejpomalejším detektorem je detektor typu SIFT (doba detekce okolo 50 ms). I zde se ukázala podobnost Harrisova detektoru a detektoru GFTT, neboť časy nutné pro detekci významných bodů jsou v obou případech téměř shodné (přibližně 4 ms). Pyramidální verze Harrisova detektoru a detektoru GFTT jsou přibližně dvakrát časově náročnější než jejich běžné verze, což odpovídá teoretickým předpokladům, neboť detekce je vlastně prováděna dvakrát (v každém patře gaussovské pyramidy).

4.3 Shrnutí výsledků

Z provedených experimentů a jejich výsledků plyne, že nejpřesnějších výsledků dosahuje navržené řešení při použití Harrisova detektoru. Poté následuje detektor Good Features To Track, pyramidální verze Harrisova detektoru a pyramidální verze detektoru GFTT.

Ostatní testované detektory se pro dlouhodobé sledování artérie ve videosekvenci ukázaly jako nevhodné, což bude podrobněji rozebráno dále. Průměrné hodnoty RMSE vypočtené z dílčích výsledků ze všech sekvencí vzniklých z reálného UZ snímku shrnuje tabulka 4.7.

Tab. 4.7: Shrnutí výsledků

detektor	Vlastní řešení RMSE [px]	Referenční metoda RMSE [px]
Harris	$2,1571 \pm 1,1805$	$23,5637 \pm 42,6128$
GFTT	$2,1900 \pm 1,4033$	$17,4266 \pm 33,9864$
PyramidHarris	$2,6019 \pm 1,8809$	$14,9629 \pm 24,1116$
PyramidGFTT	$2,6974 \pm 1,2096$	$17,4627 \pm 33,9718$
PyramidFAST	$2,9210 \pm 2,1527$	$46,3151 \pm 97,3015$
SIFT*	$3,8778 \pm 1,7676$	$9,2976 \pm 12,1503$
SURF*	$4,7680 \pm 1,7579$	$18,5777 \pm 36,2387$
FAST	$24,6887 \pm 43,1216$	$25,5803 \pm 36,4263$

*Nevhodné nastavení parametrů `maskWidth` a ϵ_{aw}

Výsledky Harrisova detektoru a detektoru GFTT jsou velmi podobné a to jak, co se týče přesnosti měření, tak i co se týče rychlosti výpočtu. Další výhodou těchto detektorů je i to, že jimi vybrané body mají vysoký informační obsah, což dokládá naše studie publikovaná v [32]. Detektor typu FAST se ukázal také jako nevhodný, neboť jeho chování je výrazně ovlivněno přítomností šumu ve zdrojových datech

a pro silně zašuměná data je naprosto nepoužitelný. Výrazné zlepšení však přineslo použití pyramidální verze tohoto detektoru. Ukázalo se, že v běžných UZ snímcích nejsou příliš hojně zastoupeny příznaky nazývané bloby a tedy, že detektory blobů (SURF a SIFT) nejsou pro použití v UZ snímcích příliš vhodné. Méně přesné výsledky při použití těchto detektorů lze dále vysvětlit nutností úpravy parametrů `maskWidth` a ϵ_{aw} . Ve výše uvedených tabulkách jsou proto výsledky pro detektory SIFT a SURF uváděny vždy s poznámkou, že nastavení parametrů nebylo vhodné. Upravené nastavení vede k tomu, že za běhu algoritmu jsou detekovány a v množině sledovaných bodů ponechány i takové body, jejichž vzdálenost od arteriální stěny je poměrně značná. Tyto body mají samozřejmě negativní vliv na přesnost měření, neboť elipsa proložená sledovanými body nekopíruje dostatečně přesně arteriální stěnu. Úprava nastavení parametrů algoritmu dále vede k tomu, že během fáze aktualizace bodů dochází k odstranění a přidání velkého počtu bodů, což vede k tomu, že arteriální stěna není sledována plynule a dochází k velkým skokům ve velikosti poloměru mezi sousedními snímky. Významné body detekované detektory SURF a SIFT jsou (díky tomu, že pro detekci významných bodů využívají scale-space reprezentaci) nezávislé na změně měřítka, což však není pro potřeby této práce nutné. Naopak jsou detektory SURF a SIFT výpočetně náročnější. Lze tedy konstatovat, že použití významných bodů nezávislých na změně měřítka není vzhledem ke zvýšení výpočetní náročnosti příliš výhodné. K podobným výsledkům jsme došli také v práci [31], kde byly testovány detektory Difference of Gaussians, Fast Hessian a Harris-Laplace (upravená verze Harrisova detektoru, která detekuje body nezávislé na změně měřítka) z hlediska jejich opakovatelnosti.

Lze konstatovat, že navržená metoda je odolná vůči jevu feature drift a je vhodná pro dlouhodobé sledování artérie v sekvenci UZ snímků, což dokazují zejména výsledky na sekvencích vytvořených softwarovým „snímáním“ fantomu. Schopnost navrženého řešení poradit si se situací, kdy artérie ze scény zcela zmizí a poté se opět objeví, byla objektivně ověřena na testovací sekvenci S_P . Referenční metoda v tomto případě podle našeho předpokladu zcela selhala.

5 ZÁVĚR

Byla představena nová metoda pro dlouhodobou analýzu pohybu artérie v příčném řezu v sekvenci UZ snímků. Byl popsán návrh a implementace systému pro automatické sledování artérie a dlouhodobé kontinuální měření jejich parametrů v sekvenci UZ snímků. Nejprve byl popsán celý navržený systém, který se skládá z několika detailně popsaných procesů. Pro lokalizaci artérie byl využit detektor typu Viola-Jones, pomocí kterého je nalezena oblast obsahující hledanou artérii a její pozice je dále zpřesněna pomocí Houghovy transformace. Na základě známé pozice arteriální stěny je definována maska, ve které jsou detekovány významné body, které jsou dále sledovány pomocí Lucas-Kanadeho metody pro výpočet optického toku. V této práci jsou navrženy dva nové procesy a to proces aktualizace sledovaných bodů a proces reinitializace. Úkolem procesu aktualizace sledovaných bodů je odstranit body, které leží daleko od arteriální stěny (a mají negativní vliv na přesnost měření) a v případě potřeby doplnit množinu sledovaných bodů novými, které leží přesně na arteriální stěně (podrobně popsáno v kapitole 3.1.3). Proces reinitializace spočívá v pravidelném vyhodnocování, zda se sledovaná artérie výrazně neposunula z poslední známé pozice. Za tímto účelem se pravidelně spouští proces lokalizace artérie a pokud je zjištěn výrazný pohyb artérie, je množina sledovaných bodů vyprázdněna a jsou detekovány nové body, které leží v oblasti arteriální stěny nalezené procesem lokalizace artérie (podrobně popsáno v kapitole 3.1.4). Díky těmto nově navrženým procesům je systém schopen velice přesně sledovat arteriální stěnu i ve velmi dlouhých videosekvencích a to i v případě, kdy v obraze dochází k výraznému pohybu artérie.

Následně byl formulován nový matematický model pohybu arteriální stěny v příčném řezu, který zohledňuje vliv dýchání. Na základě tohoto modelu bylo poté vytvořeno několik umělých sekvencí UZ snímků, které byly dále použity pro vyhodnocení přesnosti navrženého řešení. Jedná se o dva základní druhy videosekvencí: sekvence vzniklé přímou úpravou reálného UZ snímku a sekvence kompletně simulované pomocí nástroje FIELDS II. V těchto sekvencích jsou simulovány dva velmi důležité jevy: globální pohyb artérie a drobný pohyb bodových odražečů (tzv. „mikropohyb“). Vytvořené sekvence jsou jedinečné také svou délkou, což umožňuje jejich použití pro vyhodnocení přesnosti měření v dlouhých videosekvencích.

Vytvořené simulované sekvence byly použity pro komplexní testování navrženého řešení. Kromě vyhodnocení přesnosti měření byla pozornost věnována také vyhodnocení výpočetní náročnosti. Z výsledků vyplývá, že co se týče přesnosti, nejlepších výsledků je možné dosáhnout s použitím Harrisova detektoru významných bodů. Tento detektor patří také mezi jeden z nejrychlejších. Naopak jako nevhodné se ukázaly detektory založené na scale-space reprezentaci (detektory typu Fast Hes-

sian a Difference of Gaussians) a také detektor typu FAST. Z porovnání s jinými metodami vyplynulo, že navržené řešení dosahuje lepších nebo srovnatelných výsledků jako jiné metody, u kterých jsou však dostupné pouze výsledky testování na krátkých videosekvencích, které neobsahují žádné rušivé jevy (např. globální pohyb).

V práci byly splněny všechny cíle, které byly vytyčeny v kapitole 2:

- Systém je zcela **automatický** a nevyžaduje vstup operátora na začátku měření ani v případě, kdy dojde k posunu sledované artérie mimo obraz a poté zpět.
- Systém je schopen provádět **spolehlivé a přesné měření i ve velmi dlouhých sekvencích**, neboť vhodným způsobem řeší problém „odplouvání“ významných bodů (feature drift).
- Systém je **robustní vůči běžným jevům v UZ sekvencích** jako je pohyb sondy, polykání, dýchání pacienta apod.
- Systém je **odolný vůči šumu**, což bylo dokázáno na sekvencích uměle narušených šumem různého typu.
- Systém je schopen **pracovat v reálném čase** při zpracování většiny snímků. Pro dodržení požadavku na zpracování v reálném čase i v okamžicích, kdy dochází k reinicializaci měření, je nutné provést dodatečnou (avšak jednoduchou) úpravou navrženého algoritmu.
- Naměřené **hodnoty je možné uložit pro další zpracování** do souboru typu CSV a takto naměřená data je možné dále zpracovat.
- Při návrhu byla věnována velká pozornost modularitě celého systému a proto je systém jednoduše **rozšiřitelný a upravitelný**.

Kromě samotného systému pro dlouhodobou analýzu videosekvencí je dalším přínosem práce formulace komplexního modelu pohybu arteriální stěny v příčném řezu, který nebyl v odpovídající podobě dosud popsán. Tento model je unikátní tím, že zahrnuje všechny významné vlivy působící na arteriální stěnu během srdečního cyklu, tj. vedle samotné pulzace arteriální stěny i dýchací artefakty. Díky tomu, že model pro popis pohybu používá velké množství parametrů, je možné přizpůsobit výsledný model pohybu klinickým datům jejich vhodným nastavením a dosáhnout tak co největší podobnosti se skutečnými průběhy zaznamenanými u konkrétních pacientů.

Dalším přínosem práce jsou uměle vytvořené sekvence zachycující artérii v příčném řezu, které vznikly na základě navrženého modelu. Tyto sekvence je možné využít pro testování přesnosti dalších algoritmů pro sledování artérie a proto mohou být v případě zájmu poskytnuty dalším vědeckým týmům.

Navržený systém může být vzhledem ke svým vlastnostem implementován do běžně používaných UZ stanic, což by mohlo výrazným způsobem urychlit práci lékařů, kteří provádějí klinické vyšetření *arteria carotis communis* a pomoci jim při správném stanovení diagnózy.

LITERATURA

- [1] Bay, H.; Tuytelaars, T.; Gool, L. V.: Surf: Speeded up robust features. In *In ECCV*, 2006, s. 404–417.
- [2] Beneš, R.; Karásek, J.; Burget, R.; Říha, K.: Automatically Designed Machine Vision System for the Localization of CCA Transverse Section in Ultrasound Images. *Comput. Methods Prog. Biomed.*, ročník 109, č. 1, Leden 2013: s. 92–103, ISSN 0169-2607, doi:10.1016/j.cmpb.2012.08.014.
- [3] Bouguet, J.-y.: Pyramidal implementation of the Lucas Kanade feature tracker. *Intel Corporation, Microprocessor Research Labs*, 2000.
- [4] Chen, L.; Treece, G. M.; Lindop, J. E.; Gee, A. H.; Prager, R. W.; aj.: A quality-guided displacement tracking algorithm for ultrasonic elasticity imaging. 2008.
- [5] Coleman, T. F.; Li, Y.: An Interior Trust Region Approach for Nonlinear Minimization Subject to Bounds. *Technická zpráva*, Ithaca, NY, USA, 1993.
- [6] Duda, R. O.; Hart, P. E.: Use of the Hough Transformation to Detect Lines and Curves in Pictures. *Commun. ACM*, ročník 15, č. 1, Leden 1972: s. 11–15, ISSN 0001-0782.
- [7] Golemati, S.; Stoitsis, J.; Gastouniotti, A.; Dimopoulos, A.; Koropouli, V.; aj.: Comparison of Block Matching and Differential Methods for Motion Analysis of the Carotid Artery Wall From Ultrasound Images. *Information Technology in Biomedicine, IEEE Transactions on*, ročník 16, č. 5, Sept 2012: s. 852–858, ISSN 1089-7771, doi:10.1109/TITB.2012.2193411.
- [8] 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*, ročník 33, č. 12, December 2007: s. 1918–1932, ISSN 0301-5629, doi:10.1016/j.ultrasmedbio.2007.05.021.
- [9] Gosling, R. G.; Budge, M. M.: Terminology for describing the elastic behavior of arteries. *Hypertension*, ročník 41, č. 6, 2003: s. 1180–1182.
- [10] Guerrero, J.; Salcudean, S.; McEwen, J.; Masri, B.; Nicolaou, S.: Real-Time Vessel Segmentation and Tracking for Ultrasound Imaging Applications. *Medical Imaging, IEEE Transactions on*, ročník 26, č. 8, Aug 2007: s. 1079–1090, ISSN 0278-0062.
- [11] Harris, C.: A combined corner and edge detector. *Proc. Alvey Vision Conf.*, 1988, 1988.
- [12] Hofer, M.: *Kurz sonografie: překlad 4., rozšířeného a přepracovaného vydání*. Grada Publishing, 2005, ISBN 9788024709567.

- [13] Horn, B. K. P.; Schunck, B. G.: Determining Optical Flow. *ARTIFICIAL INTELLIGENCE*, ročník 17, 1981: s. 185–203.
- [14] Jensen, J. A.: FIELD: A Program for Simulating Ultrasound Systems. In *10TH NORDICBALTIC CONFERENCE ON BIOMEDICAL IMAGING, VOL. 4, SUPPLEMENT 1, PART 1:351–353*, 1996, s. 351–353.
- [15] Ledesma-Carbayo, M. J.; Kybic, J.; Desco, M.; Santos, A.; Suhling, M.; aj.: Spatio-temporal nonrigid registration for ultrasound cardiac motion estimation. *IEEE Trans. Med. Imaging*, ročník 24, č. 9, 2005: s. 1113–1126.
- [16] Liu, S.; Padfield, D.; Mendonca, P.: Tracking of Carotid Arteries in Ultrasound Images. In *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2013*, Springer, 2013, s. 526–533.
- [17] Lowe, D. G.: Object Recognition from Local Scale-Invariant Features. In *Proceedings of the International Conference on Computer Vision–Volume 2 - Volume 2*, ICCV '99, Washington, DC, USA: IEEE Computer Society, 1999, ISBN 0-7695-0164-8, s. 1150–.
- [18] Lucas, B. D.; Kanade, T.: An Iterative Image Registration Technique with an Application to Stereo Vision. In *Proceedings of the 7th International Joint Conference on Artificial Intelligence - Volume 2*, IJCAI'81, San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1981, s. 674–679.
- [19] Mašek, J.; Burget, R.; Karásek, J.; Uher, V.; Guney, S.: Evolutionary improved object detector for ultrasound images. In *Telecommunications and Signal Processing (TSP), 2013 36th International Conference on*, July 2013, s. 586–590.
- [20] Říha, K.; Beneš, R.: Circle detection in pulsative medical video sequence. In *Signal Processing (ICSP), 2010 IEEE 10th International Conference on*, Oct 2010, s. 674–677.
- [21] Říha, K.; Beneš, R.: Testing of methods for artery section area detection. In *Proceedings of the 10th WSEAS international conference on Telecommunications and informatics and microelectronics, nanoelectronics, optoelectronics, and WSEAS international conference on Signal processing*, TELE-INFO'11/MINO'11/SIP'11, Stevens Point, Wisconsin, USA: World Scientific and Engineering Academy and Society (WSEAS), 2011, ISBN 978-1-61804-005-3, s. 184–187.
- [22] Říha, K.; Mašek, J.; Burget, R.; Beneš, R.; Závodná, E.: Novel method for localization of common carotid artery transverse section in ultrasound images using modified viola-jones detector. *Ultrasound in medicine & biology*, ročník 39, 2013, ISSN 0301-5629.

- [23] Říha, K.; Potůček, I.: The Sequential Detection of Artery Sectional Area Using Optical Flow Technique. In *Proceedings of the 8th WSEAS International Conference on Circuits, Systems, Electronics, Control & Signal Processing, CSECS'09*, Stevens Point, Wisconsin, USA: World Scientific and Engineering Academy and Society (WSEAS), 2009, ISBN 978-960-474-139-7, s. 222–226.
- [24] Schlaikjer, M.; Petersen, S. T.; Jensen, J.; Stetson, P.: Tissue motion in blood velocity estimation and its simulation. In *Ultrasonics Symposium, 1998. Proceedings., 1998 IEEE*, ročník 2, 1998, s. 1495–1499 vol.2.
- [25] Shi, J.; Tomasi, C.: Good features to track. In *Computer Vision and Pattern Recognition, 1994. Proceedings CVPR '94., 1994 IEEE Computer Society Conference on*, Jun 1994, ISSN 1063-6919, s. 593–600, doi:10.1109/CVPR.1994.323794.
- [26] Stoitsis, J.; Golemati, S.; Bastouni, E.; Nikita, K.: A mathematical model of the mechanical deformation of the carotid artery wall and its application to clinical data. In *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*, Aug 2007, ISSN 1557-170X, s. 2163–2166.
- [27] Stoitsis, J.; Golemati, S.; Koropouli, V.; Nikita, K.: Simulating dynamic B-mode ultrasound image data of the common carotid artery. In *Imaging Systems and Techniques, 2008. IST 2008. IEEE International Workshop on*, Sept 2008, s. 144–148.
- [28] Tuytelaars, T.; Mikolajczyk, K.: *Local Invariant Feature Detectors: A Survey*. Haver, MA, USA: Now Publishers Inc., 2008, ISBN 1601981384, 9781601981387.
- [29] Viola, P.; Jones, M.: Robust Real-time Object Detection. *International Journal of Computer Vision*, ročník 57, č. 2, 2001: s. 137–154.
- [30] Zinßer, T.; Gräbl, C.; Niemann, H.: Efficient Feature Tracking for Long Video Sequences. In *DAGM-Sympasosium, Lecture Notes in Computer Science*, ročník 3175, editace C. E. Rasmussen; H. H. Bülthoff; B. Schölkopf; M. A. Giese, Springer, 2004, ISBN 3-540-22945-0, s. 326–333.
- [31] Zukal, M.; Beneš, R.; Číka P.; Říha, K.: Towards an Optimal Interest Point Detector for Measurements in Ultrasound Images. *Measurement Science Review*, ročník 13, č. 6, December 2013: s. 329–337.
- [32] Zukal, M.; Číka, P.: Corner detectors: Evaluation of information content. In *Telecommunications and Signal Processing (TSP), 2012 35th International Conference on*, July 2012, s. 763–767, doi:10.1109/TSP.2012.6256400.

Curriculum Vitæ

Martin Zukal

Osobní informace

Datum narození: 12. října, 1985
Místo narození: Brno
Adresa: Bellova 44, 623 00 Brno
Telefon: +420 777 697 248
E-mail: ZukalMartin@seznam.cz

Vzdělání

2010–2014 Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Technická 3058/10, 616 00 Brno, titul: Ph.D. (předpokládaná doba ukončení: 2014)
2008–2010 Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Technická 3058/10, 616 00 Brno, titul: Ing.
2005–2008 Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Technická 3058/10, 616 00 Brno, titul: Bc.
1997–2005 Gymnázium Matyáše Lercha, Žižkova 55, 616 00 Brno

Dodatečné informace ke vzdělání

2009 Tampere University of Technology, Korkeakoulunkatu 10, FI-33720 Tampere, Finsko

Ocenění

2010	Cena děkanky FEKT, VUT v Brně za diplomovou práci „Sdílení plochy při video a audiokonferencích“
2010	Magisterský titul s vyznamenáním
2010	Cena děkana FEKT, VUT v Brně za bakalářskou práci „SIP klient v jazyce JAVA“
2008	Bakalářský titul s vyznamenáním

Předchozí zaměstnání

2010–2014	<i>vědecký pracovník</i> : Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací, Technická 12, 616 00 Brno
2007–2010	<i>software developer</i> : Icewarp Technology s. r. o. , Španělská 4, 120 00 Praha 2

Participace na projektech

2010–2013	CZ.1.05/2.1.00/03.0072, <i>Centrum senzorických, informačních a komunikačních systémů (SIX)</i>
2010–2013	FR-TI2/679, <i>Média-informační systém s podporou pokročilých multimediálních služeb</i>
2010–2012	KONTAKT ME10123, <i>Výzkum algoritmů pro zpracování digitálních obrazů a obrazových sekvencí</i>

Vyžádané přednášky

- *Assessment of Feature Points Extraction in Varying Background*, Department of Automation, USTB, No. 30 Xuyuan Road, Beijing 100083, Čínská lidová republika

ABSTRAKT

Tato dizertační práce se věnuje analýze ultrazvukových (UZ) videosekvencí a to konkrétně dlouhodobému sledování krkavice v příčném řezu a měření jejích geometrických parametrů. Je zde popsán návrh a implementace systému pro automatické sledování artérie v sekvenci UZ snímků. Navržený systém využívá pro lokalizaci artérie detektor typu Viola-Jones a Houghovu transformaci. V oblasti lokalizované artérie jsou detekovány významné body, které jsou poté sledovány pomocí algoritmu pro výpočet optického toku. Navržený systém obsahuje několik inovativních procesů, díky kterým je možné provádět přesné dlouhodobé kontinuální měření parametrů artérie v sekvenci UZ snímků a výsledky tohoto měření ukládat. Následně byl formulován nový matematický model pohybu arteriální stěny v příčném řezu, který zohledňuje vliv dýchání. Na základě tohoto modelu bylo poté vytvořeno několik umělých sekvencí UZ snímků, které byly použity pro vyhodnocení přesnosti, s jakou je navržené řešení schopno měřit požadované parametry. Vytvořené sekvence snímků je možné použít pro vyhodnocení přesnosti sledování v dlouhých videosekvencích.