

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2017

Bc. Matyáš Kadlas



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY

A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

DETEKCE PULSACÍ CÉV VE VIDEOSEKVENCÍCH SÍTNICE

DETECTION OF BLOOD VESSELS PULSATION IN RETINAL SEQUENCES

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Matyáš Kadlas

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Radim Kolář, Ph.D.

BRNO 2017



Diplomová práce

magisterský navazující studijní obor **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

Student: Bc. Matyáš Kadlas

ID: 154755

Ročník: 2

Akademický rok: 2016/17

NÁZEV TÉMATU:

Detekce pulsací cév ve videosekvencích sítnice

POKYNY PRO VYPRACOVÁNÍ:

1) Prostudujte a popište metody z literatury, které jsou zaměřené na detekci a analýzu pulsací cév ve videosekvencích sítnice. Zaměřte se především na metody pro vyhodnocení spontánní venózní pulsace a pohyby arterií. 2) Jednotlivé přístupy stručně charakterizujte a zaměřte se na přístup založený na metodě hlavních komponent (PCA). 3) PCA metodu pro tuto aplikaci implementujte a otestujte na volně dostupných datech (<http://www.datadryad.org>). 4) Zaměřte se na modifikaci vytvořeného přístupu detekce pulsací pro sekvence s menším poměrem signál šum a menším kontrastem cévního řečiště. 5) Metodu otestujte a vyhodnoťte na dodaných i volně dostupných datech. Získané výsledky dostatečně diskutujte.

DOPORUČENÁ LITERATURA:

- [1] MORGAN, W.H. et al. Objective Detection of Retinal Vessel Pulsation. PLoS ONE, 2014, 10(2), s.e0116475.
[2] MORET, F. et al., Visualization of fundus vessel pulsation using principal component analysis. Investigative ophthalmology & visual science, 2011, 52(8), s. 5457–64.

Termín zadání: 6.2.2017

Termín odevzdání: 19.5.2017

Vedoucí práce: doc. Ing. Radim Kolář, Ph.D.

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Tato diplomová práce se zabývá detekcí pulzací cév ve videosekvencích sítnice. Cílem je vytvořit algoritmus pro objektivní hodnocení pulzací ve video sekvencích sítnice.

KLÍČOVÁ SLOVA

Sítnice, analýza hlavních komponent, MATLAB, konfokální skenovací oftalmoskop

ABSTRACT

This diploma thesis is dealing with the detection of blood vessels pulsation in retinal sequences. The goal is to create an algorithm for objective evaluation of pulsation in retinal video sequences.

KEYWORDS

Retina, principal component analysis, MATLAB, confocal scanning laser ophthalmoscope

KADLAS, Matyáš *Detekce pulzací cév ve videosekvencích sítnice*: diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2017. 57 s. Vedoucí práce byl doc. Ing. Radim Kolář, Ph.D.

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Detekce pulsací cév ve videosekvencích sítnice“ jsem vypracoval(a) samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

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

Brno

.....

podpis autora(-ky)

PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu diplomové práce panu doc. Ing. Radimu Kolářovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Brno

.....

podpis autora(-ky)

OBSAH

Úvod	10
1 Anatomie oka	11
1.1 Anatomie sítnice	11
2 Snímání obrazů sítnice	13
2.1 Přímá oftalmoskopie	13
2.2 Fundus kamera	13
2.3 Konfokální laserový skenovací oftalmoskop	14
3 Detekce pulzací cév	17
3.1 Analýza změny jasové složky cév	18
3.2 Analýza změny průměru cév	18
3.3 Metoda analýzy hlavních komponent	19
4 Implementace analýzy hlavních komponent	21
4.1 Předzpracování dat a výpočet PCA	21
4.2 Použitá data	26
4.3 PCA na data setu 1	28
4.4 PCA na data setu 2	30
4.5 Vizualizace pulzací	33
4.6 Detekce pulzací	36
4.6.1 Hodnocení parametrů	40
4.6.2 Korelace parametrů	43
5 Závěr	46
Literatura	47
Seznam symbolů, veličin a zkratk	51
Seznam příloh	52
A Hodnocení video sekvencí	53
B Příklady data setu 1	55
C Obsah přiloženého CD	57

SEZNAM OBRÁZKŮ

1.1	Anatomie oka [2].	11
1.2	Stavba sítnice [3].	12
2.1	Oftalmoskop přímý Keeler Jazz [4].	13
2.2	Fundus kamera [5].	14
2.3	Schéma fundus kamery.	15
2.4	Schéma zapojení laserový skenovací oftalmoskop s adaptivní optikou (AOSLO) [6].	16
3.1	Postup získání informací o pulzacích metodou z kapitoly 3.1 [14]. . .	19
3.2	Princip Analýza hlavních komponent (PCA) [18].	20
4.1	Příklad obrazových dat ve 2D matici.	22
4.2	Příklad faktorových os [26].	24
4.3	Scree plot data setu 1.	25
4.4	Jeden snímek z data setu 1.	26
4.5	Jeden snímek z data setu 2.	27
4.6	Manuální segmentace optického disku z video sekvence z obrázku 4.5.	27
4.7	Automatická segmentace retinálních cév video sekvence z obrázku 4.5.	28
4.8	Porovnání různých komponent. Obrázek A je první komponenta. Obrázek B je třetí komponenta obsahující pulzace. Obrázek C je poslední komponenta obsahující pulzace (6. komponenta). Obrázek D je první komponenta obsahující převážně šum (7. komponenta).	29
4.9	Na data na obrázku A byla použita absolutní hodnota. Data na obrázku B jsou bez absolutní hodnoty.	30
4.10	Scree plot data setu 2.	31
4.11	Komponenty vyfiltrovaných dat. Obrázky zleva představují: první komponenta obsahují statickou složku, druhá komponenta obsahující převážně pulzace a třetí komponenta obsahující kombinaci pulzací a šumu	32
4.12	Komponenty zašuměných dat. Obrázky zleva představují: první komponenta obsahují statickou složku, druhá komponenta obsahující převážně pulzace a třetí komponenta obsahující kombinaci pulzací a šumu	32
4.13	Komponenta s pulzací nekvalitní video sekvence před omezením analyzovaného prostoru	33
4.14	Komponenta s pulzací nekvalitní video sekvence po omezení analyzovaného prostoru	34
4.15	Komponenta s pulzací nekvalitní video sekvence po omezení analyzovaného prostoru a prahování	35

4.16	Komponenta s pulzací nekvalitní video sekvence po omezení analyzovaného prostoru, prahování a otevření	35
4.17	Vlevo segmentované cévy video sekvence, vpravo dilatovaná segmentace	36
4.18	Video sekvence číslo 10 obsahující velké pulzace. Vlevo vizualizace před otevřením, vpravo po dokončení algoritmu	36
4.19	Video sekvence číslo 10 obsahující malé pulzace. Vlevo vizualizace před otevřením, vpravo po dokončení algoritmu	37
4.20	Video sekvence číslo 28 bez pulzací. Vlevo vizualizace před otevřením, vpravo po dokončení algoritmu	37
4.21	Série krabicových grafů pro parametr P_1 . Levé okno obsahuje krabicové grafy pro hodnocení 1, prostřední okno pro hodnocení 2 a pravé okno pro hodnocení 3. Každé okno obsahuje vlevo krabicový graf pro pulzující video sekvence a vpravo pro nepulzující.	42
4.22	Série krabicových grafů pro parametr P_4 . Levé okno obsahuje krabicové grafy pro hodnocení 1, prostřední okno pro hodnocení 2 a pravé okno pro hodnocení 3. Každé okno obsahuje vlevo krabicový graf pro pulzující video sekvence a vpravo pro nepulzující.	43
4.23	Série krabicových grafů pro parametr P_9 . Levé okno obsahuje krabicové grafy pro hodnocení 1, prostřední okno pro hodnocení 2 a pravé okno pro hodnocení 3. Každé okno obsahuje vlevo krabicový graf pro pulzující video sekvence a vpravo pro nepulzující.	44
4.24	Krabicový graf parametru P_9 s rozdělením do tří kategorií	44
B.1	Video sekvence data setu 1 číslo 3. Komponenty zleva: 1. komponenta, 3. komponenta, 4. komponenta, 5. komponenta	55
B.2	Scree plot video sekvence z obrázku B.1.	55
B.3	Video sekvence data setu 1 číslo 9. Komponenty zleva: 1. komponenta, 3. komponenta, 4. komponenta, 5. komponenta	56
B.4	Scree plot video sekvence z obrázku B.3.	56

SEZNAM TABULEK

4.1	p-hodnoty jednotlivých parametrů studentovým t-testem	41
4.2	p-hodnoty parametru P_9 získané ANOVA testem	42
4.3	Korelace parametrů	45
A.1	Hodnocení pulzací video sekvencí data setu 2	54

ÚVOD

Tato práce se zabývá metodami pro detekci pulsací cév ve video sekvencích sítnice. Pulsace cév může sloužit jako ukazatel mnoha nemocí, například nádoru mozku nebo glaukomu. Na rozdíl od většiny metod určených pro zjištění či pacient trpí mozkovým nádorem, které jsou invazivní, detekce pulsací cév je neinvazivní.

První kapitola této práce se zběžně zabývá anatomíí oka a sítnice pro pochopení obsahu samotných video sekvencí sítnice.

Druhá kapitola se zabývá zařízeními pro snímání obrazů sítnice. Od jednoduchých ručních oftalmoskopů až po moderní konfokální laserový skenovací oftalmoskop. V kapitole se popisují vlastnosti jednotlivých zařízení, jejich funkce a využití.


Třetí kapitola se zabývá problematikou detekce pulsací cév a seznamuje čtenáře s různými metodami použitelných pro detekci. Mezi tyto metody patří analýza změny jasové složky cév, analýza změny průměru cév a analýza hlavních komponent.

Poslední kapitola diplomové práce se zabývá podrobněji metodou analýzy hlavních komponent a její implementací. Popisuje algoritmus pro vizualizaci pulzací a akvizici jednotlivých popisných parametrů, které jsou následně hodnoceny pomocí studentova t-testu a nejlepší parametr dále hlouběji analyzován testem ANOVA.

1 ANATOMIE OKA

Oko je párový smyslový orgán zprostředkující zrak. Má tvar podobný kouli s průměrem kolem 24 mm a nalézá se v obličejové části lebky v očníci. Pohyb oka zajišťuje 6 okohybných svalů. [1]

Na obrázku 1.1 lze vidět řez okem. Světlo do oka vstupuje zleva přes rohovku, která má za úkol upravit propustnost a lom světla. Dále se nachází čočka, která s rohovkou upravuje lom světla tak aby světlo bylo zaostřeno přímo na sítnici. Poslední struktura před dopadem je sklivec. Jedná se o průhledné, čiré, bezbarvé, rosolovité těleso s řídkou vláknitou strukturou, které udržuje stabilní nitrooční tlak. Světlo nakonec dopadá na sítnici, kde dochází k detekci dopadajícího světla. [1]




Obr. 1.1: Anatomie oka [2].

1.1 Anatomie sítnice

Na obrázku 1.2 lze vidět stavbu sítnice. Sítnice se nachází na vnitřní straně oka a skládá se z pěti vrstev. Světlo dopadá na sítnici, podle obrázku 1.2, zespodu (na vnitřní membránu). Vrstva, která má za úkol detekovat dopadající světlo je až vrstva světlocitlivých buněk. Než světlo na tuto vrstvu dopadne, musí projít vrstvou gangliových, amakrínových, bipolárních a horizontálních buněk. Tímto se sníží intenzita dopadajícího světla přibližně o 90%. Světlocitlivé buňky zbylou energii

transformují pomocí pigmentů na elektrické impulzy, které pomocí očního nervu předávají informaci do mozku.

Světlocitlivé buňky se dělí na dva druhy: tyčinky a čípky. Čípků se na sítnici nachází přibližně 7 milionů, zprostředkovávají barevné vidění za kvalitního osvětlení a jsou nejkoncentrovanější ve žluté skvrně. Tyčinky jsou čtenější (kolem 120 milionů) a slouží k vidění za sníženého osvětlení. Nejvíce tyčinek se vyskytuje v kruhu 20° od žluté skvrny. Jejich počet klesá jak ke žluté skvrně, tak i k periferiím. Přibližně tři milimetry nasálně od žluté skvrny se nachází slepá skvrna. Jedná se o místo, které je necitlivé na světlo, protože zde vstupuje optický nerv. [19] [20]



Obr. 1.2: Stavba sítnice [3].

2 SNÍMÁNÍ OBRAZŮ SÍTNICE

Zrak je pro člověka nejdůležitější smysl. Získáváme z něj přibližně 90% informací z vnějšího prostředí. Proto se na přístroje, které dokáží analyzovat stav zraku, klade velký důraz.

Principem všech neinvazivních zobrazovacích metod je vysílání paprsku světla přes zornici a čočku na sítnici s následnou detekcí odraženého světla.

2.1 Přímá oftalmoskopie

Jedná se o první a základní vyšetření oční sítnice. Přímý oftalmoskop je ruční zařízení obsahující osvětlení a dioptrická sklíčka pro zaostření na sítnici. Obraz se zvětšuje přibližně 15x, ale pouze malá část sítnice je viditelná. Při této metodě není možný záznam obrazu. Na obrázku 2.1 je zobrazen příklad přímého oftalmoskopu od firmy Keeler Ltd. [21]



Obr. 2.1: Oftalmoskop přímý Keeler Jazz [4].

2.2 Fundus kamera

Fundus kamera je nejrozšířenější zařízení pro zobrazení oční sítnice. Principiálně se jedná o mikroskop, ke kterému je připevněna většinou digitální kamera. Senzor typu CCD nebo CMOS fundus kamery zaznamenává snímky většinou o velikosti 3 až 18 milionů pixelů. Na obrázku 2.2 lze vidět příklad fundus kamery. [22]

Fundus kamera pracuje na principu oftalmoskopu, který byl popsán v kapitole 2.1. Zobrazovací úhel sítnice bývá většinou 30°. Pomocí širokoúhlých fundus kamer je možné dosáhnout zobrazení až 140°, ale nedokáží dosáhnout takového přiblížení jako u fundus kamer, které mají menší maximální zobrazovací úhel. [22]

Jedno ze základních rozdělení fundus kamer je na mydriatické a nemydriatické.



Obr. 2.2: Fundus kamera [5].


Nemydriatické fundus kamery nepotřebují pro vytvoření snímku sítnice rozkapání zornice, protože intenzita světla je dostatečně malá nebo záznam snímku dostatečně rychlý, aby se zornice nestáhla. Mydriatické kamery potřebují rozkapání zornice, protože se využívá intenzivnější světlo, které způsobuje zúžení zornice. Rozkapáním docílíme zachování roztažené zornice. Tato metoda je pro pacienta nepříjemná z důvodu intenzivního světla směřujícího do oka a také zhoršeného vidění po rozkapání. Obě varianty využívají, pro snížení zátěže pacienta, světlo v infračerveném (IR) spektru pro zaostření na sítnici a bílé světlo pro vyhotovení záznamu. [22]

Na obrázku 2.3 je vidět základní schéma fundus kamery. Ve stojanu jsou umístěny dvě lampy, které generují požadované světlo, které dále prostupuje barevnými filtry pro zúžení spektra procházejícího světla. Světlo prochází řadou zrcadel a čoček na duté zrcadlo, ze kterého světlo dopadá na sítnici. Odražené světlo ze sítnice prochází stejnou cestou až na duté zrcadlo, které má uprostřed otvor pro zaostřené odražené světlo ze sítnice. Pouze toto prochází dále na dělič svazku světla, kde se paprsek rozděluje do okuláru a Charge-coupled device (CCD) kamery. [7]

2.3 Konfokální laserový skenovací oftalmoskop


Jedná se o metodu snímání sítnice založenou na principu skenovacího laserového mikroskopu. Hlavní rozdíl je, že lomné struktury oka fungují jako čočky objektivu, což umožňuje snížit počet čoček v oftalmoskopu. Aberace lomných struktur oka způsobují snížení rozlišení snímků. Přesto tato metoda dosahuje lepších výsledků než dříve zmíněné metody. Konfokální laserový skenovací oftalmoskop generuje snímky s vysokým kontrastem a je možné zaostřit laser do různých hloubek sítnice a tím získat různé informace. [23]

Na obrázku 2.4 lze pozorovat schéma laserového skenovacího oftalmoskopu s adap-



Obr. 2.3: Schéma fundus kamery.

ativní optikou (Adaptive Optics Scanning Laser Ophthalmoscopy - AOSLO). Jedná se o rozšířenou verzi cSLO, kdy se snažíme s využitím adaptivní optiky odstranit vliv aberací lomných struktur oka. Laser prochází sérií čoček a štěrbinou pro zajištění úzkého paprsku. Od polopropustného zrcadla se odráží do zrcadel, které slouží jako skenovací aparát pro posun paprsku v horizontálním a vertikálním směru bez potřeby pohybu pacienta. Laser prochází okem a dopadá na sítnici, kde se následně odráží a prochází stejnou sérií zrcadel, čímž se získá přesná polohová informace, odkud odražený paprsek pochází. Odražený paprsek prochází polopropustným zrcadlem na dělič svazku světla, kde se paprsek rozdělí na CCD a do fotonásobiče. Štěrbina před fotonásobičem zajistí, že do něj dojde pouze ta část paprsku, která je zaostřená. Wavefront Sensor Array před CCD slouží k tomu, abychom na CCD senzoru mohli detekovat optické aberace. Tyto aberace pak můžeme odstranit během skenování pomocí deformabilního zrcadla, čímž zvýšíme rozlišení finálního snímku. [24]



Obr. 2.4: Schéma zapojení AOSLO [6].

3 DETEKCE PULZACÍ CÉV

Spontánní pulzace sítnicových žil (Spontaneous venous pulsation - SVP) lze sledovat jako změnu průměru anebo polohy. Tyto pulzace jsou nejviditelnější uvnitř optického disku, na větších žilách a v ohybech těchto žil. [8]

Zdroj SVP ještě nebyl plně objasněn. Existují čtyři hlavní hypotézy ohledně zdroje SVP. První hypotéza říká, že pulzace je způsobena intraokulárním tlakem, který mění svojí hodnotu a když přesáhne tlak v žilách tak se tyto žíly zhroutlí, což se projeví jako jejich pulzace. Tato hypotéza byla vyvrácena poté, co se zjistilo, že intraokulární tlak je v celém srdečním cyklu nižší než tlak v žilách[9]. Druhá hypotéza vysvětluje SVP jako důsledek snížení tlaku v žilách během systoly kvůli vyšší rychlosti krve v této fázi[8]. Třetí hypotéza vysvětluje SVP jako odezvu na pulzací gradientu intraokulárního a intrakraniálního tlaku[10]. Čtvrtá hypotéza říká, že pulzace je samo vybuzená oscilace[18].

SVP má v lékařství důležitou roli. Přítomností jsme schopni vyloučit zvýšený intrakraniální tlak nebo otok optického disku. Probíhá mnoho výzkumů, které mají za úkol zjistit, co vše ovlivňuje SVP. Existují důkazy, že SVP je ovlivňováno i přítomností glaukomu a jiných patologií oka. Výhodou detekce SVP je neinvazivnost metod pro vyšetření. Na rozdíl jiných metod pro zjištění zvýšeného intrakraniálního tlaku, které invazivní jsou. Nevýhodou je, že SVP se nevyskytuje u všech lidí (pouze u 80-90% populace), kteří jsou zdraví. Jedná se proto spíše pouze o pomocné vyšetření než o určující faktor. [11][12]

Po získání video sekvence sítnice je potřeba nejprve provést předzpracování než je možné pokračovat k samotné detekci. Prvním krokem je lícování videa. Při záznamu je pacient vyzván k omezení očního pohybu a hlava je fixována. Úplný klid ale není možný, proto je potřeba jednotlivé snímky posunout tak aby jednotlivé pixely sobě odpovídaly. Tímto se koriguje translační a rotační pohyb snímku. Pro dosažení kýžených výsledků se využívá především rigidní transformace. [16]

Druhý krok předzpracování je ořezání lícované video sekvence. Okraje snímků většinou neobsahují důležité informace o stavu sítnice a také obsahují chyby z důvodu lícování, které mohou zhoršit následnou analýzu SVP. Dále také ne vždy potřebujeme celou sítnici a ořezáním snížíme výpočetní náročnost. [16]

Třetím krokem je detekce mikrosakád a jejich odstranění spolu se snímky, kde probíhalo mrknutí. Mikrosakády jsou nepravdělné rychlé pohyby oka neovlivnitelné vůlí. Tyto pohyby způsobují rozmazání snímku. [16]

Pořadí jednotlivých kroků předzpracování lze libovolně zaměňovat.

Stejně platí i pro pulzace tepen, které ale klinicky nejsou tak důležité. Bylo navrženo, že snížení pulzace tepen může být ukazatelem na arteriosklerózu. [17]

V dalším textu budou popsány různé metody pro detekci SVP.

3.1 Analýza změny jasové složky cév

Tato metoda využívá poznatku, že hemoglobin má určitou transmitanci určenou Lambert-Beerovým zákonem (3.1 a 3.2) [13].

$$A = \alpha \cdot d \quad (3.1)$$

kde A je absorbance, α je součinitel absorpce (zeslabení) a d je tloušťka vrstvy.

Pro přepočet absorbance na transmitanci můžeme využít vzorec 3.2 [13].

$$T = 10^{-A} \quad (3.2)$$

kde T je transmitance a A je absorbance.

Absorbance, a tím pádem i transmitance, je závislá na tloušťce kapaliny, kterou světlo prochází. Proto při pulzacích, kdy dochází ke změně tloušťky cévy, se mění hodnota transmitance.


Jedná se o nejjednodušší metodu pro detekci pulzací, která je bohužel limitována pouze na záznamy sítnice lepších kvalit. Šum v záznamu velmi ovlivňuje efektivnost metody. Postup získání informací o pulzacích lze vidět na obrázku 3.1. První krok spočívá v samotném získání videozáznamu sítnice a odstranění snímků znehodnocené mrkáním nebo mikrosakádami. Následně je potřeba jednotlivé snímky slícovat, čímž se odstraní vliv náhodných pohybů oka. Třetí krok je volitelný, jedná se o oříznutí snímků kvůli snížení výpočetního času, popřípadě odstranění částí snímků, které neobsahují dostatek informace. Dále extrahujeme zelený kanál z RGB snímků. V zeleném kanálu se projevují změny jasu nejvíce. Poslední krok před analýzou pulzací je detekce cév optimálních pro analýzu (dostatečně veliké, nezašuměné okolí, velký jasový rozdíl vůči okolí). Po vyhodnocení změn jasu mezi jednotlivými snímky můžeme vytvořit barevné mapy značící velikost pulzací. [14]

3.2 Analýza změny průměru cév

Tento soubor metod využívá znalosti, kdy při pulzaci dochází ke změně průměru sítnicových cév. Všechny metody v této kategorii musí nejprve detekovat cévy, které mohou SVP obsahovat. K detekci cév lze přistupovat jednou ze čtyř hlavních technik. [15]

První technika využívá nalezení bodu, kde se vyskytuje céva a následné sledování cévy podle jistého kritéria (např. jasová hodnota, gradient jasové hodnoty). Dále se může u těchto metod využívat například i Houghova transformace. [15]

Druhá technika využívá strojové učení. Pro správnou detekci se musí algoritmu předložit vstupní data, která mají definované pixely, které patří cévám, a které cévám



Obr. 3.1: Postup získání informací o pulzacích metodou z kapitoly 3.1 [14].

nepatří. Po naučení algoritmu na těchto datech je možné detekovat cévy na neznámých datech. Tyto algoritmy využívají například neuronové sítě. [15]

Třetí technika je založena na modelech. Tyto metody využívají znalostí, že cévy udržují určitý směr a změny tohoto směru nejsou příliš závažné. K detekci některé metody využívají aktivní kontury, kdy se kontury postupně tvarují až do chvíle, kdy přisednou na hranu cévy. Aktivní kontury jsou uzavřené kontury, které se deformují vlivem vnitřních, obrazových a vnějších sil. [15]

Čtvrtá a poslední hlavní technika využívá filtrů pro odstranění struktur, které nejsou cévy. U těchto metod je důležité znát tvar cév pro definování správného filtru, který ponechá v obrazu cévy, ale ostatní struktury odstraní. Jako filtry se můžou využívat vlnkové filtry, přizpůsobené filtry a další. [15]

Po nalezení cév lze přistoupit k samotné detekci SVP. Základní metoda pro zjištění SVP je označení hrany cévy a sledování u každého snímku jestli hodnoty označeným míst se mění (hodnoty jasu v případě šedotónových snímků nebo přítomnost 1 či 0 u binárních obrazů). Ostatní metody jsou od této základní odvozeny.


3.3 Metoda analýzy hlavních komponent

Metoda analýzy hlavních komponent (Principal Component Analysis - PCA) je metodou využívanou hlavně ve statistice. Jedná se o metodu ze skupiny ordinačních analýz. Ordinační analýzy se snaží řešit statistický problém redukcí dimensionality dat sloučením korelovaných dat do menšího počtu faktorových proměnných, které obsahují na jednotlivé proměnné více variance (informace) než originální proměnné.

Při využití v obrazové analýze bereme každý snímek jako jednu proměnnou a

každý pixel jako objekt. Video sekvence obsahuje několik složek. První a nejzřejmější je statická složka, která je stejná ve všech snímcích (např. pozice slepé skvrny). Druhá složka, pro nás nejdůležitější, je dynamika sítnice, kam patří především samotná pulzace. Ostatní složky již jsou pro nás nežádoucí a snažíme se jejich vliv omezit. Mezi tyto složky patří oční pohyby a šum. [18]

PCA se snaží seskupit tyto složky k sobě podle množství variability, kterou jednotlivé složky vysvětlují. Na obrázku 3.2 je zobrazen princip PCA. Pod Vstupními daty si můžeme představit jednotlivé snímky našeho video záznamu, po provedení PCA získáme tolik komponent, kolik jsme měli proměnných (počet snímků), ale pro nás důležité komponenty jsou pouze určitý počet s větší vyčerpanou variabilitou. Do první komponenty PC0 se uložila struktura, která se opakuje nejčastěji, což jsou ústa a tvar obličeje. Do druhé komponenty PC1 se uložila druhá nejčastější struktura, která představuje pravé oko. Poslední zobrazená komponenta PC2 obsahuje levé oko. Těmito třemi komponenty dokážeme vysvětlit více než 90% variability počátečních pěti snímků. Pokud by příklad na obrázku 3.2 obsahoval šum, tak většina šumu by byla uložena až v posledních komponentách z důvodu náhodnosti výskytu šumu. [18]



Obr. 3.2: Princip PCA [18].

Výhoda PCA na rozdíl od ostatních zmíněných metod je, že je robustnější vůči šumu než metoda zmíněná v kapitole 3.1. Metoda registruje kromě změny průměru cév, také pohyby samotných cév.

4 IMPLEMENTACE ANALÝZY HLAVNÍCH KOMPONENT

Pro detekci pulzací cév ve video sekvencích sítnice byla vybrána metoda PCA. Její základ a klady oproti dalším zmíněným metodám byl popsán v kapitole 3.3. V této kapitole se budeme více zabývat samotnou implementací a podrobnějším popisem metody.

Prvním krokem je samotné načtení video sekvence do programu, ve kterém bude metoda prováděna. V této práci bude implementace prováděna v MATLABu. Při načtení je potřeba si uvědomit jaký je rozdíl mezi prezentací statistických dat a dat video sekvence. Ve většině případů se statistická data prezentují v tabulce (2D matici). Data video sekvence se ale vyskytují v sérii 2D matic za sebou (3D matice), kde každá 2D matice představuje informace o intenzitě každého pixelu v jednom snímku.

4.1 Předzpracování dat a výpočet PCA

3D reprezentace video sekvence se musí transformovat do 2D reprezentace pro jednodušší výpočet PCA. Nejjednodušší a nejefektivnější možnost je převést každý snímek do sloupcového vektoru a takto transformované snímky vložit za sebe do 2D matice. Na obrázku 4.1 je příklad takovéto 2D matice. Data jsou již standardizovaná na střední hodnotu 0 a směrodatnou odchylku 1. Jednotlivé sloupce představují snímky video sekvence a řádky určují specifický pixel v jednotlivých snímcích.

Zároveň s transformací je vhodné provést filtraci video sekvence pro snížení vlivu šumu. Je možné provést několik druhů filtrací. V této práci byly testovány tři typy filtrů. První filtr byl prostorový 2D mediánový filtr. Jedná se o nelineární filtr vhodný pro filtraci šumu s nízkou energií, vysokou frekvencí a malou korelací s video sekvencí. Tento filtr byl zvolen pro odstranění šumu přítomného na každém snímku zvlášť. Maska filtru byla volena 3×3 pro zachování informace o pulzacích. Druhý filtr byl časový 1D mediánový filtr. Tento filtr byl aplikovaný na každý pixel zvlášť v celém časovém spektru. Filtr byl zvolen pomocí znalosti, že většina pixelů si bude udržovat přibližně stejnou jasovou hodnotu v průběhu celé video sekvence. Toto pravidlo bude pouze porušovat šum a pulzace. Abychom nepřišli o informaci o pulzacích byla zvolena maska 3, která zajistila, že pulzace, které mají delší trvání, nebyly odstraněny. Třetí filtr byl pásmová propust od 0.5 do 3 Hz. Filtr byl aplikován, stejně jako 1D mediánový filtr, na každý pixel zvlášť. Tento frekvenční rozsah byl zvolen z důvodu, že odpovídá fyziologickým pulzacím sítnicových cév. Po rozsáhlém tes-

Snímky video sekvence					
Hodnota pixelu	1,640662	-0,84419	0,398657	-0,2419	0,167556
	0,280935	0,316572	0,973768	0,564425	-0,33511
	-0,33712	0,896955	-0,03268	-0,2419	-0,83778
	-0,95518	1,090416	0,973768	-1,20948	-0,67022
	-1,2024	-0,07035	0,254879	-0,2419	0,167556
	-0,21351	-1,61804	-0,03268	1,209483	-0,50267
	0,404547	-0,84419	-0,03268	-0,56443	-2,51333
	-0,0899	0,123111	0,973768	-0,40316	-0,83778
	-1,94407	-0,07035	-1,61423	-0,56443	-1,17289
	-0,21351	0,703494	-1,1829	-0,72569	0,167556
	-0,95518	-0,07035	-1,32668	-0,40316	0,167556
	-1,44963	-1,03765	-0,75157	-2,4996	0,167556
	0,898993	0,510033	-2,04557	-0,2419	1,005333
	-0,0899	-0,84419	-0,89534	0,72569	-0,67022
	-0,0899	-1,23111	-0,17645	0,886954	1,172889
	0,280935	-0,65073	0,111101	0,080632	0,167556
	0,528158	-0,84419	0,111101	-1,20948	0,167556
	-0,0899	1,090416	0,111101	0,241897	-0,16756
	-0,83157	0,510033	0,254879	0,564425	0
	1,393439	-0,65073	0,398657	2,015804	0,502667
	1,146216	0,896955	1,548879	1,048218	1,508
	1,887884	2,638102	1,980213	1,209483	2,345778

Obr. 4.1: Příklad obrazových dat ve 2D matici.

tování byla finální filtrace tvořena 1D a 2D mediánovým filtrem. Pásmová propust nebyla použita, protože dosahovala srovnatelných výsledků jako 1D mediánový filtr, ale s delším výpočetním časem.

Po získání dat ve standardní statistické reprezentaci a filtraci musíme vytvořit korelační či kovarianční matici reprezentující vztahy mezi jednotlivými snímky [25]. Volba typu matice závisí na charakteru dat. Při analýze video sekvence je vhodnější volit kovarianční matici, protože zohledňuje při výpočtu PCA absolutní hodnoty a rozsah proměnných. Pokud ale víme, že data obsahují kolísání jasové složky mezi jednotlivými snímky, je vhodnější použít korelační matici, která se snaží tato kolísání potlačit standardizací. Data na obrázku 4.1 jsou již standardizovaná, což znamená, že jednotlivé sloupce mají nulovou střední hodnotu a směrodatnou odchylku rovnou jedné.

Matice 4.1 představuje kovarianční matici. Je diagonálně symetrická. Diagonála představuje rozptyl, mimo diagonálu se nalézají kovariance jednotlivých proměnných [31].

$$M = \begin{pmatrix} \sigma_X^2 & C_{XY} & C_{XZ} \\ C_{XY} & \sigma_Y^2 & C_{YZ} \\ C_{XZ} & C_{YZ} & \sigma_Z^2 \end{pmatrix} \quad (4.1)$$

Rovnicí 4.2 lze vypočítat rozptyly pro diagonálu matice 4.1 [32].

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - E(x))^2, \quad (4.2)$$

kde x_i jsou hodnoty proměnné X , $E(x)$ je střední hodnota X a n je počet hodnot v X .

Kovariance dvou proměnných je definovaná jako: [33]

$$\text{cov}(X, Y) = E[(X - E[X])(Y - E[Y])], \quad (4.3)$$

kde $E[X]$, $E[Y]$ značí odhady střední hodnoty X a Y .

Sestavením kovarianční matice z dat na obrázku 4.1 dostaneme matici 4.4. Protože data 4.1 již byla standardizována, matice 4.4 je také korelační matice.

$$\begin{array}{ccccc} 1 & 0.171021 & 0.454778 & 0.520186 & 0.465522 \\ 0.171021 & 1 & 0.367139 & 0.095081 & 0.358113 \\ 0.454778 & 0.367139 & 1 & 0.359387 & 0.253527 \\ 0.520186 & 0.095081 & 0.359387 & 1 & 0.35513 \\ 0.465522 & 0.358113 & 0.253527 & 0.35513 & 1 \end{array} \quad (4.4)$$

Po sestavení námi vybrané matice lze již aplikovat samotný PCA algoritmus. Jak již bylo popsáno v kapitole 3.3, PCA se snaží najít nové osy (faktorové osy), které popíší co nejvíce variability celé video sekvence (redukce série snímků do jednoho snímku). Pro výpočet PCA existuje mnoho algoritmů, například singulární rozklad (Singular Value Decomposition - SVD), rozklad vlastních čísel (Eigenvalue decomposition - EIG), metoda měnících se nejmenších čtverců (Alternating least squares - ALS). [30]


Výpočet PCA v této práci byl realizovaný pomocí algoritmu EIG, který není tak přesný jako algoritmus SVD, ale pro velké objemy dat není tak časově náročný. Rozdíl mezi algoritmy EIG a SVD se snižuje s množstvím objektů (počtem pixelů na snímek).

Algoritmus EIG se realizuje prostřednictvím výpočtu vlastních čísel a vlastních vektorů korelační či kovarianční matice dat video sekvence. Vlastní čísla a vlastní vektory je možné vypočítat pouze pro čtvercové matice. Korelační a kovarianční matice tuto podmínku splňují. Dále hodnoty vstupních dat video sekvence nesmí být lineárně závislé, jinak výsledky budou zkreslené. Vlastní čísla definují variabilitu, kterou vyčerpají nové faktorové osy a vlastní vektory definují směr těchto nových faktorových os v prostoru původních proměnných. Vlastní čísla vypočítané z korelační a kovarianční matice nabývají různých hodnot.

U korelační matice suma vlastních čísel je rovna počtu proměnných (snímků videosekvence). Každá hodnota vlastního čísla představuje kolikrát více faktorová osa, patřící k tomuto vlastnímu číslu, vyčerpá variability, než kdyby variabilita byla rozdělena rovnoměrně. [25]

U kovarianční matice je suma vlastních čísel rovna sumě rozptylu. Podíl vlastního čísla a průměrného vlastního čísla definuje kolikrát více faktorová osa, patřící k tomuto vlastnímu číslu, vyčerpá variability, než kdyby variabilita byla rozdělena rovnoměrně. [25]

Příklad změny os na nové faktorové osy lze vidět na obrázku 4.2.



Obr. 4.2: Příklad faktorových os [26].

Pro výpočet vlastních čísel lze využít vzorec 4.5 [27].

$$|A - \lambda_i I| = 0, \quad (4.5)$$

kde A je kovarianční či korelační matice, λ_i jsou neznámá vlastní čísla, které chceme vypočítat a I je jednotková matice o stejné velikosti jako kovarianční či korelační matice.

Vlastní vektory lze vypočítat až po vypočítání vlastních čísel. Vlastní vektory lze vypočítat pomocí vzorce 4.6 [27].

$$(A - \lambda_i I)u_i = 0, \quad (4.6)$$

kde A je kovarianční či korelační matice, λ_i jsou jednotlivá vlastní čísla, vypočítané rovnicí 4.5, I je jednotková matice o stejné velikosti jako kovarianční či korelační matice a u_i je neznámý vektor určující směr jedné faktorové osy.

Vypočítáním determinantu vzorcem 4.5 na data na obrázku 4.1 získáme rovnici pro výpočet vlastních čísel 4.7 a 4.8 jsou jednotlivé vlastní čísla vyčíslené.

$$\lambda^5 - 1.31495\lambda^3 + 0.761036\lambda^2 - 0.115527\lambda + 0.00075873 = 0 \quad (4.7)$$


$$\lambda_1 = 2.4999, \lambda_2 = 0.0124, \lambda_3 = 0.4567, \lambda_4 = 0.9099, \lambda_5 = 1.1210 \quad (4.8)$$

Pomocí vlastních čísel uvedených v 4.8 můžeme vypočítat vlastní vektory pomocí vzorce 4.6. Pro zjednodušení je v 4.9 zobrazen pouze výsledek pro λ_1 .

$$\begin{bmatrix} 0.0576 \\ -0.0220 \\ -0.0020 \\ 0.0533 \\ 0.0918 \end{bmatrix} \quad (4.9)$$

Vypočtením vlastních vektorů pro všechna λ z 4.8 bychom získali matici vlastních vektorů o stejné velikosti jako kovarianční matice 4.4. Tyto vlastní vektory se musí maticově vynásobit se vstupními daty 4.1 pro získání hodnot jednotlivých hlavních komponent.

Množství vyjádřené variance jednotlivých os lze vyjádřit grafem Scree plot. Na obrázku 4.3 lze vidět příklad Scree plotu na obrazových datech. Na ose X jsou jednotlivé komponenty. Osa Y značí, kolik variability bylo vyčerpáno danou komponentou v procentech celkové variability. Křivka na pozadí značí kumulativní vysvětlení variability.



Obr. 4.3: Scree plot data setu 1.


Výsledky PCA je před další analýzou vhodné upravit pro vizualizaci pulzací. Z důvodu standardizace dat před PCA na průměr 0 se směrodatnou odchylkou 1 nabývají data získaná z PCA kladných i záporných hodnot. Takto upravená data

nejdou vhodné pro vizualizaci. Proto je potřeba získat absolutní hodnotu z těchto dat. Tato úprava zabezpečí, že pulzace, které mohou nabývat jak kladných, tak i záporných hodnot, budou již nabývat pouze kladných hodnot. Dále je potřeba data ještě normalizovat v rozmezí od 0 do 1.

4.2 Použitá data

V diplomové práci byly využívány dva typy dat. Data 1 byla převzata z článku [28]. Data set 1 neobsahuje téměř žádný šum a je vysoké kvality. Snímkovací frekvence data setu je 9 fps a délka záznamu 4 s. K akvizici byl použit SLO využívající blízké infračervené záření (820 nm). Data set 1 obsahuje video sekvence 10 jedinců mezi 21 a 31 lety. Byl testován jejich nitrooční tlak, který se pohyboval mezi 10 a 19 mm Hg. Oční testy neobjevily žádné patologie.

Data set 1 již prošel předzpracováním a je již připraven na testování PCA algoritmu. Během předzpracování byla data z data setu 1 ořezána pro odstranění anomálií způsobených zobrazovacím systémem, slícována a snímky postižené mrkáním či mikrosakádami odstraněny. Na obrázku 4.4 je zobrazen jeden snímek z data setu 1.



Obr. 4.4: Jeden snímek z data setu 1.


Další typ dat použitých v diplomové práci (Data set 2) byl získán na oční klinice v Erlangenu. Tato data byla pouze slícována. Data set 2 má mnohem horší poměr signálu k šumu z důvodu nízkého přisvětlování sítnice při akvizici a také nižší rozlišení. Tato data jsou ale mnohem delší (10 s) a mají vyšší snímkovací frekvenci (25

fps), což umožňuje lepší filtraci šumu při předzpracování. Na obrázku 4.5 je zobrazen jeden snímek z data setu 2.




Obr. 4.5: Jeden snímek z data setu 2.

K data setu 2 byly také dostupné manuální segmentace optického disku. Příklad této segmentace lze vidět na obrázku 4.6, která odpovídá optickému disku na obrázku 4.5. Dále k tomuto data setu byly dostupné automatické segmentace cév [29]. Na obrázku 4.7 lze vidět segmentaci cév video sekvence z obrázku 4.5.



Obr. 4.6: Manuální segmentace optického disku z video sekvence z obrázku 4.5.




Obr. 4.7: Automatická segmentace retinálních cév video sekvence z obrázku 4.5.

4.3 PCA na data setu 1

V kapitole 4.1 byl uveden postup provedení algoritmu PCA. Do diplomové práce byla metoda PCA nejdříve testována na data setu 1. Vlastnosti data setu 1 byly uvedeny v kapitole 4.2.

Po získání hlavních komponent je potřeba určit, která data ještě obsahují pro nás důležité informace (pulzace), a která data již obsahují pouze šum. Tato informace lze extrahovat ze Scree plotu, který lze vidět na obrázku 4.3. Prvních 6 komponent obsahuje informace o pulzacích (1. komponenta nebyla zobrazena z důvodu obsahu velkého podílu variability - přes 90%). Od 7. komponenty dále je obsažen většinou jen šum, což lze vidět na malém množství vysvětlené variability (kolem 0.01% na komponentu). S touto znalostí lze usoudit, pro nalezení poslední komponenty, která obsahuje pulzace je potřeba vypočítat difference všech komponent kromě první, která vždy bude obsahovat největší podíl vysvětlené variability. Největší difference nám určí místo, kde se nalézá poslední komponenta obsahující pulzace.


Na obrázku 4.8 lze vidět porovnání 4 různých komponent. Obrázek A obsahuje komponentu s nejvíce vyčerpanou variabilitou (1. komponenta). Tato komponenta obsahuje základní struktury sítnice a lze využít pro detekci větších cév, ale nepřináší žádné informace ohledně pulzací. Obrázek B a C jsou komponenty obsahující informace o pulzacích. Na Scree plotu 4.3 představující komponenty 3 a 6. Pulzace jsou zobrazeny světlými místy na snímku. Lze pozorovat, že každá komponenta zobrazuje jiné pulzace. Obrázek D představuje na Scree plotu 4.3 komponentu 7. Lze vidět, že již neobsahuje žádnou podstatnou informaci o pulzaci cév a proto při analýze lze komponenty od této dále vyřadit.



Obr. 4.8: Porovnání různých komponent. Obrázek A je první komponenta. Obrázek B je třetí komponenta obsahující pulzace. Obrázek C je poslední komponenta obsahující pulzace (6. komponenta). Obrázek D je první komponenta obsahující převážně šum (7. komponenta).

Obrázky 4.8 již prošly úpravou po výpočtu PCA. První krok bylo zobrazení s využitím absolutní hodnoty dat, protože pulzace v datech se projevuje jak kladnou tak i zápornou hodnotou. Porovnání s a bez provedení absolutní hodnoty lze pozorovat na obrázku 4.9, kde obrázek A je s použitím absolutní hodnoty a obrázek B je nativní, bez použití absolutní hodnoty. Na obrázku B jsou pulzace mnohem hůře pozorovatelné než na obrázku A. Druhý krok úpravy bylo provedení normali-

zace hodnot od 0 do 1. Další příklady komponent data setu 1 jsou v příloze B.




Obr. 4.9: Na data na obrázku A byla použita absolutní hodnota. Data na obrázku B jsou bez absolutní hodnoty.

4.4 PCA na data setu 2

Algoritmus byl vytvářen převážně pro data set 2. Vlastnosti data setu 2 byly shrnuty v kapitole 4.2. Kvůli rozdílným vlastnostem byl potřeba algoritmus upravit. Mezi

hlavní změny patřila potřeba provést filtraci na snížení šumu uvedenou v kapitole 4.1. Dále byly ještě potřeba odstranit nekvalitní snímky. Pro zvýšení efektivity algoritmu se zaměřilo pouze na oblast optického disku, kde probíhala následná detekce.


Na obrázku 4.10 je zobrazen Scree plot první video sekvence z data setu 2.




Obr. 4.10: Scree plot data setu 2.

Při porovnání se Scree plotem data setu 1 na obrázku 4.3 vidíme, že všechny komponenty na obrázku 4.10 mají mnohem větší podíl variability než na obrázku 4.3. Je to způsobeno větším podílem šumu, který ovlivňuje výsledky PCA. Protože data set 2 má mnohem více snímků (261) než data set 1 (35) jsou pulzace i šum rozděleny do více komponent.

Na obrázku 4.11 jsou zobrazeny 3 komponenty video sekvence 1 z data setu 2. Tyto komponenty lze porovnat s komponenty data setu 1 na obrázku 4.8. Před aplikací PCA algoritmu byl data set 2 ořezán pro odstranění chyb vzniklých slícováním a následně aplikovaná filtrace popsaná v kapitole 4.1. Filtrace se skládá nejdříve z prostorového 2D mediánového filtru a následně z časového 1D mediánového filtru. První obrázek zleva obsahuje první komponentu. Lze vidět, že i přes velký šum komponenta odstranila většinu šumu a dokázala zobrazit většinu sítnicových cév. Na prostředním obrázku je zobrazena druhá komponenta, která obsahuje pulzace. Jde rozeznat dvě hlavní pulzace v oblasti slepé skvrny. Video sekvence by měla obsahovat další méně zřetelné pulzace blíže k okrajům, ale z důvodu výskytu šumu, srovnatelné velikosti jako pulzace, je metoda nedokáže rozpoznat. Na posledním (pravém) obrázku je přítomna třetí komponenta. Třetí komponenta stále obsahuje pulzace, ale jsou velmi znehodnoceny šumem, a proto se k následné analýze nehodí.



Obr. 4.11: Komponenty vyfiltrovaných dat. Obrázky zleva představují: první komponenta obsahují statickou složku, druhá komponenta obsahující převážně pulzace a třetí komponenta obsahující kombinaci pulzací a šumu



Obr. 4.12: Komponenty zašuměných dat. Obrázky zleva představují: první komponenta obsahují statickou složku, druhá komponenta obsahující převážně pulzace a třetí komponenta obsahující kombinaci pulzací a šumu


Jak již bylo zmíněno v kapitole 3.3. Aplikací PCA na video sekvenci se získá tolik komponent, kolik je přítomno snímků ve video sekvenci. Proto je potřeba najít všechny komponenty, které jsou ještě vhodné pro analýzu pulzací, a které už obsahují velké množství šumu a k analýze se nehodí. Přístup k identifikaci těchto komponent v této práci spočívá ve vyhodnocení difference mezi po sobě jdoucími vysvětlenými variabilitami komponent. Tato metoda využívá znalost, že vysvětlená variabilita komponent s velkým obsahem šumu, je mnohem nižší, než komponent obsahujících převážně dynamickou složku a statickou složku, z důvodu náhodnosti šumu. S touto znalostí lze předpokládat, že pozice největší difference představuje změnu mezi komponentou s dynamickou složkou a šumem. Při této metodě se nesmí využívat první difference, protože by se zde porovnávala komponenta se statickou složkou, která obsahuje většinu vysvětlené variability (nad 90%), a komponenta s dynamickou složkou (pod 1%). Na příkladu komponent z obrázku 4.11 byla touto metodou označena druhá komponenta (prostřední obrázek) jako poslední kompo-

nenta vhodná k analýze.

Lze vidět, že algoritmus funguje správně na datech, které obsahují málo šumu a neobsahují žádné, či malé množství jasových anomálií. Na obrázku 4.12 lze vidět výsledek PCA na data setu 2 bez filtrace video sekvence. Na pravém obrázku (třetí komponenta) je zřetelně vidět, že obsahuje mnohem větší podíl šumu než na obrázku 4.11. Pro analýzu pulzací je ale důležitější prostřední obrázek (druhá komponenta), kde lze vidět, že i zde, v porovnání s 4.11, je větší obsah šumu. Z těchto výsledků lze usoudit, že aplikovaná filtrace je vhodná pro tento typ dat.

4.5 Vizualizace pulzací


Po získání komponent vhodných pro analýzu a detekci pulzací je vhodné provést průměr všech validních komponent. Tímto získáme jedinou komponentu, která obsahuje informaci o všech pulzacích, které byly předtím rozděleny do všech validních komponent. Na příkladu z obrázku 4.11 by se průměr neprovedl, protože pouze jedna komponenta byla vybrána pro analýzu.



Obr. 4.13: Komponenta s pulzací nekvalitní video sekvence před omezením analyzovaného prostoru

U sekvencí, které mají slabé pulzace nebo po oříznutí stále zůstávají anomálie, metoda nedokáže dostatečně oddělit pulzace. V těchto případech je potřeba další úprava komponenty pro extrakci informací. Příklad takové komponenty lze vidět na obrázku 4.13. Pro potlačení tohoto nechtěného jevu lze využít znalosti o umístění optického disku a jako oblast obsahující pulzace označit pouze hodnoty uvnitř této

oblasti a hodnoty pixelů mimo tuto oblast nahradit nulami. Tento postup zvýrazní pulzace uvnitř optického disku, kde je lepší poměr signálu a šumu.




Obr. 4.14: Komponenta s pulzací nekvalitní video sekvence po omezení analyzovaného prostoru


Na obrázku 4.14 je vidět výsledek omezení analyzovaného prostoru obrázku 4.13. Porovnáním těchto dvou obrázků lze vidět, že pulzace, které byly slabší, než šum ve spodní části komponenty jsou mírně intenzivnější, ale šum pozadí stále velmi ztěžuje kvalitní vyhodnocení pulzací. Tento šum má nižší hodnoty než pulzace cév, proto můžeme využít prahování pro potlačení šumu na pozadí. Po otestování několika desítek video sekvencí bylo dosaženo závěru, že pouze 2.08% nejintenzivnějších pixelů patří k pulzacím a ostatní jsou šum nebo nulové hodnoty. Výsledek tohoto prahování lze vidět na obrázku 4.15

Na obrázku 4.15 jsou již zřetelné oblasti podezřelé z pulzací. Pro jednodušší analýzu je vhodné provést morfologickou operaci otevření s maskou disku o velikosti 2 px. Tato operace se skládá z eroze následovanou dilatací. Využívá se převážně k oddělení objektů spojených úzkou šíjí, čímž se zjednoduší struktura objektů. V případě obrázku 4.15 se tato operace využije k dalšímu omezení počtu objektů, což povede k zachování pouze objektů, které mají větší šanci patřit k pulzacím. Na obrázku 4.16 lze vidět výsledek této operace.

Na obrázku 4.16 lze pozorovat, že oblasti podezřelé z pulzací se již vyskytují pouze v oblasti cév. Tento výsledek, ale není vždy možné zajistit, protože často jsou přítomné i pulzace samotného optického disku. Proto je vhodné provést další omezení analyzovaného prostoru. Pro zajištění toho, že oblasti podezřelé z pulzací



Obr. 4.15: Komponenta s pulzací nekvalitní video sekvence po omezení analyzovaného prostoru a prahování




Obr. 4.16: Komponenta s pulzací nekvalitní video sekvence po omezení analyzovaného prostoru, prahování a otevření

budou pouze přítomné na cévách a v jejich blízkém okolí musí být výstup z morfologické operace otevření vynásoben maskou segmentovaných cév. Pro zajištění toho, abychom neodstranili oblasti, které se vyskytují okolo cév, ale mohou charakterizovat pulzace cév je potřeba provést dilataci této masky. Pro dilataci byla využita maska disku o velikost 2 px. Na obrázku 4.17 lze vidět vlevo originální segmentaci cév video sekvence 4.13 a vpravo je tato segmentace dilatovaná.


Provedením všech operací uvedených v kapitole 4.5 bylo zajištěno, že výstup z

PCA obsahuje pouze oblasti podezřelé z pulzací. Tyto oblasti lze vidět na obrázku 4.16.



Obr. 4.17: Vlevo segmentované cévy video sekvence, vpravo dilatovaná segmentace


Vizualizace dalších video sekvencí lze vidět na následujících obrázcích. Obrázek 4.18 obsahuje silné pulzace, obrázek 4.19 obsahuje slabé pulzace a obrázek 4.20 je bez pulzací. Na všech obrázcích se vlevo nachází vizualizace před otevřením a vpravo po dokončení algoritmu.




Obr. 4.18: Video sekvence číslo 10 obsahující velké pulzace. Vlevo vizualizace před otevřením, vpravo po dokončení algoritmu

4.6 Detekce pulzací

Pro zařazení detekovaných pulzací je potřeba získat parametry, které budou definovat přítomnost a popřípadě sílu těchto pulzací.



Obr. 4.19: Video sekvence číslo 10 obsahující malé pulzace. Vlevo vizualizace před otevřením, vpravo po dokončení algoritmu



Obr. 4.20: Video sekvence číslo 28 bez pulzací. Vlevo vizualizace před otevřením, vpravo po dokončení algoritmu

Parametry se testovaly na 58 video sekvencích, které ohodnotili nezávisle na sobě tři lidé. Tato hodnocení lze vidět v tabulce A.1. Pulzace jsou rozděleny do tří kategorií. Kategorie jedna znamená silné pulzace. Kategorie dva značí slabé, ale stále viditelné pulzace. Kategorie tři představuje video sekvence bez pulzací. Hodnocení bylo provedeno subjektivně a často se liší mezi hodnotiteli. Tyto rozdíly v hodnocení ztěžují objektivní hodnocení navrhovaným algoritmem.

První navržený parametr využívá znalosti, že výstup PCA obsahuje informaci ve formě jasů o intenzitě pulzací. Z této znalosti lze odvodit, že video sekvence obsahující pulzace budou mít vyšší průměrné jasové hodnoty pixelů v oblasti cév optického disku. Algoritmus pro získání tohoto parametru se musí pozměnit od navrhovaného algoritmu v kapitole 4.5 pro vizualizaci pulzací. Pro zachování jasových

rozdílu mezi video sekvencemi s pulzacemi a bez pulzací se nesmí provádět normalizace dat získaných PCA po aplikaci absolutní hodnoty. Tento parametr P_1 lze vypočítat pomocí rovnice 4.10.

$$P_1 = \frac{\sum_{k=1}^n I_k}{n}, \quad (4.10)$$

kde I_k jsou jednotlivé nenulové jasové hodnoty cév obsažených v optickém disku průměru nenormalizovaných dat po výstupu z PCA a n je celkový počet těchto hodnot.

Pro zohlednění, že průměrné jasové hodnoty mezi video sekvencemi se mohou velmi lišit, byl zaveden druhý parametr. Tento parametr využívá navíc informaci o průměrném jasu optického disku mimo cévy v něm obsažené. Tento parametr může nabývat hodnot od 0 do nekonečna, kdy hodnota 1 znamená, že průměrná jasová hodnota v oblasti cév je stejná jako průměrná hodnota okolí, což by znamenalo, že k pulzaci nedochází. Vyšší hodnoty by znamenaly intenzivnější pulzace. Rovnice 4.11 obsahuje vztah pro výpočet druhého parametru P_2 .

$$P_2 = \frac{\frac{\sum_{k=1}^n I_k}{n}}{\frac{\sum_{l=1}^m U_l}{m}}, \quad (4.11)$$

kde I_k jsou jednotlivé nenulové jasové hodnoty cév obsažených v optickém disku průměru nenormalizovaných dat po výstupu z PCA, n je celkový počet těchto hodnot, U_l jsou nenulové jasové hodnoty optického disku mimo cévy v něm obsažené a m je celkový počet těchto hodnot.

Třetí parametr využívaný v této práci dále rozšiřuje parametr P_1 . Zde je zavedena průměrná jasová hodnota všech nenulových pixelů v oblasti optického disku. Dále průměrná jasová hodnota cév se rozšiřuje na počet hodnot přidáním nul, ze kterých se počítá, do velikosti optického disku. Díky této změně tento parametr může nabývat pouze hodnot od 0 do 1 za cenu vzniku korelace hodnoty s velikostí optického disku. Kdy větší hodnoty znamenají silnější pulzace. Tento parametr je možné vypočítat pomocí rovnice 4.12.

$$P_3 = \frac{\frac{\sum_{k=1}^n Q_k}{n}}{\frac{\sum_{l=1}^n Z_l}{n}}, \quad (4.12)$$

kde Q_k jsou jednotlivé nenulové jasové hodnoty cév obsažených v optickém disku rozšířené o nuly do velikosti Z_l , n je celkový počet těchto hodnot, U_l jsou nenulové jasové hodnoty optického disku.

Čtvrtý parametr využívá algoritmus pro detekci pulsujících cév (popsaný v kapitole 4.5). Po aplikaci tohoto algoritmu na data z PCA získáme pouze pixely v oblasti cév podezřelých z pulzací. Parametr obsahuje počet nenulových pixelů v oblasti cév pro charakterizaci velikosti pulzací. Video sekvence, která má silnější pulzace, by měla mít po této úpravě více nenulových pixelů v oblasti cév. Výpočet tohoto parametru je naznačen rovnicemi 4.13 a 4.14.

$$x = \sum_{k=1}^n x_k, \quad (4.13)$$

$$P_4 = n, \quad (4.14)$$

kde x je suma nenulových jasových hodnot v oblasti cév optického disku a n je počet těchto hodnot.

Pátý parametr normalizuje čtvrtý parametr v rozsahu od 0 do 1. Dosahuje toho pomocí informace o celkové velikosti cév v optickém disku. Stejně jako předchozí parametr, i zde větší hodnoty představují větší pulzace. Rovnice pro výpočet tohoto parametru je uvedena níže 4.15.

$$P_5 = \frac{n}{m}, \quad (4.15)$$

kde n je počet hodnot z rovnice 4.13 a m je celková velikost (počet pixelů) cév v oblasti optického disku.

Šestý parametr využívá nefiltrovaná data představená u prvního parametru P_1 . Z těchto dat je vybrán kvantil o hodnotě 0.9, tato hodnota byla zvolena experimentálně po testování parametru na vstupních video sekvencích. Hodnoty, které spadají do tohoto kvantilu, jsou následně sečteny. Tato suma je posléze normalizovaná přes sumu všech nefiltrovaných hodnot cév optického disku. Díky této normalizaci parametr nabývá hodnot od 0 do 1 a vyšší hodnoty znamenají silnější pulzace. Matematický zápis tohoto parametru lze vidět na rovnici 4.16.

$$P_6 = \frac{\sum_{k=1}^n I_k}{\sum_{l=1}^m O_l}, \quad (4.16)$$

kde I_k představuje jednotlivé hodnoty patřící do kvantilu 0.9 a O_l jsou jednotlivé hodnoty patřící cévám optického disku.

Sedmý parametr využívá data získané z kapitoly 4.5. Jedná se o průměr hodnot pixelů podezřelých z pulzací. Protože tyto data již prošly normalizací, tento parametr nabývá hodnot od 0 do 1. Na rozdíl od předchozích parametrů zde jsou pulzace charakterizovány nižšími hodnotami, protože slabé pulzace mají po normalizaci více hodnot blíže 1 než silné pulzace. Rovnice 4.17 popisuje výpočet tohoto průměru.

$$P_7 = \frac{\sum_{k=1}^n N_k}{n}, \quad (4.17)$$

kde N_k jsou hodnoty podezřelé z pulzací normalizované v rozsahu od 0 do 1 a n je počet těchto hodnot.

Osmý parametr využívá stejné logiky jako sedmý, ale místo průměru využívá medián. Tato změna zvětší rozdíly mezi slabými a silnými pulzacemi. Parametr stále nabývá hodnot mezi 0 a 1, kdy nižší hodnoty značí silnější pulzace.

Devátý, a poslední, parametr využívá průměr filtrovaných dat z kapitoly 4.5 násobený experimentálně zvolenou konstantou 1.5. Využívá se informace o počtu hodnot větších než takto vypočítaná hodnota. Parametr využívá normalizovaná data z kapitoly 4.5. Zde větší počet hodnot znamená silnější pulzaci. 4.18 a 4.19 popisují tento parametr.

$$x = \sum_{k=1}^n x_k, \quad (4.18)$$

$$P_9 = n, \quad (4.19)$$

kde x je suma hodnot z normalizovaných dat kapitoly 4.5 větších než $prumer \times 1.5$ a n je počet těchto hodnot.

4.6.1 Hodnocení parametrů

Z parametrů představených v kapitole 4.6 bylo potřeba vybrat ty, které nejefektivněji dokáží rozdělit pulzace. Pro hodnocení kvality parametrů byl vybrán neparametrický dvou-výběrový Wilcoxonův test. Jedná se o statistický test hypotézy. Výstupem tohoto testu je informace o zamítnutí nebo potvrzení nulové hypotézy.


Potvrzení nulové hypotézy znamená, že oba testované data sety mají shodné rozdělení hodnot. Zamítnutí nulové hypotézy a přijetí alternativní hypotézy znamená, že existuje statisticky významný rozdíl mezi rozdělením hodnot data setů. Při využívání Wilcoxonova testu je potřeba zvolit hladinu významnosti α . Jedná se o pravděpodobnost, se kterou se zamítne nulová hypotéza, ačkoliv stále platí. Nejčastěji volené hodnoty jsou 0.05 nebo 0.01. V této práci byla zvolena hodnota 0.05.

Protože Wilcoxonovým testem se provádí porovnání dvou kategorií, bylo potřeba rozdělení pulzací do 3 kategorií z tabulky A.1 upravit pouze do 2 kategorií. Kategorie 1, která představuje silné pulzace, a kategorie 2, která představuje slabé, ale detekovatelné pulzace, byly sloučeny do jedné kategorie. Tímto bylo docíleno toho, že Wilcoxonův test porovnával kategorii obsahující všechny pulzace s kategorií bez pulzací.

V tabulce 4.1 jsou výsledky Wilcoxonova testu aplikovaného na parametry vypočítané z jednotlivých video sekvencí. Čím nižší p-hodnota parametru, tím je rozložení hodnot jednotlivých kategorií od sebe více rozdílné. Z tabulky 4.1 vidíme, že pouze parametr P_9 nabývá statisticky významného rozdílu rozložení hodnot s hladinou významnosti $\alpha = 0.05$ (hodnoty jsou menší než 0.05). Na obrázku 4.21 je zobrazen krabicovými grafy parametr P_1 pro každé hodnocení zvlášť, obrázek 4.22 obsahuje stejné krabicové grafy pro parametr P_4 a obrázek 4.23 obsahuje stejné krabicové grafy pro parametr P_9 . Lze vidět, že parametr P_9 má z těchto parametrů nejlépe oddělené obě kategorie ve všech třech hodnoceních.

Tab. 4.1: p-hodnoty jednotlivých parametrů studentovým t-testem

Číslo parametru	Hodnocení 1	Hodnocení 2	Hodnocení 3
1	0,1001	0,3743	0,4445
2	0,2618	0,6693	0,1734
3	0,1666	0,4626	0,7654
4	0,2618	0,1465	0,5507
5	0,2925	0,5613	0,41191
6	0,3006	0,4730	0,9851
7	0,3702	0,7326	0,7512
8	0,2618	0,6203	0,5632
9	0,0379	0,2247	0,0071




Obr. 4.21: Série krabicových grafů pro parametr P_1 . Levé okno obsahuje krabicové grafy pro hodnocení 1, prostřední okno pro hodnocení 2 a pravé okno pro hodnocení 3. Každé okno obsahuje vlevo krabicový graf pro pulzující video sekvence a vpravo pro nepulzující.

Z předchozí analýzy lze vidět, že parametr P_9 dokáže dostatečně kvalitně rozdělit pulzující sekvence od nepulzujících. Důležitá informace je ale i velikost pulzace. Pro analýzu tří kategorií byl zvolen neparametrický Kruskal-Wallisův test. Kruskal-Wallisův test testuje, podobně jako Wilcoxonův test, podobnost rozložení hodnot jednotlivých kategorií. Výsledky Kruskal-Wallisova testu pro parametr P_9 lze vidět v tabulce 4.2. p-hodnoty Kruskal-Wallisova testu lze vyhodnotit stejně jako p-hodnoty Wilcoxonova testu. Na obrázku 4.24 lze vidět krabicový graf tohoto parametru.

Tab. 4.2: p-hodnoty parametru P_9 získané ANOVA testem

Hodnocení 1	Hodnocení 2	Hodnocení 3
0,1018	0,4602	0,0043


Z výsledků v tabulce 4.2 a na obrázku 4.24 vidíme, že analýza hodnocení 1 a 2 nedokázala zamítnout nulovou hypotézu, že kategorie se od sebe liší. Analýza hodnocení 3 ale nulovou hypotézu zamítla s velmi nízkou p-hodnotou 0.0043.




Obr. 4.22: Série krabicových grafů pro parametr P_4 . Levé okno obsahuje krabicové grafy pro hodnocení 1, prostřední okno pro hodnocení 2 a pravé okno pro hodnocení 3. Každé okno obsahuje vlevo krabicový graf pro pulzující video sekvence a vpravo pro nepulzující.

4.6.2 Korelace parametrů

V tabulce 4.3 lze vidět korelace mezi jednotlivými parametry. Korelace určuje vztah mezi proměnnými a může nabývat hodnot od -1 do 1. Korelace rovná -1 znamená, že parametry jsou antikorelované, což znamená, že když se zvýší hodnota jednoho parametru, druhý parametr se sníží. Korelace rovná 0 znamená, že mezi proměnnými není žádná statisticky zjištělná korelace a hodnoty na sobě nezávisí. Korelace rovná 1 značí naprostou korelaci, když se zvýší jeden parametr, zvýší se i druhý. Nejvyšší parametr P_9 má s většinou parametrů korelaci blízkou nule. Pouze s parametry P_4 a P_5 má slabou kladnou korelaci. Korelace je způsobena tím, že všechny tři parametry využívají jako základ informaci o počtu pulzujících pixelů, a nikoliv informaci o intenzitě. Tučně vyznačeny jsou velké korelace či antikorelace. Největší korelace je mezi parametry P_1 a P_2 . Tato korelace je zaviněna tím, že parametr P_2 je pouze normovaný parametr P_1 . Další velká korelace je mezi parametry P_3 a P_4 . Tyto parametry nesdílí žádné společné kroky při výpočtu, a proto je korelace zaviněna dosažením podobných výsledků o pulzacích nezávisle na sobě. Poslední větší korelace je mezi parametry P_7 a P_8 . Zde je korelace způsobena tím, že se parametry počítají ze stejných dat, ale jeden pracuje s průměrem hodnot a druhý s mediánem.



Obr. 4.23: Série krabicových grafů pro parametr P_9 . Levé okno obsahuje krabicové grafy pro hodnocení 1, prostřední okno pro hodnocení 2 a pravé okno pro hodnocení 3. Každé okno obsahuje vlevo krabicový graf pro pulzující video sekvence a vpravo pro nepulzující.



Obr. 4.24: Krabicový graf parametru P_9 s rozdělením do tří kategorií

Tab. 4.3: Korelace parametrů

Parametr	1	2	3	4	5	6	7	8	9
1	1	0.970	0.094	0.107	0.12	-0.260	0.493	0.506	-0.133
2	0.970	1	0.126	0.164	0.147	-0.281	0.484	0.482	-0.066
3	0.094	0.126	1	0.874	0.500	-0.751	0.078	0.035	0.457
4	0.107	0.164	0.874	1	0.742	-0.482	0.201	0.149	0.538
5	0.127	0.147	0.500	0.742	1	-0.048	0.200	0.148	0.423
6	-0.260	-0.281	-0.751	-0.482	-0.048	1	-0.147	-0.135	-0.038
7	0.493	0.484	0.078	0.201	0.200	-0.147	1	0.989	-0.064
8	0.506	0.482	0.035	0.149	0.148	-0.135	0.989	1	-0.178
9	-0.133	-0.066	0.457	0.538	0.423	-0.038	-0.064	-0.178	1

5 ZÁVĚR

Cílem diplomové práce bylo seznámit čtenáře s metodami pro detekci pulsací cév ve video sekvencích sítnice.

Seznámení čtenáře s obecnými informacemi ohledně anatomie oka a sítnice, zařízení pro vytvoření video sekvencí pro detekci pulsací a metodami pro detekci pulsací bylo obsaženo v kapitolách 1, 2 a 3.

První část čtvrté kapitoly měla za úkol seznámit čtenáře podrobněji s vybranou metodou analýzy hlavních komponent a postupem výpočtu této metody. Seznámila čtenáře s testovacími daty a reálnými daty, pro které byla metoda vytvářena a ukázala problém s vysokým obsahem šumu a anomáliemi v datech.

Dále byl popsán algoritmus, který byl vytvořen pro vizualizaci detekovaných pulzací. Následně byl čtenář seznámen se sérií popisných parametrů, které byly následně objektivně hodnoceny Wilcoxonovým testem. Parametr s nejnižší p-hodnotou byl dále testován Kruskal-Wallisovým testem.

Z navrhovaných parametrů uspěl pouze parametr využívající informaci o velikosti oblasti pulzace P_9 . Parametr Wilcoxonovým testem, který byl využit k porovnání rozdělení do kategorie s pulzacemi a do kategorie bez pulzací, dosáhl nejlepší p-hodnoty 0.0071 u hodnocení 3. Následně byl tento parametr podroben Kruskal-Wallisovu testu, který testoval rozdělení do tří kategorií. Parametr obstál i v tomto testu s p-hodnotou 0.0043 u hodnocení 3. Ostatní hodnocení měli p-hodnotu vyšší než 0.1. Tyto rozdíly ve výsledcích byly způsobeny velkým rozdílem v hodnocení. Z těchto výsledků bylo usouzeno, že metoda dokáže objektivně rozdělit video sekvence do tří kategorií: silné pulzace, slabé pulzace a bez pulzací.

LITERATURA

- [1] HUGHES, James. 2007. Velká obrazová všeobecná encyklopedie. *Svojtka & Co.* aktualiz. vyd. Praha. ISBN 8073528231 [cit. 21. 10. 2016].
- [2] NOVOTNÝ, Ivan a Michal HRUŠKA, 2002. Biologie člověka. *Fortuna*. 3., rozš. a upr. vyd. Praha, ISBN 80-7168-819-3 [cit. 21. 10. 2016].
- [3] REICHL, Jaroslav a Martin VŠETIČKA, 2006. Stavba oka [online]. [cit. 21. 10. 2016]. Dostupné z URL: <<http://fyzika.jreichl.com/main.article/view/486-stavba-oka/>>.
- [4] ASKIN & Co medical technology, 2016. Oftalmoskop přímý Keeler Jazz [online]. [cit. 23. 10. 2016]. Dostupné z URL: <<http://www.askin.cz/prime-direktni/>>.
- [5] LÜCKING, 2016. Funduskamera [online]. [cit. 28. 10. 2016]. Dostupné z URL: <<http://www.augenarzt-luecking.de/index.php?id=25>>.
- [6] JROD, 2010. Diagram of the AOSLO setup. *Own work, Public Domain* [online]. [cit. 5. 11. 2016]. Dostupné z URL: <<https://commons.wikimedia.org/w/index.php?curid=10142582>>.
- [7] SHANKLE, Jonathan, 2004. Ophthalmic photography: retinal photography, angiography, and electronic imaging. *Survey of Ophthalmology* [online]. **49**(2), 264. ISSN 00396257. [cit. 28. 10. 2016]. Dostupné z: doi:10.1016/j.survophthal.2003.12.001
- [8] WILLIAMSON-NOBLE, FA, 1952. Venous pulsations. *Transactions of the Ophthalmological Societies of the United Kingdom*. **52**, p. 317-326. [cit. 18. 11. 2016].
- [9] VAN TRIGT AC, 1853. The ophthalmoscope *Lancet*. London, **2**, p. 417. ISBN 0140-6736. [cit. 18. 11. 2016].
- [10] LEVINE, David N, 1998. Spontaneous Pulsation of the Retinal Veins. *Microvascular Research* [online]. **165**, 154–165. ISSN 0026-2862. [cit. 18. 11. 2016]. Dostupné z: doi:10.1006/mvre.1998.2098
- [11] MATAFTSI, Asimina, Anna MOURGELA, et al., 2014. *Frequency of spontaneous pulsations of the central retinal vein in the paediatric population* [online]. 2014. ISBN 1536-481X (Electronic)r1057-0829 (Linking). [cit. 18. 11. 2016]. Dostupné z: doi:10.1111/aos.12430

- [12] JACKS, a S a N R MILLER, 2003. Spontaneous retinal venous pulsation: aetiology and significance. *Journal of neurology, neurosurgery, and psychiatry* [online]. **74**(1), 7–9. ISSN 00223050. [cit. 18. 11. 2016]. Dostupné z: doi:10.1136/jnnp.74.1.7
- [13] NAVRÁTIL, Leoš a Jozef ROSINA, et al., 2010. *Lambert-Beerův zákon* [online]. [cit. 19. 11. 2016]. Dostupné z URL: <http://www.wikiskripta.eu/index.php/Lambert-Beer%C5%AFv_z%C3%A1kon>.
- [14] MORGAN, William H., Anmar ABDUL-RAHMAN, et al., 2015. Objective detection of retinal vessel pulsation. *PLoS ONE* [online]. **10**(2). ISSN 19326203. [cit. 19. 11. 2016]. Dostupné z: doi:10.1371/journal.pone.0116475
- [15] ODSTRČILIK, Jan, Radim KOLAR, et al., 2013. Retinal vessel segmentation by improved matched filtering: evaluation on a new high-resolution fundus image database. *IET Image Processing* [online]. **7**(4), 373–383. ISSN 1751-9659. [cit. 27. 11. 2016]. Dostupné z: doi:10.1049/iet-ipr.2012.0455
- [16] SCHWENN, O, R TROOST, et al., 2002. Ocular pulse amplitude in patients with open angle glaucoma, normal tension glaucoma, and ocular hypertension. *Br J Ophthalmol* [online]. **86**(9), 981–984. ISSN 00071161. [cit. 27. 11. 2016]. Dostupné z: doi:10.1136/bjo.86.9.981
- [17] SWAN, Kenneth C a Paul BAILEY, 1959. Cinematography of the Retinal Vessels. *Transactions of the American Ophthalmological Society* [online]. **57**, 210–220. ISSN 0065-9533. [cit. 15. 5. 2017]. Dostupné z: <<http://www.ncbi.nlm.nih.gov/pmc/articles/PMC1316333/>>.
- [18] MORET, F., C.M. POLOSCHEK, et al., 2011. Visualization of fundus vessel pulsation using principal component analysis. *Investigative Ophthalmology and Visual Science* [online]. **52**(8). [cit. 27. 11. 2016]. Dostupné z: doi:10.1167/iovs.10-6806
- [19] KADLAS, Matyáš, 2015. Digitální zpracování fotografií sítnice: bakalářská práce. *Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství* [online]. 51 s. [cit. 29. 11. 2016]. Dostupné z URL: <https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=100954>.
- [20] HRAZDIRA, Ivo a Vojtěch MORNSTEIN, 2001. Lékařská biofyzika a přístrojová technika. *Neptu*. 381 s. ISBN 80-902-8961-4. [cit. 29. 11. 2016].

- [21] MeDitorial +, 2010. Přímá oftalmoskopie. *MeDitorial +* [online]. [cit. 29. 11. 2016]. Dostupné z URL: <<http://www.zeleny-zakal.cz/prima-oftalmoskopie>>.
- [22] HLOŽÁNEK Martin, 2006. Přístrojová technika v oftalmologii. *Pražské centrum virtuální oftalmochirurgie* [online]. [cit. 29. 11. 2016]. Dostupné z URL: <<http://www.fbmi.cvut.cz/e/pristroje-pro-oftalmologii%E2%88%921234/1828.pdf>>.
- [23] ŘÍHA, F, 2008. Registrace autofluorescenčních obrazů sítnice *Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií* [online]. 70 str. [cit. 30. 11. 2016]. Dostupné z URL: <<https://dspace.vutbr.cz/xmlui/bitstream/handle/11012/3983/Registrace%20autofluorescen%c4%8dn%c3%adch%20obraz%c5%af%20s%c3%adtnice.pdf?sequence=1&isAllowed=y>>.
- [24] National Institutes of Health, 2012. Adaptive Optics Scanning Laser Ophthalmoscope (AOSLO). *University of California* [online]. [cit. 30. 11. 2016]. Dostupné z URL: <<http://roorda.vision.berkeley.edu/aoslo.htm>>.
- [25] JARKOVSKÝ Jiří, Simona LITTNEROVÁ, 2011. Analýza hlavních komponent jako příklad výpočtu redukce dimenzionality pomocí ordinační analýzy *Masarykova univerzita* [online]. [cit. 1. 12. 2016]. Dostupné z URL: <<http://www.iba.muni.cz/esf/res/file/bimat-prednasky/vicerozmerne-statisticke-metody/VSM-07.pdf>>.
- [26] NICOGUARO, 2016. Gaussian Scatter PCA. *CC BY 4.0* [online]. [cit. 22. 12. 2016]. Dostupné z URL: <<https://commons.wikimedia.org/w/index.php?curid=46871195>>.
- [27] KHAN ACADEMY, 2012. Eigen-everything [online]. [cit. 23. 12. 2016]. Dostupné z URL: <<https://www.khanacademy.org/math/linear-algebra/alternate-bases/eigen-everything/v/linear-algebra-introduction-to-eigenvalues-and-eigenvectors>>.
- [28] MORET, Fabrice, Charlotte M. REIFF, et al., 2015. Quantitative Analysis of Fundus-Image Sequences Reveals Phase of Spontaneous Venous Pulsations. *Translational Vision Science & Technology* [online]. 4(5). ISSN 2164-2591 [cit. 23. 12. 2016]. Dostupné z: doi:10.1167/tvst.4.5.3.
- [29] ODSTRČILÍK, J.; KOLÁŘ, R.; HARABIŠ, V.; TORNOW, R., 2015. Classification- Based Blood Vessel Segmentation in Retinal Images *In Computational Vision and Medical Image Processing V*. [cit. 15. 5. 2017]. London,

- UK: CRC Press Taylor and Francis Group, s. 95-100. ISBN: 978-1-138-02926-2.
- [30] JOLLIFFE, I. T, 2002. Principal component analysis. *Springers*. ISBN 0-387-95442-2. [cit. 26. 12. 2016].
- [31] BÖHM, Josef, Miroslav HAMPACHER a Vladimír RADOUCH, 1990. Teorie chyb a vyrovnávací počet: vysokoškolská učebnice pro studenty stavebních fakult. *Geodetický a kartografický podnik*. ISBN 80-7011-056-2. [cit. 29. 12. 2016].
- [32] OTIPKA, Petr a Vladislav ŠMAJSTRL, 2008. Pravděpodobnost a statistika. *Technická univerzita*. ISBN 978-80-248-1302-8. [cit. 29. 12. 2016].
- [33] BRETA, R, 2001. Kovariance. *Wikipedia: the free encyclopedia* [online]. [cit. 29. 12. 2016]. Dostupné z URL: <<https://cs.wikipedia.org/wiki/Kovariance>>.

SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK

CCD Charge-coupled device

CMOS Complementary metal–oxide–semiconductor, doplňující se
kov-oxid-polovodič

IR infračerveném

AOSLO laserový skenovací oftalmoskop s adaptivní optikou

cSLO Konfokální laserový skenovací oftalmoskop

SVP Spontaneous venous pulsation

SVD Singulární rozklad - Singular Value Decomposition

EIG Rozklad vlastních čísel - Eigenvalue decomposition

ALS Metoda měnících se nejmenších čtverců - Alternating least squares

PCA Analýza hlavních komponent

SEZNAM PŘÍLOH


A	Hodnocení video sekvencí	53
B	Příklady data setu 1	55
C	Obsah přiloženého CD	57

A HODNOCENÍ VIDEO SEKVENCÍ


Tab. A.1: Hodnocení pulzací video sekvencí data setu 2

Číslo sekvence	Hodnocení 1, 2, 3	Číslo sekvence	Hodnocení 1, 2, 3
1	2, 1, 1	31	1, 1, 1
2	3, 3, 2	32	2, 1, 1
3	3, 1, 3	33	1, 2, 1
4	1, 1, 2	34	2, 2, 1
5	3, 3, 2	35	1, 1, 2
6	2, 1, 1	36	1, 1, 1
7	2, 2, 3	37	1, 1, 1
8	1, 3, 3	38	3, 3, 3
9	3, 1, 3	39	1, 2, 1
10	1, 1, 1	40	3, 2, 2
11	2, 2, 1	41	2, 3, 2
12	3, 3, 2	42	3, 3, 2
13	1, 1, 2	43	2, 1, 1
14	1, 2, 1	44	2, 2, 2
15	1, 1, 2	45	2, 2, 1
16	2, 3, 2	46	2, 2, 2
17	2, 2, 3	47	1, 3, 2
19	3, 3, 1	48	1, 1, 2
20	1, 1, 2	49	2, 1, 2
21	1, 1, 1	50	2, 2, 2
22	2, 3, 2	51	2, 3, 3
23	2, 3, 2	52	1, 2, 3
24	1, 1, 1	53	3, 2, 1
25	3, 2, 3	54	2, 1, 3
26	1, 1, 2	55	1, 2, 2
27	3, 3, 2	56	1, 2, 3
28	3, 3, 3	57	3, 2, 3
29	1, 2, 1	58	1, 3, 1
30	3, 1, 2	59	3, 3, 1


B PŘÍKLADY DATA SETU 1




Obr. B.1: Video sekvence data setu 1 číslo 3. Komponenty zleva: 1. komponenta, 3. komponenta, 4. komponenta, 5. komponenta



Obr. B.2: Scree plot video sekvence z obrázku B.1.



Obr. B.3: Video sekvence data setu 1 číslo 9. Komponenty zleva: 1. komponenta, 3. komponenta, 4. komponenta, 5. komponenta



Obr. B.4: Scree plot video sekvence z obrázku B.3.

C OBSAH PŘÍLOŽENÉHO CD

Na přiloženém CD, pod názvem Kadlas_Matyas_DP.pdf, lze nalézt tento text diplomové práce. V adresáři Program se nachází zdrojové kódy k navrhovanému algoritmu. Soubor diplomka.m je spouštěcí soubor pro ostatní funkce. Soubor comp.m obsahuje kód pro výpočet komponent. Soubor filtrace.m obsahuje kód pro provedení filtrace. Soubor normalizace.m obsahuje kód pro aplikaci normalizace. Soubor video.m obsahuje kód pro načtení videa. Soubor parametry.m obsahuje zvlášť spustitelný skript pro statistické testování. Program byl napsán a testován v programu MATLAB 2016a.

```
/ ..... kořenový adresář přiloženého CD
├── Program ..... Zdrojové kódy programu
│   ├── diplomka.m ..... Hlavní soubor
│   ├── comp.m ..... Funkce pro výpočet komponent
│   ├── filtrace.m ..... Funkce pro provedení filtrace
│   ├── normalizace.m ..... Funkce pro aplikaci normalizace
│   ├── video.m ..... Funkce pro načtení videa
│   └── parametry.m ..... Skript pro statistické testování
└── Kadlas_Matyas_DP.pdf ..... Text diplomové práce
```