

Univerzita Hradec Králové
Fakulta informatiky a managementu

DIPLOMOVÁ PRÁCE

Univerzita Hradec Králové
Fakulta informatiky a managementu
Katedra Informačních technologií

**Bezkontaktní identifikační systém založený
na obrazové analýze zkoumaného prvku**

Diplomová práce

Autor: Lukáš Kolda

Studijní obor: Aplikovaná informatika

Vedoucí práce: **doc. Ing. Ondřej Krejcar, Ph.D.**

Prohlašuji, že jsem diplomovou práci zpracoval samostatně a s použitím uvedené literatury.

V Hradci Králové dne 7.7.2016

.....

Anotace

Tato diplomová práce se zabývá tvorbou biometrického systému pro identifikaci uživatelů pomocí biometrických charakteristik kontury ruky a krevního řečiště na hřbetu ruky. První část práce popisuje různé metody zpracování obrazu. V druhé části se práce zabývá návrhem a realizací hardwaru a softwaru pro experimentální biometrický systém. Softwarová část je napsána v jazyce C# s využitím knihovny OpenCV a wrapperu Emgu CV.

Annotation

Title:

Contactless identification system based on image analysis of the scanned element

This thesis deals with the creation of a biometric system to identify users using biometric characteristics of hand contour and bloodstream on the back of hand. The first part describes the various methods of image processing. The second part deals with the design and implementation of hardware and software for experimental biometric system. The software part is written in C # using the OpenCV library and wrapper Emgu CV.

Obsah

1.	Úvod	1
2.	Cíle práce	3
3.	Problematika zpracování obrazu	4
3.1	Vyjádření obrazu	4
3.2	Snímání a digitalizace obrazu	4
3.3	Vzorkování.....	5
3.4	Šum	5
3.5	Osvětlení scény	5
3.6	Filtry a transformace obrazu	8
3.7	Geometrické transformace	13
3.8	Morfologická filtrace	13
3.9	Segmentace obrazu	14
3.10	Normalizace ohodnocení.....	16
4.	Rešerše relevantní literatury a existujících řešení	18
4.1	Geometrie ruky	18
4.2	Krevní řečiště	20
5.	Definice problému a požadovaných parametrů systému	21
5.1	Biometrická autentizace a identifikace	21
5.2	Měření výkonu biometrických systémů.....	22
5.3	Zvýšení bezpečnosti biometrických systémů	23
6.	Návrh a realizace hardware pro snímání biometrických charakteristik	24
7.	Návrh a implementace softwarového řešení.....	28
7.1	Použité softwarové nástroje	28
7.2	Proces identifikace uživatele.....	29
7.3	Proces vytvoření šablony	30
7.4	Získání obrazu.....	31
7.5	Filtrování obrazu	32
7.6	Segmentace obrazu	37
7.7	Definice biometrických charakteristik.....	44
7.8	Extrakce biometrických charakteristik	47
7.9	Ohodnocení mírou shody	51
7.10	Popis tříd a datových struktur.....	56

8.	Testování navrženého systému	58
8.1	Metodologie testování.....	58
8.2	Testy rychlosti experimentálního systému.....	58
8.3	Testy spolehlivosti experimentálního systému	59
9.	Diskuze výsledků.....	63
9.1	Možnosti pokračování vývoje.....	64
10.	Závěr.....	65
	Seznam literatury.....	66
	Seznam obrázků.....	71
	Seznam grafů	73
	Seznam tabulek.....	74
	Použité zkratky	75

1. Úvod

Biometrie je vědní obor, který se zabývá jedinečnými prvky člověka a zkoumáním živých organismů. Slovo biometrie pochází z latinských slov Bios a Metron, kde Bios znamená život a slovo Metron měřit. Mezi zakladatele tohoto vědního oboru je považován Alphons Bertillon, který založil kriminalistickou metodu pro evidenci a identifikaci pachatelů založenou na antropometrii, měření lidského těla.

S rychlým pokrokem v oblasti informačních technologií se stalo reálné používat biometrii k verifikačním a identifikačním účelům. Propojením identity s určitým jedincem se nazývá osobní identifikace. Verifikace (autentizace) označuje problém potvrzení nebo zamítnutí osobní identifikace osoby, která se prokazuje danou identitou (Jsem opravdu ten, za koho se vydávám?). Identifikace označuje problém hledání identity pro neznámou osobu (Kdo jsem?). Používání biometrických identifikačních systémů začíná být v současném světě stále více rozšířené. Začínají se objevovat notebooky s čtečkami otisků prstů, Windows 10 mají funkci Hello, která podporuje přihlašování pomocí biometrie (otisk prstu, rozpoznání obličeje nebo snímání oční duhovky), do praxe se zavádí biometrické pasy, atd. Důvody pro zavádění biometrie v aplikacích, které požadují identifikaci uživatele, namísto současných karet, klíčů nebo přihlašovacích údajů jsou jasné: odpadá problém se ztrátou nebo zapomenutím, významně se snižuje riziko zkopírování nebo zfalšování.

Bohužel biometrie není dokonalé řešení. Analýza a někdy i samotné snímání biometrických vlastností je komplikovaný proces, výstup navíc není jednoznačný. Výsledkem je pouze pravděpodobnost úspěchu (ta se u nejlepších systémů pohybuje přes 99%). Díky pokusům o podvod je vhodné během snímání detekovat živost subjektu (nejčastější typy útoků jsou prováděny pomocí maket nebo modelů dané části těla).

Mezi různými biometrickými charakteristikami, které lze u člověka rozeznávat, je rozeznávání podle rukou nejstarší [1]. Na ruce člověka lze rozeznávat např.: geometrii ruky, otisky prstů, rýhy na dlani, rýhy na kloubech prstů, obraz krevního řečiště a další. Jakmile dosáhne osoba dospělosti, zůstávají tyto charakteristiky relativně stále po celý zbytek života a lze je tedy využít k identifikaci nebo verifikaci člověka [2]. Navíc lze tyto charakteristiky (mimo otisku prstů), na rozdíl například od snímání oční sítnice, snímat kamerou se základním rozlišením (640x480 pixelů). Proto je možné vytvořit relativně levné a malé snímací zařízení těchto biometrických charakteristik ruky.

V druhé kapitole této práce naleznete stanovené cíle práce. Třetí kapitola obsahuje popis technologií pro snímání obrazu a metod pro zpracování obrazu. Čtvrtá kapitola je určena pro shrnutí současných prací zabývajících se biometrií rukou. Pátá kapitola obsahuje popis technik hodnocení kvality biometrického systému. Šestá kapitola obsahuje popis výběru vhodného hardwaru a postup sestavení zařízení pro snímání obrazů vhodných pro biometrický systém. V kapitole sedmé naleznete popis vlastní implementace experimentálního softwaru pro zvolené řešení. Osmá kapitola je věnována popisu testování navrhnutého systému. Devátá kapitola obsahuje zhodnocení dosažených výsledků a návrhy na možné další vylepšení stávajících nedostatků. Výsledky dosažené v celé práci jsou shrnuty v desáté kapitole.

2. Cíle práce

Cílem práce je seznámit se s problematikou biometrické identifikace uživatelů. Hlavní důraz bude kladen na identifikaci podle biometrických charakteristik rukou uživatelů. Cílem práce bude na základě nabitých informací navrhnout a realizovat experimentální biometrický systém pro identifikaci uživatelů. Konkrétně lze cíle práce rozdělit na tyto body:

- Seznámit se s různými postupy při zpracování a vyhodnocení obrazu.
- Seznámit se s metodami slučování ohodnocení jednotlivých metrik v multi-biometrických systémech.
- Navrhnout vhodné komponenty hardwarového přípravku pro získávání snímků rukou testovaných osob.
- Použít navrhnutý hardwarový přípravek pro snímání testovaných osob.
- Vytvořit experimentální software implementující vybrané postupy zpracování obrazu a biometrické identifikace.
- Porovnat a otestovat přesnost jednotlivých metod výpočtu míry shody.
- Porovnat metody normalizace jednotlivých metrik před sloučením do výsledné míry shody.

3. Problematika zpracování obrazu

V této kapitole se zaměřím na popsání stávajících metod pro analýzu a zpracování obrazu.

3.1 Vyjádření obrazu

Pojem obraz lze matematicky popsat jako spojitou funkci dvou nebo tří argumentů [3] ve tvaru $f = (x, y)$ nebo $f = (x, y, z)$. Tuto funkci nazýváme obrazovou funkcí, kde její proměnné x, y jsou reálná čísla, představující souřadnice v rovině. Proměnná z může sloužit pro popis obrazu měnícího se v čase. Hodnotou funkce je měřená fyzikální veličina. Nejčastější měřenou veličinou je jas, ale mohou to být i jiné veličiny, např. teplota apod. Hodnota obrazové funkce také nemusí být reprezentována pouze jedinou hodnotou. Například v případě použití barevného modelu RGB to budou hodnoty tři, pro každou barevnou složku jedna.

3.2 Snímání a digitalizace obrazu

Snímání obrazu je prvním krokem při zpracování scény a má velký vliv na dosažené výsledky při vyhodnocení obrazu. Proces snímání obrazu je vlastně převedení optické veličiny na elektrickou veličinu. Tento proces zajišťuje snímací čip, který je umístěn v kameře za objektivem. Nejběžnější technologie snímačů jsou CCD a CMOS. Nabízenými parametry jsou obě technologie při použití v oblasti rozpoznávání obrazu srovnatelné. V dnešní době rozhoduje spíše výrobní cena dané technologie. Proto převládá u kamer s nižším rozlišením a menší velikostí čipu (do 2/3“) technologie CCD a CMOS technologie se používá u vysokých rozlišení a velkých snímacích čipů.

O zpracování signálu ze snímacího čipu na obrazová data se stará A/D převodník. Provádí vzorkování obrazu v matici $M \times N$ bodů a kvantování jasové úrovně do K intervalů. Většina systémů pro digitální zpracování obrazu pracuje s 256 úrovněmi jasu na obrazový bod (pixel). Pro reprezentování úrovně jasu tedy používáme 8 bitů na pixel. U barevných kamer se nejčastěji pracuje s 8 bity pro každou barevnou složku v modelu RGB pro každý pixel. Na každý pixel je tedy použito 24 bitů, což dovoluje vyjádřit více než 16,7 miliónů různých barev.

3.3 Vzorkování

Při vzorkování hraje důležitou roli vzorkovací interval. Při velké vzdálenosti vzorkovacích bodů může docházet ke ztrátě detailů. Aby k tomu nedocházelo, měl by být vzorkovací interval menší nebo roven polovině rozměru nejmenších detailů v původním obraze. Tuto skutečnost shrnuje Shannonova věta, která říká, že vzorkovací frekvence musí být alespoň dvakrát větší než nejvyšší frekvence vzorkovaného signálu. Každý vzorkovací bod představuje jeden obrazový bod (pixel) ve vzorkovací mřížce. Standardně se můžeme setkat s dvěma typy mřížek, s „klasickou“ čtvercovou a hexagonální, složenou z pravidelných šestiúhelníků.

3.4 Šum

I při uzavřené závěrce vykazuje čip nenulový šum. Temný šum čipu je dán zejména vlastní náhodnou fluktuací náboje zejména vlivem tepelných kmitů krystalové mřížky polovodiče, který je vyhodnocen jako skutečný signál dopadajícího světla. Ten se tvoří díky tepelnému pohybu, kdy vznikají právě tyto šumové náboje - elektrony - a elektromagnetickému pozadí, které ani při uzavřené závěrce není možné zcela odstínit. Platí, že s rostoucí teplotou tento temný šum obvykle roste. Bohužel procesor kamery není schopen rozlišit tento temný šum čipu od skutečného signálu při osvětlení čipu.

Kromě temného šumu se na odchylkách podílí i tzv. horké pixely (hot pixels), které vznikají při vybuzení elektronů z buňky vlivem dopadu energetické částice na čip, či tepelných pohybů při delších expozicích a dojde u nich k úplné saturaci jednotlivých pixelů. Další šum vzniká při vyčítání CCD čipu. Tento druh šumu se nazývá čtecí šum. Šum vzniká při zesílení na danou hodnotu ISO ekvivalentu v zesilovači. Nakonec je tu šum vzniklý při konverzi analogových dat do AD převodníku. Aby bylo možné rozlišit nějaký signál, měl by být vyšší než šum, tedy nad tzv. úrovní šumu, šumovou hladinou.


3.5 Osvětlení scény

Pro aplikace strojového vidění se vždy snažíme potlačit vnější vlivy prostředí, které by negativně ovlivňovaly zpracování a následné vyhodnocení obrazu. Jednou z možností jak těmto negativním vlivům předejít je použití dodatečného nasvícení scény pomocí speciálních světel, které scénu intenzivně nasvítí a „přehluší“ okolní běžné osvětlení. Obzvláště vhodné je doplnit objektiv filtrem, který propouští pouze záření o stejné vlnové délce jako použité světlo, čímž se efekt výrazně posílí.

Požadavky na tato světla jsou především:

- dostatečná intenzita,
- homogenní nasvícení scény,
- stálost intenzity osvětlení v čase (v důsledku opotřebení).

S ohledem na výše popsané požadavky, se jako zdroj záření využívá technologie různých halogenových, xenonových nebo fluorescenčních lamp, laserů a LED. Historicky se nejvíce využívalo halogenových a fluorescenčních lamp, ale v dnešní době jsou ve většině aplikací nahrazeny LED technologií, která je spolehlivější. Ve speciálních případech 3D snímání se využívá nasvícení scény laserem. Laser tvoří světelnou „linku“, která je snímána kamerou. Každý snímek pak zachycuje profil snímaného objektu. Softwarově se jednotlivé profily vyhodnotí a vytvoří se z nich 3D model snímaného objektu.



Obrázek 1 - Možné typy osvětlení scény (vlastní práce autora)

Podle umístění zdroje záření uvnitř světla a tvaru světla existuje několik základních typů světel. Každý typ je vhodný pouze na určité aplikace strojového vidění a vytváří specifický obraz. Základní techniky nasvícení scény jsou znázorněny na obrázku (Obrázek 1). Následuje popis základních technik nasvícení scény.

Přímé osvětlení scény

Základní typ osvětlení snímané scény. Světlo osvěcuje objekt ze stejné strany, jako je snímán kamerou. Nevýhodou je možný výskyt odlesků a vznik ostrých stínů. Přímé osvětlení se dále dělí na dva typy: přímé osvětlení a rozptýlené osvětlení. Umístění osvětlení přímého rozptýleného je znázorněno na obrázku (Obrázek 2).

U přímého osvětlení se používají světla plošné nebo kruhové konstrukce. Zdroj záření osvětluje scénu přímo. Výhodou tohoto typu osvětlení je vysoká intenzita osvětlení scény.

Rozptýlené osvětlení funguje obdobně, pouze využívá k osvětlení scény odraženého světla. Scéna je osvětlena světlem přicházejícím z více směrů a tím dochází k potlačení ostrých stínů v obraze. Konstrukce těchto světel je ve většině případů kopule, na které dochází ke zpětnému odrazu světla. Výhodou je potlačení stínů, nevýhodou je nižší intenzita osvětlení scény v porovnání s přímým osvětlením.




Obrázek 2 - Příklady přímého osvětlení scény [29]

Boční osvětlení scény

Někdy bývá označováno jako osvětlení typu darkfield. Jedná se o speciální techniku osvětlení snímané scény, kdy paprsky světla dopadají převážně na boky snímaného předmětu. Dochází tak k zvýraznění svislých hran snímaného předmětu. Příklad umístění bočního osvětlení je znázorněn na obrázku (Obrázek 3).

Pro menší předměty existují kruhová světla se zdrojem světla namířeným dovnitř, nebo lze stejného efektu docílit použitím více přímých světel umístěných do kruhu.

Výhodou je absence tvorby nežádoucích odlesků a zvýraznění svislých hran. Nevýhodou je obtížné mechanické umístění světla těsně nad snímaný předmět.




Obrázek 3 - Příklad bočního osvětlení scény [29]

Zadní osvětlení scény

Jde o techniku osvětlení scény, kdy je světlo umístěné z pohledu kamery až za snímaným předmětem. Ve výsledném obraze je při tomto nasvícení scény pouze kontura snímaného předmětu a samotný předmět je zobrazen tmavě. Tato technika osvětlení scény je tedy vhodná pro vyhodnocování tvaru zkoumaného předmětu a často se kombinuje s ostatními technikami osvětlení scény. Příklad použití zadního osvětlení je znázorněn na obrázku (Obrázek 4).

Konstrukce světel je obdobná jako u přímého osvětlení scény, pouze doplněná o difuzor. Ten zajistí dostatečný rozptyl a homogenitu světla.

Výhodou je téměř binární obraz. Nevýhodou je nutnost použití dalšího způsobu osvětlení scény, když je třeba vyhodnocovat také „vnitřek“ snímaného předmětu a ne pouze vnější tvar.




Obrázek 4 - Příklad zadního osvětlení scény [29]

3.6 Filtry a transformace obrazu

Při zpracování této kapitoly jsem čerpal z [4]. Metody předzpracování obrazu různými transformacemi a filtry slouží ke zlepšení obrazu před dalším zpracováním. Cílem předzpracování je potlačit šum a zkreslení vzniklé při digitalizaci obrazu nebo zvýraznění určitých rysů obrazu podstatných pro další zpracování (například hledání hran). Předzpracováním nezískáme žádnou novou obrazovou informaci, můžeme pouze některé informace potlačit nebo zvýraznit.

Bodová změna jasové stupnice

Jednou z nejjednodušších operací s obrazy je transformace jasů. Při této transformaci se hodnota jasu pixelu z původního obrazu $f(i)$ nahradí novou hodnotou, která je dána funkcí $f'(i)$. V závislosti na průběhu této funkce lze pomocí transformace jasu realizovat několik často používaných operací. Velmi často se při vyhodnocování obrazu používá binarizace (prahování), kdy se z původního obrazu v odstínech šedé vytvoří binární obraz (pouze černá a bílá barva). V některých případech se též používá zvýšení kontrastu obrazu. Graf (Graf 1) znázorňuje průběhy jednotlivých transformačních funkcí.



Graf 1 - Transformační funkce (vlastní práce autora)


Ekvalizace histogramu

Histogram slouží k hodnocení rozložení intenzit v digitálním obraze. Histogram je grafické znázornění vektoru s počtem složek rovným počtu možných úrovní intenzit obrazových bodů. Tento vektor je označen písmenem H a hodnota každé složky vektoru odpovídá četnosti bodů příslušné intenzity v obraze. Typický tvar histogramu digitálního obrazu, který nevyužívá všechny dostupné úrovně intenzit, je uveden na obrázku 5. Z histogramu je zřejmé, že v obraze schází zejména hodnoty intenzit na okrajích intervalu $\langle 0,1 \rangle$, což obvykle snižuje kvalitu obrazu. Ekvalizace histogramu je algoritmus, který změní rozložení intenzit v obraze tak, aby se v něm vyskytovaly pokud možno intenzity v širokém rozmezí, a to přibližně se stejnou četností. U obrazů s konečným počtem obrazových bodů se lze tomuto cíli jen přiblížit.


Výsledná intenzita obrazového bodu po ekvalizaci I' se vypočítá z původní intenzity obrazového bodu I , a to pomocí rovnice:

$$I' = \frac{I}{X \cdot Y} \cdot \sum_{i=I_0}^{i=I} H(i) \quad (1)$$

$H(i)$ je i -tá složka vektoru histogramu (počet bodů v obraze se stejnou intenzitou), X , Y jsou rozměry obrazu a I_0 je nejnižší intenzita původního obrazu.



Obrázek 5 - Obraz s nízkým kontrastem a jeho histogram [26]



Obrázek 6 - Obraz s kontrastem upraveným ekvalizací a jeho histogram [26]

Výsledkem je obraz s větším kontrastem, zvláště u obrazů s podobnými hodnotami jasu (rentgenové snímky kostí, podexponovaná fotografie, atd.). Ukázka obrazu s nízkým kontrastem je na obrázku (Obrázek 5). Na obrázku (Obrázek 6) je ukázka obrazu po použití ekvalizace. Ekvalizace také umožňuje v obraze s celkově vysokým kontrastem zvýraznit špatně rozpoznatelné detaily s nízkým kontrastem. Nevýhodou je možné zvýšení kontrastu také u nežádoucího šumu v obraze.

Jasové korekce pomocí lokálního okolí pixelu

Algoritmy (filtry) upravující jas daného pixelu pracují s jeho lokálním okolím, na rozdíl od bodových jasových korekcí, při kterých se pracovalo pouze s hodnotou jasu daného pixelu. Filtry lze rozdělit do dvou skupin. Jsou to filtry vyhlazující obraz (potlačení šumu) a filtry gradientní operace (zvýraznění hran).

Mezi vyhlazovací filtry patří průměrování. Filtr přiřadí novému bodu intenzitu, která je spočítána aritmetickým průměrem hodnot intenzit bodů z obdélníkového okolí původního bodu. Tímto filtrem lze odstranit aditivní šum s náhodným rozložením. Nevýhodou tohoto filtru je velká míra rozmazání. K minimalizaci rozmazání se v praxi nepoužívá aritmetický průměr, ale medián. Filtr aritmetický průměr i medián lze použít iterativně.

Mediánový filtr

Mediánový filtr patří mezi nelineární filtry obrazu. Prochází postupně všechny pixely zdrojového obrazu. Z okolí každého pixelu je vybrán pixel ležící uprostřed posloupnosti seřazených hodnot. Vlastnost, podle které je posloupnost pixelů seřazena, je u černobílého obrazu intenzita pixelů. U barevného obrazu to může být intenzita jedné RGB složky, vážený

součet RGB, odstín nebo sytost v barevném systému HSI. Filtrování obrazu pomocí mediánového filtru se využívá k potlačení nahodilých chyb v obraze, jako je vysokofrekvenční šum. Filtr z obrazu odstraňuje detaily, jako jsou drobné čáry a ostré rohy, ale zachovává hrany velkých objektů (nedochází k rozmazání). Míra ztráty detailů velmi záleží na zvolené velikosti okolí bodu. Na obrázku (Obrázek 7) je ukázka zašuměného obrazu a obrazu po použití mediánového filtru.



Obrázek 7 - Příklad použití mediánového filtru [27]

Gradientní filtry

Do skupiny gradientních filtrů patří algoritmy založené na vyhodnocení velikosti gradientu (strmost změny jasu v obraze). Tyto filtry se využívají k zvýraznění hran objektů v obraze.

K vyhodnocení gradientu jsou používány dva různé postupy. První z nich je vyhodnocení pomocí aproximování derivace obrazové funkce pomocí diferencí (například Sobelův nebo Laplaceův operátor). Hlavní nevýhodou tohoto postupu je velká závislost na šumu a velikosti objektů v obraze. Druhý způsob je potom detekování průchodu druhé derivace obrazové funkce nulou (například operátor Marra a Hildretové).

3.7 Geometrické transformace

Geometrická transformace je dána vektorovou funkcí T_G , která transformuje bod v rovině (x,y) do bodu (x',y') . Pomocí této transformační funkce lze provádět různé operace s obrazem, jako je zvětšování, rotace, posun atd. Lze také eliminovat různé zkreslení obrazu vzniklé při snímání, jako je například odstranění perspektivy.

3.8 Morfologická filtrace

Morfologická filtrace obrazu pracuje s obrazy jako s bodovými množinami a používané postupy se dosti liší od dříve popisovaných principů filtrace. Pro její popis se obvykle používá teorie množin a topologie.

Morfologická filtrace mění tvar nebo strukturu (objekty se zvětšují, zmenšují, spojují, rozdělují nebo tříští na další objekty atd.) objektů. Můžeme ji využít např. k odstranění nežádoucí informace z obrazu, která vzniká např. při prahování.

Při morfologických transformacích pracujeme s tzv. strukturním elementem a výsledný pixel je výsledkem (logické) operace mezi množinou mřížky strukturního elementu a množinou bodů zdrojového obrazu, ležících pod body strukturního elementu. Mezi základní operace binární morfologie patří: dilatace, eroze, otevření a uzavření.

Dilatace


Dilatace eliminuje izolované díry v objektech a rozšiřuje obrysy objektů na úkor okolního pozadí. Jestliže se pod jakoukoliv jedničkovou buňkou strukturního elementu nachází černý pixel, pak výsledkem operace je černý pixel. Postup výpočtu dilatace obrazu je znázorněna na obrázku (Obrázek 8).



Obrázek 8 - Postup filtrování obrazu dilatací [30]

Eroze

Eroze eliminuje izolované pixely na pozadí a ubírá obrysy objektů. Černý pixel je výsledkem operace jen tehdy, když jsou černé pixely současně pod všemi jedničkovými buňkami strukturního elementu, ve všech ostatních případech je výsledkem bílý pixel. Postup výpočtu eroze obrazu je znázorněna na obrázku (Obrázek 9).



Obrázek 9 - Postup filtrování obrazu erozí [30]

Otevření

Otevření přerušuje tenké spoje mezi objekty a zvětšuje mezi nimi v těchto místech mezery. Zde se využívá skutečnosti, že eroze a dilatace nejsou navzájem inverzními operacemi. Otevření je tedy eroze následovaná dilatací. Eroze odstraní tenká propojení, tím se natolik změní tvar objektu, že následná dilatace již není schopna tyto části přidat. Masivní těla objektů se přitom prakticky nemění.

Uzavření

Obdobně dilataci následovanou erozí nazýváme uzavřením. Transformace opět mění pouze detaily obrazu, které jsou velikostně srovnatelné s velikostí strukturního elementu. Tvary větších objektů se přitom nemění. Pomocí uzavření můžeme propojit objekty, které se dříve nedotýkaly, nebo můžeme potlačit díry uvnitř objektů.

3.9 Segmentace obrazu


Jedná se o techniku nebo skupinu technik, které rozdělí obraz na objekty zájmu a pozadí. Objekty zájmu jsou zkoumané reálné předměty nasnímané do obrazu. Objekty zájmu lze segmentovat pomocí různých technik. Všechny techniky jsou založené na předpokladu, že objekty zájmu jsou částí obrazu s určitými stejnými vlastnostmi.

Prahování


Jedná se o nejjednodušší metodu segmentace. Předpokládá, že objekt zájmu lze odlišit od pozadí pouze intenzitou jednotlivých pixelů. To znamená, že při vhodně zvoleném prahu budou mít všechny pixely patřící do objektu zájmu hodnotu intenzity vyšší než práh a všechny pixely patřící do pozadí budou mít hodnotu intenzity nižší než práh.

Práh lze zvolit pevný na základě znalosti obrazu empiricky. Další možnost je pro každý obraz automaticky vypočítat nejvhodnější práh z histogramu, průměrem všech hodnot intenzit v obraze, mediánem všech intenzit v obraze, atd. Histogram obrazu vhodný k výpočtu globálního prahu zobrazuje obrázek (Obrázek 10). Lze také použít adaptivní výpočet prahu, což znamená, že pro každý pixel původního obrazu se určuje práh samostatně výpočtem z jeho okolí.

V některých případech, kdy je obraz příliš zašuměný, mezi objektem zájmu a pozadím je malý kontrast, nebo se na objektu zájmu vyskytují odlesky, nelze metodu prahování použít. Histogram příliš zašuměného obrazu je na obrázku (Obrázek 11).



Obrázek 10 - Histogram vhodný pro výpočet prahu [31]



Obrázek 11 - Histogram nevhodný pro výpočet prahu [31]

Hranové detektory

K detekci hran (angl. edge detection) se obvykle používají gradientní operátory, např. Cannyho hranový detektor nebo Sobelův filtr. Protože výstupem gradientního operátoru je obraz, kde jsou sice hrany zvýrazněny, ale může obsahovat další artefakty odpovídající lokálním nehomogenitám v obraze, je třeba obraz dále upravit. K odstranění artefaktů vzniklých lokálními malými rozdíly obvykle postačuje prahování. Vzhledem ke svým vlastnostem mohou detektory hran vytvářet přerušované hranice i falešné hranice, obraz hranic je tedy třeba dále zpracovat.

Region-based techniky

Metody detekující přímo oblasti v obraze namísto hranic (hran) těchto oblastí jsou efektivnější pro zašumělý obraz. Je-li v obraze hodně šumu, hranové operátory obtížně detekují hrany. Hlavním segmentačním kritériem pro detekci oblastí v obraze je homogenita oblasti. Kritériem homogenity mohou být: úroveň šedi, barva, textura, tvar, model, apod.

Podstatou metod je, že konstrukce segmentu postupuje zdola nahoru, od jednoho pixelu po celý segment. Nejprve jsou nějakým algoritmem v obraze rozmístěny iniciální (semínkové, angl. seed) pixely, obvykle rovnoměrně nebo náhodně, segment pak vzniká iterativním rozrůstáním se okolí iniciálního pixelu.

Při použití metod založených na růstu segmentu není zaručeno, že při různém počtu a rozmístění iniciálních pixelů bude výsledek segmentace identický. Na druhou stranu jsou tyto metody schopny segmentovat i takový obraz, který obsahuje značné množství šumu.

3.10 Normalizace ohodnocení

Při zpracování této kapitoly jsem vycházel z práce A. Ross a A. Jain [5].

Jedná se o transformaci změřených hodnot. Normalizace se využívá pro porovnání více měřených hodnot pocházejících z různých zdrojů (hrubé hodnoty). Normalizace zajišťuje sjednocení měřítka a upravuje umístění hodnoty v tomto novém měřítku. Pro realizaci normalizace existuje několik známých postupů výpočtu.

Metoda min-max

Nejjednodušší postup výpočtu je min-max normalizace neboli normalizace rozpětím. Pro výpočet je nutné znát minimální a maximální možné hodnoty, kterých může funkce nabývat. Jestliže možné hodnoty funkce nejsou ohraničené (platí pro všechny použité metriky), je nutné minimum i maximum odhadnout na základě testovacích dat. Normalizované ohodnocení no se vypočítá podle rovnice:

$$no = \frac{o - \min_{i=1}^N o_t^i}{\max_{i=1}^N o_t^i - \min_{i=1}^N o_t^i} \quad (2)$$

kde o je hrubé ohodnocení, N je počet prvků v množině testovacích dat, o_t^i prvek testovacích dat. Jestliže jsou minimum a maximum odhadnuté, je tato metoda citlivá na odlehlé hodnoty v testovacích datech. Normalizované ohodnocení je potom zkreslené.

Z-skóre

Jedna z nejčastějších normalizačních metod. K výpočtu je využíván aritmetický průměr a směrodatná odchylka testovacích dat. Metoda vychází z předpokladu, že měřená data mají normální rozdělení. Normalizované ohodnocení no se vypočítá pomocí rovnice:

$$no = \frac{o - \mu_t}{\sigma_t} \quad (3)$$

kde o je hrubé ohodnocení, μ_t je aritmetický průměr testovacích dat a σ_t je směrodatná odchylka testovacích dat.

V případě že rozložení hodnot dané metriky není normální, nezachová se po normalizaci původní rozdělení měřených dat. Je to způsobeno tím, že směrodatná odchylka a průměr jsou optimální pouze pro normální rozdělení. Zatím co hodnoty metriky nemusí mít normální rozdělení. Z tohoto důvodu není tato metoda normalizace vhodná pro všechny metriky.

Normalizace pomocí mediánu a MAD

Mediánová absolutní odchylka (MAD) je míra variability, která je málo ovlivněna odlehlými hodnotami a extrémami ve vstupním souboru dat. Na rozdíl od výpočtu směrodatné odchylky, v kterém se odchylky od průměru mocní na druhou, takže velké odchylky mají velkou váhu, je MAD robustní a malé množství odlehlých hodnot výsledky příliš neovlivní. Z těchto důvodů použití MAD a mediánu pro výpočet normalizace by mělo být robustní. Normalizované ohodnocení no se vypočítá pomocí rovnic:

$$no = \frac{o - Me_{i=1}^N o_t^i}{MAD} \quad (4)$$

$$MAD = Me(|o_t^i - Me_{i=1}^N o_t^i|) \quad (5)$$

kde o je hrubé ohodnocení, N je počet prvků v množině testovacích dat, o_t^i prvek testovacích dat, Me je medián. Bohužel medián a MAD mají malou efektivitu při normalizaci. To znamená, že tato technika nemusí ve všech případech transformovat hodnoty do společného rozsahu pro spojení všech metrik.

4. Rešerše relevantní literatury a existujících řešení

Používání různých biometrických znaků (oční duhovka, otisk prstu, geometrie ruky, rozložení cév v ruce, obraz sítnice oka, rozpoznání tváře, atd.) k autentizaci a identifikaci osob není otázkou pouze poslední doby.

4.1 Geometrie ruky

Jako první komerčně nabízený systém, založený na vyhodnocení geometrie ruky, byl vyvinutý Davidem Sidlauskasem. Ten si ho nechal patentovat v roce 1985 [13] a hned následující rok byl systém dostupný komerčně.

Při vyhodnocení geometrie ruky lze snímat například: délku, šířku a tloušťku prstů a dlaně, zakřivení prstů, plochu dlaně, šířku kloubů na prstech. Tyto charakteristiky jsou dány tvarem a uspořádáním kostí ruky. Proto na ně působí vnější vlivy (úrazy, stárnutí, tělesná hmotnost) pouze omezeně a je tedy možné tyto charakteristiky využít k identifikaci člověka [2]. Využití je ale omezeno pouze na aplikace, kde je požadována střední úroveň zabezpečení (docházkové systémy, systémy řízení přístupu), protože geometrie ruky není příliš unikátní biometrickou vlastností.

Ve starších verzích a také v současných jednoduchých (levných) verzích systémů rozpoznávání geometrie ruky se používá snímání ruky umístěné na kontrastním podkladu, kdy je pozice ruky vymezena kolíky [13]. Tato metoda snímání obrazu ruky je jednodušší na vyhodnocení (vyhodnocovací oblasti v obraze jsou pevně definovány), ale přináší také mnoho nevýhod. Největší nevýhodou je zkreslení způsobené fixací ruky, které negativně ovlivňuje výsledky identifikace. Dále tu je možnost zachycení a zkopírování otisku ruky z podkladu, kdy by někdo mohl teoreticky vytvořit model ruky a neoprávněně překonat systém identifikace. Další z nevýhod je otázka hygieny. V dnešní době kdy svět ohrožují epidemie (SARS, H1N1, Ebola, atd.) není vhodné, aby se mnoho lidí dotýkalo rukou snímacího zařízení.

A. Jain a kolektiv [7] použili ve své práci pět kolíků pro fixaci pozice ruky a snímali ruku z horního a také bočního pohledu. Pro vyhodnocení použili 16 geometrických charakteristik. Dosažený EER byl 6%. Sanchez-Reillo a kolektiv [9] použili 6 kolíků a 25 geometrických charakteristik. Dosažený EER byl pod 3%.

Řešením pro odstranění deformací způsobené kolíky je snímání ruky bez vymežovacích kolíků. Ruka se snímá přiložením na skener. Odstraněním kolíků, které vymezují pozici ruky při snímání, dojde k uvolnění ruky, která má potom přirozený tvar, čímž se odstraní nežádoucí deformace [10]. Vzniká ale problém, kdy ruka může být na skener položena pokaždé do trochu jiné pozice. Řešením je zaměřování ruky v obraze, kdy se nejdříve naleznou referenční body měření (konečky prstů, prohlubně mezi prsty, atd.).

A.Wong a P. Shi ve své práci [10] použily pro snímání deskový skener bez fixačních kolíků. Vyhodnocovaly velikost a geometrii konečků prstů. Dosáhly hodnoty FFR 11,1% a FAR nízkých 2,2%. Při použití fixačních kolíků dosáhly FFR pouze 4%, ale FAR se zvýšil na 4,9%. Metoda snímání bez fixačních kolíků je tedy mnohem vhodnější pro bezpečnostní aplikace, v kterých je důležitější FAR parametr (míra falešného přijetí).

Některé práce se zabývají odstraněním nevýhod přikládání ruky na podložku a zkoušejí snímat ruku volně před kamerou. Například S. Haeger [11] se ve své práci pokoušel snímat ruku volně v prostoru před kamerou. Při vyhodnocení používal jako záměrný bod těžiště ruky. Z těžiště pak sestrojil soustředné kružnice, které procházely přes prsty. Pomocí těchto kružnic potom měřil prsty. Výsledkem bylo měření velikosti prstů ve 124 bodech. Dosáhl FFR 54,3% a FAR 8,6%. Špatné výsledky byly způsobené nejspíše přílišným pohybem a náklonem ruky před kamerou, kdy hlavně pohyb od a ke kameře způsobí velké odchylky ve velikosti obrazu ruky díky perspektivnímu zkreslení objektivu.

Zheng a kolektiv [12] ve své práci hledali matematické metody, které by mohly sloužit k popisu geometrických charakteristik ruky a nebyly závislé na perspektivním zkreslení objektivu kamery, ani na úhlu pohledu. Experimentálně se v práci podařilo dosáhnout EER 2,1% při 5 zkoumaných charakteristikách a s databází 52 referenčních snímků rukou. Při vyhodnocování 18 charakteristik bylo dosaženo dokonce EER 0,0%.

4.2 Krevní řečiště

Další cestou, jak identifikovat člověka, je rozpoznávání rozložení žil v krevním řečišti dlaně nebo zápěstí. Jedná se o relativně novou metodu identifikace člověka. První komerční systémy založené na tomto principu byly uvedeny na trh až kolem roku 2000 [13]. Mezi výhody této metody patří zejména obtížné zfalšování krevního řečiště. Je to dáno tím, že cévy jsou uvnitř ruky a nelze je snadno napodobit. Mezi další výhody patří bezkontaktnost snímání a relativní neměnnost vzoru krevního řečiště po celý dospělý věk uživatelů [6].

H. Tilborg a kolektiv [14] ve své práci popisují dvě snímací metody: FIR a NIR.

FIR je zkratka pro far infrared, což znamená vzdálené infračervené spektrum. Je to technologie kdy se snímá tepelné vyzařování (vlnová délka 15 - 1000 μm) zkoumaného objektu (člověka). Výhodou této metody je, že není potřeba žádné další speciální osvětlení. Tato technologie je ale bohužel citlivá na změny vnějších i vnitřních podmínek jako je vlhkost a teplota prostředí nebo aktuální zdravotní stav snímaného člověka. Výsledný obraz je tedy velmi nestálý a závisí na mnoha podmínkách.

NIR je zkratka pro near infrared, což znamená blízké infračervené spektrum. Tato technologie snímání využívá pronikání infračerveného záření (vlnová délka 0,76 – 1,4 μm) do tkání a orgánů. Záření proniká do hloubky přibližně 3 mm. Odkysličený hemoglobin v žilách pohlcuje nejvíce záření o vlnové délce přibližně $7,6 \times 10^{-4}$ mm [13]. Velké žíly vystupující blízko povrchu hřbetu ruky tedy pohlcují více IR záření než okolní tkáň. Tím se dosáhne potřebného kontrastu mezi pozadím (tkání) a zkoumaným objektem (velké žíly). Žíly jsou potom v obrazu zachyceny jako tmavší oblasti. Důležitá podmínka pro tuto technologii snímání je použití kamery s IR filtrem a vhodného osvětlení scény IR zdrojem záření. Výhodou NIR technologie snímání obrazu je malá závislost na okolním prostředí a na stavu snímaného člověka. Také různé tóny a odchylky ve zbarvení kůže nemají na výsledný obraz vliv.

5. Definice problému a požadovaných parametrů systému

Cílem této práce je navrhnout, realizovat a otestovat systém, který bude identifikovat uživatele podle biometrických charakteristik. Pro identifikaci uživatelů jsem si zvolil biometrické charakteristiky založené na kontuře ruky a obrazci žil krevního řečiště uživatele. Systém se bude skládat z hardwarové části (osvětlení, kamera, optická soustava) a části softwarové, která bude zpracovávat obrazy pořízené kamerou a vyhodnocovat shodu pomocí databáze uložených uživatelů.

5.1 Biometrická autentizace a identifikace

Biometrická autentizace a identifikace je postup, při kterém lze pomocí měření některých charakteristických vlastností s určitou mírou přesnosti identifikovat nebo autentizovat danou osobu. Mezi měřitelné charakteristiky, které lze využít pro biometrickou identifikaci, patří například: otisk prstu, oční sítnice, geometrie ruky, geometrie obličeje, atd. Mezi biometrické charakteristiky patří také určitý vzorec chování jako například: dynamika chůze, akustická charakteristika hlasu, atd.

Ve srovnání biometrické autentizace s autentizací pomocí hesla nebo personálního identifikačního čísla (PIN) má biometrická autentizace značné výhody. Mezi hlavní výhody patří: nemožnost ztracení nebo zapomenutí, zcizení, nemožnost vyzrazení další osobě a v neposlední řadě snadné použití (není potřeba si nic pamatovat ani zadávat).

Možné využití biometrie v současném světě se tedy nabízí všude tam, kde je nutné autentizovat uživatele systému. Nahrazením přihlašování uživatele pomocí hesla biometrickou autentizací získají uživatelé mnohem vyšší bezpečnost a pohodlnost používání. Hlavní oblasti pro nasazení biometrické autentizace jsou tedy docházkové systémy, systémy pro kontrolu vstupu, bankomaty, stravovací systémy, autorizace při používání PC, atd.

Princip funkce automatizované biometrické identifikace je následující. Nejdříve dojde k nasnímání fyzické biometrické charakteristiky a uložení do databáze společně s daty o uživateli. Tímto je systém připraven identifikovat daného uživatele. Při vlastní identifikaci se opět nejdříve nasnímá charakteristika uživatele. Dále se porovnává nasnímaná charakteristika s databází uložených charakteristik a hledá se největší míra shody. Když míra shody přesáhne určitou minimální mez, je uživatel identifikován.

5.2 Měření výkonu biometrických systémů

Efektivnost a přesnost biometrických systémů lze měřit a popsat mnoha statistickými koeficienty. Mezi nejdůležitější koeficienty při přesnosti verifikace patří FAR (pravděpodobnost falešného přijetí), FRR (pravděpodobnost falešného zamítnutí), EER (celková chyba systému). Obdobně se při měření přesnosti identifikace využívá FMR (četnost falešné identifikace), která odpovídá FAR a FNMR (četnost nenalezení identifikace), která odpovídá FRR.

Mezi nejdůležitější koeficienty měření výkonu patří čas potřebný pro zápis vzorové charakteristiky a čas potřebný pro autentizaci uživatele.

FAR

FAR je pravděpodobnost, s kterou systém přijme (autentizuje) neoprávněnou osobu. Tato chyba systému vede často k vzniku škod. Je to tedy ukazatel míry bezpečnosti systému. Z bezpečnostního, ale i marketingového hlediska jde o kritickou vlastnost systému. Koeficient vypočítáme z následujícího vztahu, v kterém N_{FA} je počet falešných přijmání systémem a N je počet pokusů o autentifikaci osobou, která nemá oprávnění:

$$FAR = (N_{FA}/N) \quad (6)$$

FRR

FRR je pravděpodobnost, s kterou systém nepřijme (neautentizuje) oprávněného uživatele. Jde o chybu, kdy uživatel má normálně do systému přístup, ale systém ho nerozezná. Tento koeficient lze také chápat jako míru komfortu, protože opakování pokusů o autentizaci uživatele obtěžují. Z bezpečnostního hlediska nemá tato chyba systému velký význam. Koeficient vypočítáme podle následujícího vztahu, v kterém N_R je počet odmítnutí oprávněné osoby a N_{EIA} je počet pokusů o autorizaci oprávněnými osobami:

$$FRR = (N_R/N_{EIA}) \quad (7)$$

EER

EER je hodnota kdy se pravděpodobnost FAR a FRR rovnají při určité hodnotě prahu vyhodnocení (rozhodovací hranice). Čím je hodnota EER nižší, tím je systém spolehlivější.

5.3 Zvýšení bezpečnosti biometrických systémů

Biometrické autentizační systémy mají obecně vysokou míru bezpečnosti, kdy se FAR pohybuje u jednotlivých biometrických charakteristik v řádu jednotek procent. V některých reálných aplikacích mohou být přesto požadavky na bezpečnost vyšší. Metod, jak zvýšit bezpečnost, je několik. Systém může pracovat s charakteristikami, které je velmi těžké je napodobit a jsou skryté. Příkladem může být snímání oční duhovky, pro které je FAR pod 1% [5]. Nevýhodou je však velmi vysoká pořizovací cena.

Druhou možností, jak zvýšit bezpečnost systému, je snímání více biometrických charakteristik v jednom systému (minimálně dvou, ale i více). Příkladem může být kombinace snímání otisku prstů a zároveň snímání hlasu. Takový systém má relativně přijatelnou cenu, ale jeho bezpečnost se výrazně zvýší. Protože platí následující vztahy pro FAR a FRR [13]:

$$FAR_{celkove} = FAR_1 \cdot FAR_2 \cdot \dots \quad (9)$$


$$FRR_{celkove} = FRR_1 + FRR_2 + \dots \quad (10)$$

Koeficient FAR roste rychleji než FRR, čímž se násobně zvyšuje bezpečnost a zároveň se komfort používání snižuje pomalu.


6. Návrh a realizace hardware pro snímání biometrických charakteristik

Pro snímání obrazu jsem použil technologii NIR, která dovoluje snímat rozložení velkých žil v krevním řečišti [14]. Výhodou je omezení vlivu okolního denního světla a tím zvýšení opakovatelnosti snímání. Další výhodou oproti metodě FIR je možnost použití standardní kamery, která je citlivá také na IR záření. Celá sestava se tedy skládala z digitální kamery s objektivem a filtrem a zdroje IR osvětlení.

Pro snímání obrazu jsem použil digitální kameru s rozlišením 640x480 pixelů a bitovou hloubkou 8 bitů na pixel. To znamená, že výsledný obraz z kamery je šedo tónový s 255 odstíny šedi. Kamera používá pro přenos dat FireWire rozhraní. Citlivost CCD čipu kamery na IR záření popisuje graf (Graf 2).




Graf 2 - Citlivost kamery na záření [28]




Graf 3 - Charakteristika IR filtru [29]

Objektiv jsem použil s pevnou ohniskovou vzdáleností z výrobní řady VCN s ohniskovou vzdáleností 4,5 mm. Důležitou součástí objektivu byl IR filtr. Použitím filtru kamera snímala pouze IR část spektra. To bylo důležité pro omezení vlivu denního světla na snímání obraz. Charakteristiku použitého IR filtru popisuje graf (Graf 3).

Další součástí snímacího zařízení byl zdroj IR záření. Provedl jsem testy s různými typy zdrojů IR záření. Testoval jsem následující typy osvětlení: přímé kruhové osvětlení, přímé liniové osvětlení, difuzní DOM osvětlení a zadní osvětlení.




**Obrázek 12 - Kruhové přímé osvětlení
(vlastní práce autora)**



**Obrázek 13 - Liniové přímé osvětlení
(vlastní práce autora)**



**Obrázek 14 - Zadní difuzní osvětlení
(vlastní práce autora)**



**Obrázek 15 - DOM difuzní osvětlení
(vlastní práce autora)**

U přímého kruhového (Obrázek 12) a také přímého liniového (Obrázek 13) osvětlení se projevilo nerovnoměrné nasvětlení snímané ruky. Bylo to způsobeno nejspíše nedostatečnou velikostí použitých světel. Projevily se také odrazy světla od pokožky, které jsou nežádoucí hlavně při vyhodnocování žil krevního řečiště. Měl jsem k dispozici pouze kruhové osvětlení RK1220 o vnějším průměru 40 mm a liniové osvětlení LAL14x75 o délce 75 mm.

Dále jsem testoval osvětlení typu DOM (Obrázek 14). Tyto světla používají k osvětlení scény odražené paprsky od vnitřní reflexní stěny světla. Tím je dosaženo rovnoměrné nasvícení scény a zároveň je poskytován světelný tok rozptýlený. Rozptýlený světelný tok pomáhá k potlačení nechtěných odrazů od lesklých materiálů, v našem případě od hladké pokožky. K dispozici jsme měli typ SFD 42/12 s vnějším průměrem 84 mm. Osvětlení ruky s použitím tohoto světla bylo homogenní. Velké žíly na hřbetě ruky byly rozeznatelné a kontrastní.

Jako poslední testovaný zdroj záření jsem testoval zadní osvětlení (Obrázek 15). Při tomto typu osvětlení scény je snímáný objekt umístěn mezi kameru a zdroj osvětlení. Byl použit typ

FDL 08, který poskytuje difuzní zdroj záření. S tímto typem osvětlení jsem dosáhl velmi dobrých výsledků pro vyhodnocení kontury tvaru ruky, ale bohužel nelze použít pro zamýšlenou kontrolu krevního řečiště, což bylo pro navrhovaný systém nevhodné.

Testoval jsem také různé vlnové délky použitého osvětlení. Testoval jsem UV, IR, bílé a červené osvětlení. Nejlepší výsledky jsem dosáhl s IR osvětlením. Ukázalo se jako nejvhodnější pro kontrolu krevního řečiště a zároveň je použitelné také pro kontrolu geometrie ruky. Díky použití osvětlení a kamerového filtru v IR spektru nevznikaly na kůži nežádoucí odlesky, tak jako u ostatních vlnových délek. Vady kůže, jako jsou vrásky, se také v IR spektru projeví oproti ostatním vlnovým délkám minimálně.

Na základě výsledků testů jsem jako nejvhodnější typ osvětlení zvolil typ DOM, který jako zdroj záření využívá LED s vlnovou délkou 850 nm. S tímto typem osvětlení jsem získal snímky s homogenním osvětlením, s dobře rozeznatelnou strukturou žil na hřbetě ruky a zároveň s dostatečným kontrastem ruky proti pozadí pro vyhodnocení kontury ruky.

Všechny světelné zdroje byly od firmy Vision & Control GmbH. Jako zdroj záření používají LED technologii s různou vlnovou délkou.


Tabulka 1 - Přibližný odhad cen použitých komponent (vlastní práce autora)

CCD kamera GuppyPRO F-031B	Allied Vision Technologies GmbH	600 EUR
Objektiv VCN 1,4/4,5 f=4,5 mm	Vision & Control GmbH	150 EUR
IR filtr	Heliopan Lichtfilter-Technik Summer GmbH & Co KG	40 EUR
Osvětlení SFD 42/12 IR	Vision & Control GmbH	700 EUR
Celkem		1490 EUR

Celá sestava světla a kamery byla umístěna na konstrukci z hliníkových profilů, která byla instalována na nastavitelný stojan tak, aby se mohla případně upravit výška sestavy nad podložkou. Jako pozadí byl použit černý matný povrch, tak aby bylo dosaženo co největšího kontrastu mezi snímanou rukou uživatele a pozadím. Ceny všech použitých komponent systému shrnuje tabulka (Tabulka 1). Celá sestava kamery, optiky a osvětlení je zachycena na obrázcích (Obrázek 16) a (Obrázek 17).



**Obrázek 16 - Sestava kamery a osvětlení
(vlastní práce autora)**



**Obrázek 17 - Sestava kamery a osvětlení
(vlastní práce autora)**

7. Návrh a implementace softwarového řešení

Navrhovaný systém identifikace uživatele je založen na snímání ruky uživatele a následné extrakci biometrických charakteristik, které se porovnají s databází šablon. Výsledkem porovnání je šablona, která vykazuje nejvyšší shodu s aktuálním uživatelem. Překročí-li tato míra shody nastavený práh, je uživatel úspěšně identifikován.

Extrakce biometrických charakteristik bude založena na dvou odlišných postupech. Prvním postupem bude nalezení kontury ruky a následné vyhodnocení geometrie ruky. Druhým postupem bude vyhodnocení krevního řečiště na hřbetě ruky.

Celý systém se bude skládat ze dvou hlavních procesů. První proces bude vytvoření databáze šablon uživatelů. Druhý proces bude identifikace uživatele.

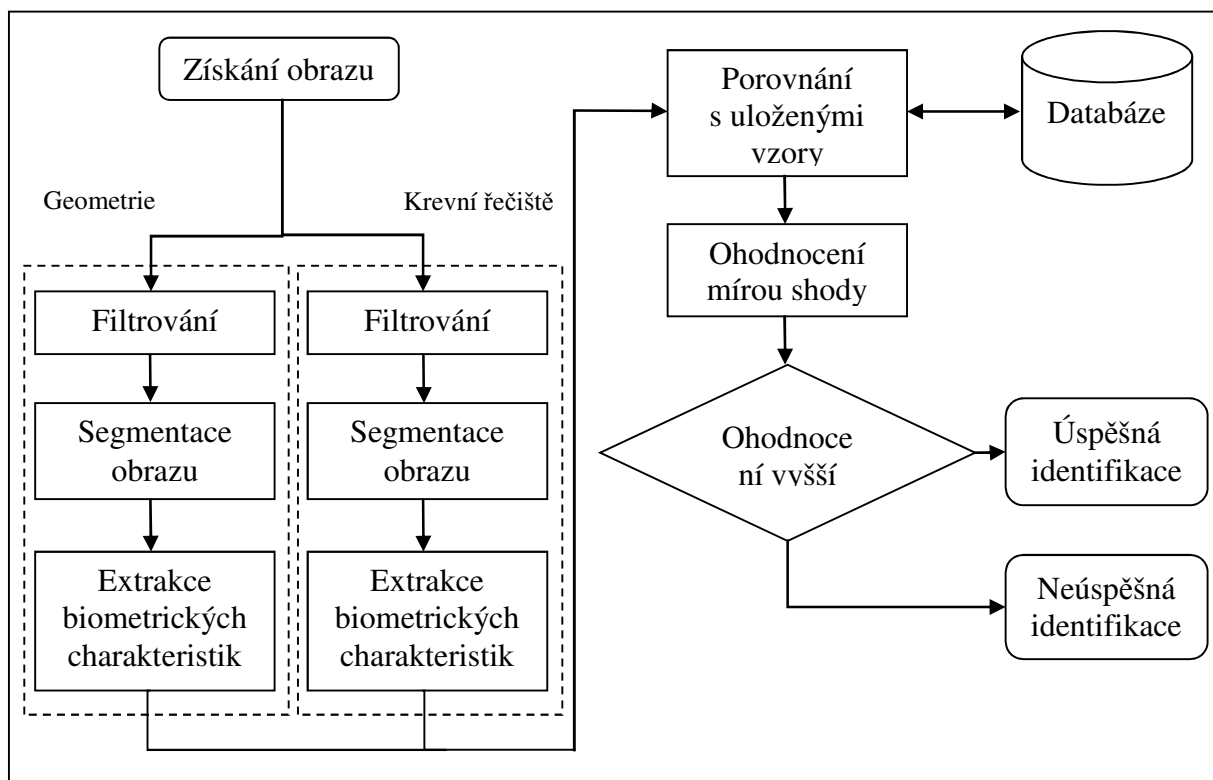
7.1 Použité softwarové nástroje

Celý experimentální software jsem vyvíjel v programovacím jazyku C# v prostředí Microsoft Visual Studio Express 2013.

Pro zpracování obrazu (filtrace obrazu, práce s konturou) jsem použil knihovnu OpenCV. Tato knihovna byla původně vyvíjena společností Intel. V dnešní době je poskytována pod licencí BSD a je dostupná zdarma pro akademické i komerční využití. OpenCV podporuje jazyky C, C++, Java a Python. Pro využití knihovny v jazyku C# jsem musel použít wrapper Emgu CV, který umožňuje volat funkce OpenCV z jazyků podporujících Microsoft .NET Framework.

7.2 Proces identifikace uživatele

Funkce celého softwarového systému identifikace uživatelů se skládá z kroků, které jsou znázorněny v diagramu na obrázku (Obrázek 18).



Obrázek 18 - Vývojový diagram identifikace uživatele (vlastní práce autora)

Proces zpracování a vyhodnocení obrazu začíná získáním obrazu. V reálném nasazení se nasnímá aktuální obraz kamerou, ve vytvořeném experimentálním systému jsem implementoval nahrávání obrazu ze souboru, který byl nasnímán kamerou pomocí popsáného hardwaru. Toto řešení jsem použil zejména z důvodu potřeby totožného vstupního obrazu pro testování různých nastavení a vyhodnocovacích algoritmů systému.

Následuje krok filtrace vstupního obrazu, který odstraní vady obrazu jako je šum a zkreslení. Dalším krokem je segmentace obrazu. Segmentace je postup, který umožní z nasnímaného obrazu extrahovat objekty zájmu a odlišit je tak od pozadí. Provádí se zvlášť pro geometrii ruky a zvlášť pro krevní řečiště. Výsledkem jsou dva segmentované obrazy. V případě hledání geometrie ruky se jedná o nalezení kontury snímané ruky uživatele, v případě krevního řečiště se jedná o další filtraci a skeletonizaci.

Následuje krok extrakce biometrických charakteristik. V tomto kroku dochází k převodu obrazových dat na matematický popis zkoumaného objektu. Tento krok má stěžejní význam

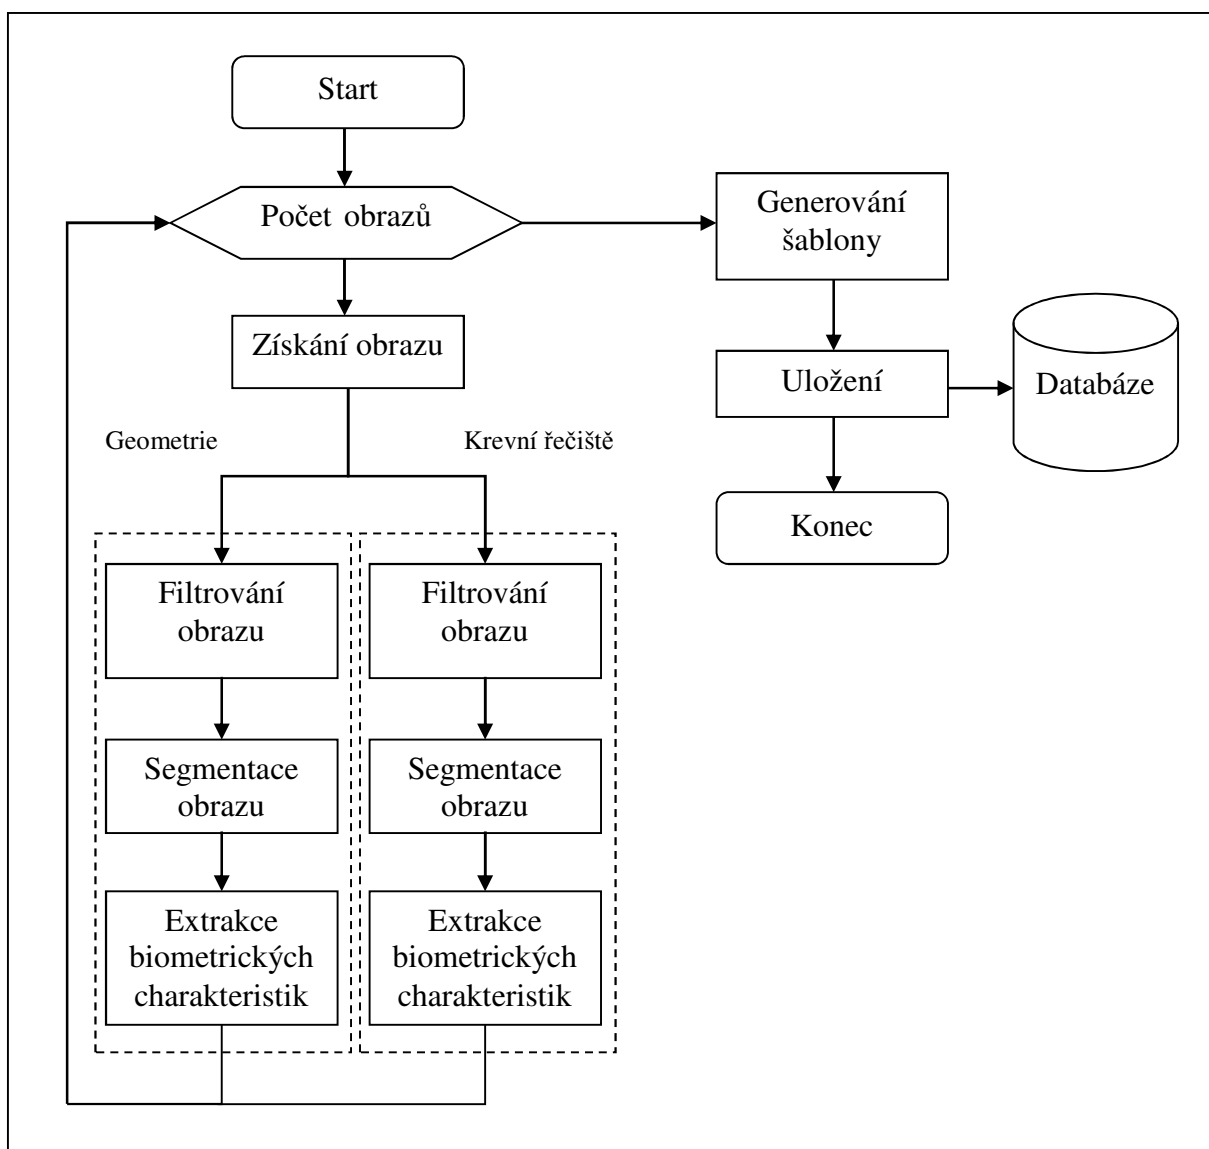
pro dosažení dobrých výsledků celého systému. Důležitá je nejen přesnost změřených charakteristik, ale také opakovatelnost. Opět se provádí zvlášť pro geometrii ruky a zvlášť pro krevní řečiště.

Následuje krok, v kterém se porovnají změřené biometrické charakteristiky s šablonami uloženými v databázi. Výsledkem porovnání je ohodnocení, které vyjadřuje míru shody pro každou šablonu z databáze.

Dalším krokem je vybrání šablony, která má nejvyšší míru shody se zkoumaným objektem.

Posledním krokem je vyhodnocení, zda nalezená nejvyšší míra shody překračuje minimální hodnotu prahu. Jestliže je tato podmínka splněna, dosáhl systém úspěšné identifikace uživatele.

7.3 Proces vytvoření šablony



Obrázek 19 - Vývojový diagram vytvoření šablony (vlastní práce autora)

Proces vytvoření šablony uživatele (Obrázek 19) začíná získáním minimálně třech různých obrazů ruky od uživatele. Získání obrazů je řešeno stejným způsobem jako při výše popsaném procesu identifikace uživatele.

V dalších krocích se postupuje obdobně jako v procesu identifikace uživatele až po extrakci biometrických charakteristik. Rozdíl je pouze v množství zpracovaných obrazů. Zatímco v případě procesu identifikace se vyhodnocuje pouze jeden obraz a výsledkem jsou extrahované biometrické charakteristiky, v případě tvorby nové šablony uživatele je zpracováno více obrazů a výsledkem je tedy sada více různých extrahovaných charakteristik.

V následujícím kroku je vytvořena vlastní šablona uživatele. Pro potřeby algoritmů, které jsou použity pro vypočítání míry shody, obsahuje šablona potřebná data, která se generují na základě získané sady biometrických charakteristik.

Posledním krokem je uložení šablony do databáze.

7.4 Získání obrazu

Snímání obrazu zajišťuje kamera, která převádí reálný obraz (fyzikální veličinu) do datové podoby. Paprsky záření procházejí nejdříve IR filtrem, který propustí pouze IR část spektra a ostatní vlnové délky potlačí. Dále paprsky prochází objektivem, v kterém se paprsky usměrní a zaostří. Objektivem lze také regulovat intenzitu propouštěného záření pomocí nastavitelné clony. Po průchodu objektivem dopadají paprsky na CCD čip kamery. Snímací čip je složen z mnoha na světlo citlivých snímačů uspořádaných do matice [15]. Dopadající záření na snímačích díky fotoefektu generuje kladný elektrický náboj. Tento náboj odpovídá intenzitě dopadajícího záření na jednotlivé snímače. Po skončení snímání se náboje jednotlivých snímačů přesouvají do zesilovače a AD převodníku, který převádí analogový signál na digitální data.

Data z kamery jsou do počítače přenášena pomocí rozhraní IEEE 1394b (FireWire). Pro snímání obrazu do počítače jsem použil software AVT Universal Package od výrobce kamery Allied Vision Technologies.

7.5 Filtrování obrazu

Část pro geometrii ruky

Obraz získaný z kamery obsahuje šum, který je nežádoucí a negativně ovlivňuje výsledky celého systému. Potlačení šumu zvýšíme přesnost a rychlost extrakce biometrických charakteristik. Šum vzniká ve snímači kamery jako výsledek nedokonalosti snímače, zesilovače a AD převodníku. Viz kapitola 3.4.

Pro potlačení šumu jsem použil filtrování obrazu. Bohužel při použití filtrů vždy dochází ke zlepšení jednoho parametru obrazu na úkor jiného. Například při použití vyhlazování obrazu potlačíme šum, ale na druhou stranu se potlačí nebo dokonce úplně odstraní tenké linky, které jsou v některých případech důležité. Proto vždy volíme nejvhodnější kompromis nastavení filtrů v závislosti na aktuálním cíli.

V mém případě jsem použil pro potlačení šumu v obraze metodu obyčejného průměrování. Metoda filtruje obraz tak, že jako nový jas bodu přiřadí aritmetický průměr jasu obdélníkového okolí bodu. Nevýhodou je velké rozmazávání hran, ale dobře funguje na rozsáhlé homogenní plochy. Opakovanou aplikací filtru je rozmazání silnější. Limitně vede tato operace k jednobarevnému obrazu, jehož barva je průměrem ze všech hodnot v obraze. Pro výpočet se využívá konvoluce, kdy velikost konvolučního jádra je volitelná (jedná se o parametr metody, s narůstajícími rozměry jádra se zesiluje efekt rozmazání) a všechny hodnoty jsou rovny jedné. Rovnice pro výpočet za použití jádra o velikosti 3x3:

$$f(i, j) = \frac{1}{9} \sum_{k=-1}^1 \sum_{l=-1}^1 g(i+k, j+l) \quad (11)$$

Pokud bychom měli n obrazů stejné scény, bylo by možné průměrovat body z různých obrazů podle rovnice (12) a nedošlo by k rozmazání obrazu. To však v mém případě není možné, protože uživatel může rukou pod kamerou hýbat, čímž by snímané obrazy nezachycovaly stejnou scénu.

$$f(i, j) = \frac{1}{n} \sum_{k=1}^n g_k(i, j) \quad (12)$$

Obraz dále obsahuje zkreslení, které je způsobeno objektivem. Jedná se hlavně o vinětaci a soudkovité zkreslení. Při vinětaci dochází k efektu, kdy v rozích obrazu má obraz nižší jas než uprostřed obrazu. Je to způsobeno průchodem paprsků přes čočky objektivu, kdy paprsky na


okrajích procházejí větším množstvím materiálu než uprostřed čočky. Při soudkovitém zkreslení dochází ke geometrické deformaci v rozích obrazu, v kterých se obraz „zaobluje“. Je to způsobeno vlastností čoček, kdy uprostřed čočky dochází k většímu zvětšení než při okraji čočky.

Obě tato zkreslení obrazu není potřeba v mém případě kompenzovat, protože nemají vliv na funkci systému. Tato zkreslení jsou totiž závislá na použitém objektivu (ohniskové vzdálenosti) a na zvolené cloně objektivu. V mém případě se tedy po zvolení ideálního objektivu a finálním nastavení clony objektivu nebudou tyto parametry po celou dobu testování systému měnit. To znamená, že toto pevné zkreslení budou obsahovat snímky při učení nových charakteristik pro nové uživatele systému. Stejně zkreslení budou obsahovat také snímky při identifikaci uživatelů.

Část pro krevní řečiště

Prvním krokem je nalezení regionu zájmu (ROI). Je to část obrazu, která obsahuje objekt zájmu (krevní řečiště na hřbetě ruky). Je vhodné pracovat pouze s touto menší částí obrazu. Důvodem je snížení výpočetní náročnosti a tím zrychlení procesu vyhodnocení obrazu.

Pozice a velikost ROI se určuje podle pozice a tvaru zkoumané ruky. To znamená, že extrakce biometrických charakteristik krevního řečiště se musí provádět až po zpracování charakteristik tvaru ruky. Způsob definice ROI popisuje obrázek (Obrázek 20).




Obrázek 20 - Definice ROI (vlastní práce autora)

Nejdříve se nalezne přímka mezi body „údolí“ číslo 2 a 4, která se následně posune do středu ruky. To zajistí vyloučení oblastí v blízkosti „údolí“ mezi prsty, v kterých by nebylo vhodné provádět extrakci charakteristik krevního řečiště. V okolí „údolí“ se projevuje nerovnost pokožky a vznikají stíny, které by negativně ovlivňovaly extrakci charakteristik krevního řečiště. Začátek oblasti ROI začíná až na úrovni kloubů, které díky infračervenému nasvícení scény neovlivňují obraz. Na obrázcích (Obrázek 21) a (Obrázek 22) je vidět rozdíl mezi obrazy snímanými barevnou kamerou a černobílou kamerou s využitím IR osvětlení a IR filtru.



**Obrázek 21 - Žíly a kůže snímané barevnou kamerou
(vlastní práce autora)**




**Obrázek 22 - Žíly a kůže snímané s využitím IR osvětlení
(vlastní práce autora)**

Šířka ROI odpovídá vzdálenosti bodů „údolí“ číslo 2 a 4. Pro každého uživatele, ale i pro každý jednotlivý snímek, může být šířka ROI rozdílná. Výška ROI je vypočtena jako 1,4 násobek šířky.

Dalším krokem je zkopírování obrazu z ROI do nové instance obrazu a následná rotace. Rotace obrazu zajistí, aby byl obraz krevního řečiště orientován delší stranou na výšku. Výsledek po kopírování ROI a rotaci je vidět na obrázku (Obrázek 23).



Obrázek 23 - Krevní řečiště před filtrací (vlastní práce autora)



Obrázek 24 - Krevní řečiště po mediánové filtraci (vlastní práce autora)



Obrázek 25 - Krevní řečiště po ekvalizaci (vlastní práce autora)

Následuje filtrování obrazu. Nejdříve jsem obraz filtroval pomocí filtru medián s poměrně velkým okolím bodu (11 pixelů). Tím jsem dosáhl velkého vyhlazení obrazu, kdy jsou z obrazu odstraněny vrásky kůže a případné ochlupení, ale zároveň zůstanou zachovány tvary žil. Tento filtr se běžně využívá především pro odstranění drobnějších vad obrazu, ale v tomto případě byl úspěšně využit pro zachování pouze tvaru žil. Výsledek je vidět na obrázku (Obrázek 24).

Algoritmus mediánového filtru prochází všechny pixely obrazu. Pro každý pixel z původního obrazu se vyberou pixely z jeho okolí. Pixely se seřadí podle hodnoty jejich intenzity. Ze seřazených pixelů se vybere pixel ležící uprostřed. Výsledná intenzita pixelu v novém obrazu po filtraci odpovídá intenzitě vybraného pixelu. Okolí může mít různý tvar, ale ve většině případů se použije čtverec.

Pro další úpravu obrazu jsem použil ekvalizaci histogramu. Jedná se o úpravu jasů jednotlivých pixelů v závislosti na histogramu. U obrazů s podobnými intenzitami pixelů, jako v mém případě, dojde ke zvýšení kontrastu. Tímto postupem se zvětšil rozdíl mezi pozadím a objektem zájmu (krevním řečištěm). Výsledek zachycen na obrázku (Obrázek 25).

7.6 Segmentace obrazu

Část pro geometrii ruky

Segmentace obrazu je jeho dělení na oblasti, jejichž vlastnosti jsou v určitých ohledech podobné. Typickou úlohou segmentace je odlišit objekty zájmu od sebe navzájem a také od pozadí. Existuje řada metod, které lze při segmentaci využít. Mezi základní patří metody založené na zkoumání histogramu (k určení prahu při prahování), další zkoumají podobnost, nebo shodu pixelů v okolí zkoumaného pixelu (tzv. region growing), nebo naopak rozdíly mezi sousedícími pixely.

V mém případě jsem použil segmentaci metodou prahování. Mnoho objektů nebo oblastí obrazu je charakterizováno konstantní odrazivostí, či pohltivostí svého povrchu. Potom je možné využít určené jasové konstanty prahu k oddělení objektů od pozadí. Vzhledem k výpočetní nenáročnosti je prahování nejrychlejší segmentační metodou. Výsledkem prahování je v ideálním případě kompletní segmentace požadovaných objektů.

Jedná se o transformaci vstupního obrazu f na výstupní binární obraz f' dle vztahu:

$$f'(i, j) = \begin{cases} 1 & \text{pro } f(i, j) \geq T \\ 0 & \text{pro } f(i, j) < T \end{cases} \quad (13)$$

Kde T je předem určená konstanta (práh) a $f'(i, j) = 1$ pro části obrazu náležící ke zkoumaným objektům. Práhování testuje postupně všechny obrazové elementy obrazu a přiřazuje jim hodnoty podle zadaných podmínek. Zásadní problém metody je zvolení správné hodnoty prahu T . Hodnotu prahu lze zadat ručně jako konstantu nezávislou na obrazu, což je možné použít pouze u aplikací, při kterých máme garantované neměnné úrovně jasu objektů a pozadí a zároveň jsou objekty i pozadí homogenní. U aplikací, kdy předem nevíme, jak hodně se může hodnota jasu měnit, musíme volit některou z metod automatického nastavení prahu.

Existují dvě základní metody automatického nastavení jasu: s využitím globálních vlastností obrazu nebo s využitím lokálních vlastností obrazu.

Metoda využívající globálních vlastností obrazu využívá k určení hodnoty prahu informace ze všech pixelů v obraze. Práh se určí podle histogramu nebo se použije průměrná hodnota intenzity všech obrazových bodů v obraze.

Druhou metodou je použití různého prahu pro každý element obrazu, který se vypočítá z blízkého okolí bodu. Výpočet hodnoty pixelu se provede podle rovnice:

$$f'(i, j) = \begin{cases} 1 & \text{pro } f(i, j) \geq (\mu_{ij} - T_g) \\ 0 & \text{pro } f(i, j) < (\mu_{ij} - T_g) \end{cases} \quad (14)$$

Kde μ_{ij} je právě průměrná hodnota všech bodů z blízkého okolí bodu. Velikost okolí se zvolí podle zamýšleného cíle segmentace a je závislé hlavně na velikosti a tvaru zkoumaných objektů. Konstanta T_g je hodnota, o kterou se práh dodatečně upraví. Hodnota bývá kladné číslo, ale lze použít i záporné. Opět volíme v závislosti na požadovaném výsledku segmentace, určuje se empiricky pro danou úlohu.

V experimentálním softwaru jsem testoval použití prahování s automatickým nastavením prahu podle lokálního okolí bodu. Toto řešení jsem zvolil z důvodu jisté nehomogenity zkoumaného objektu (ruky). Tato nehomogenita je způsobena například vráskami na kůži, různou barvou kůže atd. Bohužel jsem nebyl schopen docílit takového nastavení parametrů prahování, jako je velikost okolí a konstanta T_g , při kterých by výsledný obraz byl vhodný k dalšímu zpracování (nalezení kontury ruky). Proto jsem nakonec využil prahování založené na globálním nastavení prahu pro celý obraz v závislosti na průměrné hodnotě intenzity v celém obraze sníženou o konstantu. Tato metoda poskytla nejlepší obraz vhodný pro další zpracování.

Následující obrázky znázorňující různé chyby prahování. Obrázek (Obrázek 26) zobrazuje výchozí obraz prahování. Obrázek (Obrázek 27) zobrazuje výsledek prahování s příliš vysokým prahem, kdy už mizí části objektu zájmu. Na obrázku (Obrázek 28) je výsledek prahování s příliš nízkým prahem. K objektu zájmu se přidala část pozadí. Poslední obrázek (Obrázek 29) zobrazuje ideální stav po úspěšném prahování.



Obrázek 26 - Zdrojový obraz ruky
(vlastní práce autora)



Obrázek 27 - Prahování s příliš vysokým prahem
(vlastní práce autora)



Obrázek 28 - Prahování s příliš nízkým prahem
(vlastní práce autora)




Obrázek 29 - Prahování s ideálním prahem
(vlastní práce autora)

Část pro krevní řečiště

Zpracování obrazu v experimentálním softwaru pokračuje adaptivním prahováním krevního řečiště (Obrázek 30 a)). Využil jsem stejné metody prahování jako v případě výše popsaném prahování obrazu pro geometrii ruky. Získaný obraz odpovídá krevnímu řečišti velkých žil. Bohužel se v získaném obraze vyskytuje hodně šumu a neúplných čar. Proto se obraz musí dále filtrovat.

Pro vyhlazení obrazu jsem použil opět mediánový filtr v kombinaci s morfologickými filtry. Nejdříve se provede mediánový filtr s velikostí okolí bodu 3 pixely, který odstraní drobné fragmenty v obrazu (Obrázek 30 b)). Následuje dilatace, která je použita dvakrát iterativně. Dilatací se z části spojí jednotlivé části žil, které nebyly spojené v důsledku šumu a chyb v obraze (Obrázek 30 c)). Posledním filtrem v sérii je eroze. Eroze zajistí další vyhlazení obrazu a z části odstraní drobné chyby v obraze (Obrázek 30 d)).



a) b) c) d)
Obrázek 30 - Postup filtrace krevního řečiště: a) po prahování; b) po mediánové filtraci; c) po dilataci; d) výsledek
(vlastní práce autora)

Při návrhu a realizaci dalšího postupu zpracování obrazu a následné extrakci a vyhodnocení biometrických charakteristik krevního řečiště jsem vycházel z podobnosti získaného obrazu s obrazem otisku prstů při daktyloskopii, na kterou upozornil ve své práci Lingyu Wang a kolektiv [16].

Po vyhlazení obrazu výše popsány filtry jsem postupným ztenčováním obrazu provedl skeletizaci (nalezení kostry) obrazu. Skeletizace se využívá především v biometrických systémech při daktyloskopii pro strojové zpracování otisků prstů [17]. Jednotlivé papilární linie na otisku prstu jsou totiž příliš tlusté a vznikalo by při vyhodnocování větvení k chybám. Právě z tohoto důvodu jsou papilární linie v obrazu transformovány do čar o tloušťce jednoho pixelu, které tvoří kostru původních linií. Větvení a konce čar na této kostře odpovídá původním liniím, ale je jednodušší na vyhodnocení.

Ztenčení je morfologická operace, která se používá k odstranění vybraných pixelů z binárních obrazů, podobně jako eroze či otevření. Při ztenčování se okrajové pixely odečítají od objektů, ale nikoliv ty pixely, jejichž zmizení by již způsobilo rozdělení objektu na více částí. Neodstraňuje se tedy ta část hranice objektů, která by způsobila porušení souvislosti objektů.

Ve spojitém prostoru je kostra (skeleton) definována jako množina středů maximálních vepsaných kruhů uvnitř objektů. Maximální vepsaný kruh je takový kruh, který se okraje objektu dotýká ve dvou a více bodech a tedy již nelze dále zvětšit. Takto definovaná kostra ale pro diskrétní obrazy nezaručuje jednopixelovou tloušťku skeletů. Proto se v algoritmech strojového vidění řeší skeletonizace pomocí postupného ztenčování.


Existuje několik algoritmů řešící iterativní ztenčování. V roce 1986 Alberto Martin a kolektiv [18] analyzoval několik různých ztenčovacích algoritmů. V této práci zjistil, že nejlepší výsledky z hlediska spolehlivosti a efektivity podávají algoritmy založené na metodě vzorů a metodě „označ a vymaž“. Tyto algoritmy hledají v obraze v každé iteraci známé vzory, většinou o rozměrech 3x3 pixely, které nasvědčují tomu, že se zkoumaný pixel nachází na okraji objektu. Když je nalezen známý vzor, středový pixel je označen. Jestliže tyto označené pixely odpovídají podmínkám nerozdělení zkoumaného objektu, jsou na konci iterace vymazány. Algoritmus končí, když na konci iterace není označen žádný pixel k vymazání.

Jedním ze zástupců této skupiny algoritmů, který jsem vybral pro implementaci do experimentálního softwaru, je ztenčovací algoritmus Zhang-Suen [19]. Vyniká jednoduchostí implementace, dobrou odolností vůči rozdělení objektu a dobrou odolností při vyhodnocování nekvalitní kontury objektu.

Algoritmus Zhang-Suen používá jako jednu z podmínek pro vymazání pixelu tzv. počet

propojení pixelu. Jedná se o počet samostatných propojení zkoumaného pixelu s pixely objektu zájmu. Počet propojení může mít hodnotu v rozmezí 0-4. Na obrázku (Obrázek 31) jsou zobrazené příklady okolí pixelu. Počet propojení je následující:


- a) 0 propojení,
- b) 1 propojení,
- c) 2 propojení,
- d) 3 propojení,
- e) 4 propojení.



Obrázek 31 – Příklady počtů propojení pixelu (vlastní práce autora)

Počet propojení se vyhodnocuje na základě počtu přechodů mezi sousedními pixely, při kterých se změní hodnota pixelu (objekt zájmu / pozadí a obráceně). Tento počet přechodů odpovídá po vydělení dvěma počtu propojení. Označení pixelů při popisu funkce algoritmu zachycuje obrázek (Obrázek 32).

Iterace v algoritmu Zhang-Suen se skládá ze dvou částí (dílčích iterací). V každé dílčí iteraci algoritmus prochází všechny pixely patřící do objektu zájmu (většinou černé pixely). Při splnění všech podmínek dané iterace dojde k vymazání okrajového pixelu (změní se intenzita na bílou). V první dílčí iteraci se označují a mažou jižní a východní okrajové pixely a severozápadní rohové pixely, v druhé pak severní a západní okrajové pixely a jihovýchodní rohové pixely.



Obrázek 32 - Označení pixelů v algoritmu výpočtu počtu propojení pixelu (vlastní práce autora)

Podmínky pro vymazání okrajových pixelů pro první dílčí iteraci jsou následující:


- a) Počet propojení pixelu se rovná jedné.
- b) Počet sousedních pixelů, které patří do objektu zájmu, je nejméně 2 a ne více než 6.
- c) Alespoň jeden z bodů P2, P4 nebo P6 patří do pozadí (bílé).
- d) Alespoň jeden z bodů P4, P6 nebo P8 patří do pozadí (bílé).

Po dokončení iterace jsou všechny označené okrajové pixely, které splňují všechny podmínky, vymazány z objektu zájmu a stávají se pozadím. Podmínky pro vymazání okrajových pixelů pro druhou dílčí iteraci jsou následující:

- a) Počet propojení pixelu se rovná jedné.
- b) Počet sousedních pixelů, které patří do objektu zájmu, je nejméně 2 a ne více než 6.
- c) Alespoň jeden z bodů P2, P4 nebo P8 patří do pozadí (bílé).
- d) Alespoň jeden z bodů P2, P6 nebo P8 patří do pozadí (bílé).

Po dokončení iterace jsou všechny označené okrajové pixely, které splňují všechny podmínky, vymazány z objektu zájmu a stávají se pozadím. Průběh iterací je znázorněn na obrázku (Obrázek 33).

Algoritmus končí, když po poslední iteraci nedošlo k odstranění žádného okrajového bodu z objektu zájmu. Znamená to, že obraz se rovná kostře původního obrazu a dalším ztenčováním by došlo k rozdělení kostry do více částí.




a) b) c) d)
Obrázek 33 - Postup ztenčování: a) 2. iterace; b) 6. iterace; c) 10. iterace; d) výsledek (vlastní práce autora)


Jak je vidět na posledním obrázku (Obrázek 33 d)), vlivem vad v obraze zůstali součástí kostry také body nebo neukončené čáry. Jsou to například žíly, které v jednom místě zabíhají hlouběji do tkáně ruky a pro kameru jsou již neviditelné. Tyto artefakty je nutné před vlastní extrakcí eliminovat.

K eliminaci jsem použil vlastní filtr obrazu, který je založen na počtu propojení pixelu.

Algoritmus filtru prochází všechny pixely obrazu a hledá pixely, které jsou na konci čáry nebo osamocené pixely. Ohodnocení, zda pixel je na konci čáry, respektive je osamocený, vychází z výše popsaného principu počtu propojení pixelu. Je-li počet propojení pro zkoumaný pixel 0, jedná se o samostatný pixel a hned dojde k vymazání pixelu. Je-li počet propojení 1, jedná se o pixel na konci čáry. Je-li zároveň pixel uprostřed obrazu, jedná se o neukončenou čáru a pixel je vymazán. Zároveň algoritmus nalezne v okolí vymazaného pixelu pokračování čáry (nový koncový bod neukončené čáry) a opět provede kontrolu, zda se jedná o koncový bod nebo zda bylo dosaženo rozdvojení, odkud neúplná čára vycházela. Tímto způsobem jsou odstraněny vždy celé neúplné čáry. Až po kompletním odstranění neúplné čáry algoritmus pokračuje v procházení obrazu pixel po pixelu a hledá další koncový pixel neúplné čáry. Díky tomu je obraz vyčištěn v jediném kroku. Obrázek (Obrázek 34) zachycuje výchozí obraz s označenými neúplnými čárami. Na obrázku (Obrázek 35) je výsledný obraz po odstranění neúplných čar.



Obrázek 34 - Kostra s označenými částmi k odstranění
(vlastní práce autora)



Obrázek 35 - Kostra po odstranění neúplných čar
(vlastní práce autora)

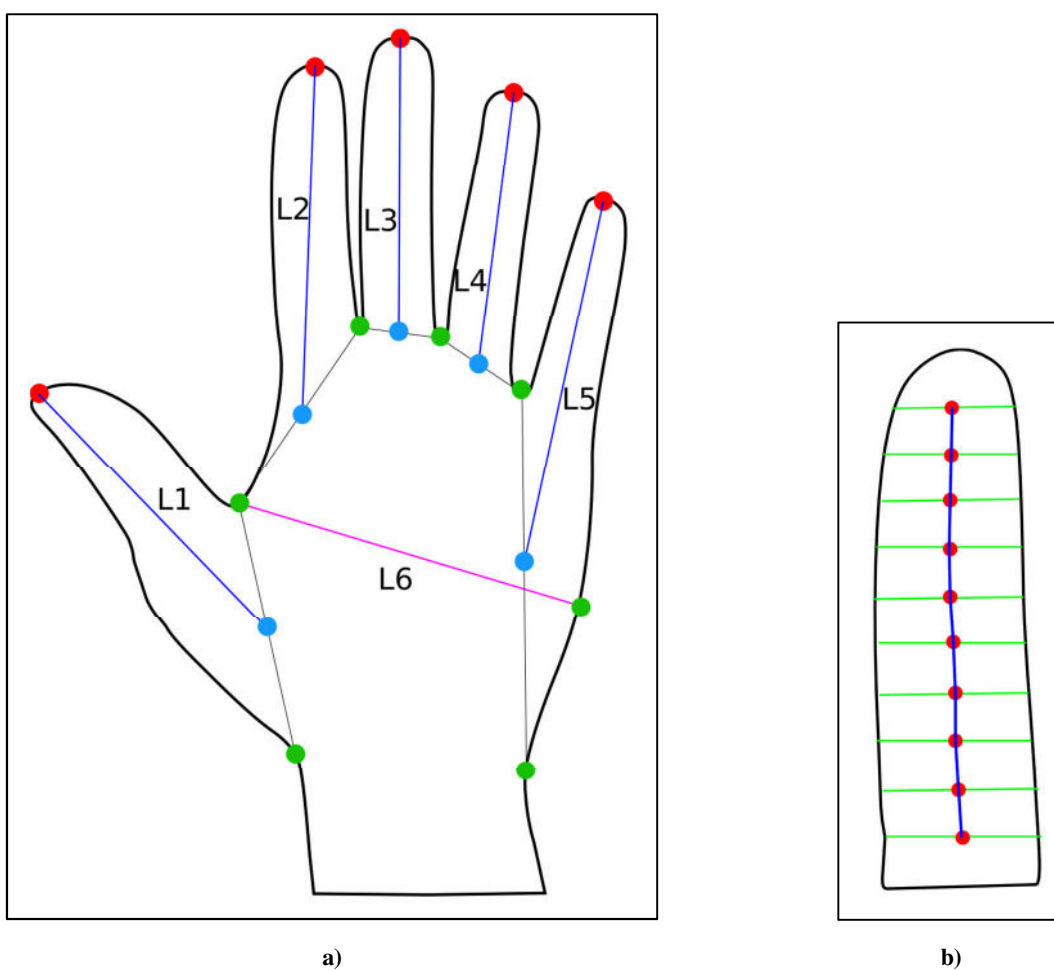
Tímto posledním krokem odstranění neúplných čar jsem získal kostru, která zachycuje rozložení velkých žil krevního řečiště. Tato forma je vhodná pro extrakci biometrických charakteristik.

7.7 Definice biometrických charakteristik

Geometrie ruky

Při návrhu biometrických charakteristik, s kterými bude experimentální systém pracovat, jsem vycházel z práce Nidhi Saxen a kolektivu [20] a A.Wong and P. Shi [10].

Měřené charakteristiky, které jsem použil v experimentálním projektu, popisuje následující obrázek (Obrázek 36).




Obrázek 36 - Znáznornění měřených biometrických charakteristik (vlastní práce autora)


Na obrázku (Obrázek 36 a)) jsou znázorněny měřené charakteristiky na dlani. Měří se délky jednotlivých prstů ruky, vždy od konce prstu (červený bod) ke středu jeho základny (modrý bod). Základna je definována přímkou procházející sousedními „údolími“ (zelené body). Dále se měří vzdálenosti mezi konci prstů, ale bez vzdálenosti palec-ukazovák. Důvod vyloučení této vzdálenosti je její přílišná variabilita. To znamená, že rozdíly této vzdálenosti na více snímcích od jednoho uživatele byly větší než rozdíly mezi uživateli. Měří se také vzdálenosti bodů „údolí“, ale opět bez palce. Jako poslední charakteristika se měří šířka dlaně L6.

Na obrázku (Obrázek 36 b)) je detail jednoho z prstů ruky, na kterém jsou znázorněny měřené charakteristiky pro každý prst ruky. Měří se vždy v deseti bodech, které jsou rovnoměrně rozloženy po celé délce prstu. V každém bodě se měří šířka prstu. Dále se určuje pozice středu (červený bod), z které se vypočítá úhel, který svírají dva sousední úseky (naznačeno modrými úsečkami).


Na následujících grafech (Graf 4), (Graf 5) a (Graf 6) jsou zachyceny rozdíly biometrických charakteristik pro dva různé uživatele. Data jsou získána ze sady čtyř obrazů pro každého uživatele.



Graf 4 - Porovnání šířek prstů dvou uživatelů (vlastní práce autora)




Graf 5 – Porovnání vzdálenosti mezi konci prstů (vlastní práce autora)



Graf 6 - Porovnání délek prstů (vlastní práce autora)

Krevní řečiště

Při definování vhodných biometrických charakteristik pro identifikaci osob pomocí krevního řečiště jsem vycházel z práce Lingyu Wanga a kolektivu [16]. Při definování biometrických charakteristik jsem využil podobnosti krevního řečiště a otisku prstů. Při identifikaci osoby podle otisku prstů se místo porovnání celého obrazu (na základě vzoru) využívá porovnání pozic kritických bodů, tzv. markantů. Markantem v případě vyhodnocení otisků prstů může být začátek a konec papilární linie, bifurkace (rozdvojení), háček, očko, atd. Příklady markantů jsou na obrázku (Obrázek 37). Podobně lze stejné postupy použít pro identifikaci osob pomocí krevního řečiště.



Obrázek 37 – Základní typy markantů využívané při daktyloskopii [21]

Pro potřeby navrhovaného experimentálního softwaru jsem definoval dva typy markantů: větvení žil a ukončení žil na kraji obrazu. Počet nalezených markantů se liší pro každého uživatele, ale pro jednoho uživatele by měl být stejný při každém snímání. Protože výřez z původního obrazu, na kterém se provádí extrakce biometrických charakteristik krevního řečiště, je správně orientován a zaměřen vzhledem ke zkoumané ruce uživatele, měly by pozice markantů při vícenásobném opakování snímání pro jednoho uživatele zůstat na stejné pozici. Proto experimentální software pracuje se souřadnicemi markantů vztažených přímo k obrazu krevního řečiště.

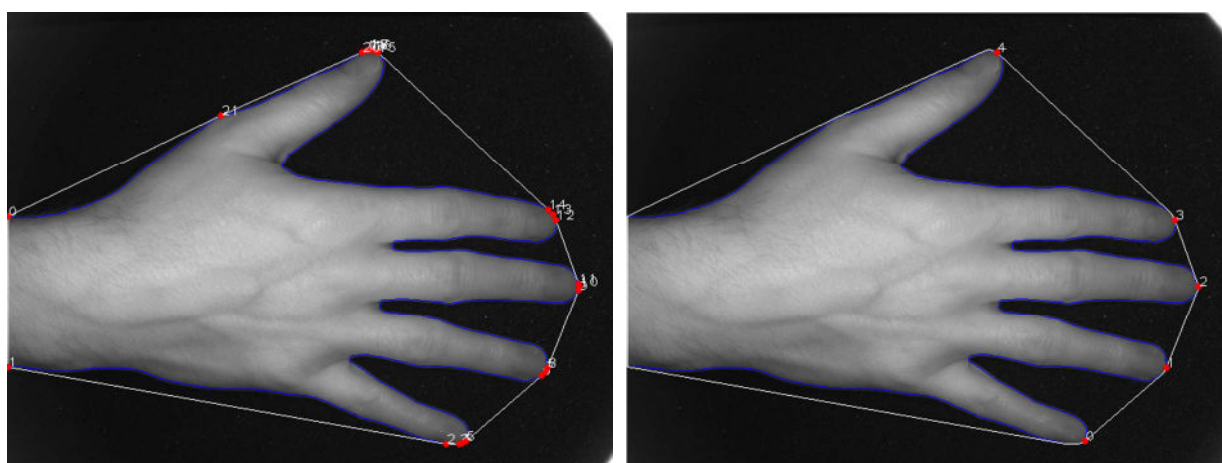
7.8 Extrakce biometrických charakteristik

Algoritmus pro geometrii ruky

Výsledkem segmentace je binární obraz (pozadí má hodnotu 0, objekty hodnotu 255), v kterém bude algoritmus hledat charakteristiky popisující zkoumané objekty. Hlavní důvod extrakce charakteristik je úspora objemu dat šablon a vyšší rychlost zpracování.

Vlastní algoritmus extrakce nejdříve nalezne konturu, která odpovídá tvaru testované ruky. Nalezení kontury je v tomto případě jednoduché, protože hledaná linie souvisejících bodů, která tvoří konturu, je jasně definovaná díky binárnímu obrazu získaného předzpracováním obrazu. Pro nalezení kontury jsem využil funkci `findContour` z knihovny `OpenCV`, která implementuje algoritmus popsany S.Suzuki a K. Abe [22]. Algoritmus extrakce biometrických charakteristik dále pracuje pouze s nalezenou konturou.


Dalším krokem v algoritmu extrakce je nalezení konvexní obálky kontury, která je využita k nalezení bodů na koncích prstů. Jedná se o polygon, který je tvořen nejkrajnějšími body kontury. Výsledkem je tedy sekvence bodů tvořící obal. V této sekvenci bodů se nacházejí nejen konce prstů ruky, ale i další nežádoucí body (Obrázek 38 a)). Jsou to například nepotřebné body na zápěstí nebo vícenásobný bod na konci prstu. Nežádoucí body jsem podle několika jednoduchých kritérií identifikoval a odstranil (Obrázek 38 b)). Mezi kritéria patří vzdálenost sousedních bodů a pozice bodu v obraze.




a) b)
Obrázek 38 - Konvexní obálka kontury: a) kompletní; b) po filtraci nežádoucích bodů (vlastní práce autora)

Následně algoritmus hledá body v údolích mezi prsty. Opět se využije kontura ruky, na které se hledají defekty. Defekt je v tomto případě bod na kontuře, který je na úseku vymezeném dvěma sousedními body obálky, který je nejdál od přímky spojující body obálky. To znamená,

že mezi každými dvěma body v sekvenci konvexní obálky je nalezen jeden defekt. Proto se nalezené defekty (Obrázek 39) filtrují na minimální hloubku (vzdálenost od obálky), čímž se eliminují drobné defekty a zůstanou pouze defekty odpovídající údolím mezi prsty. Způsob měření minimální hloubky znázorňuje obrázek (Obrázek 40).




Obrázek 39 - Nalezené body v údolích (vlastní práce autora)



Obrázek 40 - Znázornění minimální hloubky údolí (vlastní práce autora)

V dalším kroku dochází k vlastnímu měření biometrických charakteristik. Měří se charakteristiky pro každý prst a také souhrnné charakteristiky pro celou ruku.

Pro každý prst se nejdříve definuje jeho koncový bod a dva body sousedních údolí. Mezi těmito body údolí se vypočítá střed, kterým se vede osu prstu do koncového bodu. Touto osou je definován směr prstu. Dále se určí začátek prstu, který je dán bodem údolí (použije se bod údolí bližší ke konci prstu). Změří se délka prstu jako vzdálenost mezi koncem a začátkem prstu. Délka prstu se rozdělí na deset dílů. Ukázka měření biometrických charakteristik jednoho prstu je na obrázku (Obrázek 41).




Obrázek 41 - Znázornění měření délky a šířky prstů (vlastní práce autora)

Algoritmus postupuje od konečku prstu. V každém kroku se posune po ose prstu o jeden díl. V každém kroku se měří šířka a střed prstu. Koncové body prstu se určí jako průsečík kolmice k ose prstu a kontury ruky.

Při testování experimentálního softwaru a porovnání výsledků jsem upravil algoritmus

extrakce. Úprava spočívá v měření šířek prstů pouze v bodech na 2., 3., 6., 7. a 8. pozici. Měření úhlů jsem zredukoval na měření mezi pozicí 1., 3., 7. a 10. Podle předchozích výsledků se v těchto bodech biometrické charakteristiky nejvíce liší. Měření pouze v těchto bodech má tedy největší přínos pro rozlišení uživatelů.



Obrázek 42 – Znázornění všech měřených charakteristik na ruce (vlastní práce autora)


Na celé ruce se měří vzdálenosti konců prstů mezi sebou a vzdálenosti mezi údolími. Jako poslední biometrická charakteristika se změří šířka dlaně. Ta je definována bodem počátku (údolí mezi palcem a ukazovákem) a směrem (paralelní přímka s přímkou spojující údolí 4 a 3). V daném směru se hledá průsečík s konturou ruky. Celkový obraz ruky po měření biometrických charakteristik zobrazuje obrázek (Obrázek 42).

Algoritmus pro krevní řečiště


Pro extrakci markantů z obrazu jsem opět využil principu počtu propojení pixelu.

Algoritmus prochází každý pixel obrazu kostry krevního řečiště. Pro každý pixel, který patří k objektu zájmu, se spočítá počet propojení pixelu. Každý pixel, který má počet propojení vyšší než 3, je bodem větvení a je označen jako markant. Každý pixel, který má počet propojení 1 a je na okraji obrazu, je konečný bod žíly a je také označen jako markant.


Následující grafy (Graf 7), (Graf 8) a (Graf 9) zobrazují četnosti výskytu podle počtu markantů v jednotlivých obrazech. Průměrný počet markantů v obrazech byl 18,6, průměrný počet bodů větvení 7,9 a průměrný počet konců žil 10,7. Počty nalezených markantů nejsou velké, ale vzhledem k velké rozlišovací síle stačí tento menší počet markantů k identifikaci osoby[16].



Graf 7 – Histogram celkového počtu markantů žil (vlastní práce autora)



Graf 8 – Histogram počtu větvení žil
(vlastní práce autora)



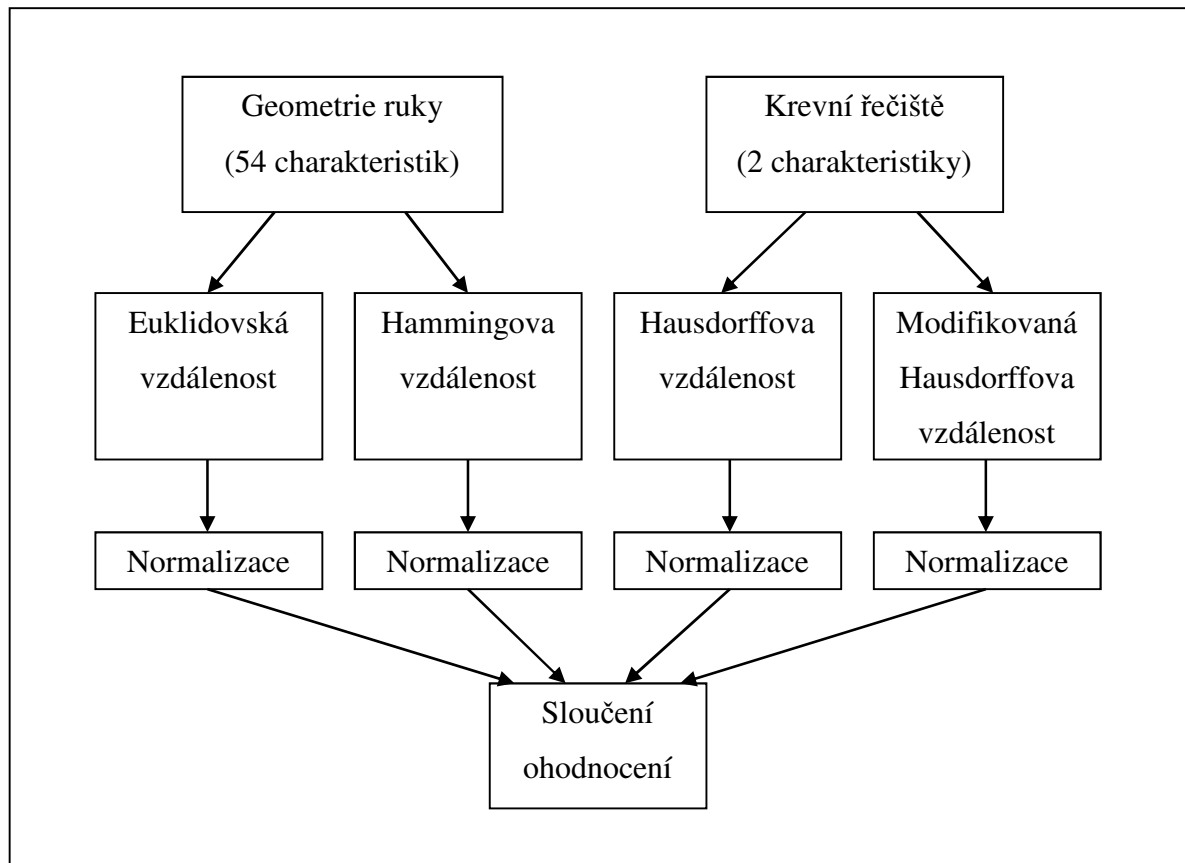
Graf 9 – Histogram počtu konců žil
(vlastní práce autora)

7.9 Ohodnocení mírou shody

Poslední fází v procesu identifikace uživatele je porovnání biometrických charakteristik uživatele s uloženými šablonami známých uživatelů. K porovnání se používají různé techniky a postupy souhrnně označované jako metriky. Vývojový diagram znázorňující proces výpočtu celkové míry shody je na obrázku (Obrázek 43).

V experimentálním softwaru jsem použil pro ohodnocení míry shody vždy dvě různé metriky pro dané biometrické charakteristiky. Pro geometrii ruky to byla euklidovská vzdálenost a Hammingova vzdálenost. Pro krevní řečiště to byla Hausdorffova vzdálenost a modifikovaná Hausdorffova vzdálenost.

Pro výpočet celkového ohodnocení je potřeba nejdříve jednotlivé výstupy z různých metrik normalizovat. Normalizace zajistí, aby všechny mezivýsledky měly stejnou váhu bez ohledu na použité metodě.



Obrázek 43 - Vývojový diagram pro výpočet míry shody (vlastní práce autora)

Euklidovská vzdálenost

Jedná se o vzdálenost dvou bodů v n -rozměrném prostoru. Vypočítá se podle rovnice:

$$d = \sqrt{\sum_{i=1}^N (x_i - t_i)^2} \quad (15)$$

kde n je počet dimenzí, což je v případě porovnání šablony a testovacích dat počet změřených biometrických charakteristik, x_i je i -tý prvek testovaných dat a t_i je i -tý prvek šablony. Počet dimenzí šablony i testovacích dat je shodný. Výsledná hodnota je tedy součet všech rozdílů mezi šablonou a testovacími daty.

Hammingova vzdálenost

Pojem Hammingova vzdálenost pochází z teorie informace. Při porovnání dvou řetězců stejné délky označuje Hammingova vzdálenost nejmenší počet pozic, v kterých se liší. Neboli počet záměn, které je potřeba provést pro změnu jednoho z řetězců na druhý.

R. S. Reillo a kolektiv [32] ve své práci zobecnil Hammingovu vzdálenost do formy vhodné

pro ohodnocování podobnosti biometrických dat. Navrhl použít porovnání na základě počtu nesouhlasných biometrických charakteristik. Výsledkem je metrika, která neměří velikost odchylky, tak jako Euklidovská vzdálenost, ale udává počet jednotlivých biometrických charakteristik, u kterých je při porovnání testovacích dat se šablonou odchylka větší než směrodatná odchylka pro biometrickou charakteristiku. Směrodatná odchylka se pro každou charakteristiku definuje při generování šablony. Směrodatná odchylka byla zvolena díky předpokladu, že charakteristiky jednoho uživatele při vícenásobném vyfocení nikdy nebudou úplně stejné. Předpokládané rozdělení hodnot pro danou charakteristiku odpovídá normálnímu rozdělení. Hammingova vzdálenost se vypočítá podle rovnice:

$$d(x_i, \bar{x}_i) = \#\{i \in \{1..N\} / |x_i - \bar{x}_i| > \sigma_i\} \quad (16)$$

kde x_i je biometrická charakteristika testovacích dat s pořadovým číslem i , \bar{x}_i je průměr biometrické charakteristiky (ze šablony) s pořadovým číslem i , N je celkový počet biometrických charakteristik pro danou šablonu, σ_i je směrodatná odchylka (ze šablony) s pořadovým číslem i .

Hausdorffova vzdálenost

Pojmenována po německém matematikovi Felixovi Hausdorffovi. Jedná se o teorii, která měří, jak daleko jsou od sebe vzdáleny dvě množiny bodů v metrickém prostoru.

Jinými slovy, dvě množiny jsou si blízko, jestliže v okolí každého bodu jedné množiny se nachází nějaký bod z druhé množiny. Hausdorffova vzdálenost (dále jen HV) je potom nejdelší vzdálenost ze všech těchto vzdáleností mezi páry bodů, které jsou tvořeny bodem z první i druhé množiny bodů. Čím více jsou si dvě množiny bodů podobné, tím je HV menší. V oblasti strojového vidění se HV často používá k hledání tvarů v obraze. Obraz se filtruje hranovým detektorem, následně se nalezené hrany převedou na sekvence bodů (kontury). Algoritmus se následně pokouší nalézt pro definovanou šablonu umístění v obraze s nejmenší hodnotou HV.

Vzhledem k tomu, že biometrická charakteristika krevního řečiště je tvořena množinou bodů, u kterých hraje roli pozice v obraze (jedná se vlastně o jakýsi vzor), pokusil jsem se v navrhovaném experimentálního softwaru využít HV pro výpočet míry shody, jelikož HV přirozeně porovnává podobnost tvarů. Na rozdíl od ostatních přístupů, jako je například vyhodnocení překrytí tvarů (nenachází-li se pod bodem šablony bod i v testovacím obraze, je tento bod ignorován, i když se nachází v těsné blízkosti), které není vhodné pro „řídké“

množiny bodů, není potřeba pro výpočet HV mít páry bodů přesně korespondující [16]. Nevýhodou HV je vysoká citlivost na odlehlé hodnoty.

Orientovaná HV označovaná \bar{H} mezi množinami bodů A a B odpovídá maximální vzdálenosti ze všech párů $x \in A$ a $y \in B$. Orientovaná HV je vyjádřena rovnicí:

$$\bar{H}(A, B) = \max_{x \in A} \{ \min_{y \in B} \{ \|x, y\| \} \} \quad (17)$$

kde $\|.,.\|$ je libovolná funkce ohodnocení, většinou euklidovská vzdálenost. Orientovaná HV není symetrická, takže platí $\bar{H}(A, B) \neq \bar{H}(B, A)$. Orientovaná HV neurčuje vzdálenost mezi množinou A a B , pouze nám udává nejdelší vzdálenost z bodu $x \in A$ k nejbližšímu bodu $y \in B$. Naproti tomu neorientovaná HV označovaná H je maximem z \bar{H} v obou směrech a udává rozdíl dvou množin bodů. Rovnice pro výpočet neorientované HV:

$$H(A, B) = \max \{ \bar{H}(A, B), \bar{H}(B, A) \} \quad (18)$$

V experimentálním softwaru jsem použil pro implementaci HV algoritmus bez optimalizací, protože vzhledem k velikosti množin je i s použitou implementací dostatečně rychlý.

Modifikovaná Hausdorffova vzdálenost

Jak bylo řečeno výše, HV je velmi náchylná na odlehlé hodnoty. To znamená, že i několik málo bodů z testovací množiny bodů, které jsou mimo body ze šablony, způsobí velký nárůst hodnoty HV, i když jsou si jinak obě množiny velmi podobné. Při řešení této slabiny zkoumali M.P. Dubuisson a A.K. Jain [23] mnoho variant modifikací HV. Z výsledků jejich práce vyplývá, že při použití modifikované HV (dále jen MHV) je problém odlehlých hodnot potlačen. Na rozdíl od původní rovnice je neorientovaná MHV definována rovnicí

$$H(A, B) = \frac{1}{N_A} \sum_{x \in A} \min_{y \in B} \{ \|x, y\| \} \quad (19)$$

kde N_A je počet prvků množiny A a $\|.,.\|$ je libovolná funkce ohodnocení, většinou euklidovská vzdálenost.

Normalizace ohodnocení

Před sloučením výsledků jednotlivých metrik je nutné tyto výsledky normalizovat. Jednotlivé metriky totiž poskytují výsledky v rozdílných „rozměrech“. Například hodnoty výstupu

z Hausdorffovy vzdálenosti se pohybují od 21,5 pro shodu do 335 pro úplně odlišný vzorek. Naproti tomu hodnoty pro Hammingovu vzdálenost se hodnoty pohybují od 33 pro shodu a 47 pro rozdílné vzorky.

Pro normalizaci ohodnocení jsem v experimentálním softwaru použil metodu min-max a normalizaci pomocí mediánu a MAD. Metodu min-max jsem vybral z důvodu rychlého a jednoduchého výpočtu. Metodu mediánu a MAD z důvodu robustnosti a odolnosti metody na odlehlé hodnoty. Obě metody normalizace jsem otestoval a porovnal výsledky.

Sloučení ohodnocení shody z více metrik

Slučování ohodnocení ve vícenásobných biometrických systémech (snímá a vyhodnocuje více druhů biometrických charakteristik) lze provádět na různých úrovních zpracování.

Nejnižší úroveň je slučování na úrovni vstupních dat, kdy se slučují data nezpracovaná. Jedná se například o sloučení více obrazů jednoho člověka, které se průměrují. Další zpracování se provádí už na zprůměrovaném obrazu, čímž se zvýší přesnost.

Další úroveň je sloučení na úrovni změřených biometrických charakteristik. Na této úrovni už lze slučovat jednotlivé charakteristiky nezávisle na jejich typu. Je třeba použít před sloučením normalizaci. Výhodou sloučení na této úrovni je hlavně úspora datové náročnosti a zvýšení rychlosti zpracování.

Další úroveň je sloučení na úrovni ohodnocení shody z jednotlivých metrik. Při tomto způsobu se jednotlivá ohodnocení shody slučují po normalizaci. Tento způsob je nejčastěji využívaný [24] a poskytuje přehledné a jednoduché zpracování výsledků (na rozdíl od předchozích úrovní).

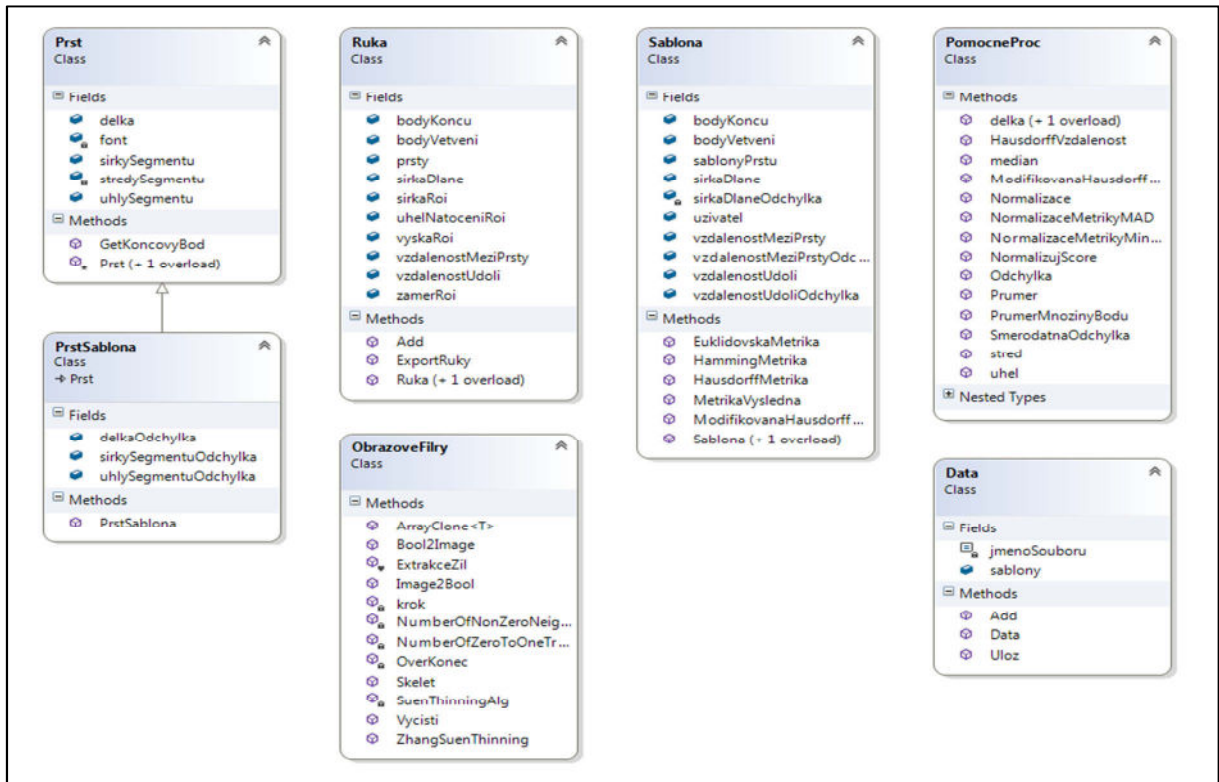
V experimentálním softwaru jsem využil sloučení metrik na nejvyšší popisované úrovni. Sloučení na této úrovni je jednoduché na implementaci a přehledné pro záznam dílčích výsledků z jednotlivých metrik.

Vlastní sloučení metrik je realizováno pomocí aritmetického průměru. Tento způsob je jednoduchý na implementaci do systému a zároveň poskytuje nejlepší výsledky[25].

Při konečném vyhodnocení identifikace se testuje šablona s nejlepší nalezenou shodou (čím nižší ohodnocení, tím větší míra shody), zda splňuje podmínku prahu (v experimentálním softwaru nastaveno na 50%) a podmínky minimálního odstupe od druhé nejlepší shody.

7.10 Popis tříd a datových struktur

Celou aplikaci pro identifikaci uživatele popisuje na obrázku (Obrázek 44) diagram tříd.



Obrázek 44 - Diagram tříd (vlastní práce autora)

Třída Ruka

Třída obsahuje algoritmy pro kompletní analýzu obrazu včetně předzpracování obrazu, segmentace obrazu a extrakce biometrických charakteristik.

Třída Prst

Třída obsahuje algoritmy pro extrakci biometrických charakteristik jednotlivých prstů.

Třída Sablona

Třída obsahuje algoritmy pro vytvoření šablony uživatele. Šablona se generuje na základě dat ze sady instancí třídy Ruka. Na základě dodaných dat se generují průměry a odchylky jednotlivých biometrických charakteristik potřebných pro vyhodnocení míry shody. Zároveň poskytuje funkce pro výpočet shody šablony s instancí třídy Ruka.

Třída Data

Hlavním účelem třídy je správa jednotlivých šablon uživatelů. Šablony jsou zařazeny v kolekci List. Třída poskytuje funkce pro uložení a načtení šablon z pevného disku.

Třída PomocneProc

Obsahuje pouze statické metody. Jedná se o podpůrné výpočty (délka, úhel, atd.) využívané ostatními třídami.

Třída ObrazoveFiltry

Obsahuje pouze statické metody. Jedná se o algoritmy a filtry použité pro předzpracování a úpravy obrazu.

8. Testování navrženého systému

Následující kapitola obsahuje popis testování experimentálního systému pro biometrickou identifikaci uživatelů. V první části je popsána rychlost biometrického systému. Dále kapitola obsahuje ukazatele hodnotící spolehlivost biometrického systému.

8.1 Metodologie testování

Pro testování navrženého biometrického identifikačního systému jsem měl k dispozici snímky rukou deseti lidí. Od každého člověka byly pořízeny čtyři vzorky (čtyři různé obrazy). Ve zkoumané skupině byli jak muži, tak ženy, věk osob byl v rozmezí 25-60 let. Vlastnosti testovaných osob shrnují následující tabulky (Tabulka 2) a (Tabulka 3).

Tabulka 2 - Rozdělení testovaných osob podle pohlaví (vlastní práce autora)

Muži	Ženy	Celkem
8	2	10

Tabulka 3 - Rozdělení testovaných osob podle věku (vlastní práce autora)

20-30	30-40	40-50	50-60	Celkem
2	5	2	1	10

Pro testování jsem zvolil takto malou skupinu, protože sestava hardwarových komponent pro snímání obrazů byla pro transport velmi rozměrná: cca 0,8 x 0,8 x 0,6 metru a zapůjčená pouze na omezenou dobu. Z těchto důvodů jsem nebyl schopen zajistit více testovacích dat. Testování systému jsem prováděl na osobním počítači s následujícími parametry (jsou uváděny pouze parametry mající vliv na běh aplikace):

- OS – Windows 10, 64 bitů
- CPU – Intel Core i5-5257U s frekvencí 2,7 GHz (maximální turbo frekvence 3,1 GHz)
- RAM – 8 GB

8.2 Testy rychlosti experimentálního systému

Vyhodnocení jednoho testovacího obrazu trvalo v rozmezí od 0,6 do 0,9 sekundy. Výpočetně nejnáročnější byl algoritmus extrakce biometrických charakteristik. Rychlost zpracování jednotlivých kroků zpracování a vyhodnocení obrazů shrnuje tabulka (Tabulka 4).

Tabulka 4 - Časy potřebné pro vykonání jednotlivých kroků zpracování a vyhodnocení obrazů

krok programu	geometrie ruky		krevní řečiště	
	průměrný čas [ms]	maximální odchylka [ms]	průměrný čas [ms]	maximální odchylka [ms]
předzpracování obrazu	1,25	14,75	3,5	8,5
segmentace	1,08	8,9	152,7	70,3
extrakce charakteristik	667,5	168,5	8,83	3,26
výpočet shody a přiřazení	0,97	3	1	1,9

8.3 Testy spolehlivosti experimentálního systému


Hodnocení spolehlivosti systému jsem provedl tak, že jsem nejdříve systém naučil všechny osoby a uložil jejich šablony. Následně jsem systém nechal identifikovat každý obraz z testovacích dat. Zároveň jsem vyhodnocoval výsledky každé identifikace. Jelikož jsem věděl, které osobě aktuální obraz patří (testovací obrazy byly označeny písmeny, pro každou osobu jedno písmeno) mohl jsem provést vyhodnocení správnosti identifikace systémem. Možné varianty vyhodnocení mohli být:

- OK identifikace – systém správně identifikoval osobu,
- Falešná identifikace – systém identifikoval osobu chybně, pro daný obraz byla identifikována nesprávná osoba,
- Neúspěšná identifikace – systém nedokázal nalézt dostatečnou shodu s žádnou uloženou šablonou, nebyly splněny podmínky minimálního odstupu ohodnocení nebo nebyl překročen minimální práh.


Pro hodnocení systému jsem zvolil ukazatele FMR, FNMR a EER, které udávají četnost výše popsaných chyb.

Nejdříve jsem provedl porovnání jednotlivých metrik na výše uvedeném vzorku dat. To znamená, že celkovou míru shody tvořila pouze jedna metrika. Jako hodnotu prahu jsem zvolil 0,5 a rozmezí minimálního odstupu od 0 do 0,5. Pro normalizaci metrik jsem použil metodu min-max.


Grafy (Graf 10) a (Graf 11) zachycují výsledky testování dvou různých metrik pro geometrii ruky. Grafy (Graf 12) a (Graf 13) zachycují výsledky testování dvou různých metrik pro krevní řečiště.




Graf 10 - EER pro Euklidovskou vzdálenost (vlastní práce autora)



Graf 11 - EER pro Hammingovu vzdálenost (vlastní práce autora)




Graf 12 - EER pro HV (vlastní práce autora)




Graf 13 - EER pro MHV (vlastní práce autora)

Pro vyhodnocení míry shody geometrie ruky je vhodné pro běžné použití využít Hammingovu vzdálenost, protože má nižší hodnotu EER, přibližně 0,2 oproti 0,35. Pro vyhodnocení míry shody krevního řečiště je vhodné využít metriku MHV, která má nižší hodnotu EER, přibližně 0,1 oproti 0,27. Celkově nejlepší výsledky jsem dosáhl s metrikou MHV.

V další části testování jsem vybral nejlepší metriku pro geometrii ruky (Hammingova metrika) a nejlepší metriku pro krevní řečiště (MHV). S těmito metrikami jsem vytvořil multi-biometrický systém a opět testoval výkonost tohoto systému na výše popsaném vzorku dat. Výsledky jsou zachyceny v grafu (Graf 14).



Graf 14 - EER pro sloučené metriky Hammingovu a MHV (vlastní práce autora)




Graf 15 – EER pro sloučené všechny metriky (vlastní práce autora)

Výsledky potvrdily předpokládané zlepšení výkonu multi-biometrického systému oproti biometrickému systému s jednou biometrií. Hodnota EER se u multi-biometrického systému snížila o polovinu oproti samotné biometrii krevního řečiště. Také průběh chyby FNMR (četnost nenalezení shody) se vyhladil a mírně snížil.

Na závěr této části testování jsem sloučil všechny zkoumané metriky. Došlo tedy k tomu, že každé biometrické charakteristiky (geometrie ruky i krevní řečiště) vyhodnocovaly dvě metriky zároveň. Hodnota EER se v tomto případě oproti multi-biometrickému systému nezměnila, pouze se mírně zhoršil průběh chyby FNMR. Výsledky jsou zachyceny v grafu (Graf 15).

V poslední části testování biometrického systému jsem porovnal dvě metody normalizace. Pro tento test jsem zvolil multi-biometrický systém (metrika Hammingova vzdálenost a MHV), který v předchozí části testování dosáhl nejlepších výsledků. Výsledky pro min-max normalizaci jsou v grafu (Graf 14) a pro MAD normalizaci jsou v grafu (Graf 16).




Graf 16 - EER pro sloučené metriky s použitím MAD normalizace (vlastní práce autora)

Výsledky ukázaly, že při použití normalizační metody MAD a mediánu má chyba FNMR lepší průběh oproti normalizační metodě min-max. Křivka v grafu stoupá pomaleji a také konečná hodnota je nižší. Hodnota ERR zůstala stejná.

9. Diskuze výsledků

Výsledkem práce je nalezení nejvhodnější kombinace metrik pro multi-biometrický systém založený na bezkontaktním snímání biometrických charakteristik. Použité algoritmy jednotlivých metrik vykazují různou přesnost a jsou zatíženy určitými faktory, jejichž zlepšením by bylo možné dosáhnout lepších výsledků identifikace.

Mezi faktory ovlivňující negativně výsledky identifikace patří zejména chyby při snímání obrazu. V testovacích datech se objevily obrazy od jedné osoby, na kterých nebyl biometrický experimentální systém schopen správně extrahovat biometrické charakteristiky (Obrázek 45). Důvodem byla nedostatečná mezera mezi prsty a tím pádem nebylo možné správně určit údolí mezi prsty (bod č. 3), což znemožnilo správnou extrakci. Řešením by byla správná poloha ruky uživatele při focení obrazu.



Obrázek 45 – Selhání algoritmu extrakce charakteristik na chybně nasnímaném vzorku (vlastní práce autora)

Dalším negativním faktorem byl nízký kontrast obrazu pro kontrolu krevního řečiště. Při filtrování obrazu docházelo k přerušení žil v obraze nebo naopak byl za žilu považován stín na pokožce ruky. Tento malý kontrast byl nejspíše způsoben velkou vzdáleností osvětlení scény od snímání ruky.

Poslední faktor mající vliv na výsledky bylo rozlišení kamery 640x480 obrazových bodů, které se ukázalo jako nedostatečné. Důvodem je malý rozdíl měřených šířek prstů mezi

jednotlivými osobami v řádu jednotek pixelů. Při vyšším rozlišení by bylo měření přesnější a tím by bylo přesnější i vyhodnocení shody.

Hodnocení jednotlivých metrik bylo provedeno pomocí porovnání četností dvojího typu chyb (falešná identifikace a nenalezení shody) a hodnoty EER. Čím je hodnota EER nižší, tím je vyšší přesnost dané metriky. Nejnižší hodnotu měla metrika Modifikovaná Hausdorffova vzdálenost (MHV), pro kterou mělo EER hodnotu 11%.

Následně jsem vybral nejlepší metriky pro dané biometrické charakteristiky (Hammingova vzdálenost a MHV) a sloučil je do výsledného ohodnocení. Výsledný multi-biometrický systém měl hodnotu EER 5%, čímž se potvrdil předpoklad, že při slučování metrik roste přesnost systému [13].

Dále jsem porovnával dvě metody normalizace metrik před jejich sloučením. Normalizace pomocí mediánu a MAD se ukázala jako vhodnější, protože hodnota EER se nezměnila, ale průběh křivky FNMR nestoupal tak strmě jako v případě normalizace min-max.

Navržené řešení biometrického systému by bylo možné využít například jako docházkový systém, kdy je potřeba identifikace uživatelů, ale není vyžadována vysoká míra bezpečnosti.

Pro nasazení experimentálního biometrického systému do podmínek reálného provozu by musel být celý systém dále vylepšen. Největším problémem by pravděpodobně byly nežádoucí okolní vlivy prostředí. Například přímé sluneční světlo, které by ovlivnilo intenzitu snímaného obrazu. Dalším problémem by mohla být změna vlastností podkladu při průběžném opotřebení, na který by se ruce při snímání pokládaly. Dále by se musela zlepšit uživatelská přívětivost hardwaru pro snímání ruky, aby bylo použití rychlejší a pohodlnější.

9.1 Možnosti pokračování vývoje

Pro další vývoj navrhovaného biometrického systému by bylo vhodné využít kameru s vyšším rozlišením, která by zajistila vyšší přesnost měření. Pro další vývoj a testování větších objemů dat by bylo nutné optimalizovat algoritmus pro extrakci biometrických charakteristik geometrie ruky, který se ukázal v celém systému jako nejpomalejší část. Dále by bylo vhodné ověřit výsledky na větším vzorku osob.

10. Závěr

Cílem práce bylo navrhnout a vytvořit experimentální biometrický systém pro identifikaci osob na základě biometrických charakteristik ruky uživatele. Pro splnění cíle bylo nutné navrhnout a použít vhodný hardware (kamera, objektiv, osvětlení) pro snímání obrazů rukou uživatelů. V teoretické části práce jsem popsal základní postupy zpracování, filtrování a vyhodnocení obrazu. Pro zvýšení přesnosti identifikace experimentálního biometrického systému jsem navrhl a realizoval multi-biometrický identifikační systém, který pracuje s biometrickými charakteristikami geometrie ruky a krevního řečiště na hřbetě ruky.

Vlastní práci jsem započal návrhem základních funkcí a procesů biometrického systému. Dále jsem pokračoval návrhem a sestavením přípravku pro snímání obrazu rukou. Seznámil jsem se s různými možnostmi osvětlení snímané scény a s vlastnostmi digitálních kamer. Po provedeném testování různých typů osvětlení scény jsem zvolil nejvhodnější kombinaci pro použití v biometrickém systému. Dále jsem pokračoval tvorbou funkcí potřebných pro předzpracování, filtraci a segmentaci nasnímaných obrazů z kamery. Po segmentaci jsem z připravených obrazů extrahoval biometrické charakteristiky. Pro každý typ biometrických charakteristik jsem použil pro výpočet míry shody se šablonou dvě různé metriky. Pro geometrii ruky to byla Euklidovská vzdálenost a Hammingova vzdálenost, pro krevní řečiště to byla Hausdorffova vzdálenost a Modifikovaná Hausdorffova vzdálenost. Dále jsem vytvořil datové struktury pro uložení šablon uživatelů v systému. Pro normalizaci výsledků metrik před sloučením jsem použil metody min-max a metodu s využitím mediánu a MAD.

Následně jsem otestoval výkon biometrického systému na vzorku osob. Osoby vkládali ruce do testovacího přípravku volně do přibližně naznačené pozice bez použití kolíků nebo jiných technických prostředků, které by ruce pevně fixovaly v určité pozici. Při testování jsem porovnal výkon jednotlivých metod výpočtu míry shody vzorku se šablonou. Také jsem porovnal výsledky metod pro normalizaci ohodnocení před sloučením a jejich dopad na celkový výkon systému. Po identifikaci metrik s nejvyšším výkonem jsem vytvořil výsledný biometrický systém, který dosáhl hodnoty EER 5% na testovaném vzorku osob.

Závěrem lze říci, že se povedlo navrhnout vhodný postup zpracování a vyhodnocení obrazu rukou uživatelů. Vytvořený experimentální biometrický systém byl schopen s vysokou přesností identifikovat uživatele, a tím bylo dosaženo cíle této práce.

Seznam literatury

- [1] Hand-based biometrics. *Biometric Technology Today* [online]. 2003, **11**(7), 9-11 [cit. 2016-06-30]. DOI: 10.1016/S0969-4765(03)07018-8. ISSN 09694765.
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0969476503070188>
- [2] YÖRÜK, Erdem, Helin DUTAĞACI a Bülent SANKUR. Hand biometrics. *Image and Vision Computing* [online]. 2006, **24**(5), 483-497 [cit. 2016-06-30].
DOI: 10.1016/j.imavis.2006.01.020. ISSN 02628856.
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0262885606000497>
- [3] ŠONKA, Milan a Václav HLAVÁČ. *Počítačové vidění*. Praha: Grada, 1992.
Nestůjte za dveřmi. ISBN 80-85424-67-3.
- [4] MOŽNÝ, Karel. *Rozpoznávání znaků pomocí umělé inteligence* [online]. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2010. 60 s. Diplomová práce [cit. 2016-06-30]. Dostupné z: https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=27758
- [5] ROSS, Arun a Anil K. JAIN. Fusion Techniques in Multibiometric Systems. *Face Biometrics for Personal Identification* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, s. 185 [cit. 2016-06-30].
DOI: 10.1007/978-3-540-49346-4_12. ISBN 978-3-540-49344-0.
Dostupné z: http://link.springer.com/10.1007/978-3-540-49346-4_12
- [6] Vein recognition in Europe. *Biometric Technology Today* [online]. 2004, **12**(9), 6-11 [cit. 2016-06-30]. DOI: 10.1016/S0969-4765(04)00205-X. ISSN 09694765.
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S096947650400205X>
- [7] JIAN, A.K. a N. DUTA. Deformable matching of hand shapes for user verification. In: *Proceedings 1999 International Conference on Image Processing (Cat. 99CH36348)* [online]. IEEE, 1999, s. 857-861 [cit. 2016-06-30].
DOI: 10.1109/ICIP.1999.823019. ISBN 0-7803-5467-2.
Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=823019>

- [8] ANIL, K. Jain, A. ROSS a S. PANKANTI. A prototype hand geometry-based verification system. In: *Proc. 2nd Int. Conf. Audio- and Video-Based Biometric Person Authentication* [online]. IEEE, 1999, s. 166–171 [cit. 2016-06-30].
Dostupné z: http://www.cse.unr.edu/~bebis/CS790Q/PaperPresentations/RossHand_AVBPA9_9.pdf
- [9] SANCHEZ-REILLO, R., C. SANCHEZ-AVILA a A. GONZALEZ-MARCOS. Biometric identification through hand geometry measurements. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [online]. **22**(10), 1168-1171 [cit. 2016-06-30]. DOI: 10.1109/34.879796. ISSN 01628828.
Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=879796>
- [10] WONG, Alexandra L.N. a P. SHI, Peg-free hand geometry recognition using hierarchical geometry and shape matching. *Proc. IAPR Workshop on Machine Vision Applications*[online]. 2002, s. 281–284 [cit. 2016-06-30].
Dostupné z: <http://www.ee.ust.hk/~eeship/Papers/MVA02.pdf>
- [11] HAEGER, S., *Feature Based Palm Recognition*[online], Univ. South Florida, 2003 [cit. 2016-06-30].
Dostupné z: <http://marathon.csee.usf.edu/~aparasha/ta-vision/shaeger.ppt>
- [12] GANG ZHENG, CHIA-JIU WANG a T.E. BOULT. Application of Projective Invariants in Hand Geometry Biometrics. *IEEE Transactions on Information Forensics and Security* [online]. 2007, **2**(4), 758-768 [cit. 2016-06-30]. DOI: 10.1109/TIFS.2007.908239. ISSN 1556-6013.
Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4358839>
- [13] ŠČUREK, Rodomír. *Biometrické metody identifikace osob v bezpečnostní praxi : studijní text.* [online]. Vysoká škola báňská - Technická univerzita Ostrava, 2008 [cit. 2016-06-30]. Dostupné z: http://www.fbi.vsb.cz/shared/uploadedfiles/fbi/biometricke_metody.pdf
- [14] TILBORG, Henk C. A. van a Sushil. JAJODIA. *Encyclopedia of cryptography and security.* 2nd ed. New York: Springer, 2011. Strana 1353-1354. ISBN 978-1-4419-5906-5.

- [15] VOJÁČEK, Antonín. Principy a málo známé vlastnosti CCD snímačů obrazu. In: *automatizace.hw.cz*[online]. 10. 4. 2006 [cit. 2016-06-30].
Dostupné z: <http://automatizace.hw.cz/clanek/2006041001>
- [16] WANG, Lingyu, Graham LEEDHAM a David SIU-YEUNG CHO. Minutiae feature analysis for infrared hand vein pattern biometrics. *Pattern Recognition* [online]. 2008, **41**(3), 920-929 [cit. 2016-06-30]. DOI: 10.1016/j.patcog.2007.07.012. ISSN 00313203. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0031320307003391>
- [17] RAK, Roman, Vašek MATYÁŠ a Zdeněk ŘÍHA. *Biometrie a identita člověka ve forenzních a komerčních aplikacích*. Praha: Grada, 2008.
ISBN 978-80-247-2365-5.
- [18] MARTIN, Alberto a Sabri TOSUNOGLU. *Image Processing techniques for Machine Vision*[online]. Florida: Florida International University Department of Mechanical Engineering, 1986 [cit. 2016-06-30]. Dostupné z: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.113.7842&rep=rep1&type=pdf>
- [19] ZHANG, T. Y. a C. Y. SUEN. A fast parallel algorithm for thinning digital patterns. *Communications of the ACM*[online]. 1984, **27**(3) [cit. 2016-06-30].
Dostupné z: <http://www-prima.inrialpes.fr/perso/Tran/Draft/gateway.cfm.pdf>
- [20] SAXENA, Nidhi, a kolektiv. Hand geometry: A new method for biometric recognition. *International Journal of Soft Computing and Engineering (IJSCE)*[online]. 2013, **2**(6), 2231-2307[cit. 2016-06-30]. Dostupné z: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.301.2411&rep=rep1&type=pdf>
- [21] KOVÁŘ, Martin, *Snímač otisku prstu: Diplomová práce* [online]. Brno: VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ, 2015 [cit. 2016-06-30]. Dostupné z: https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=100507
- [22] SUZUKI, Satoshi a Keiichi A BE. Topological structural analysis of digitized binary images by border following. *Computer Vision, Graphics, and Image Processing* [online]. 1985, **30**(1), 32-46 [cit. 2016-06-30]. DOI: 10.1016/0734-189X(85)90016-7. ISSN 0734189x. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0734189X85900167>

- [23] DUBUISSON, M.-P. a A.K. JAIN. A modified Hausdorff distance for object matching. In: *Proceedings of 12th International Conference on Pattern Recognition* [online]. IEEE Comput. Soc. Press, 1994, s. 566-568 [cit. 2016-06-30].
DOI: 10.1109/ICPR.1994.576361. ISBN 0-8186-6265-4. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=576361>
- [24] ROSS, Arun a Anil K. JAIN. Fusion Techniques in Multibiometric Systems. *Face Biometrics for Personal Identification* [online].
Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, s. 185 [cit. 2016-06-30].
DOI: 10.1007/978-3-540-49346-4_12. ISBN 978-3-540-49344-0.
Dostupné z: http://link.springer.com/10.1007/978-3-540-49346-4_12
- [25] MARASCO, Emanuela a Carlo SANSONE. *An Experimental Comparison of Different Methods for Combining Biometric Identification Systems* [online].
s. 255-264 [cit. 2016-06-30]. DOI: 10.1007/978-3-642-24088-1_27.
Dostupné z: http://link.springer.com/10.1007/978-3-642-24088-1_27
- [26] Příspěvatelé Wikipedie, *Ekvalizace histogramu* [online], Wikipedie: Otevřená encyklopedie, 2013, Datum poslední revize 22. 09. 2013, 17:43 UTC, [cit. 1. 07. 2016]. Dostupné z: https://cs.wikipedia.org/w/index.php?title=Ekvalizace_histogramu&oldid=10749314
- [27] Příspěvatelé Wikipedie, *Median filter* [online], Wikipedie: Otevřená encyklopedie, 2016, Datum poslední revize 23. 05. 2016, 12:18 UTC, [cit. 1. 07. 2016]. Dostupné z: https://en.wikipedia.org/w/index.php?title=Median_filter&oldid=721681480
- [28] *Allied Vision Technologies: Prezentace společnosti* [online].
Stadtroda: Allied Vision Technologies GmbH, 2016 [cit. 1. 07. 2016].
Dostupné z: <https://www.alliedvision.com/en/products/cameras/detail/Guppy%20PRO/F-031.html>

- [29] *Vision & Control: Prezentace společnosti* [online].
Stadtroda: Vision & Control GmbH, 2016 [cit. 1. 07. 2016]. Dostupné z:
<http://www.vision-control.com/en/products-services/product-catalogue>
- [30] Moravské přístroje a.s., Základní principy strojového vidění. In: *elektroprumysl.cz*
[online]. 19. leden 2012 [cit. 15. 07. 2016]. Dostupné z:
<http://www.elektroprumysl.cz/vizualizace-a-komunikace/zakladni-principy-strojoveho-videni-8-dil/vsechny-stranky>
- [31] Příspěvatelé Wikipedie, *Segmentace obrazu* [online], Wikipedie: Otevřená encyklopedie, Datum poslední revize 2. 12. 2013, 02:56 UTC, [citováno 15. 07. 2016]. Dostupné z:
https://cs.wikipedia.org/w/index.php?title=Segmentace_obrazu&oldid=10988879

Seznam obrázků

Obrázek 1 - Možné typy osvětlení scény (vlastní práce autora)	6
Obrázek 2 - Příklady přímého osvětlení scény [29]	7
Obrázek 3 - Příklad bočního osvětlení scény [29].....	8
Obrázek 4 - Příklad zadního osvětlení scény [29].....	8
Obrázek 5 - Obraz s nízkým kontrastem a jeho histogram [26].....	10
Obrázek 6 - Obraz s kontrastem upraveným ekvalizací a jeho histogram [26].....	11
Obrázek 7 - Příklad použití mediánového filtru [27]	12
Obrázek 8 - Postup filtrování obrazu dilatací [30]	13
Obrázek 9 - Postup filtrování obrazu erozí [30].....	14
Obrázek 10 - Histogram vhodný pro výpočet prahu [31].....	15
Obrázek 11 - Histogram nevhodný pro výpočet prahu [31].....	15
Obrázek 12 - Kruhové přímé osvětlení (vlastní práce autora).....	25
Obrázek 13 - Liniové přímé osvětlení (vlastní práce autora)	25
Obrázek 14 - Zadní difuzní osvětlení (vlastní práce autora)	25
Obrázek 15 - DOM difuzní osvětlení (vlastní práce autora)	25
Obrázek 16 - Sestava kamery a osvětlení (vlastní práce autora).....	27
Obrázek 17 - Sestava kamery a osvětlení (vlastní práce autora).....	27
Obrázek 18 - Vývojový diagram identifikace uživatele (vlastní práce autora).....	29
Obrázek 19 - Vývojový diagram vytvoření šablony (vlastní práce autora)	30
Obrázek 20 - Definice ROI (vlastní práce autora).....	34
Obrázek 21 - Žíly a kůže snímané barevnou kamerou (vlastní práce autora)	35
Obrázek 22 - Žíly a kůže snímané s využitím IR osvětlení (vlastní práce autora).....	35
Obrázek 23 - Krevní řečiště před filtrací (vlastní práce autora)	36
Obrázek 24 - Krevní řečiště po mediánové filtraci (vlastní práce autora).....	36
Obrázek 25 - Krevní řečiště po ekvalizaci (vlastní práce autora).....	36
Obrázek 26 - Zdrojový obraz ruky (vlastní práce autora)	38
Obrázek 27 - Prahování s příliš vysokým prahem (vlastní práce autora).....	38
Obrázek 28 - Prahování s příliš nízkým prahem (vlastní práce autora)	39
Obrázek 29 - Prahování s ideálním prahem (vlastní práce autora).....	39
Obrázek 30 - Postup filtrace krevního řečiště: a) po prahování; b) po mediánové filtraci; c) po dilataci; d) výsledek (vlastní práce autora).....	39
Obrázek 31 – Příklady počtů propojení pixelu (vlastní práce autora).....	41

Obrázek 32 - Označení pixelů v algoritmu výpočtu počtu propojení pixelu (vlastní práce autora).....	41
Obrázek 33 - Postup ztenčování: a) 2. iterace; b) 6. iterace; c) 10. iterace; d) výsledek (vlastní práce autora)	42
Obrázek 34 - Kostra s označenými částmi k odstranění (vlastní práce autora).....	43
Obrázek 35 - Kostra po odstranění neúplných čar (vlastní práce autora)	43
Obrázek 36 - Znázornění měřených biometrických charakteristik (vlastní práce autora)	44
Obrázek 37 – Základní typy markantů využívané při daktyloskopii [21].....	46
Obrázek 38 - Konvexní obálka kontury: a) kompletní; b) po filtraci nežádoucích bodů (vlastní práce autora)	47
Obrázek 39 - Nalezené body v údolích (vlastní práce autora)	48
Obrázek 40 - Znázornění minimální hloubky údolí (vlastní práce autora)	48
Obrázek 41 - Znázornění měření délky a šířky prstů (vlastní práce autora)	48
Obrázek 42 – Znázornění všech měřených charakteristik na ruce (vlastní práce autora)	49
Obrázek 43 - Vývojový diagram pro výpočet míry shody (vlastní práce autora)	52
Obrázek 44 - Diagram tříd (vlastní práce autora).....	56
Obrázek 45 – Selhání algoritmu extrakce charakteristik na chybně nasnímaném vzorku (vlastní práce autora)	63

Seznam grafů

Graf 1 - Transformační funkce (vlastní práce autora)	9
Graf 2 - Citlivost kamery na záření [28].....	24
Graf 3 - Charakteristika IR filtru [29]	24
Graf 4 - Porovnání šířek prstů dvou uživatelů (vlastní práce autora).....	45
Graf 5 – Porovnání vzdálenosti mezi konci prstů (vlastní práce autora).....	45
Graf 6 - Porovnání délek prstů (vlastní práce autora)	45
Graf 7 – Histogram celkového počtu markantů žil (vlastní práce autora).....	50
Graf 8 – Histogram počtu větvení žil (vlastní práce autora)	51
Graf 9 – Histogram počtu konců žil (vlastní práce autora)	51
Graf 10 - EER pro Euklidovskou vzdálenost (vlastní práce autora)	60
Graf 11 - EER pro Hammingovu vzdálenost (vlastní práce autora).....	60
Graf 12 - EER pro HV (vlastní práce autora).....	60
Graf 13 - EER pro MHV (vlastní práce autora)	60
Graf 14 - EER pro sloučené metriky Hammingovu a MHV (vlastní práce autora)	61
Graf 15 – EER pro sloučené všechny metriky (vlastní práce autora)	61
Graf 16 - EER pro sloučené metriky s použitím MAD normalizace (vlastní práce autora).....	61

Seznam tabulek

Tabulka 1 - Přibližný odhad cen použitých komponent (vlastní práce autora)	26
Tabulka 2 - Rozdělení testovaných osob podle pohlaví (vlastní práce autora)	58
Tabulka 3 - Rozdělení testovaných osob podle věku (vlastní práce autora)	58
Tabulka 4 - Časy potřebné pro vykonání jednotlivých kroků zpracování a vyhodnocení obrazů	59

Použité zkratky

FAR – false acceptance rate – pravděpodobnost falešného přijmutí při verifikaci

FRR – false rejection rate – pravděpodobnost falešného odmítnutí při verifikaci

EER - equal error rate – pravděpodobnost chyby systému.

FMR – false matching rate – pravděpodobnost falešné shody při identifikaci

FNMR – false non matching rate – pravděpodobnost neúspěšné identifikace

CCD – charge couple device – zařízení s vázanými náboji

IR – infrared – infračervené spektrum

UV – ultraviolet – ultrafialové spektrum

LED – diody emitující světlo

MAD - mediánová absolutní odchylka

HV – Hausdorffova vzdálenost

MHV – modifikovaná Hausdorffova vzdálenost

ROI – region of interest – region v obraze, v kterém je zkoumaný objekt zájmu

FIR – far infrared – vzdálené infračervené spektrum (15–1000 μm)

NIR – near infrared – blízké infračervené spektrum (0,76–1,4 μm)