

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ  
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ  
ÚSTAV INTELIGENTNÍCH SYSTÉMŮ


FACULTY OF INFORMATION TECHNOLOGY  
DEPARTMENT OF INTELLIGENT SYSTEMS

APLIKACE PRO ROZPOZNAVÁNÍ SÍTNICE  
LIDSKÉHO OKA


BAKALÁŘSKÁ PRÁCE  
BACHELOR'S THESIS

AUTOR PRÁCE  
AUTHOR

RADEK DROZD



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ  
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ  
ÚSTAV INTELIGENTNÍCH SYSTÉMŮ

FACULTY OF INFORMATION TECHNOLOGY  
DEPARTMENT OF INTELLIGENT SYSTEMS

# APLIKACE PRO ROZPOZNÁVÁNÍ SÍTNICE LIDSKÉHO OKA

APPLICATION FOR RECOGNITION OF HUMAN EYE RETINA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Radek Drozd

VEDOUCÍ PRÁCE

SUPERVISOR

Doc. Ing. Martin Drahanský, Ph.D.

## **Abstrakt**

Rozložení cévního řečiště v sítnici lidského oka je pro každého jedince unikátní, jedná se proto o velmi důležitou biometrickou charakteristiku. Zpracování barevného snímku sítnice může figurovat jako jedna z částí zamýšleného biometrického systému. V této bakalářské práci je popsán algoritmus pro automatickou extrakci cévního řečiště, lokalizaci slepé a žluté skvrny, nalezení bodů větvení cév a jejich uložení jako biometrické šablony. Algoritmus byl implementován v programovacím jazyce C++ za použití knihovny OpenCV a testován na barevných snímcích sítnice pořízených fundus kamerou. Výsledný program běží v digitálním signálovém procesoru firmy Texas Instruments. Práce obsahuje úvod do biometrie, zpracování signálů a anatomie oka.

## **Abstract**

The blood vessels layout in a human eye retina is unique for every person in the world, so it is one of important biometric characteristics. Processing of colour retina image may be a part of an intended biometric system. There is an algorithm for automatic blood vessels detection, optic disc and macula localisation, finding of bifurcation points and saving those as a biometric template presented in this bachelor's thesis. C++ programming language and OpenCV library were used for implementation. The application was tested on a set of colour retina images, taken by fundus camera. The final application is supposed to run on a digital signal processor, developed by Texas Instruments. The thesis gives the introduction into biometrics, signal processing and human eye anatomy.

## **Klíčová slova**

sítnice, biometrie, fundus kamera, céva, matched filtering, digitální signálový procesor, filtrování, slepá skvrna, žlutá skvrna, bod větvení

## **Keywords**

retina, biometrics, fundus camera, blood vessel, matched filtering, digital signal processor, filtering, optic disc, macula, bifurcation point

## **Citace**

DROZD, Radek. Aplikace pro rozpoznávání sítnice lidského oka (bakalářská práce). Brno: FIT VUT v Brně, 2012.

# Aplikace pro rozpoznávání sítnice lidského oka

## Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením doc. Ing., Dipl.-Ing. Martin Drahanského, Ph.D. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....  
Radek Drozd  
12. května 2012

## Poděkování

Rád bych poděkoval vedoucím práce, doc. Ing., Dipl.-Ing. Martinu Drahanskému, Ph.D. a Ing. Josefu Hájkovi za odborné vedení, poskytnuté konzultace a vstřícný přístup. Dále bych rád poděkoval Ing. Tomáši Novotnému za pomoc se zprovozněním vývojového kitu.

© Radek Drozd, 2012

*Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.*

# Obsah

1	Úvod.....	1
2	Úvod do biometrie .....	2
2.1	Historie .....	2
2.2	Základní biometrické pojmy .....	4
2.2.1	Identita .....	4
2.2.2	Identifikace .....	5
2.2.3	Verifikace .....	5
2.2.4	Autentizace .....	5
2.2.5	Biometrický systém .....	6
2.2.6	Biometrické vlastnosti .....	6
2.2.7	Charakteristiky biometrických vlastností .....	7
2.2.8	Měření výkonnosti biometrických metod .....	7
3	Teorie signálů.....	9
3.1	Úvod do teorie informace .....	9
3.2	Digitální signál.....	9
3.2.1	Základní pojmy .....	10
3.2.2	Získání digitálního signálu.....	10
3.2.3	Filtrace signálu.....	11
3.3	Zpracování obrazu .....	11
4	Anatomie oka .....	12
4.1	Biometrické rysy oka .....	13
4.1.1	Identifikace pomocí duhovky oka.....	13
4.1.2	Identifikace pomocí sítnice oka .....	14
5	Návrh aplikace .....	16
5.1	Požadavky na aplikaci .....	16
5.1.1	Definice souřadného systému .....	16
5.2	Lokalizace žluté a slepé skvrny .....	18
5.2.1	Střed slepé skvrny .....	18
5.2.2	Fovea.....	19
5.3	Hledání bodů větvení.....	20
5.3.1	Automatická úprava kontrastu .....	21
5.3.2	Matched filter.....	21
5.3.3	Prahování .....	22

5.3.4	Ztenčení cév .....	22
5.3.5	Body větvení .....	22
6	Implementace .....	24
6.1	Cílová platforma .....	24
6.2	Struktura aplikace .....	25
6.3	Ukázka výstupu aplikace .....	27
7	Testování .....	29
7.1	Segmentace cévního řečiště .....	29
7.1.1	Výsledky .....	30
7.2	Určení biometrického vzoru .....	30
7.2.1	Lokalizace slepé skvrny .....	30
7.2.2	Lokalizace fovei .....	31
7.2.3	Přesnost určení bodů větvení .....	31
7.3	Výsledky tetování na dalších databázích .....	32
7.4	Shrnutí .....	33
8	Závěr .....	35

# 1 Úvod

Sítnice lidského oka je jedním z mála míst lidského těla, kde lze neinvazivním způsobem pozorovat cévní systém [3]. Tento systém je pro každého jedince unikátní, neshoduje se ani cévní řečiště, jednovaječných dvojčat, liší se i levé oko od pravého. Cévní řečiště sítnice navíc splňuje všechny vlastnosti požadované od vhodné biometricky – je univerzální (má ho každý), je jedinečné (žádné dvě cévní řečiště v sítnici se neshodují), v čase se jeho tvar nemění (pouze vlivem oční choroby) a je snímatelné. Společně s faktem, že mluvíme o vnitřní části oka, které není zvnějšku lehce přístupné pro manipulaci, činí toto ze sítnice kvalitní biometrickou vlastnost, navíc velmi odolnou proti podvržení.

V současné době na trhu není dostupné žádné komerční zařízení, biometrický systém, vycházející z anatomických vlastností sítnice. Díky velkému rozmachu elektronických technologií v posledních několika letech, kdy je stále větší důraz kladen na bezpečnost, se stává toto téma velmi aktuálním.

Zpracováním barevného snímku sítnice se zabývá několik prací, většinou se však jedná o aplikace v medicíně, jako součást diagnostického systému. Z biometrického hlediska se snímkem sítnice zabývá například článek [2], ze které jsem částečně vycházel.

Moje práce se zabývá získáním biometrické šablony ze snímku sítnice, cílem je nezávislost šablony na vstupním snímku, tedy určení šablony na základě anatomických vlastností sítnice, nikoli z vlastní vstupního snímku. Algoritmus prezentovaný v práci tohoto dosahuje určení souřadnic bodů větvení cév řečiště v závislosti na poloze slepé a žluté skvrny. Výsledná aplikace je naprogramována v programovacím jazyce C++ za využití knihovny OpenCV (knihovna funkcí určených pro zpracování obrazu a počítačové vidění). Cílovou platformou je digitální signálový procesor.

První část práce uvádí teoretický podklad z oblasti biometrie, zpracování signálů a anatomie lidského oka. Na těchto základech pak staví další část, zabývající se návrhem, implementací a testováním aplikace.

## 2 Úvod do biometrie

Pojem biometrie vznikl spojením řeckých slov *bios*, tedy život a *metron*, měření. V biometrii mluvíme o „měření života“. V různých oborech tento pojem vykládáme poněkud odlišně. Například v medicíně biometrie označuje statistické výpočty medicínského nebo biologického charakteru, oproti tomu, v oboru informačních technologií biometrií zpravidla rozumíme systém určený k identifikaci lidských jedinců na základě rozpoznání a porovnání vzorů biologicky pozorovatelných vlastností osoby. Souhrnně lze tedy biometrii označit, jako vědu zabývající se měřením živých charakteristik člověka.

Využití biometrie k identifikaci vychází z přesvědčení, že některé vybrané vlastnosti jsou pro člověka jedinečné a lze ho podle jejich rozpoznání jednoznačně identifikovat. Identifikace jedince na základě biometrických vlastností sahá velmi daleko do historie a patří, i když si to patrně neuvědomujeme, mezi každodenní činnosti každého z nás. Jako příklad můžeme uvést rozpoznání kamaráda pomocí obličeje, jeho hlasu, způsobu chůze, siluety postavy a další. Zvířata využívají biometrii také, například k identifikaci pomocí pachu u psů (to souvisí s vyšší dokonalostí jejich čichu).

V poslední době se o biometrii mluví převážně v souvislosti s informačními technologiemi a systémy pro automatické rozpoznání totožnosti. Tyto jsou využívány na místech s omezeným přístupem, mnohdy vyžadující nějakou formu zabezpečení. Biometrické systémy (viz kapitola 2.2.5) tak nahrazují jiné formy prokázání totožnosti (přístupová karta, PIN kód, a jiné) nebo je doplňují – používají se v kombinaci s nimi. Jejich účelem je snížit pravděpodobnost vniknutí neoprávněné osoby do systému. Mezi hlavní výhody autentizace na základě biometrické vlastnosti řadíme nemožnost ztráty (na rozdíl například od přístupové karty), vyšší pohodlí, nemožnost popření identity a nižší riziko podvržení identity (tato vlastnost se však liší u konkrétních metod, jak bude uvedeno dále). Mezi hlavní nevýhody pak můžeme jmenovat fakt, že výstupem systému je míra shodnosti, tedy nejednoznačné skóre. Dále možnost napadení samotného biometrického systému a s ním související problém zjišťování pravosti předložené informace [1].

### 2.1 Historie

Jak již bylo zmíněno výše, kořeny biometrie sahají hluboko do historie. Již v pravěku musel člověk, umět identifikovat své druhy. Fakt, že tehdejší jedinec žil pouze v malé skupině to značně ulehčoval. S nástupem nových komunikačních technologií, globální počítačové sítě se však lidstvo posunulo do stádia, kdy takřka žádný jedinec nežije samostatně, případně v malé skupině, naopak se nabízí diskuse, zda vlivem současných telekomunikačních možností nežijeme v jedné velké, globální, skupině. Určení identity jedince se v tak početné skupině lidí pak stává více a více složitou záležitostí.

Informace jako taková se může stát velmi cennou komoditou, jejíž ztráta nám může způsobit obrovské škody. V době digitálních technologií, kdy je jasným trendem ukládat informace v elektronické podobě, řešíme tedy zabezpečení celých informačních systémů a autorizaci přístupu k nim. Například při bankovní transakci, která se provádí na druhé straně planety, než se nachází počítač, jehož prostřednictvím byl příkaz zadán, vyvstává nutnost ověřit identitu osoby, jež transakci provedla. Byla skutečně tou osobou, za kterou se vydává? Byla k této transakci oprávněna? Každoročně dojde v USA k 15 milionům krádeží elektronické identity s celkovou způsobenou škodou přesahující 50 miliard dolarů [1].

Mezi nejstarší důkazy o využití biometrických vlastností osoby řadíme tzv. *petroglyfy*, ryté obrazy znázorňující lidskou ruku. Tyto byly nalezeny na dnešním území státu Indiana, USA, jejich stáří se odhaduje na několik tisíc let. Existují i archeologické důkazy o využití otisků prstů k identifikaci v Číně a Asýrii datované do 7. - 6. tisíciletí před naším letopočtem. Podle dochovaného spisu, jehož autorem je Kio Kang-yen, znali Číňané unikátnost otisku prstu a využívali ho při obchodování. V letech 618-906 našeho letopočtu byl podle čínského zákoníku muž povinen připojit otisky svých prstů k listině, písemné žádosti, popisující důvody k rozvodu [4].

K prvnímu popsanému hromadnému sběru biometrických údajů, konkrétně otisků prstů, došlo po roce 1858, kdy William James Herschel, britský úředník působící služebně v Indii, donutil indického dodavatele na stavbě cesty, ve snaze aby dostal svým závazkům, připojit pod smlouvu otisk palce pravé ruky. Tak, jak to dříve viděl u Čínských obchodníků. Začal otisky prstů studovat a později toho využil při vyplácení důchodové renty neustále rostoucímu počtu indických dělníků. Ti, jelikož byli z velké části negramotní, se nedokázali podepsat, a proto převzetí částky stvrdili otiskem prstu. Navíc se Herschelovi zdáli všichni Indové tak podobní, že je jinak než podle otisků prstů nerozeznal.

Přibližně ve stejné době, tj. po roce 1879, se začal otisky prstů zabývat jiný Angličan, Henry Faulds, který v té době přednášel fyziologii v tokijské nemocnici. Byl patrně prvním, který použil otisky prstů v kriminalistice. Sejmutím otisků prstů na místě vloupání a jejich porovnáním s otisky údajného pachatele a přispěl k jeho osvobození. Pravý pachatel byl později chycen. Faulds v roce 1880 vypracoval návod pro snímání otisků prstů, kde, mimo jiné, navrhuje snímat otisky všech deseti prstů. Práce obou zmíněných vyústila ve vzájemný spor o prvenství. K praktickému využití daktyloskopie<sup>1</sup> v tomto období zatím nedošlo [4].

Další v řadě Angličanů, kteří přispěli k identifikaci osob pomocí tělesných vlastností, byl Francis Galton, bratranec Charlese Darvina. Ten v roce 1880 položil základy vědy zvané antropometrie, která se zabývá obecně měřením rozměrů lidského těla. Stejný přístup používal již od roku 1878 Alphonse Bertillon, pařížský kriminalista, který antropometrii, nazvanou po něm též Bertillionáž, zavedl do policejní praxe. Na práci Herschela a Fauldse navázal Galton ve své práci

---

<sup>1</sup>Daktyloskopie z řeckého *daktylos*, prst, a *skopein*, viděti.

<sup>2</sup> DNA - deoxyribonukleová kyselina [1].

*Fingerprints*, kterou vydal v roce 1892. V následujících letech srovnává obě metody (antropometrii i daktyloskopii) a obě doporučuje k zavedení do praxe. Tak se i stává a daktyloskopie se v roce 1900 prosazuje jako identifikační i verifikační měřítko [1]. Mezi první vyžití patřila identifikace vojáků v Indii, kteří připravovali stát o finance na žoldu tak, že utekli od útvaru, ke kterému byli přiděleni a nechali se znovu naverbovat. Tak dostali měsíční žold vyplacen několikrát. Odhaduje se, že po zavedení daktyloskopie klesl počet takových dezercí z původního počtu asi 35000 na 500-600 ročně [4].

Z pohledu informačních technologií je klíčové zavedení identifikačního oddělení FBI (*Federal Bureau of Investigation*, česky Federální úřad pro vyšetřování), které vzniklo v roce 1924 nařízením Kongresu USA. Toto oddělení pro identifikaci používá otisky prstů a vzniká tak obrovská daktyloskopická databáze. V roce 1971 počet otisků přesáhl 200 milionů. Toto množství se ukázalo jako nezpracovatelné v papírové formě. Bylo tedy rozhodnuto pokračovat ve zpracování otisků prstů digitálně – pomocí počítače. Vzniká tak systém nazvaný AFIS (*Automated Fingerprint Identification System*), poprvé použit v roce 1965. V roce 1999 přestala FBI úplně využívat papírovou databázi [4]. V roce 2010 tak systém AFIS obsahuje 66 milionů sad (10 otisků všech prstů na ruku) otisků prstů. Průměrně dojde k 162 000 prohledání denně. Doba vyhledání je přibližně 1 hodina, v urgentních případech okolo 10 minut [1].

## 2.2 Základní biometrické pojmy

V této podkapitole vysvětlím několik základních pojmů, které budou dále v práci využity.

### 2.2.1 Identita

Identita (latinsky *identitas*, ze slova *idem* – stejný), neboli totožnost je chápána jako vztah mezi objekty, jež se shodují ve všech svých vlastnostech. Platí zde princip identity, který je základním stavebním kamenem logiky a říká: každý objekt je identický jen sám se sebou [4]. V [1] je identita definována jako jednoznačná charakteristika každého z nás.

Pojem lidská identita je v [4] definována jako kombinace biologických i psychických, vrozených i získaných individuálně, specifických vlastností a schopností vnímání sám sebe. Ztělesnění našeho vlastního já. Odtud vychází fakt, že osoba je totožná, identická, pouze sama se sebou.

Dále je nutné rozlišit identitu fyzickou (biologickou) a identitu elektronickou (virtuální). Fyzickou identitu máme každý pouze jednu, která je nezaměnitelná, nezpochybnitelná a vzniká na základě dědičnosti. Z pohledu biologie je dána lidským genomem – strukturou DNA<sup>2</sup>. Toto však neplatí u elektronické identity. Zde záleží jen a pouze na tom, jak se ji rozhodneme definovat. Pokud

---

<sup>2</sup> DNA - deoxyribonukleová kyselina [1].

pro nás například bude jednoznačným identifikátorem osoby v internetu její emailová adresa, může mít každý hned několik takových adres a tím i několik elektronických identit.

## 2.2.2 Identifikace

Definice pojmu identifikace je několik, pro nás je důležitá definice identifikace z pohledu biometrických systémů. Identifikaci budeme definovat jako proces zjišťování identity osoby. Tento proces má na vstupu biometrickou informaci, například otisk prstu. Informace je následně biometrickým systémem porovnána s celou dostupnou databází. Jedná se tedy o porovnání 1:N, které může být časově velmi náročné. Pro snížení času vyhledávání se využívá hierarchická struktura databáze znalostí, založená na několika základních vlastnostech vedoucích ke snížení počtu porovnávaných záznamů. Výstupem systému je pak nalezená identita nebo hlášení identita nenalezena. Při vkládání nového záznamu do databáze znalostí musí dojít ke kontrole, zda tento objekt již není v databázi obsažen pod jinou identitou. Dochází tedy k prohledávání databáze i při přidávání nového záznamu [1].

## 2.2.3 Verifikace

Dalším pojmem, který se často v biometrii vyskytuje, je verifikace. Ta se od identifikace zásadně liší a to tím, že při verifikaci dochází k porovnávání 1:1, neboť vstupem biometrického systému je, podobně jako u identifikace, biometrická vlastnost, ta je ale uživatelem doplněna o jeho elektronickou identitu. Na jejím základě dojde k vyhledání biometrického záznamu uživatele (v případě neexistence se automaticky přístup zamítá) a ten se porovná s poskytnutou biometrickou vlastností. Pokud dojde ke shodě, je přístup povolen, jinak je zamítnut [1]. Jedná se tedy o ověření, zda je uživatel skutečně tím, za koho se vydává.

## 2.2.4 Autentizace

Tento pojem souvisí s oběma výše uvedenými. Setkáváme se s ním často u přístupových systémů. Rozhodnutí proběhne na základě stanoveného prahu – systém vypočítá, do jaké míry se poskytnutá informace shoduje s referenční informací a tuto míru porovná se stanoveným prahem. Pak buďto povolí přístup, nebo přístup zamítne [4].

Autentizace, prokázání identity, může probíhat na základě tří typů informací:

- co víme (přístupové heslo),
- co vlastníme (klíč, karta, ...),
- co jsme (biometrická vlastnost).

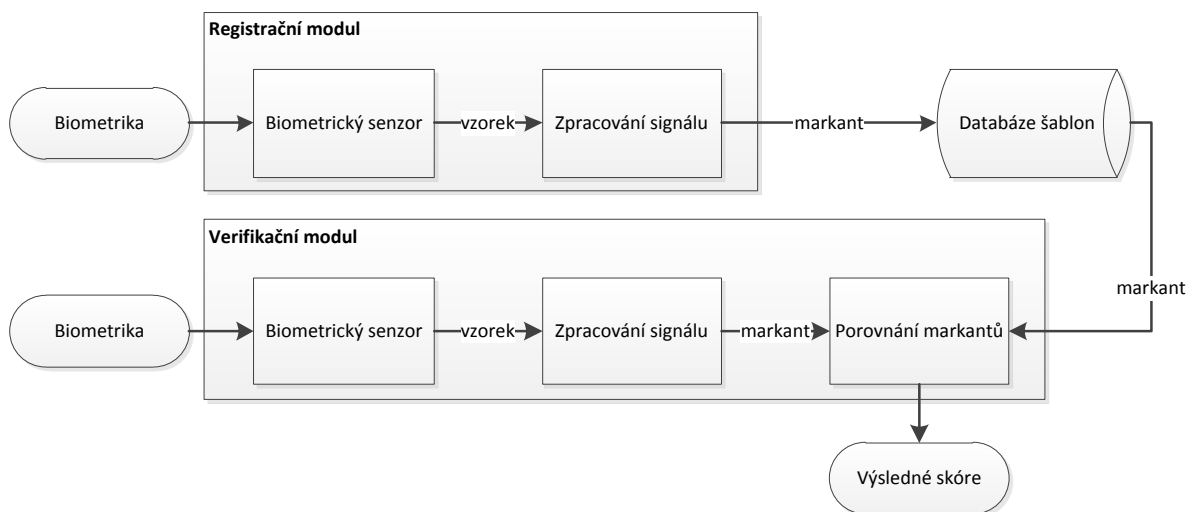
Nejpohodlnější pro uživatele je autentizace na základě toho, co jsme. Biometrickou vlastnost těžko zapomeneme jako heslo, a těžko ztratíme jako například klíče. Bezpečnost systému zabezpečeného pomocí biometrické autentizace je odlišná u každé metody a nedá se formulovat obecně. Například

pořízení falzifikátu otisku prstu nepředstavuje větší problém, protože otisky prstu zanecháváme takřka všude. Kdežto kopii sítnice oka vytvoříme jenom stěží.

## 2.2.5 Biometrický systém

Schéma biometrického systému můžeme vidět na Obr. 2.1: Schéma biometrického systému.. Skládá se ze dvou modulů – registračního a verifikačního (identifikačního), které jsou však často integrovány do jednoho celku [1].

Oba tyto moduly mají na vstupu danou biometriku, kterou nasnímají biometrickým senzorem. Tato část se označuje jako sběr dat. Výstupem senzoru je daný vzorek, například obrázek, nebo záznam zvuku. Z něj se dále extrahují požadované rysy odfiltrováním šumu – irelevantních informací. Obecně tedy systém provádí zpracování signálu. Vzhledem k výstupu, kterým je extrahovaný biometrický rys, můžeme říct, že se jedná o ztrátovou kompresi, neboť z biometrického markantu není možné zpět rekonstruovat danou biometriku [7]. Součástí zpracování vstupního signálu může být i kontrola kvality vstupního signálu. Pokud systém shledá vstup nekvalitním, zamítne jej a nepokračuje v jeho dalším zpracování.



Obr. 2.1: Schéma biometrického systému.

Registrační modul uloží získaný rys ve formě šablony do databáze, spolu s identitou uživatele. Oproti tomu verifikační (identifikační) modul získaný rys porovná s šablonou (šablonami) uloženými v databázi šablon (uživatelů).

## 2.2.6 Biometrické vlastnosti

Následuje krátký přehled využívaných biometrických vlastností [1].

### Anatomické (fyzické, statické) vlastnosti:

- otisky prstů – daktyloskopie,
- geometrie ruky,

- krevní řečiště (žíly hřbetu ruky, dlaně, prstu),
- tvar tváře, snímek tváře pořízený termokamerou,
- snímek duhovky, snímek sítnice,
- otisk a tvar ucha.

#### **Behaviorální (dynamické) vlastnosti:**

- hlas a řeč,
- mimika obličeje, pohyby rtů,
- podpis a písmo,
- dynamika stisku kláves,
- pohyb a chůze.

### **2.2.7 Charakteristiky biometrických vlastností**

Biometrické vlastnosti je třeba nějakým způsobem charakterizovat, abychom je mohli navzájem porovnávat a na základě porovnání rozhodnout o vhodnosti použití dané biometriky v konkrétním případě. Mezi hlavní charakteristiky patří následující [1]:

- **Univerzalita** – každý měřený subjekt by měl mít danou vlastnost.
- **Jedinečnost** – daná vlastnost by měla být dostatečně unikátní, aby bylo možné na jejím základě jednoznačně rozlišit jednu osobu od druhé.
- **Konstantnost** – daná vlastnost by se neměla měnit v čase.
- **Získatelnost** – vlastnost musí být kvantitativně měřitelná a symbolicky vyjádřitelná.
- **Výkonnost** – vlastnost se nesmí v čase změnit, zestárnout, a ovlivnit tak výkonnost biometrického systému
- **Akceptace** – značí ochotu subjektů ke snímání dané vlastnosti neboli uživatelskou přívětivost.
- **Odolnost proti zfalšování** – značí míru úsilí nutného pro vytvoření falsifikátu dané vlastnosti.
- **Finanční náklady na pořízení** – ekonomické měřítko ovlivňující manažerské rozhodnutí o zavedení systému. V podstatě se jedná o celkové náklady na nasazení systému.

### **2.2.8 Měření výkonnosti biometrických metod**

Jak jsme již uvedli výše, výstupem porovnání extrahovaných biometrických markantů je skóre porovnání. To se pohybuje v intervalu  $<0; 1>$ , kde 0 je neshoda a 1 je shoda. Tato míra je následně porovnána se zvoleným prahem  $T$  a na základě porovnání systém rozhodne o přijetí nebo zamítnutí identity. Mohou tedy nastat 4 možné scénáře. Správné chování systému:

- Osoba A je přijata jako osoba A.
- Osoba B je zamítnuta jako osoba A.

Chybové chování systému pak nastane, když:

- Osoba B je přijata jako osoba A (chybné přijetí).
- Osoba A je zamítnuta jako osoba A (chybné odmítnutí).

Těmito případy se budeme dále zabývat [4].

### **Míra chybného přijetí (FAR)**

Míra chybného přijetí neboli FAR (z angl. *False Accept Rate*) se testuje tak, že necháme systém vyhodnocovat shodnost nasnímaných vlastností s uloženou identitou, tyto si však nikdy neodpovídají. FAR hodnotu pak vypočteme jako podíl počtu verifikačních transakcí, které vyhodnotil jako přijetí k celkovému počtu verifikačních transakcí - viz vzorec 2.1 [4].

$$FAR = \frac{\text{počet přijatých transakcí}}{\text{celkový počet transakcí}} \quad (2.1)$$

Nízká hodnota FAR je vyžadována například u systému zabezpečujících přístup k objektům, kdy by chybné přijetí znamenalo bezpečnostní problém.

### **Míra chybného odmítnutí (FRR)**

Míru chybného odmítnutí – FRR (z angl. *False Rejection Rate*) se testuje tak, že necháme systém porovnávat nasnímanou biometrickou vlastnost s odpovídající biometrickou šablonou a zkoumáme počet odmítnutých verifikačních transakcí. FRR pak vypočítáme jako podíl odmítnutých transakcí k celkovému počtu transakcí. Viz vzorec 2.2 [4].

$$FRR = \frac{\text{počet odmítnutých transakcí}}{\text{celkový počet transakcí}} \quad (2.2)$$

V praxi neznamená falešné odmítnutí žádný velký problém, jednoduše se opakuje nasnímání biometrie. V případě vysokého FRR ovšem dochází ke zdržení uživatele a tím k výraznému snížení uživatelské přívětivosti systému.

### **Receiver operating characteristic (ROC)**

ROC křivka se běžně využívá ke znázornění poměru FRR na FAR, tím se odstraní závislost na zvoleném prahu. Je tedy určena k porovnání přesnosti biometrických systémů.

## 3 Teorie signálů

V následující kapitole popíší základy teorie informace, signálů, jejich zpracování a zpracování obrazu. Kapitola slouží jako obecný úvod čtenáře do problematiky a definuje základní pojmy dané oblast. Neklade si za cíl obsáhnout celý rozsáhlý matematický aparát, vztahující se k této tematice, právě naopak, informace jsou podány ve zkrácené formě, tak, aby na ně mohlo být navázáno v části práce zabývající se návrhem aplikace, kde bude doplněn a popsán konkrétní postup, včetně popisu jednotlivých kroků, extrakce biometrických rysů z obrazu, použitých v aplikaci.

### 3.1 Úvod do teorie informace

Základní stavební jednotkou signálového systému je *informace* [1]. Jelikož existuje několik možných definic tohoto pojmu, uvedeme pouze jednu, která je z infromatického hlediska důležitá, a sice definici z teoretického slovníku informatiky. Ten definuje informaci jako: *obsah jakéhosi oznámení, určeného pro přenos v prostoru a čase. V nejširším slova smyslu jako obsah vztahu mezi materiálními objekty, projevující se změnami těchto objektů* [1].

Proces komunikace pak probíhá mezi zdrojem informace, realitou a příjemcem informace, například člověkem nebo strojem. Tato informace má obvykle podobu zprávy, kterou musí příjemce zpracovat neboli interpretovat – přidat jí sémantiku. Nosičem zprávy v prostředí, umožňujícím její šíření je signál.

Celý výše uvedený systém nazýváme komunikačním systémem. Ten se tedy skládá ze zdroje informace, vysílače, přijímače a cíle. V systému se může rovněž vyskytovat zdroj rušení. Postup činnosti je pak následující: Zdroj informace generuje zprávu, kterou předá vysílači. Ten ji transformuje do formy signálu, který následně přijímač transformuje zpět do formy zprávy, kterou předá příjemci informace (cíl). Zdroj rušení působí jako nežádoucí element, který signál při přenosu nějakým způsobem deformuje [1].

### 3.2 Digitální signál

Definice signálu opět není jednoznačná, vzhledem k velkému množství oborů, ve kterých se signály vyskytují (můžeme rozlišit například optické, elektrické, magnetické, mechanické a jiné signály), z nichž každý význam pomu signál vykládá trochu odlišně. Intuitivní definici signálu je možné odvodit z výše uvedeného výkladu. Signál chápeme jako cokoli, nesoucí nějakou informaci (hlas, světlo, gesta, elektromagnetické pole vysílané anténou a jiné). Dále budeme signál tedy chápat jako průběh nějakého měřitelného jevu v čase, tedy jakoukoli funkci času.

Rozlišujeme dva základní typy signálu: analogové a digitální. Rozdíl mezi nimi je, že analogový signál může nabývat hodnot z nekonečné množiny, například reálných čísel, kdežto digitální signál je diskrétní signál (viz dále), který může nabývat pouze určitého, předem daného, počtu hodnot [1].

### 3.2.1 Základní pojmy

Již jsme definovali analogový a digitální signál. Nyní definujeme diskrétní a spojitý signál. K tomu však potřebujeme několik dalších dílčích definic z [1].

*Spojitá proměnná* je taková proměnná, která může nabývat libovolného, nekonečného, počtu hodnot z intervalu reálných čísel. Naopak *diskrétní proměnná* nabývá pouze konečného počtu hodnot.

*Nezávislou proměnnou* použijeme pro vysvětlení chování *závislé proměnné*. Ta je popisována jako výstup systému, jehož vstupem jsou nezávislé proměnné.

*Spojitý signál* pak chápeme jako spojitou funkci  $f(x)$ , kde  $x$  je spojitá, nezávislá proměnná. Oproti tomu *diskrétní signál* je posloupnost hodnot  $f[n] = f_n = f(n)$ , nad kterou je dáno celočíselné uspořádání vzhledem k celočíselnému indexu  $n$ . Tato posloupnost mohla vzniknout například jako série měření.

### 3.2.2 Získání digitálního signálu

Získání digitálního signálu z analogového spojitého signálu se souhrnně označuje jako proces digitalizace, a v zásadě se skládá ze dvou kroků: vzorkování signálu a kvantování.

#### Vzorkování signálu (angl. sampling)

Je proces, kdy spojitý signál vyjádříme pomocí spočetné množiny vzorků, jejichž hodnoty byly sejmuty s vhodnou frekvencí z analogového signálu, jde tedy o diskretizaci signálu. Ideálně vzorkujeme nekonečnou posloupností Diracových impulsů (funkce, která v nule nabývá hodnoty nekonečno, ve zbytku definičního oboru je nulová) [1].

#### Kvantování signálu

Druhá fáze digitalizace se nazývá kvantování neboli snímání. Jedná se o nevratný ztrátový proces, kdy jsou hodnoty z oboru reálných čísel převáděny na konečný počet kvantizačních hladin, zpravidla na množinu hodnot od 0 do 255, reprezentovanou jedním bytem. Podle způsobu rozložení kvantizační množiny rozlišujeme *kvantování uniformní*, neboli lineární, kdy mají mezi sebou kvantizační hladiny stejnou vzdálenost. Oproti tomu *neuniformní kvantování* je takové, kdy nejsou vzdálenosti hladin stejné. Například logaritmické nebo exponenciální.

Jelikož je kvantování jakousi formou aproximace, zajímá nás kvalita výsledné aproximace, tu můžeme vyjádřit pomocí kvantizační chyby, tedy rozdílu původní hodnoty a kvantizační hladiny.

### 3.2.3 Filtrace signálu

Filtrací signálu rozumíme proces, který slouží ke zvýraznění požadovaných vlastností signálu nebo naopak k potlačení nežádoucích vlastností signálu. Filtry popisujeme přenosovou funkcí nebo diferenčními rovnicemi.

#### Lineární filtrace

O lineárních filtrech hovoříme primárně v teoretické oblasti filtrování, neboť lineární filtry jsou poměrně jednoduché a je k nim zpracován potřebný matematický aparát. U těchto filtrů platí princip superpozice. Tyto filtry dělíme podle typu impulsní odezvy (odezva filtru na Diracův impuls) na filtry s konečnou (FIR – *Finite Impulse Response*) a nekonečnou (IIR - *Infinite Impulse Response*) impulsní odezvou. FIR filtry představují v podstatě váženou sumu zpožděných vstupů a neexistencí zpětné vazby zaručují stabilitu. Oproti tomu IIR filtry jsou vždy rekurzivní – obsahují zpětnou vazbu – a může tedy docházet k problémům se stabilitou. Jejich výhodou oproti FIR filtrům je především menší náročnost výpočtu při zachování kvality výstupu.

#### Nelineární filtrace

Přes zpracovaný teoretický aparát naráží lineární filtry na některé problémy, například zachování ostrosti hran. Tyto filtry lze v některých případech úspěšně nahradit filtry nelineárními. Příkladem může být mediánová filtrace [1].

## 3.3 Zpracování obrazu

Obraz lze chápat jako funkci dvou nezávislých proměnných  $z = f(x, y)$ , díky čemuž můžeme obraz jednoduše považovat za dvourozměrný signál. Metody zpracování obrazu jsou však do značné míry specifické a proto se vymezují do zvláštní kategorie zpracování obrazu. V naší aplikaci využijeme několik metod zpracování obrazu, ty budou podrobněji vysvětleny dále, v části návrhu aplikace.


## 4 Anatomie oka

Okem (neboli oční koulí) jako takovým rozumíme vlastní recepční orgán zrakového ústrojí. Jeho skladbu je možné vidět na obrázku 4.1. Má tvar takřka koule. Celkově je oko tvořeno třemi vrstvami. Vazivová vnější vrstva oka je v přední části tvořena *rohovkou* (průhledná vazivová tkáň), která je více zakřivená, než *bělima*, jež tvoří zadní část.

Prostřední vrstva oka je cévnatá a tvoří ji *cévnatka (choroidea)*, *řasnaté tělísko*, *duhovka (iris)* a *zornice (pupila)*. *Cévnatka* je na cévy velmi bohatá vrstva, zabírající největší část plochy střední vrstvy. Její funkcí je výživa vrstev oka a také ostření zraku na dálku, které probírá regulací napětí v cévnatce. *Řasnaté tělísko* složí jako závěs pro čočku, která je přichycena k jeho vnitřnímu okraji pomocí systému jemných vláken. *Duhovka* má tvar mezikruží, v jehož středu se nachází otvor – zornice. Duhovka jako taková odděluje přední a zadní oční komoru. Její funkci je možné připodobnit k cloně fotoaparátu – rozevívá čočku při nedostatku světla a ostření na dálku, a naopak svírá čočku při ostření na blízko a dostatku světla. Z biometrického pohledu se jedná o významnou část orgánu.

Vnitřní nervová vrstva je tvořena *sítnicí (retinou)*. Ta je tvořena nervovými zakončeními citlivými na světlo, tzv. světločivnými elementy (*fotoreceptory*), kterými jsou *čípky* a *tyčinky*. Ty jsou stavbou podobné, liší se však tvarem. Tyčinek je v oku více, asi 120 milionů, a jsou citlivější, reagují na světlo nižší intenzity, využíváme jich tedy k detekci intenzity světla, jimi sejmutý obraz je černobílý. Oproti tomu čípky, kterých je v oku méně, jen asi 6-7 milionů, jsou určeny ke snímání barev, způsobují tedy barevné vidění. Dělíme je na tři druhy podle toho, jakou barvu daný čípek snímá. Z biometrického hlediska jsou na sítnici významné dva útvary – *žlutá skvrna (makula)* a *slepá skvrna (optický disk)*. Žlutá skvrna je místo s nejvyšší koncentrací čípku v oku, díky čemuž se jedná o místo s nejostřejším viděním. Jako slepá skvrna je označováno místo, kde do oka ústí zrakový nerv. V tomto místě se nenachází žádné fotoreceptory a mozek si tak část světla dopadající do tohoto místa musí v obraze domyslet. Sítnice je po duhovce druhou částí oka využívanou v biometrii.

Uvnitř bulbu se pak nachází *sklivec, rosolovité těleso*, vyplňující vnitřní oko, *čočka, přední a zadní komora*, obě vyplněné komorovým mokem [6].



Obr. 4.1: Řez okem (převzato z [13]).

## 4.1 Biometrické rysy oka

Jak již bylo zmíněno výše, z biometrického hlediska se využívají dvě části oka, a sice duhovka (iris) a sítnice (retina). Obě tyto součásti jsou velmi vhodné, neboť jsou u každého jedince unikátní a je extrémně náročné je zfalšovat. Nevýhodou je možnost změny jejich vlastností vlivem choroby.

### 4.1.1 Identifikace pomocí duhovky oka

Umístění a anatomie duhovky bylo popsáno výše. Jedná se o plochou část svaloviny zodpovědnou za stahování a roztahování čočky. Barva (způsobená melaninem), struktura a vzor duhovky jsou unikátní (i u dvojčat) a zůstávají neměnné i během života.

Duhovka je pozorovatelná pouhým okem, díky čemuž je pořízení jejího snímku uživatelsky daleko přívětivější, což je hlavní výhoda oproti identifikaci pomocí sítnice. Tím pádem je využívána i v komerční sféře.

Postup takové identifikace začíná pořízením snímku duhovky, pomocí fotoaparátu. Dnes i ze vzdálenosti 1 metru, takže uživatel není příliš omezen. Dále je třeba na snímku lokalizovat oko a duhovku. Ta je následně rozvinuta do obdélníkového tvaru pomocí Daugmanova algoritmu [7]. Ten mapuje každý bod uvnitř duhovky do polárních souřadnic určených úhlem a poloměrem. Takto

reprezentovaný obraz je pak zakódován pomocí Gaborova filtrování. Výsledná šablona je pak posloupnost jedniček a nul (256 bytů). Šablony se porovnávají pomocí výpočtu Hammingovy vzdálenosti (suma exkluzivních součtů jednotlivých bitů šablony). Šablony se vůči sobě posouvají a jako výsledné skóre je pak brána nejnižší Hammingova vzdálenost.

Již zmíněnou výhodou této metody jsou stabilita biometricky, neinvazivní pořízení snímku a uživatelská přívětivost. Dále je možné zmínit malou velikost šablony. Jako nevýhodou je nižší bezpečnost v porovnání se snímáním sítnice, neboť duhovka může být podvržena například použitím kontaktní čočky [1].


## 4.1.2 Identifikace pomocí sítnice oka

Historie rozpoznávání pomocí sítnice oka sahá až do roku 1935, kdy při studiu očních nemocí zjistil oční lékař Dr. Carleton Simon, že krevní řečiště v cévnatce oka je jedinečné. Tuto domněnku dále zkoumal Dr. Paul Towel (publikováno v roce 1955), který se zabýval studiem jednovaječných dvojčat. Zjistil, že sítnice a duhovka vykazují nejmenší podobnost ze zkoumaných vzorů.

V podstatě jedinou průmyslovou aplikací rozpoznávání sítnice oka má na svědomí Robert Hill, který v roce 1975 založil firmu EyeDentify, v rámci které zkonstruoval zařízení EyeDentificationSystem [2]. Jeho vývoj trval řadu let a v počátcích se jednalo o konstrukčně velmi složité zařízení. To se podařilo postupem času zjednodušit a komerčně nasadit.

Principem systému bylo porovnání intenzity kontrastu v extrahovaných bodech (těch bylo 96), které byly nasnímány z kruhové oblasti sítnice. V šabloně byl každý z nich reprezentován 4bity. Komerčně se však zařízení příliš neujalo a v současné době bylo staženo z trhu. Důvodem bylo patrně odmítání uživatelů, kterým je snímání obrazu sítnice nepříjemné, protože se musím přiblížit na vzdálenost pouhých několika centimetrů od snímacího zařízení. Někteří měli dokonce strach, že dojde k poškození jejich zraku laserem. Ten se však ke snímání sítnice nikdy nevyužíval (používá se osvětlení infračerveným světlem, které je pro lidské oko neviditelné, tedy není nijak nepříjemné) [1].

V současné době tedy není na trhu k dispozici komerční zařízení pro identifikaci na základě sítnice a výzkum se přenesl spíše do vědecké/akademické sféry. Výzkumy se zabývají rozpoznáváním na základě snímků celé sítnice získaných fundus kamerou (lékařské zařízení určené k vyšetření oka). Zkoumá se cévní řečiště cévnatky (choroidea), které je možné nasnímat díky reflexi cév při osvětlení infračerveným světlem a díky částečné průsvitnosti sítnice. Důležité v naší aplikaci budou body, ve kterých dochází k větvení cév. Ty budou určeny svou pozicí vůči středu optického disku – slepé skvrny - viz obrázek 4.2 [5].



*Obr. 4.2: Snímek sítnice pořízený fundus kamerou (zesvětleno pro účely tisku).*

Jak bude uvedeno v další kapitole, v mé aplikaci vycházím z jedinečnosti cévního systému v choroidu. Tento obsahuje více než 400 jedinečných charakteristik [2]. Ten, jak již bylo zmíněno, reprezentují pomocí bodů větvení a křížení cév. Jak je uvedeno v kapitole 7, těchto bodů bylo při použití kvalitního snímku nalezeno algoritmem několik set (v průměru 256).

## 5 Návrh aplikace

Cílem práce je vytvořit aplikaci, která ze zadaného snímku sítnice extrahuje biometrický markant, který je pro danou sítnici jedinečný a umožní pak jeho další porovnání. Dalším požadavkem je výsledná reprezentace markantu formou, jež je vhodná pro jeho uchování. Aplikace se nebude zabývat ukládáním, správou ani porovnáváním markantů jako takových, ale pouze jeho extrakcí ze vstupního snímku. Nejedná se tedy o biometrický systém, ale pouze o jednu z jeho částí, zabývající se primárně zpracováním (filtrací) obrazu. Všechny operace probíhají nad zeleným kanálem obrazu, jelikož je nejvýraznější.

Všechny přístupy k identifikaci na základě sítnice jsou založeny na jedinečnosti cévního řečiště v choroidu, jak bylo uvedeno výše. V mé cílené aplikaci vycházím z [5], kde je cévní systém reprezentován pomocí bodů větvení (*angl. bifurcation points*) cév (v aplikaci detekují i body ve kterých dochází ke křížení cév). Tyto body jsou pak určeny svou polohou ve snímku sítnice.

### 5.1 Požadavky na aplikaci

Aplikace jako taková se, jak již bylo zmíněno, zabývá extrakcí bodů větvení (křížení) v cévním systému. Tyto body jsou následně určeny svou polohou. Aby byl markant invariantní vůči pootočení snímku, je nutné určit souřadný systém tak, aby v případě rotace snímku došlo k odpovídající rotaci souřadného systému. Dále by získaný markant neměl být závislý na posunutí snímku (translaci) a na změně jeho velikosti.

#### 5.1.1 Definice souřadného systému

Z výše popsaných nároků jasně vyplývá, že souřadný systém nesmí být založen na poloze v rámci snímku, ale musí být určen anatomickými strukturami obsaženými v sítnici. Dvě z nich se přímo nabízí, a sice slepá a žlutá skvrna. Obě dvě jsou poměrně výrazné a jasně rozpoznatelné na snímku (žlutá skvrna se na snímku vyznačuje jako netmavší region, slepá skvrna pak jako nejsvětlejší region). Navíc je jejich vzájemná poloha anatomicky dána, což napomáhá zrychlit jejich lokalizaci.

Souřadnicový systém je tedy zvolen ortonormální, tedy takový, ve kterém platí ortonormalita. Tento se vyznačuje tím, že jeho souřadnicové osy jsou na sebe vzájemně kolmé a mají stejné měřítko. Pro definici takového systému je pak dostačující určit jeho střed (v rovině se jedná o bod se souřadnicemi  $[0; 0]$ ), směr jedné z os a měřítko.

V [5] je střed souřadnicového systému určen středem slepé skvrny a kladná poloosa  $x$  je určena polohou bodu větvení, který je nejbližší středu slepé skvrny. Měřítko je pak určeno prohlášením vzdálenosti nejbližšího bodu větvení od středu slepé skvrny za jednotkovou vzdálenost. Tím je zaručena nezávislost na rozlišení vstupního snímku.

V mém algoritmu je střed souřadného systému určen stejně jako v [5], tedy středem slepé skvrny. Liším se však v určení směru kladné poloosy, kterou definuji jako spojnicí středu slepé skvrny s foveou, tedy středem žluté skvrny. K této změně mě vedla snaha zvýšit odolnost systému vůči drobným rozdílům v různých snímcích stejné sítnice. Při použití středu žluté skvrny dojde buďto k jejímu úplnému zamítnutí, tedy nepodaří se foveu lokalizovat nebo se lokalizace fovei podaří a výsledek se u dvou různých snímků stejné sítnice bude jen mírně lišit. Je tedy větší šance, že v případě nasazení algoritmu v biometrickém systému bude výsledné skóre porovnání odpovídat shodnosti obou sítnic. Toto je zapříčiněno jedinečností fovei – žlutá skvrna je v oku jenom jedna.

Oproti tomu, určení souřadného systému nejbližším bodem větvení může vést k fatální chybě, jelikož je takových bodů v sítnici několik desítek až stovek (algoritmus jich v závislosti na kvalitě vstupního snímku rozezná až 300), a jejich koncentrace v oblasti slepé skvrny, tedy nejbliže jejímu středu, je také značná (jelikož cévní systém ústí do sítnice právě v místě slepé skvrny, společně s očním nervem). Vzdálenost nejbližších bodů větvení od středu slepé skvrny se liší jen minimálně (mnohdy je rozdíl vzdáleností obou bodů od středu slepé skvrny menší, než 1% této vzdálenosti), může tedy v případě mírné odlišnosti snímků dojít k určení jiného bodu, jako nejbližšího, čímž by se skóre porovnání markantů blížilo 0 (měřítko by sice bylo velmi podobné, ale případný jiný směr kladné poloosy  $x$  by porovnání znehodnotil).

V definovaném souřadném systému pak určuje polohu bodu jeho vzdálenost ( $d$ ) od středu souřadnic a úhel ( $\varphi$ ), který svírá s kladnou poloosou  $x$ . Bod  $p_1$  bude určen jako [5]:

$$p_1 = [d, \varphi] \quad (5.1)$$

Vzdálenost  $d$  je v tomto algoritmu počítána jako Euklidovská vzdálenost, definovaná jako:

$$d(x, y) = |x - y| = \sqrt{\sum_{i=1}^N (x_i + y_i)^2} \quad (5.2)$$

což lze považovat za zápis Pythagorovy věty. Tato vzdálenost je jednoduše vyčíslitelná a má dostatečnou vypovídající hodnotu [1].

Úhel, který svírá spojnice bodu se středem slepé skvrny s kladnou poloosou  $x$ , je pak určen inverzní goniometrickou funkcí  $\tan^{-1}$ :

$$\varphi = \tan^{-1}\left(\frac{x}{y}\right) \quad (5.3)$$

kde  $x$  je vzdálenost bodu  $p_1$  od slepé středu skvrny na ose  $x$  vstupního snímku. Obdobně  $y$  na ose  $y$ . Jelikož funkce  $\tan^{-1}$  vrací výsledek v intervalu  $(-90^\circ; 90^\circ)$ , je nutné určit, v jakém kvadrantu se bod

nachází a následně úhel upravit tak, aby se výsledná hodnota úhlu odpovídala úhlu v intervalu  $<0^\circ; 360^\circ$ ).

## 5.2 Lokalizace žluté a slepé skvrny

Jak bylo popsáno výše, nalezení středu slepé skvrny (anglicky *optic disc*) a fovei, tedy středu slepé skvrny (maculy) je velmi důležité pro určení souřadného systému, do kterého budou následovně mapovány body větvení cév. Segmentací obou oblastí se zabývá několik prací, změřených převážně na zpracování snímku sítnice z lékařského hlediska. V každé z kapitol věnující se jednotlivým oblastem uvedu výběr z těchto postupů, a jak jsem postupoval ve své práci.

### 5.2.1 Střed slepé skvrny


Nalezením slepé skvrny ve snímku sítnice se zabývá několik prací, prezentujících různé výpočetní modely. Tyto se od sebe navzájem liší přesností určení středu a výpočetní složitostí. Například v [9] se k nalezení přesné hranice oblastí slepé skvrny využívá metody *Principal component analysis* a následnou aplikaci metody *Gradient Vector Flow Snakes*. Tento model je výpočetně náročný a vykazuje velmi vysokou přesnost nalezení hranice slepé skvrny. V našem případě, je však důležitější hledání středu slepé skvrny, než přesné určení její hranice.

Oproti tomu v [10] je uvedený výpočetně velmi rychlý, avšak nepřesný algoritmus, založený na předpokladu, že slepá skvrna je na snímku sítnice oblastí s cca 5% nejsvětlejších pixelů. Tento přístup je postaven na principu prahování a je tedy klíčové zvolit vhodnou hodnotu prahu. Ten se volí na základě iterativního výpočtu, kdy v každém kroku počítáme průměrnou intenzitu pixelu pozadí  $\mu_b$  a pixelu popředí  $\mu_o$ .

$$\mu_b = \frac{\sum_{i=k}^n np_i hl_i}{\sum_{i=k}^n np_i} \quad \mu_o = \frac{\sum_{i=n+1}^{max} np_i hl_i}{\sum_{i=n+1}^{max} np_i} \quad (5.4)$$

kde  $np_i$  je počet pixelů s intenzitou  $hl_i$ .

Tento algoritmus vykazoval vysokou chybovost na testovacích snímcích, proto jsem se rozhodl jej neimplementovat, ale použít algoritmus uvedený v [8]. Ten je založený na hledání oblasti pixelů s nejvyšší průměrnou intenzitou okolí. Na obrázek je aplikován filtr dolní propusti (nová hodnota pixelu je určena jako průměr z okolních pixelů). Velikost okolí je přibližně stejná jako průměr slepé skvrny. Pixely s nejvyšší intenzitou jsou následně označeny bílou barvou, ostatní černě. Pak hledáme největší bílou oblast a v jejím okolí teprve v původním obrázku hledáme slepou skvrnu. Tento postup po aplikaci na testovací snímky vykazoval nižší chybovost, než algoritmus z [10].



Obr. 5.1 Lokalizace slepé skvrny. (A) oblast zájmu, zelený kanál, (B) obrázek po odstranění cév, (C) po detekci hran, (D) výstup prahování, po erozi, (E) detekovaný kruh, (F) detekovaný kruh v původním snímku.

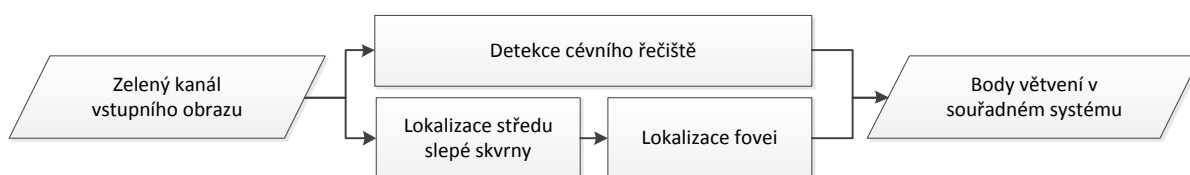
Následně je na vybranou oblast aplikováno několik obrazových filtrů a v takto upravené oblasti se pak hledá kruh (jelikož slepá skvrna velmi připomíná kruh) pomocí Houghovy transformace [11]. Jako první je třeba ze získané oblasti odstranit cévy, které, jelikož mají tmavší barvu než pozadí, by se nepříjemně projevíly v následující detekci hran, což by ovlivnilo výsledek. Odstranění cév docílíme aplikací morfologické operace dilatace [11] a následně aplikace Gaussova rozostření [11]. V takto upraveném obraze můžeme detekovat hrany, v našem případě pomocí Sobelova detektoru hran[11]. Následně na obraz aplikujeme prahování, morfologickou erozí odstraníme šum a aplikujeme Houghovu transformaci pro detekci kruhu [11], kde získáme nejen střed kruhu ale i jeho poloměr, který využijeme v další části algoritmu. Celý postup lze vidět na obrázku 5.1.

## 5.2.2 Fovea

Detekce fovei, neboli středu žluté skvrny, je rovněž nutná k určení souřadnicového systému, jak již bylo zmíněno výše. V aplikaci vycházím z postupu uvedeného v [10], kde je proces hledání založen na anatomických vlastnostech oka, konkrétněji na vzdálenosti fovei od středu slepé skvrny, která je rovna přibližně dvojnásobku průměru slepé skvrny. Dále je znám úhel spojnice středu slepé skvrny a fovei. Ten se pohybuje mezi  $-6^\circ$  a  $+3^\circ$ . Je tedy nutné nejprve detekovat střed slepé skvrny a teprve pak se pokusit detekovat foveu. Rovněž je nutné před začátkem hledání fovei určit průměr slepé skvrny.

Postup hledání žluté skvrny se skládá z několika dílčích kroků. Nejprve se z obrázku vybere oblast (výseč), ve které se žlutá skvrna nachází, a zbytek obrázku vyplníme bílou barvou. Tato výseč je určena úhlem, vzdáleností a středem slepé skvrny. V [10] jsou následně odstraněny tmavé cévy (jejich extrakci popíši v kapitole 5.3 a pak je aplikováno prahování. Tento postup však nedosahoval požadovaných výsledků, kamenem úrazu bylo určení prahu.

Proto jsem se rozhodl postupovat podobně, jak o při hledání slepé skvrny. Na vybranou oblast je aplikován filtr dolní propusti, následně hledáme pixely s nejnižší intenzitou, ty označíme. Nakonec jako foveu označíme střed největší označené oblasti.



Obr. 5.2 Schéma činnosti aplikace.

## 5.3 Hledání bodů větvení

Body větvení jsou body, ve kterých se větví cévy v choroidu. Toto samo nastiňuje postup při jejich hledání, a sice fakt, že jako první je třeba zmíněné cévy v obrázku detekovat a teprve následně na nich hledat body, ve kterých se větví.

Tématem detekce krevního řečiště ve snímku sítnice se zabývá několik prací. V podstatě se vyskytují dva hlavní přístupy k tématu. První, je výpočetně méně náročný a je založen na morfologii. Například v [9] je použita operace top-hat. Ta je zde definována pomocí rovnice 5.5.

$$h_1 = \phi^{(s_1 B)}(g) - g \quad (5.5)$$

kde  $g$  zelený kanál vstupního obrazu,  $\phi^{(s_1 B)}$  značí morfologickou operaci *close* aplikovanou pomocí čtvercového strukturního elementu  $s_1 B$ , jehož délka hrany je větší, než maximální šířka detekované cévy.

Druhý možný postup je založen na aplikaci 2D filtru. Pro lidské oko jsou výsledky obou postupů srovnatelné, ale pro další zpracování poskytuje druhý postup lepší výsledky, proto jsem se ho rozhodl implementovat. Přesný postup uvádím dále. Celý postup bude aplikován na zelený kanál vstupního obrazu, stejně jako při lokalizaci slepé a žluté skvrny.

### 5.3.1 Automatická úprava kontrastu

Cévy ve snímku sítnice mají poměrně malý kontrast (opět záleží na kvalitě vstupního snímku) a to i přes to, že pracujeme pouze se zeleným kanálem obrazu, ve kterém jsou cévy nejvíce kontrastní. Běžně používané metody, jako je (adaptabilní) roztažení histogramu nejsou v případě sítnice příliš efektivní. Na druhou stranu ruční úprava histogramu je sice velmi efektivní, ale v našem případě nepoužitelná, protože automatické provedení operace je podmínkou nutnou. Poměrně dobré výsledky má metoda *Fast Gray level grouping* (volně přeloženo jako *rychlé seskupování úrovní šedi*) [9].

Tato metoda je detailně popsána ve [14] a [15], včetně implementačních detailů, proto jen krátce nastíním postup. Algoritmus pracuje s takzvanými koši – intervaly úrovní šedi, které jsou definovány svou dolní a horní hranicí a počtem příslušících pixelů. Při inicializaci se vytvoří právě tolik košů, kolik je nenulových složek histogramu, všechny koše mají délku intervalu rovnu 1 a jejich velikost odpovídá složkám histogramu.

Následně probíhá iterativní výpočet, kdy je v každém kroku snížen počet košů o 1, výpočet probíhá, dokud se počet košů nerovná požadovanému počtu. V průběhu jednoho kroku je vždy vyhledán koš, s nejmenším počtem příslušných pixelů a ten je sloučen s menším ze sousedních košů. Výstupem je pak mapovací funkce, která určuje každému pixelu vstupního obrázku novou hodnotu. Hlavní výhodou této metody je, že histogram výsledného obrázku se více blíží rovnoměrnému rozložení pravděpodobnosti.

### 5.3.2 Matched filter

Metoda je založená na výsledné odezvě vstupního obrazu na dvourozměrný filtr. Tato odezva vzniká diskrétní dvourozměrnou konvolucí filtru se vstupním obrazem. Filtr je generován na základě vzorce 5.6.

$$K(x, y) = -e^{\left(\frac{x^2}{2\sigma^2}\right)}, \text{ pro } y \leq \left\lfloor \frac{L}{2} \right\rfloor \quad (5.6)$$

kde  $L$  je minimální délka, po kterou céva nemění směr a  $\sigma$  značí směrodatnou odchylku. Přesný postup získání filtru je převzat z [16]. Jeden takto vygenerovaný filtr pak několikrát otočíme, vždy o  $15^\circ$ , čímž získáme sadu celkem dvanácti filtrů. Tyto postupně aplikujeme na vstupní obrázek, čímž dostaneme 12 odezev a ty pak váhově sečteme, čímž dostaneme výslednou odezvu. Posledním krokem je čištění pozadí, které se ve výsledném obraze projeví jako velmi zašuměné. Toto je způsobeno tím, že pozadí vstupního obrazu je černé a tudíž má na daný filtr vysokou odezvu. Nabízí se dvě řešení – upravit pozadí vstupu nebo si ho uložit a následně aplikovat na výstup. Volil jsem druhou možnost.

### 5.3.3 Prahování

Výsledná odezva z předchozího kroku poměrně dobře zobrazí detekované cévy, nicméně stále se jedná o obraz ve stupních šedi, což není výhodné pro další zpracování. Je tedy nutné převést obraz do binární podoby. Toto provedeme pomocí jednoduchého prahování.

Zvolená hodnota prahu velmi ovlivní kvalitu výstupu a liší se pro každý vstup (vstupní snímky sítnic se velmi odlišují světlostí). Hodnota prahu musí být proto spočítána pro každý snímek zvlášť. Výsledky ukazují, že detekované cévy zaujímají přibližně 3% - 10% vstupního obrazu (v závislosti na kameře, kterou byl snímek pořízen). Při volbě prahu proto vycházím právě z tohoto faktu.

Další možností, kterou jsem vzal v úvahu, je použití adaptabilního prahování. Tento postup však vykazoval chybovost, neboť se ve výsledku objevily fragmenty cév, které ve skutečnosti neexistují a které adaptabilní prahování neodfiltrovalo. Jelikož snímky nasnímané jedním zařízením mají velmi podobné obrazové vlastnosti, ukázalo se přesněji parametrizovat tuto operaci zvlášť pro každou sadu snímků.

Na získaný binární obraz následně aplikujeme morfologickou operaci *close*, která odstraní drobné černé segmenty (díry), čímž zvýšíme spojitost cév a odstraníme chyby, kdy je místo jedné silnější cévy detekováno několik tenčích.

### 5.3.4 Ztenčení cév

Pro detekci bodů větvení je nutné ztenčit (anlg. *thinning*) separované cévní řečiště na šířku pouze jednoho pixelu. Takto ztenčené cévy by se měly nacházet vprostřed původní cévy. Jednoduchý algoritmus je převzat z [12] a v principu funguje následovně. Pokud byla provedena v předchozím průchodu nějaká změna v obraze, provede další průchod, ve kterém vždy označí jako pixely k odstranění takové pixely, které jsou bílé, mají více než jeden sousední pixel (tzn., že nejsou koncovým pixelem) a ani nejsou jediným spojením dvou oblastí. Je nutné rovnoměrně střídát směry ořezávání obrazu, protože kdybychom prováděli ořezávání pouze v jednom směru, došlo by k deformaci cév a výsledná tenká céva by se nenacházela vprostřed té původní.

### 5.3.5 Body větvení

Posledním krokem je samotná detekce bodů větvení. V obraze upraveném podle výše uvedeného postupu se nachází pouze cévy ztenčené na šířku 1 pixelu (uvažujeme 8 okolí bodu), takže v něm můžeme dané body pohodlně detekovat. Jako bod větvení označíme takový bod, ze kterého vychází tři cévy. Toto lze jednoduše detekovat jako počet přechodů  $0 \rightarrow 1$  a  $1 \rightarrow 0$  v osmi-okolí bodu.

Jediný problém působí malé fragmenty, které vznikly jako nechtěný produkt při ztenčování obrazu. Těchto fragmentů je velké množství, jedná se v podstatě o krátké čáry. Díky tomuto je detekováno poměrně velké množství falešných bodů větvení. Tomuto můžeme předejít, stanovíme-li

minimální délku, které musí dosahovat každá céva, vycházející z potenciálního bodu větvení. Pokud tuto vlastnost kterákoli z cév nesplňuje, nejedná se o bod větvení.

Uložení a archivace bodů větvení je již na straně případného zamýšleného biometrického systému. Aplikace body vypíše jako uspořádanou dvojici, viz rovnice 5.1. Schéma činnosti aplikace lze vidět na obrázku 5.2.

## 6 Implementace

Aplikace byla implementována v programovacím jazyce C++ s využitím knihovny OpenCV (Open Source Computer Vision) [17], což je knihovna pro počítačové vidění v reálném čase a pro zpracování obrazu. Běží na platformách Windows, Linux, Mac a Android. Je implementována v jazycích C, C++, Python a Java (pouze pro platformu Android). V současné době má více než 3,5 milionu stažení a přibližně 46 000 členů uživatelské skupiny. Obsahuje více než 2500 optimalizovaných algoritmů. Knihovna je dostupná pod licencí BSD<sup>3</sup> a je volná pro akademické i komerční použití [17].

Aktuálně je publikována verze 2.3 knihovny, ve které je aplikace implementována. Knihovna velmi zjednodušila práci se vstupními snímky, obsahuje funkce pro načítání, ukládání obrázků, morfologické operace, Hughovu transformaci, prahování, rozhraní pro přístup k jednotlivým bodům obrazu a mnoho dalších, které jsem využil. Některé funkce však v knihovně chybí a musel jsem je implementovat sám. Sem patří například ztenčení a automatická úprava kontrastu. Zdroje k jejich implementaci jsou popsány v kapitole 5.

Výsledný program je konzolová aplikace bez grafického rozhraní, která načte vstupní snímek zadaný jako parametr a na standardní výstup vypíše souřadnice bodů větvení jako uspořádanou dvojici, viz rovnice 5.1. Aplikace byla vyvíjena v prostředí virtuálního stroje s operačním systémem Ubuntu verze 10.04.

### 6.1 Cílová platforma

Jak vyplývá ze zadání práce, cílovou platformou pro běh aplikace je prostředí s digitálním signálovým procesorem (dále jen DSP). Pro tento účel byl zvolen vývojový kit TMS320DM6467 vyrobený firmou Texas Instruments. Tento byl zvolen s ohledem na paměťovou náročnost aplikace a dále s ohledem na jeho dostupnost v laboratoři výzkumné skupiny STRaDe<sup>4</sup>. V přípravku běží operační systém MontaVista Linux LSP, který umožní použití knihovny OpenCV.

#### Technická specifikace TMS320DM6467 (výběr):


- Texas Instruments TMS320DM6467 Multi-CPU processor (ARM926EJ-S and C64x+),
- 256 Mbytes of DDR2 DRAM,
- 128 Mbytes of NAND Flash Memory, I2C EEPROM, SPI EEPROM,
- RS-232 UART,

---

<sup>3</sup> <http://opensource.org/licenses/bsd-license.php>

<sup>4</sup> *Security Technology Research and Development*, výzkumná skupina na Fakultě informačních technologií Vysokého učení technického v Brně.

- USB 2.0 Host connector,
- 10/100/1000 Ethernet interface,
- Configurable boot load options,
- ATA Hard Disk Interface,
- Single voltage power supply (+5 V),
- External JTAG emulation interface.



Obr. 6.1: Vývojový kit TMS320DM6467.

## 6.2 Struktura aplikace

Vzhledem k tomu, že se jedná o testovací aplikaci, která díky využití knihovny OpenCV dosahuje poměrně malého rozsahu (1500 řádků kódu), není aplikace dělena na moduly. Celý program je tedy v jednom souboru. Všechny proměnné, konstanty a názvy funkcí jsou pojmenovány anglicky. Rovněž tak komentáře hlaviček funkcí, jednotlivých kroků algoritmu a výstupy programu.

Po deklaraci použitých knihoven následuje sled deklarací konstant, které jsou určeny pro snadnou parametrizaci programu (při využití jiné databáze, tedy snímků jiných rozměrů). Jsou přichystány a otestovány 2 sady deklarací a sice pro databáze DRIVE (možno aplikovat i na snímky databáze STARE) a Gold Standard Database (doplněno o parametry pro snímky STRaDe).

Následuje `main()` funkce programu. V této se postupně volají další funkce. Nejprve se program snaží najít střed slepé skvrny. Pokud se to nepodaří, končí chybovým hlášením. V opačném případě je volána funkce pro hledání fovei. Jelikož je hledání bodů větvení časově nejnáročnější částí běhu programu, probíhá až jako poslední, a to pouze v případě, že určení souřadného systému bylo provedeno úspěšně. Výstupem funkce pro hledání bodů větvení je kolekce souřadnic v obraze. Ty je

třeba přepočítat, aby výsledné body byly určeny polohou v závislosti na výše definovaném souřadném systému. Následně jsou tyto body vypsané na standardní výstup.

Lokalizace středu slepé skvrny probíhá primárně ve funkcích `FindOpticDiscCenter` a `GetCircleCenter`. První z nich se zabývá zpracováním celého vstupního obrazu. Nejdříve na obraz aplikuje filtr dolní propusti o velikosti definované konstantou `ODDIAMETER`. Následně z histogramu zjistí jakou maximální intenzitu mají pixely v rozmazaném snímku a označí je bílou barvou. Zbylé jsou označeny černě. Takto označené oblasti bílých pixelů uloží do kolekce `areas` a vybere z nich tu největší. Její střed je pak předán jako vstupní parametr funkci `GetCircleCenter`, kde hraje úlohu středu oblasti zájmu. Její velikost je určena konstantou `ROISIZE`. Funkce `GetCircleCenter` tedy jako první ze vstupního obrazu vybere oblast zájmu a s tou dále pracuje. Pomocí morfologické dilatace (velikost strukturního elementu určena konstantou `ODELEMENTSIZE`) a dolní propusti odstraní z obrazu cévy. Následně aplikuje Sobelův detektor hran a pomocí prahování převede obraz do binární formy. Hodnota prahu je určena hodnotou konstanty `ODTHRESH`. Morfologická eroze sníží šum a morfologická operace `close` zvýší spojitost hledaného kruhu. Posledním krokem je hledání kruhu pomocí Houghovi transformace. Velikost hledaného kruhu je omezena konstantami `ODDIAMETERMIN` a `ODDIAMETERMAX`. Získané souřadnice středu je ještě třeba upravit, aby určily střed v rámci celého snímku, nejen v rámci použité oblasti zájmu.

Lokalizace fovei probíhá ve funkci `FindFovea` na velmi podobném principu jako první část lokalizace slepé skvrny. Prvním krokem je výběr výseče, ve které se nachází žlutá skvrna. Ta je určena pozicí a poloměrem slepé skvrny. Její přesné vymezení je následující: patří do ní všechny body vstupního snímku, jejichž vzdálenost od středu slepé skvrny je v intervalu  $1 \times$  průměr slepé skvrny do průměru slepé skvrny  $\times$  hodnota konstanty `MACULAMAXDIST`, a zároveň spadají do vymezeného úhlu k horizontální linii. Interval úhlu je jako  $170 \pm \text{MACULANGLE}$  stupňů v případě pravého oka a  $350 \pm \text{MACULANGLE}$  stupňů v případě snímku levého oka. Ostatní pixely jsou označeny bílou barvou. Na výseč je pak aplikován filtr dolní propusti, jehož velikost přibližně odpovídá velikosti žluté skvrny, uložené v konstantě `MACULAELEMENTSIZE`. Nejtmavší pixely snímku (určeno z histogramu) jsou následně označeny bíle, ostatní černě. Střed největší bílé oblasti je pak označen za foveu.

Časově nejnáročnější částí programu je segmentace cévního řečiště. O tu se v kódu stará funkce `BloodVesselDetection`. První operací je automatické zlepšení kontrastu, které se provede volitelně v závislosti na histogramu vstupního kanálu. Následuje aplikace dvanácti 2D filtrů, ve funkci `MatchFiltering`. V té se prvně zavolá funkce `GetFilters`, která vytvoří jeden vzorový filtr, ten je následně 12krát otočen o  $15^\circ$ . Ty jsou vráceny v poli filtrů a následně aplikovány na vstupní obraz. Odezvy těchto filtrů se váhově sčítají. Na výsledný snímek je pak aplikováno prahování. Hodnota prahu se počítá z histogramu, který je procházen od nejvyšší intenzity k nižší a sčítá se počet pixelů jednotlivých intenzit. Jakmile tento počet přesáhne procento dané konstantou

BVPERCENTAGE aktuální hodnota intenzity je prohlášena za práh. Na získaný binární obraz je aplikováno ztenčení, v programu funkce `Thinning`. Ta iterativně prochází obraz ze 4 směrů. Tím je zajištěna pozice ztenčené cévy vprostřed jejího původního obrazu. Jakmile jsou cévy ztenčené na šířku jednoho pixelu, je volána funkce `GetBifurcationPoints`, která projde osmi-okolí všech bílých bodů obrazu a spočítá, kolik cév z něj vychází. V případě, že tři a všechny jsou dostatečně dlouhé (ověří funkce `CheckMismatch` na základě konstanty `MINLINELENGTH`), je bod zařazen do seznamu `bifurcationPoints`. Za zmínku stojí funkce `IsLongEnough`, která je volána na každou ze tří cév. Tato funkce se vyznačuje omezenou rekurzí.

Takto získaný seznam bodů větvení je vrácen do funkce `main`. Jelikož je jejich poloha určena pozicí pixelu ve snímku, je nutné převést ji do polárního souřadného systému. Pro uložení polohy bodu pak slouží struktura `bifurcationPoint`, která obsahuje dvě položky datového typu `float`. Jedna určuje vzdálenost od středu slepé skvrny a druhá úhel svíraný s kladnou poloosou  $x$ . Tyto body jsou pak vypsány na standartní výstup.


## 6.3 Ukázka výstupu aplikace

Program vypisuje na standartní výstup nalezené body větvení jako uspořádanou dvojici: úhel, vzdálenost. Tento formát je vhodný k dalšímu zpracování, například aplikací `Gnuplot`<sup>5</sup>. Ukázka výstupu aplikace je níže. Obrázek 6.2 ukazuje výstup aplikace po zpracování pomocí aplikace `Gnuplot` a obrázek 6.3 ukazuje zvýrazněné hledané anatomické struktury ve vstupním snímku.


```
# angle      distance
101.18      1.28028
39.2025     2.48212
43.7628     2.04498
111.953     1.16148
112.297     1.13379
100.872     1.09919
34.7682     2.41061
42.3407     1.77278
44.4422     1.65975
40.7295     1.81892
...
```

---

<sup>5</sup> Terminálová aplikace pro tvorbu grafů licencovaná GNU licencí. Dostupná z <http://www.gnuplot.info>.



Obr. 6.2: Výstup aplikace po zpracování programem Gnuplot. Zeleně je vyznačena fovea, červeně pak body větvení. Střed slepé skvrny je počátkem souřadnic.



Obr. 6.3: Nalezené anatomické struktury zaznačené ve vstupním snímku. Modrou barvou je zaznačena slepá skvrna a její střed. Červenou barvou je značena fovea a zeleně jsou pak označeny body větvení.

## 7 Testování

Pro účely testování byly zvoleny dvě databáze snímků sítnice. První z nich je *Gold Standard Database for Evaluation of Fundus Image Segmentation Algorithms*<sup>6</sup>, která poskytuje velmi kvalitní snímky sítnic jak zdravých očí - 15 snímků, tak očí postižených glaukomem (lidově zelený zákal) - 18 snímků a diabetickou retinopatií (dále jen DR) - 15 snímků. Další její výhodou je dostupnost snímků obsahujících odborníky manuálně segmentované cévní řečiště, které byly použity jako vzor pro porovnání účinnosti segmentace cévního řečiště.

Druhou databází, která byla použita, jsou snímky nasnímané fundus kamerou v laboratoři výzkumné skupiny STRaDe. Tyto se vyznačují nižší kvalitou obrazu, nižším kontrastem mezi pozadím a cévami, vyšším počtem odlesků a celkově jsou snímky tmavší, než snímky první databáze.

Další využití snímků pochází z databází STARE<sup>7</sup> a DRIVE<sup>8</sup>. Snímky obou databází se vyznačují velmi malým rozlišením a nejsou proto příliš vhodné, neboť aplikace byla laděna na snímky s vyšším rozlišením.


### 7.1 Segmentace cévního řečiště

Pro testování přesnosti segmentace cévního řečiště byla zvolena metoda jednoduchého porovnání snímku získaného aplikací před ztenčením cév s manuálně segmentovaným řečištěm. Výstupem porovnání je procento shodných bodů obou obrazů. Výpočet ukazuje vzorec 7.1.

$$S = \frac{P_s}{P_s + P_d} \quad (7.1)$$

kde  $P_s$  značí počet shodných pixelů a  $P_d$  značí počet pixelů, ve kterých hodnota obou obrazů liší.

V úvahu se berou pouze body sítnice ve snímku, nikoli černý okraj, to je možné vidět na obrázku 7.1.



Obr. 7.1 Porovnání segmentace cévního řečiště zdravého oka. (A) manuálně segmentované cévní řečiště, (B) výstup aplikace před ztenčením, (C) použitá maska.

<sup>6</sup> Dostupná z <http://www5.informatik.uni-erlangen.de/research/data/fundus-images>

<sup>7</sup> Dostupná z <http://www.parl.clemson.edu/stare/>

<sup>8</sup> Dostupná z <http://www.isi.uu.nl/Research/Databases/DRIVE/>

## 7.1.1 Výsledky

Souhrnné výsledky ukazuje tabulka 7.1. Jde vidět, že automatická segmentace se v průměru shoduje s manuální segmentací cévního řečiště takřka v devadesáti pěti procentech bodů snímku sítnice. Nejlépe se shodují snímky zdravých očí, nejhůře pak snímky očí postižených DR. Směrodatná odchylka naměřených výsledků se pohybovala v rozmezí 1-2%, což ukazuje poměrně vysokou spolehlivost algoritmu.

Tabulka 7.1 Výsledky porovnání automatické a manuální segmentace cévního řečiště.

	Zdravé	Glaukom	Diabetická retinopatie	<b>Celkem</b>
Průměrná shoda	95,78%	95,00%	94,12%	<b>94,97%</b>
Směrodatná odchylka	1,01%	0,98%	1,77%	<b>1,24%</b>

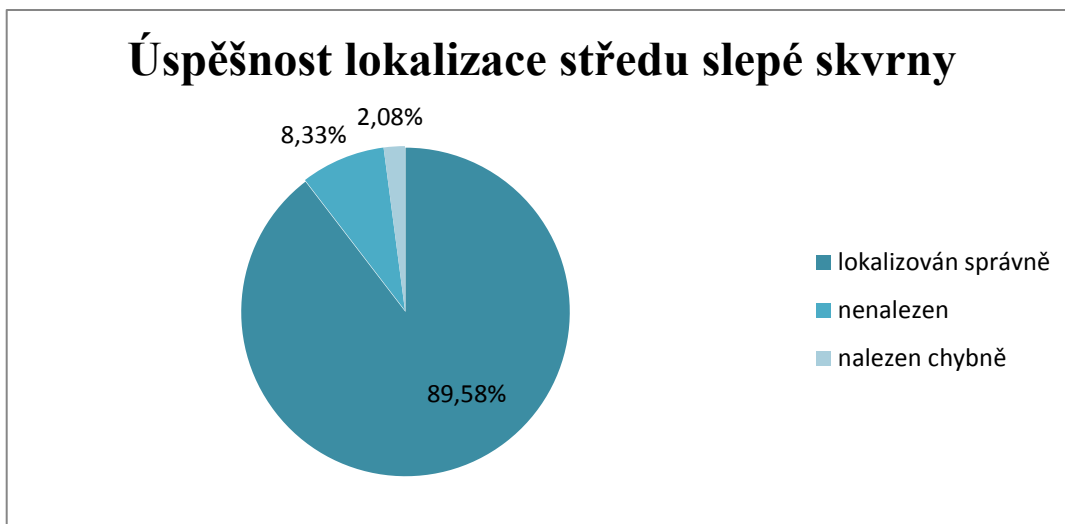
## 7.2 Určení biometrického vzoru

Testování určení biometrického vzoru se nedá provádět strojově, neboť není dostupná verifikační šablona, vůči které bychom získané výsledky mohli porovnat. Veškeré testování tedy muselo být provedeno ručně, a sice kontrolou každého snímku uživatelem. Kontrolována byla tato fakta: rozpoznání slepé skvrny, fovei a kontrola lokace rozpoznaných bodů větvení. Testováno bylo, stejně jako při segmentaci cévního řečiště, celkem 48 snímků, z toho 15 snímků zdravého oka, 18 oka postiženého glaukomem a 15 snímků oka postiženého DR.

### 7.2.1 Lokalizace slepé skvrny

Za správné rozpoznání středu slepé skvrny byla považována situace, kdy se detekovaný střed nacházel uvnitř slepé skvrny. U většiny snímků (43 snímků, tj. 89,58%) byl střed slepé skvrny algoritmem rozpoznán správně.

Ve 4 případech (8,33%) algoritmus nedokázal ze vstupního snímku určit střed slepé skvrny a skončil chybou. Toto chování je považováno za korektní. V jednom případě pak algoritmus detekoval střed slepé skvrny chybně (střed se nenacházel v oblasti slepé skvrny a algoritmus neskončil chybou). Toto chování je považováno za nekorektní a odpovídá cca 2,08% snímků. Všechny tyto případy (algoritmus nedetekoval střed slepé skvrny nebo jej detekoval chybně) nastaly pouze u snímků očí postižených DR, což ukazuje na nízkou odolnost aplikace proti této oční chorobě. Výsledky je možné vidět na obrázku 7.2.



Obr. 7.2 Graf úspěšnosti lokalizace středu slepé skvrny.

## 7.2.2 Lokalizace fovei

Jak bylo popsáno v kapitole zabývající se návrhem algoritmu, pro lokalizaci fovei je nutné správně určit střed slepé skvrny. Nebudeme tedy brát v potaz případy, kdy byla fovea chybně lokalizována díky špatné lokalizaci středu slepé skvrny (což je cca 10,42% případů, viz předchozí odstavec). Za chybu postupu hledání fovei tedy považujeme situaci, kdy byl detekován střed slepé skvrny správně, ale fovea špatně. Takový případ nastal u dvou snímků, což odpovídá přibližně 4,65%.

## 7.2.3 Přesnost určení bodů větvení


Testování přesnosti určení bodů větvení probíhala pouze vizuální kontrolou, neboť díky vysokému počtu těchto bodů není možné označit všechny chybně detekované. Průměrný počet bodů, které algoritmus detekoval, je 256 bodů větvení na jeden snímek. Toto číslo bylo nejnižší u snímků zdravého oka, nejvyšší u snímků postižených DR. Průměrné počty nalezených bodů větvení ukazuje tabulka 7.2.

Tabulka 7.2 Počty nalezených bodů větvení.

	Zdravé oko	Glaukom	Diabetická retinopatie	<b>Celkem</b>
Průměrná shoda	242	249	277	<b>256</b>
Směrodatná odchylka	50	87	59	<b>67</b>

Vysoký počet bodů větvení detekovaných na snímcích očí postižených DR je způsoben vlivem nemoci na sítnici. Ta se projevuje poškozením krevních cév v choroidu. Na snímcích sítnice se toto ukazuje jako světlé nebo tmavé skvrny. Tyto jsou následně aplikací mylně označeny jako cévy a je na nich detekováno velké množství bodů větvení. Oba tyto případy ukazuje obrázek 7.3, na kterém lze vidět jak světlé (A), tak tmavé (B) skvrny.

U Snímků očí postižených glaukomem, se většinou žádné chyby neprojeví. Pouze ve dvou případech byl počet nalezených bodů výrazně nižší (bylo detekováno asi 30 bodů), což bylo patrně způsobeno rozdílným odstínem snímků, vyžadujícím úpravu nastavení prahování. Obecně však lze předpokládat, že algoritmus bude mít problémy dosahovat vyšší přesnosti u snímků nemocných očí.



Obr. 7.3 Ukázka výřezu ze snímků sítnic poškozených DR. Vlevo vstupní snímek, vpravo jsou zelenou barvou označeny detekované body větvení.

### 7.3 Výsledky tetování na dalších databázích

Aplikace byla testována i na snímcích pořízených fundus kamerou v laboratoři výzkumné skupiny STRaDe. Jak bylo zmíněno výše, tyto snímky se vyznačují rapidně nižší kvalitou, než snímky z *Gold Standard Database*. Je zde nižší kontrast mezi cévami a pozadím, proto je náročnější segmentovat cévní řečiště. Obzvláště při okrajích jsou snímky velmi tmavé, cévy jsou zde takřka neviditelné. Určité zlepšení přináší automatická úprava kontrastu, ani ta však není všemocná. Navíc k těmto snímkům neexistují manuálně segmentovaná řečiště. Velkým problémem jsou rovněž odlesky, které se objevují na snímcích. Tyto jsou výrazně světlejších odstínů, než zbytek fotografie. Díky tomu jsou algoritmem často označeny jako slepá skvrna. Její chybná detekce pak vede ke špatné lokalizaci

fovei. Tu samotnou mnohdy není lehké detekovat, neboť na některých snímcích zabírá velkou část rozsáhlá tmavá skvrna. I když je fovea lokalizována, není možné ověřit správnost výsledku, neboť ani okem nelze polohu fovei určit. Proto byl učiněn výběr 148 nejkvalitnějších snímků, na kterých jsou slepá skvrna i fovea okem jasně rozpoznatelné a ty pak byly použity k testování úspěšnosti jejich nalezení.

Poslední dvě databáze, STARE a DRIVE, byly použity obzvláště proto, že vystupují jako jakési referenční databáze, na kterých je testována většina aplikací. Databáze obsahují snímky s velmi malým rozlišením (0,3 MPix v případě DRIVE a 0,4 MPix v případě STARE), na které algoritmus nebyl optimalizován. Výsledky testování, obzvláště u databáze DRIVE předčily očekávání, výsledky databáze STARE odpovídají očekávání. Výsledky lze vidět v tabulkách 7.3 a 7.4.

*Tabulka 7.3 Výsledky porovnání automatické a manuální segmentace cévního řečiště.*

	<b>DRIVE</b>	<b>STARE</b>
Průměrná hodnota	92,90%	79,62%
Směrodatná odchylka	2,27%	7,03%

*Tabulka 7.4 Výsledky rozpoznání slepé skvrny.*

	<i>Úspěšně lokalizován</i>	<i>Nebyl rozpoznán</i>	<i>Špatně rozpoznán</i>
<b>Gold</b>	89,58%	8,33%	2,08%
<b>STRaDe</b>	70,95%	28,38%	0,68%
<b>DRIVE</b>	85%	5%	10%
<b>STARE</b>	64,26%	21,43%	14,29%

Při tetování lokalizace fovei jsem uvažoval pouze ty případy, kdy byla správně rozpoznána slepá skvrna. Jak vyplívá z výše uvedeného postupu, je to nutná výchozí podmínka. Výsledky je možné vidět v tabulce 7.5.

*Tabulka 7.5 Výsledky lokalizace fovei.*

	<i>Správně lokalizována</i>	<i>Špatně lokalizována</i>
<b>Gold</b>	95,35%	4,65%
<b>STRaDe</b>	90,48%	9,52%
<b>DRIVE</b>	70,59%	29,41%
<b>STARE</b>	55,56%	44,44%

## 7.4 Shrnutí

Obecně lze říci, že algoritmus má značné problémy s nekvalitními snímky na vstupu. Velké problémy činní jak odlesky, které jsou často m díky své vysoké světlosti mylně označeny jako slepá skvrna, tak i tmavé skvrny, které se často vyskytují při okrajích snímků. Tyto způsobují problémy při

hledání bodů větvení, díky svému tmavému odstínu mají kladnou odezvu na použitý filtr a jsou pak mylně označeny za cévy. V případě nasazení algoritmu v biometrickém systému je tedy třeba klást důraz na kvalitu snímání obrazu sítnice, případně algoritmus lépe optimalizovat na jeden konkrétní zdroj snímků, který bude vykazovat pouze vady předem známého typu.

Dále se ukázala poměrně malá odolnost algoritmu vůči snímkům nemocných očí, obzvláště vůči snímkům očí postižených diabetickou retinopatií. Zde se vyskytují dva druhy problémů. Prvním je fakt, že tmavé i světlé skvrny, kterým se toto onemocnění vyznačuje, jsou mylně interpretovány jako cévy. Druhý problém pak způsobují světlé skvrny, které v případech, kdy mají vhodnou velikost a jsou vhodně umístěny, mohou být aplikací chybně označeny za slepou skvrnu.

## 8 Závěr

V práci jsem se pokusil uvést velmi stručný úvod do biometrie a sní pojených pojmů, zpracování signálů a obrazu, byla zmíněna základní fakta z anatomie oka. V kapitole zabývající se návrhem aplikace jsem vždy uvedl stručný přehled nabízejících se řešení pro daný problém a zdůvodnil, jaké důvody mě vedly k volbě daného postupu. Aplikace byla testována na dvou sadách snímků.

Konkrétní implementace byla přizpůsobena sadě testovacích snímků, což spočívalo ve vhodném nastavení parametrů. Možné pokračování v této práci se nabízí v její úpravě pro nasazení v konkrétním biometrickém zařízení, případně rozšíření aplikace do podoby biometrického systému, který se zabýval i uchováním biometrických šablon a jejich porovnáním. Takové nasazení by si ovšem vyžádalo rozsáhlejší testování, získání ROC křivky, FAR a FRR statistik. Na Fakultě informačních technologií Vysokého učení technického v Brně se konstrukcí podobného zařízení zabývají členové výzkumné skupiny STRaDe. Výsledky této práce mohou být při jeho konstrukci nápomocny.

Jak ukázalo testování, aplikace velmi dobře pracuje s kvalitními snímky ve vysokém rozlišení, pro které byla navržena. Určité problémy aplikaci činní méně kvalitní snímky obsahující odlesky, často označené jako slepá skvrna, případně tmavé skvrny, často se vyskytující po krajích fotek. Ty bývají mylně interpretovány jako cévy. Další problémy odhalené při tetování, se objevily u snímků očí postižených diabetickou retinopatií. Skvrny, kterými se onemocnění projevuje, byly často mylně klasifikovány jako slepá skvrna (v případě světlých skvrn) nebo jako cévy, v případě světlých i tmavých skvrn.

Proto se nabízí pokračování práce optimalizací, zaměřenou na vyšší přesnost zpracování snímků postižených diabetickou retinopatií. Podle [3] tato nemoc v současnosti postihuje 40 – 50% diabetiků. Jejich počet přitom, podle údajů Diabetické asociace ČR, každoročně roste. Lze tedy předpokládat, že v případě praktického nasazení biometrického systému zabývajícího se identifikací pomocí sítnice budou postižení diabetickou retinopatií činit nezanedbatelnou část uživatelů.

# Literatura

- [1] DRAHANSKÝ, Martin a Filip ORSÁG. *Biometrie*. 1. vyd. [Brno: M. Dražanský], 2011, 294 s. ISBN 978-80-254-8979-6.
- [2] DAS, Ravi. Retina recognition: Biometric technology in practice. *Keesing journal of documents: a bimonthly magazine about developments in the security industry*. 2011, č. 22, s. 11-14. ISSN 1871-272x. Dostupné z: [http://www.biometricnews.net/Publications/Biometrics\\_Article\\_Retinal\\_Recognition.pdf](http://www.biometricnews.net/Publications/Biometrics_Article_Retinal_Recognition.pdf)
- [3] FLORYČEK, Jan. *Experimenty se snímky sítnice oka*. Brno, 2010. Bakalářská práce. Vysoké učení technické v Brně.
- [4] RAK, Roman. *Biometrie a identita člověka ve forezních a komerčních aplikacích*. 1. vyd. Praha: Grada, 2008, 631 s. ISBN 978-80-247-2365-5..
- [5] BHAWANI, Chowdhary a Latif SHIRAZ. Pattern Matching Algorithm using Polar Spectrum in Retina Recognition for Human Identification System. *Australian journal of basic and applied sciences / International network for scientific information ; INSInet*. 2011, č. 5, s. 1385-1392. ISSN 1991-8178. Dostupné z: <http://www.insipub.com/ajbas/2011/October-2011/1385-1392.pdf>
- [6] ČIHÁK, Radomír. *Anatomie 3. 2., upr. a dopl. vyd.* Praha: Grada, 2004, 673 s. ISBN 80-247-1132-X.
- [7] *Biometric systems: technology, design and performance*. Editor James Wayman. London: Springer-Verlag, 2005, 370 s. ISBN 18-523-3596-3.
- [8] AQUINO, Arturo, Manuel EMILIO GEGÚNDEZ a Diego MARÍN. Automated Optic Disc Detection in Retinal Images of Patients with Diabetic Retinopathy and Risk of Macular Edema. . *World Academy of Science, Engineering and Technology*. 2009, č. 60, s. 87-92. Dostupné z: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.193.2849&rep=rep1&type=pdf>
- [9] SARADHI, S. BALASUBRAMANIAN a V. CHANDRASEKARAN. Performance Enhancement of Optic Disc Boundary Detection using Active Contours via Improved Homogenization of Optic Disc Region. *Information and Automation*. 2006, 15-17, s. -. DOI: 10.1109/ICINFA.2006.374126. Dostupné z: [http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=4250216&tag=1](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4250216&tag=1)
- [10] SIDDALINGASWAMY, P. C. a G. K. PRABHU. Automated Detection of Anatomical Structures in Retinal Images. *International Conference on Computational Intelligence and Multimedia Applications*. Los Alamitos, CA: IEEE Computer Society, 2007, č. 10. ISSN 0-7695-3050-8. Dostupné z: [http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=4426361](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4426361)
- [11] PARKER, J. *Algorithms for image processing and computer vision*. New York: Wiley Computer Publishing, 1997, 417 s. ISBN 04-711-4056-2.
- [12] PARKER, J. *Algorithms for image processing and computer vision*. New York: Wiley Computer Publishing, 1997, s. 181-193. ISBN 0122060938.
- [13] Wikipedie, otevřená encyklopedie. Licence public domain [cit. 2012-05-05]. Dostupné z [http://commons.wikimedia.org/wiki/File:Schematic\\_diagram\\_of\\_the\\_human\\_eye\\_cs.svg](http://commons.wikimedia.org/wiki/File:Schematic_diagram_of_the_human_eye_cs.svg)
- [14] CHEN, ZhiYu, Besma R. ABIDI, David L. PAGE a Mongi A. ABIDI. Gray-Level Grouping (GLG): An Automatic Method for Optimized Image Contrast Enhancement—Part I: The Basic Method. *IEEE transactions on image processing: a publication of the IEEE Signal Processing Society*. 2006, č. 8, s. 2290-2302. ISSN 1057-7149. Dostupné z: [http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=1658093&tag=1](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1658093&tag=1)

- [15] CHEN, ZhiYu, Besma R. ABIDI, David L. PAGE a Mongi A. ABIDI. Gray-Level Grouping (GLG): An Automatic Method for Optimized Image Contrast Enhancement— Part II: The Variations. *IEEE transactions on image processing: a publication of the IEEE Signal Processing Society*. 2006, č. 8. ISSN 1057-7149. Dostupné z: <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=01658094>
- [16] CHAUDHURI, Subhasi. Detection of blood vessels in retinal images using two-dimensional matched filters. *IEEE transactions on medical imaging*. 1989, č. 3, s. 263-269. ISSN 0278-0062. Dostupné z: [http://ieeexplore.ieee.org/xpl/freeabs\\_all.jsp?arnumber=34715](http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=34715)
- [17] *OpenCV Wiki* [online]. 2006, Last change 2012-03-16 [cit. 2012-05-05]. Dostupné z WWW: <http://opencv.willowgarage.com/wiki/Welcome>.

Seznam příloh

CD obsahující:

Zdrojové kódy aplikace

Binární soubor aplikace pro spuštění ve vývojovém kitu TMS320DM6467

Text této práce ve formátu Portable Document Format (PDF)