



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV INTELIGENTNÍCH SYSTÉMŮ

DEPARTMENT OF INTELLIGENT SYSTEMS

**SLOŽENÍ SNÍMKU PRSTU S VIDITELNÝM KREVNÍM
ŘEČIŠTĚM**

CREATION OF COMPOSITE IMAGE WITH VISIBLE BLOODSTREAM

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

JAKUB PEKÁREK

VEDOUcí PRÁCE

SUPERVISOR

Ing. ŠTĚPÁN RYDLO

BRNO 2024

Zadání bakalářské práce



154230

Ústav: Ústav inteligentních systémů (UITS)
Student: **Pekárek Jakub**
Program: Informační technologie
Název: **Složení snímku prstu s viditelným krevním řečištěm.**
Kategorie: Zpracování obrazu
Akademický rok: 2023/24

Zadání:

1. Seznamte se s tématem detekce krevního řečiště prstu. Dále se seznamte se možnostmi zpracování obrazu s předem definovanými úhly pohledu pomocí odrazových ploch.
2. Navrhněte postup pro následné zpracování obrazu za účelem vytvoření kompozitního snímku s cílem maximalizace rozlišitelnosti krevního řečiště v prstu.
3. Navržené postupy z předchozího bodu zadání implementujte a otestujte na databázích nasnímaných prstů s viditelným krevním řečištěm.
4. Shrňte dosažené výsledky, diskutujte možná rozšíření.

Literatura:

- UHL, Andreas, Christopher BUSCH, Sébastien MARCEL a Raymond VELDHUIS. *Handbook of vascular biometrics*. Cham: Springer Open, 2020. Advances in computer vision and pattern recognition. ISBN 978-3-030-27730-7.
- Lutowski, Z.; Bujnowski, S.; Marciniak, B.; Kloska, S.; Marciniak, A.; Lech, P. A Novel Method of Vein Detection with the Use of Digital Image Correlation. *Entropy* 2021, 23, 401.
<https://doi.org/10.3390/e23040401>

Při obhajobě semestrální části projektu je požadováno:

- Splnění bodů 1 a 2

Podrobné závazné pokyny pro vypracování práce viz <https://www.fit.vut.cz/study/theses/>

Vedoucí práce: **Rydlo Štěpán, Ing.**
Vedoucí ústavu: Hanáček Petr, doc. Dr. Ing.
Datum zadání: 1.11.2023
Termín pro odevzdání: 9.5.2024
Datum schválení: 6.11.2023

Abstrakt

Práce popisuje zpracování snímku prstu pro vytvoření kompozitního snímku s viditelným krevním řečištěm. Krevní řečiště je detekováno algoritmem Maximum Curvature. Následně bylo experimentováno s hledáním a spojováním klíčových bodů pomocí algoritmů SIFT a ORB. Protože však algoritmy nepřinášely požadované výsledky, musí být klíčové body vyznačovány manuálně. Z nich je vytvořen odhad matice transformace. Pomocí odhadu matice transformace je spojena dvojice snímků. Tento cyklus přiřazení klíčových bodů a spojení snímků probíhá i pro nově vytvořené snímky. Po spojení posledních dvou snímků je výsledkem kompozitní snímek s viditelným krevním řečištěm. Tento kompozitní snímek může být dále využit pro verifikaci nebo identifikaci osob.

Abstract

This thesis describes a method for creating a composite image with a visible bloodstream. The bloodstream is detected by the Maximum Curvature algorithm. After that it was experimented with detecting and matching keypoints via algorithms SIFT and ORB. However, the resulting matches from these algorithms were not good enough, therefore the keypoints have to be manually assigned. From these keypoints, an estimated transformation matrix was created. This matrix was then used for connecting two images. A cycle of assigning keypoints and connecting images is repeated even for newly created images. The final composite image with a visible bloodstream is created after connecting last two images. This composite image can be further used for verification or identification people.

Klíčová slova

biometrie, krevní řečiště, prst, kompozitní snímek, identifikace, verifikace, MaximumCurvature, SIFT, ORB, zpracování obrazu, klíčové body

Keywords

biometrics, bloodstream, finger, composite image, identification, verification, MaximumCurvature, SIFT, ORB, image processing, image keypoints

Citace

PEKÁREK, Jakub. *Složení snímku prstu s viditelným krevním řečištěm*. Brno, 2024. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Štěpán Rydlo

Složení snímku prstu s viditelným krevním řečištěm

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením pana Ing. Štěpána Rydla. Uvedl jsem všechny literární prameny, publikace a další zdroje, ze kterých jsem čerpal.

.....
Jakub Pekárek
6. května 2024

Poděkování

Rád bych poděkoval svému vedoucímu práce Ing. Štěpánu Rydlovi za konzultace a vedení práce.

Obsah

1 Úvod	4
2 Biometrie	5
2.1 Verifikace a identifikace	5
2.2 Mezitřídní a vnitrotřídní variabilita	6
2.3 Biometrický systém	6
2.4 Bezpečnost biometrického systému	7
2.5 Charakteristiky biometrických rysů	8
2.6 Využití krevního řečiště v biometrii	9
3 Návrh řešení	11
3.1 Rozdělení úhlů a rotace prstu	12
3.2 Předzpracování	12
3.3 Detekování a vyznačení krevního řečiště	13
3.4 Detekce klíčových bodů	14
3.5 Spojování klíčových bodů	18
3.6 Odhad matice transformace pomocí klíčových bodů	19
3.7 Vytvoření kompozitního snímku	19
3.8 Používané algoritmy	19
4 Realizace	21
4.1 Použité knihovny a struktura řešení	22
4.2 Rozdělení úhlů do jednotlivých snímků	23
4.3 Předzpracování	26
4.4 Detekce krevního řečiště	29
4.5 Detekce klíčových bodů a jejich spojování	34
4.6 Vytvoření a použití transformační matice	41
4.7 Skládání snímků	43
5 Závěr	47
Literatura	48

Seznam obrázků

2.1	Schéma biometrického systému	6
2.2	Úhly útoku na biometrický systém	7
2.3	Graf absorpce NIR různými látkami v těle, převzato z [1]	10
3.1	Příklad vstupního snímku	11
3.2	Hledání krevního řečiště za pomoci rozdílů v zakřivení křivky jasu v průřezu prstu. Převzato z [37]	13
3.3	Wide Line Detector, modré kolečko je středový bod, modrá kružnice označuje oblast, červenými křížky jsou označeny pixely jejichž rozdíl hodnoty oproti středovému bodu je menší nebo se rovná zadané hodnotě	14
3.4	Oktávy a rozdíl Gaussiánů, převzato a upraveno [35]	15
3.5	Vyhledávání lokálních extrémů, x značí nalezený extrém, zelené kolečka místa, se kterými je porovnáváno, převzato a upraveno [35]	16
3.6	Vektor popisující klíčový bod, pro přehlednost je okolí zmenšeno na 8x8 a vektor 2x2 oproti reálným 16x16 a 4x4, modře označeno pole působení Gaussovy funkce, převzato a upraveno [35]	17
3.7	Postup bilineární interpolace pro výpočet hodnoty bodu P , převzato z [9]	20
4.1	Postup zpracování řešení	21
4.2	Rozdíly v nalezeném krevním řečišti při rozdílném způsobu převodu na odstíny šedi	23
4.3	Ukázka využití masky pro ořez jednoho úhlu	24
4.4	Snímky ukazující před a po provedení rotace, pozn. snímky jsou pro zlepšení viditelnosti důležitých částí oříznuty	25
4.5	vygenerované masky algoritmem LeeMask s odlišným druhem předzpracování, (a)(b) jsou prst l1 a (c)(d) jsou prst c	26
4.6	(a) Rozdíl v detekovaném krevním řečišti, červeně s ekvalizací histogramu, modře bez, růžová při překrytí, (b) Snímek po ekvalizaci histogramu	27
4.7	Porovnání algoritmů pro předzpracování	28
4.8	Detekované krevního řečiště po odlišném nastavení směrodatné odchylky 2D Gaussova filtru σ a doba zpracování t	29
4.9	Detekovaná údolí v průchodech průřezů snímku pod různými úhly	30
4.10	Pravděpodobnost výskytu krevního řečiště	31
4.11	Spojené středy cév	31
4.12	Detekované krevního řečiště při odlišném nastavení poloměru oblasti r a počtu sousedů g s konstantním poměrem 0,5	32
4.13	Detekované krevního řečiště při odlišném nastavení poloměru oblasti r a počtu sousedů g s konstantním poměrem 0,2	33

4.14	Detekované krevního řečiště při odlišném nastavení poloměru oblasti r , počtu sousedů g s konstantním poměrem 0,2 a odlišným nastavením hranice t . . .	33
4.15	Nalezené klíčové body pomocí algoritmu SIFT	34
4.16	Spojení nalezená metodou hledání hrubou silou, viditelných je pouze prvních 15 spojení pro lepší přehlednost	35
4.17	Spojení nalezená algoritmem FLANN, viditelných je pouze prvních 15 spojení pro lepší přehlednost	36
4.18	Spojení a klíčové body nalezené algoritmem ORB, spojování bylo provedeno hrubou silou s křížovou kontrolou, viditelných je pouze prvních 15 spojení pro lepší přehlednost	38
4.19	Manuálně vyznačené klíčové body na snímcích prstu s viditelným krevním řečištěm	39
4.20	Porovnávání šablony	40
4.21	Snímek, ve kterém bylo hledáno je červeně a snímek, ze kterého byla vytvořena šablona je modře	40
4.22	Transformování snímku	41
4.23	Pojmenování jednotlivých pohledů a z nich vytvořených snímků pod různými úhly	43
4.24	Nevhodné snímky pro vytvoření kompozitního snímku	44
4.25	Postupné skládání sousedních snímků	44
4.26	Hotové kompozitní snímky s viditelným krevním řečištěm	46

Kapitola 1

Úvod

S biometrií se v dnešní době setkáváme takřka denně. Jelikož je každý člověk jedinečný, můžeme tuto jedinečnost pozorovat i na jeho částech. Jako jsou například prsty, z nich můžeme získat unikátní otisk a ten využít k verifikaci nebo identifikaci. Unikátní je i krevní řečiště, a právě krevním řečištěm prstu se zabývá tato práce. Přesněji jde o zpracování snímku, na kterém je prst vidět díky zrcadlům z mnoha úhlů a je prosvěcován světlem pod určitou vlnovou délkou, které zvýrazní krevní řečiště.

Protože většina dnešních skenů krevního řečiště je provedena pouze z jednoho úhlu, je z celého krevního řečiště prstu využít pouze tento jeden úhel na indentifikaci. Využitím více úhlů může dojít k přesnější a bezpečnější identifikaci. Jedním ze způsobů, jak získat více úhlů je pomocí několika snímků prstu pod různými úhly, ty je však nutné spojit a zvýraznit na nich krevní řečiště.

Proto je cílem práce z těchto mnoha úhlů vytvořit kompozitní snímek, tedy snímek složený z několika snímků, na kterém bude viditelné zmíněné krevní řečiště. Práce se zabývá dvěma hlavními problémy. Prvním je detekce krevního řečiště na snímku prstu prosvěcovaným světlem o vlnové délce v oblasti blízkého infračerveného záření. A druhým je samotné spojování těchto snímků do jednoho kompozitního snímku.

Kapitola 2

Biometrie

Bio- z řeckého *bios*, znamenající život a -metrie z latinského *metria*, znamenající měřit [11]. Je obor zabývající se rozpoznáváním jedinečných rysů člověka, které jsou využívány k identifikaci a verifikaci osob. Tyto rysy lze rozdělit do dvou hlavních skupin, fyziologické a behaviorální. Behaviorální rysy identifikují jedince podle jeho chování. Mezi behaviorální rysy patří například styl chůze, psaní na klávesnici, písmo, mluva a tlukot srdce [29]. Fyziologické rysy jsou vlastnosti lidského těla, které se nemění vůbec nebo se od určitého věku zásadně nemění. V dnešní době je z této skupiny nejpoužívanější identifikace pomocí otisku prstů. Dalšími fyziologickými rysy jsou například tvar obličeje, vzor duhovky, krevní řečiště sítnice, krevní řečiště dlaně, krevní řečiště prstu a DNA [46].

Biometrie má oproti klasickým způsobům verifikace, například osobního identifikačního čísla (PIN), výhodu v tom, že si uživatel systému nemusí pamatovat žádné kombinace čísel či hesla. Díky tomu zvyšuje uživateli pohodlí. Rys nelze oproti heslu či čipové kartě ztratit nebo zapomenout. Proto jsou biometrické způsoby verifikace bezpečnější než klasické způsoby, které jsou závislé na paměti nebo vlastnictví [47].

2.1 Verifikace a identifikace

V biometrii jsou často používány pojmy verifikace a identifikace. Při verifikaci je ověřováno, zda je uživatel doopravdy ten, za koho se vydává. V biometrických systémech je to ověřeno načtením biometrické šablony uživatele, za kterého se vydává, z databáze a porovnáním biometrické šablony uživatele. Při shodě je uživatel verifikován. Verifikace probíhá nejenom v biometrických systémech, ale například i při práci s bankomatem. Bankovní karta nese informace o jejím čísle, době expiraci a jméno majitele karty [53]. Zadané osobní identifikační číslo je porovnáno s uloženým osobním identifikačním číslem v databázi banky. Pokud se shodují, je uživatel verifikován a dostává přístup ke svému účtu [58][47].

Při identifikaci jsou uživatelovy data porovnávána s uloženými daty, dokud není nalezena shoda. Shoda dat označí o jakého uživatele se jedná. V biometrickém systému se porovnává uživatelova biometrická šablona se všemi biometrickými šablonami načtenými z databáze. Při nalezení shody je uživatel identifikován. K identifikaci mohou být například použity otisky prstů, nalezené na místě činu bezpečnostními složkami. Tyto otisky jsou následně porovnávány s databází otisků prstů. Při shodě je osoba, která otisky zanechala, identifikována [58][47].

2.2 Mezitřídní a vnitrotřídní variabilita

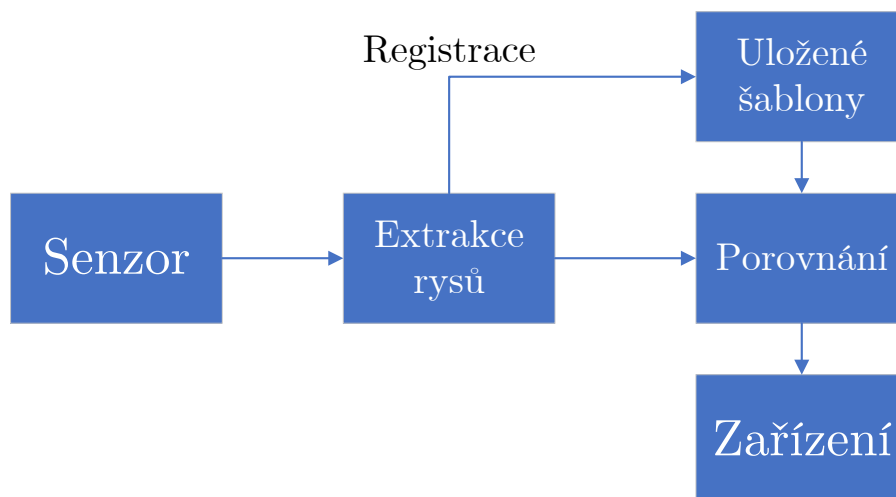
Vnitrotřídní variabilita značí jaký je rozdíl mezi vzorky jedince mezi jednotlivými snímáními. Například rozdíl ve skenech otisků prstů při opakovaném skenování stejným člověkem. V ideálním případě by měla být nulová, ale některé rysy jsou náchylné na fyzické poškození. Tímto rysem je například otisk prstu či sken obličeje. U otisku prstů může při fyzické práci dojít k odření nebo zranění, které je natolik výrazné, že znemožní jejich použití k verifikaci nebo identifikaci. Naopak geometrie krevního řečiště má nízkou vnitrotřídní variabilitu, protože se jejich relativní pozice nemění. Neměnnost pozice krevního řečiště, tedy převážně cév je zajištěna její částí *Tunica externa*, což je vnější obal, kotvící cévu k okolním orgánům [8][50][17].

Mezitřídní variabilita značí jaký je rozdíl mezi vzorky různých jedinců. Ideální mezitřídní variabilita je co nejvyšší, což znamená velké rozdíly mezi vzorky.

2.3 Biometrický systém

Biometrický systém obsahuje dvě části. Část registrační obsahuje biometrický senzor, který získá biometrický vzorek a převede ho do digitální podoby. V případě detektoru otisků prstů se může jednat například o digitální kameru, která vytvoří snímek osvětlené části prstu, nebo kapacitní senzor, který detekuje papilární linie prstu a převede je do digitální podoby [24]. Následně je potřeba z digitální podoby získat biometrické markanty. Jsou to extrahované rysy, které lze využít k identifikaci. Poté je z biometrických markantů vytvořena biometrická šablona. Tato šablona je matematická reprezentace biometrických markantů, která je zašifrována a uložena v databázi [62][17][47].

Validační část obsahuje také biometrický senzor a způsob extrahování rysů. Od registrační části se liší tím, že vytvořená biometrická šablona se neukládá do databáze. Při verifikaci je z databáze načtena příslušná biometrická šablona a je porovnána s vytvořenou biometrickou šablonou. Pokud je shoda biometrických šablon dostatečná je identifikace dané osoby úspěšná. Při nízké shodě biometrických šablon je verifikace neúspěšná [62][17][47].

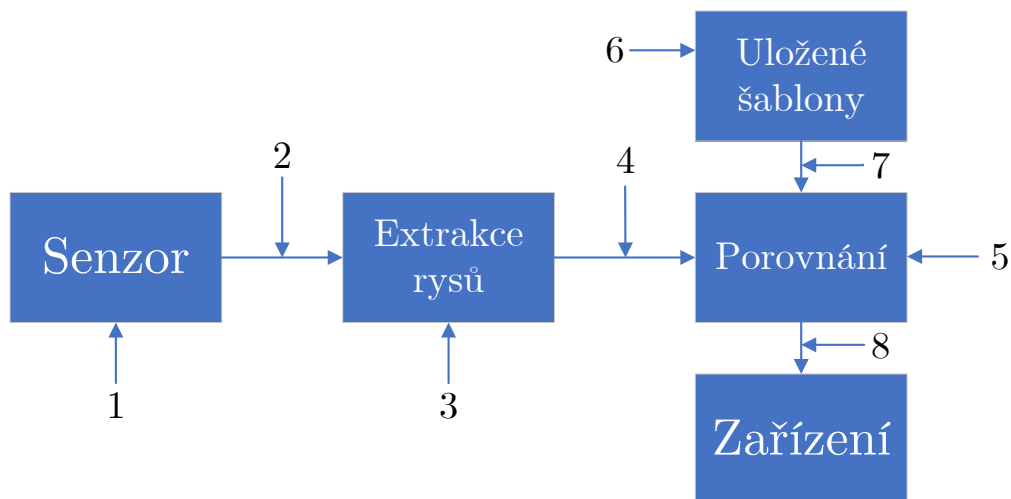


Obrázek 2.1: Schéma biometrického systému

Na obrázku 2.1 je zobrazeno schéma biometrického systému. Dvě části z předchozích dvou odstavců jsou zde spojeny dohromady, jak tomu bývá. Při registraci se biometrický vzorek ze senzoru zpracuje a vytvoří se z něho biometrická šablona. Ta je následně uložena v databázi. Při verifikaci nebo identifikaci je opět vzorek zpracován a vytvořena biometrická šablona s rozdílem, že se porovnává s existující šablonou. Při shodě je zařízení oznámena shoda a naopak.

2.4 Bezpečnost biometrického systému

Biometrický systém musí být odolný vůči různým druhům útoků, které na něj mohou být prováděny. Například biometrické šablony ukládané v databázi bývají šifrované, aby i při úniku dat nebylo možné bez privátního klíče biometrické šablony dešifrovat. Pro ochranu proti falešným biologickým vzorkům může být senzor vybaven kontrolou živosti. Ta ověřuje zda je biologický vzorek od živého jedince a nejedná se například o silikonový otisk prstu. Živost lze zkontrolovat například detekcí srdečního tepu [52][3][17].



Obrázek 2.2: Úhly útoku na biometrický systém

Obrázek 2.2 vyznačuje místa, na které mohou být provedeny útoky. Jaký způsob útoku by mohl být možný na čísla označených místech je popsáno níže:

1. Vložením falešného biologického vzorku do senzoru je možné provést útok na biometrický systém. Útočník se ale nejdříve musí dostat k originálnímu vzorku, což může být velmi obtížné až nemožné. Proti útoku lze využít již zmíněnou kontrolu živosti.
2. Nahráním předchozí úspěšné komunikace a následně jejím přehráním.
3. Virus ovlivňující extrakci rysů.
4. Záměnou biometrické šablony může útočník uspět v následném porovnání. Útočník musí mít přístup k této části biometrického systému a musí znát uloženou biometrickou šablonu, se kterou bude porovnávána.

5. Virus ovlivňující porovnávání může vracet falešné shody biometrických šablon.
6. Modifikace uložených biometrických šablon. Útočník může přidat novou biometrickou šablonu nebo modifikovat existující.
7. Nahrazení biometrické šablony. Útočník pošle k porovnávání falešnou biometrickou šablonu.
8. Nahrazení výsledku porovnávání. Útočník modifikuje výstup z porovnávání tím obějde celý biometrický systém a zařízení dostává informaci o úspěšné verifikaci nebo identifikaci.

2.5 Charakteristiky biometrických rysů

U každého biometrického rysu je možné hodnotit jejich charakteristiky. Dle hodnocení těchto charakteristik lze následně vybrat nejvhodnější biometrický rys pro dané využití.

Hlavní charakteristiky ovlivňující výběr biometrického rysu: [47][28][49][30]

- **Jedinečnost** - Biometrická informace musí být jedinečná pro každého jedince.
- **Přijatelnost** - Jak moc budou lidé ochotni používat rys pro verifikaci nebo identifikaci.
- **Stálost** - Udává k jak velké dojde změně v určitém časovém rozestupu. Například oční sítnice má velmi dobrou stálost, jelikož se geometrie krevního řečiště v sítnici nemění.
- **Univerzálnost** - Jaké množství populace má tento rys k dispozici. V ideálním případě má rys celá populace, protože ale dochází ke zraněním či genetickým vadám není tomu tak. Například nelze získat otisk prstů od jedince, který přišel o ruce.
- **Výkonnost** - Jak přesná a jak rychle byla získána biometrická informace.
- **Zfalšovatelnost** - Jak jednoduché je vytvořit falzifikát biometrického rysu.
- **Získatelnost** - Jak jednoduché a rychlé je získat biometrickou informaci od jedince. Například test DNA má velmi nízké hodnocení získatelnosti, protože se jedná o zdlouhavý proces.

Dalšími charakteristikami, které je vhodné zvážit při výběru biometrického rysu, mohou být cena, velikost zařízení, spotřeba energie a odolnost.

Biometrický rys	Jedinečnost	Přijatelnost	Stálost	Univerzálnost
Otisk prstu	Vysoká	Vysoká	Průměrná	Průměrná
Vzor duhovky	Vysoká	Průměrná	Vysoká	Vysoká
Podpis	Vysoká	Průměrná	Průměrná	Nízká
Obličej	Průměrná	Vysoká	Průměrná	Vysoká
Mluva	Vysoká	Vysoká	Nízká	Průměrná
Styl chůze	Průměrná	Průměrná	Průměrná	Vysoká
Dynamika úhozů	Nízká	Nízká	Nízká	Nízká
Tvar ruky	Průměrná	Průměrná	Nízká	Vysoká
DNA	Vysoká	Průměrná	Vysoká	Vysoká
Krevní řečiště prstu	Vysoká	Průměrná	Vysoká	Průměrná

Biometrický rys	Výkonnost	Zfalšovatelnost	Získatelnost
Otisk prstu	Průměrná	Průměrná	Průměrná
Vzor duhovky	Vysoká	Nízká	Vysoká
Podpis	Průměrná	Nízká	Vysoká
Obličej	Nízká	Vysoká	Vysoká
Mluva	Průměrná	Vysoká	Průměrná
Styl chůze	Nízká	Průměrná	Vysoká
Dynamika úhozů	Nízká	Průměrná	Průměrná
Tvar ruky	Průměrná	Průměrná	Vysoká
DNA	Vysoká	Nízká	Nízká
Krevní řečiště prstu	Vysoká	Nízká	Průměrná

Tabulka 2.1: Porovnání biometrických rysů a jejich charakteristik [47][28][49][4]


2.6 Využití krevního řečiště v biometrii

Použití krevního řečiště je jeden z novějších způsobů pro verifikaci nebo identifikaci osob. Jeden ze způsobů u ruky spočívá v osvětlení nebo prosvícení části ruky infračerveným zářením. Hemoglobin, který je obsažen v červených krvinkách, pohlcuje infračervené záření více než ostatní tkáň. Proto při provedení snímku bude krevní řečiště tmavší oproti okolní tkáni. Snímek je potřeba udělat kamerou schopnou zachytit infračervené záření. Snímek sítnice a jejího krevního řečiště je možné vytvořit za viditelného světla, protože je krevní řečiště dobře rozpoznatelné. Po pořízení snímku je snímek zpracován v biometrickém systému [17][47][55].

Tento způsob skenování a verifikace osob je rychlý a zároveň bezpečný, protože geometrii krevního řečiště nelze jednoduše od osoby získat, a i při získání krevního řečiště ruky je vytvoření falešné ruky nepraktické. Na rozdíl od otisků prstů se poslední zařízení zaměřují na bezkontaktní snímání krevního řečiště, a to vede k větší hygieničnosti. U rukou není tento způsob skenování náchylný na mechanické poškození rukou, protože je krevní řečiště pod kůží, takže dokud má osoba ruku, může být provedena verifikace nebo identifikace. V dnešní době skenery krevního řečiště dlaně používají některé banky v Japonsku pro verifikaci osob v bankomatech [21][17][47][55].

Použití blízkého infračerveného světla

Blízké infračervené světlo, více známé pod anglickým názvem *Near-Infrared* nebo zkratkou NIR je často používané ve vaskulární biometrii. Využívá se k detekci žil a zbytku krevního řečiště, protože hemoglobin pohlcuje více infračerveného světla než okolní tkáň [56].



Obrázek 2.3: Graf absorpce NIR různými látkami v těle, převzato z [1]


Obrázek 2.3 ukazuje absorpční koeficienty látek v závislosti na vlnové délce. Na ose y je v logaritmickém měřítku absorpční koeficient, osa x označuje vlnovou délku. Okysličená krev je v grafu vyznačena červeně, neokysličená krev modře tečkovaně, kůže žlutě čárkovaně a tuk zeleně čárkovaně. Lze tedy pozorovat proč budou na snímcích vidět krevní řečiště a to je z důvodu vyšší absorpce. Také by mělo být možné nepřímou detekovat tepny vedoucí okysličenou krev od žil, které vedou krev neokysličenou. Právě díky rozdílu jejich absorpce při rozsahu vlnové délky od 700 do 850 nm. Rozdíl na vstupních snímcích však není dostatečně znatelný k jejich rozpoznání, a proto bude detekováno celé krevní řečiště [56][61][1].

Kapitola 3

Návrh řešení

Vstupními snímky jsou snímky z přístroje sestaveného na fakultě informačních technologií, výzkumnou skupinou STRaDe. Každý prst je za pomoci zrcadel na jednom snímku vidět pod několika úhly. Pro každý prst je vytvořena sada snímků, kde v každém snímku je prst v přístroji prosvěcován rozdílnou intenzitou světla. Pro každý prst jsou dvě sady snímků, z dorsální a palmární strany.

Pohledy na prst, pod různými úhly, je třeba rozdělit do jednotlivých snímků. Z rozdělených snímků je odebráno pozadí a zůstává pouze prst. Na nalezení a zvýraznění krevního řečiště bude použita knihovna Biometric Vein Recognition Library, obsahující několik způsobů detekce krevního řečiště [13]. Pro vytvoření kompozitního snímku bude využita knihovna OpenCV, která obsahuje velké množství funkcí pro práci s obrazem [43].



Obrázek 3.1: Příklad vstupního snímku

3.1 Rozdělení úhlů a rotace prstu

Protože je na snímku prst viditelný z různých úhlů je potřeba nejdříve rozdělit jednotlivé pohledy. Toho lze docílit manuálně vytvořenou maskou, jelikož se pohledy nemění. Masku je následně použita k rozdělení pohledů.

Následující algoritmy očekávají snímky prstu v horizontální poloze. I pro konečné skládání kompozitního snímku je vhodné mít veškeré snímky ve stejné poloze. Protože je poloha odrazů prstů ve vstupním snímku z přístroje mezi subjekty neměnná, lze manuálně změřit úhel a provést rotaci okolo místa, kde prst vstupuje do přístroje.

Pro rotaci o daný úhel okolo zadaného bodu je potřeba vytvořit matici transformace. Ta bude vytvořena vynásobením matice translace ke středu rotace, matice rotace a opačné matice translace, aby nedošlo k posunu středu rotace. Tyto matice lze vidět v rovnici 3.1, kde x_0 a y_0 jsou souřadnice středu rotace, θ je úhel rotace a x a y jsou vstupní souřadnice.

$$f(x, y) = \begin{bmatrix} 1 & 0 & x_0 \\ 0 & 1 & y_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos(\theta) & -\sin(\theta) & 0 \\ \sin(\theta) & \cos(\theta) & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & -x_0 \\ 0 & 1 & -y_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (3.1)$$

3.2 Předzpracování

Protože následující detekce krevního řečiště je závislá na kontrastu krevního řečiště oproti okolní tkáni je vhodné provést předzpracování, které zvýší kontrast krevního řečiště. Kontrast je zvýšen také prstu oproti pozadí, což umožní přesnější vytvoření masky. Zvyšování kontrastu bude testováno dvěma algoritmy a to ekvalizací histogramu, neboli Histogram Equalization a algoritmem CLAHE. Následně bude vytvořena přesnější maska prstu pomocí algoritmu Lee Mask.

Ekvalizace histogramu

Cílem ekvalizace histogramu je zvýšení kontrastu, dosáhne se toho rozprostřením nejčastěji se vyskytujících hodnot. Toho je docíleno pomocí distribuční funkce histogramu vstupního snímku. Jelikož má distribuční funkce obor hodnot pouze v rozsahu od nuly do jedné, je třeba ji vynásobit počtem možných úrovní šedé mínus jedna. Při použití této funkce na snímek bude jeho histogram ekvalizován [26].

CLAHE

Algoritmus CLAHE, jehož zkratka znamená *Contrast Limited Adaptive Histogram Equalization*, pracuje také s histogramem, ale nejdříve je snímek rozdělen do oblastí dané velikosti. Poté jsou intervaly v histogramu přesahující zadanou hodnotu rovnoměrně rozprostřeny do ostatních intervalů, takto lze předejít zesilování šumu. Následně provedena ekvalizace histogramu pro každou oblast. Díky rozprostření přesahujících intervalů může mezi oblastmi vzniknout výrazný rozdíl, proto jsou okraje oblastí odebrány a tyto mezery jsou dopočítány bilineární interpolací z okolních hodnot mezi oblastmi [40].

Lee Mask

Pro přesnější masky prstu je použita funkce LeeMask, která je součástí knihovny Biometric Vein Recognition Library. Funkce je implementací metody k lokalizaci oblasti, ve které se


nachází prst, popsané v článku od autorů Eui Chul Lee, Hyeon Chang Lee a Kang Ryoung Park [32].

Metoda předpokládá prst v horizontální poloze, další důvod pro předchozí rotaci snímku prstu. Dále rozdělí prst horizontálně na horní a dolní polovinu. Následně postupuje po sloupcích zadané šířky, ty jsou rozděleny na oblasti zadané výšky a hledá rozdíl v jasů v těchto oblastech, protože prst je prosvěcován blízkým infračerveným světlem, bude jasnější jak pozadí. Největší rozdíl mezi oblastmi se zvolí jako hranice mezi pozadím a prstem. Pro každou polovinu je vyhledávání provedeno zvlášť. V horní polovině je vyhledávána horní hranice prstu a v dolní polovině dolní hranice [32].

3.3 Detekování a vyznačení krevního řečiště

Maximum Curvature

K detekci krevního řečiště lze použít knihovnu Biometric Vein Recognition Library. Tato knihovna využívá algoritmu Maximum Curvature, zobrazené na obrázku 3.2, která hledá velké rozdíly v zakřivení křivky jasů ve sloupci pixelů. Při nalezení takového bodu nebo bodů, jsou zkontrolovány také jejich okolní pixely. Dle jejich hodnot je určeno zda bude céva zakreslena a jakým směrem [13][37].

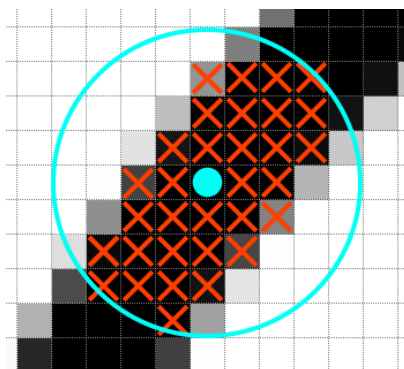


Obrázek 3.2: Hledání krevního řečiště za pomoci rozdílů v zakřivení křivky jasů v průřezu prstu. Převzato z [37]

Wide Line Detector

Dalším algoritmem z knihovny Biometric Vein Recognition Library je Wide Line Detector. Ten pro každý pixel na snímku, prochází pixely v jeho okolní kruhové oblasti. Velikost okolní kruhové oblasti je dána zadaným poloměrem r . Pro každý pixel v oblasti je vypočítán rozdíl jeho hodnoty od hodnoty středového, pokud je rozdíl menší nebo se rovná zadané hodnotě t je pomocné proměnné přičtena jedna. Po zkontrolování všech okolních pixelů

je hodnota pomocné proměnné porovnána s zadanou hodnotou g , pokud je menší nebo se rovná je středový pixel označen za část krevního řečiště, jinak se jedná o pozadí. Obrázek 3.3 zobrazuje příklad fungování algoritmu [33][27].



Obrázek 3.3: Wide Line Detector, modré kolečko je středový bod, modrá kružnice označuje oblast, červenými křížky jsou označeny pixely jejichž rozdíl hodnoty oproti středovému bodu je menší nebo se rovná zadané hodnotě

3.4 Detekce klíčových bodů


Pro detekci klíčových bodů bude využito metod SIFT a ORB z knihovny OpenCV. Klíčové body jsou důležité pro vytvoření kompozitního snímku. Nejdříve se využije jedné ze zmíněných metod pro jejich nalezení na snímcích prstu z různých úhlů. Poté je potřeba na sousedních snímcích najít nejvíce se shodující klíčové body. Na nalezení shodujících se bodů se použije třídy BFMatcher a FLANN z knihovny OpenCV.

SIFT

neboli Scale-Invariant Feature Transform. Pracuje v následujících čtyřech krocích.

V prvním kroku se provede konvoluce snímku s 2D Gaussovým filtrem s postupně se zvyšující směrodatnou odchylkou. Tím vznikne sada snímků se zvyšující se intenzitou filtrace, v SIFT je tato sada označována jako oktáva. Následně je celá oktáva zmenšena pomocí Gaussovy pyramidy, na poloviční rozlišení. Zmenšení není prováděno snížením rozlišení, ale další filtrací 2D Gaussovým filtrem. Sousední snímky v oktávě jsou od sebe odečteny. Odečtením je vytvořen rozdíl Gaussiánů, v originále *Difference of Gaussians* se zkratkou *DoG*. Tímto způsobem jsou vytvořeny rozdíly mezi všemi sousedními snímky, ve všech oktávách. Přesný počet oktáv používaných v SIFT je čtyři a počet snímků v každé oktávě je pět. Budou tedy vytvořeny čtyři rozdíly Gaussiánů mezi snímky v každé oktávě, viz obrázek 3.4[35][51][16].

V těchto rozdílech jsou vyhledány lokální maxima a minima. Každý extrém je porovnán s jeho osmi sousedními pixely a s pixely na stejných pozicích v předchozím a následujícím rozdílu Gaussiánů v rámci stejné oktávy. Dojde k 26 porovnání a pokud je porovnáván extrém největší nebo nejmenší, pokud šlo o lokální maximum nebo minimum, je tento bod určen jako potencionální klíčový bod a bude dále zpracováván, viz obrázek 3.5. Takto jsou zkontrolovány všechny lokální extrémy ve všech rozdílech Gaussiánů [35][51][16].




Obrázek 3.4: Oktávy a rozdíl Gaussiánů, převzato a upraveno [35]

Druhým krokem je zpřesnění lokalizace klíčových bodů. Protože je v minulém kroku nalezeno velké množství potencionálních klíčových bodů, je třeba vybrat nejvhodnější nebo spíše eliminovat méně vhodné body. V prvním kole eliminací jsou eliminovány body s nízkým kontrastem. Toho je docíleno výpočtem Taylorova rozvoje druhého stupně, který je posunutý tak, aby jeho počátek byl v právě kontrolovaném bodě. Pokud je výsledek rozvoje větší než 0,5 v jakémkoliv směru znamená to, že extrém leží blíže k jinému bodu. V tomto případě je kontrolovaný bod změněn a pozice extrému je interpolací určena. Pokud je však funkční hodnota v tomto bodě menší než 0,03, je bod eliminován [35][51][16].

Rozdíl Gaussiánů zvýrazní nejvíce hrany, ty však nejsou vhodné jako klíčové body, protože ve směru hrany nedochází k výrazným změnám, které by byly unikátní. Také si jsou klíčové body na hraně navzájem velmi podobné. Proto je vhodné potencionální klíčové body na hranách eliminovat. Použita je k tomu Hessova matice o rozměru 2×2 , která obsahuje odhady derivací sousedících bodů. Vlastní hodnoty matice jsou úměrné k zakřivení v okolí bodu. Po výpočtu determinantu této matice a součtu prvků na hlavní diagonále jsou tyto hodnoty použity pro výpočet poměru mezi největší vlastní hodnotou a menší vlastní hodnotou. Vlastní hodnoty nejsou přímo počítány, protože se jedná o náročnější výpočet než pouze poměr vlastních hodnot. Pokud je poměr vlastních hodnot větší jak 10, je tento potencionální bod eliminován. Tento způsob eliminace potencionálních klíčových bodů na hranách je použit v algoritmu Harris Corner Detection, odkud byl převzat do algoritmu SIFT. Tím je eliminace potencionálních bodů u konce a body, které nebyly eliminovány jsou nyní považovány za klíčové body [35][16][25].

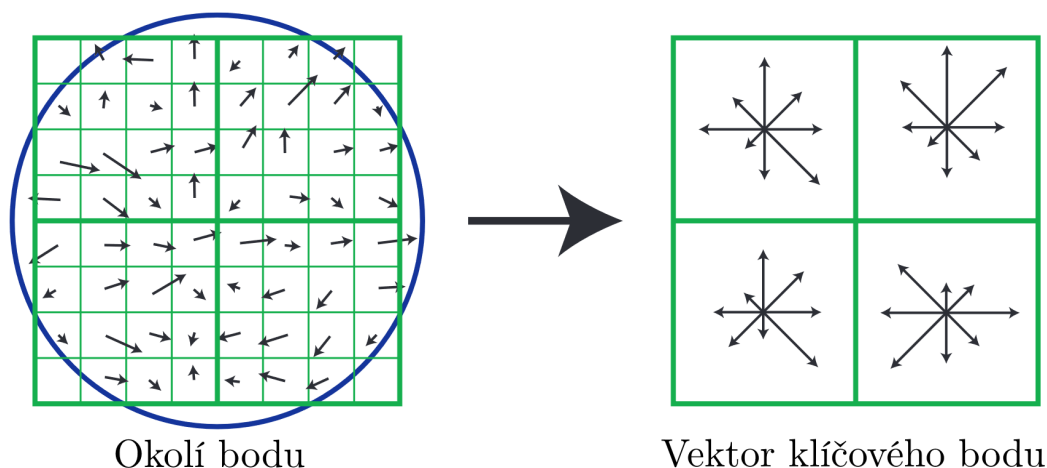
Ve třetím kroku jsou klíčovým bodům přiřazena orientace. Díky přiřazení rotace je tato metoda neměnná na otočení snímku. Orientace je klíčovému bodu přiřazena následovně. V rozdílů Gaussiánů, ve kterém byl klíčový bod prvně nalezen, to je rozdíl dvou snímků v určité októvě z kroku jedna, jsou vypočítány hodnoty označující velikost změny přechodu a směr tohoto přechodu z bodů v okolí klíčového bodu. Následně je vytvořen histogram z těchto hodnot. Histogram je rozdělen podle směru přechodu do 36 intervalů



Obrázek 3.5: Vyhledávání lokálních extrémů, x značí nalezený extrém, zelené kolečka místa, se kterými je porovnáváno, převzato a upraveno [35]

pokrývajících celých 360 stupňů. Směr přechodu určí do jakého intervalu bod bude přiřazen a jeho velikost změny přechodu bude tedy přičtena do hodnoty vybraného intervalu. Z vytvořeného histogramu vybereme interval s nejvyšší hodnotou. Pokud v histogramu není žádný interval, který by měl velikost větší jak 80% nejvyšší hodnoty, je klíčovému bodu přiřazena orientace. Pokud však existuje další vrchol v histogramu, který má hodnotu vyšší jak 80% té nejvyšší hodnoty, je vytvořen další klíčový bod s totožnou pozicí a s orientací danou tímto dalším vrcholem v histogramu. Klíčové body jsou vytvořeny pro všechny vrcholy překračující zmíněnou hranici 80% nejvyšší hodnoty [35][16].

Čtvrtý krok přiřadí každému klíčovému bodu vektor, který popisuje okolí tohoto bodu. Díky tomuto vektoru bude klíčový bod neměnný na změnách světlosti a úhlu pohledu. Například při budoucím porovnávání a spojování klíčových bodů mezi dvěma snímky, může být jeden ze snímků vyfocen pod jiným úhlem a nebo i za jiného osvětlení, aniž by bylo negativně ovlivněno porovnávání a spojování klíčových bodů. Pracovat se bude s pixely okolo klíčového bodu, opět se použije snímek, ve kterém byl v prvním kroku klíčový bod nalezen. Okolních 16x16 pixelů je rozděleno do 16 skupin o velikosti 4x4. V každém pixelu je stejně jako v kroku třetím vypočítána velikost změny přechodu a směr přechodu. Nyní jsou však hodnoty otočeny v závislosti na orientaci klíčového bodu. Tím se udrží neměnnost při rotaci snímku. Na celou oblast 16x16 je použita Gaussova funkce se směrodatnou odchylkou o velikosti poloviny oblasti. To zajistí, že pixely nejbližší klíčovému bodu mají výrazně vyšší váhu než body na okraji oblasti. Stejně jako v kroku třetím jsou vytvořeny histogramy podle úhlu přechodu pixelů. Histogramy jsou však vytvořeny pro každou podoblast o velikosti 4x4 zvlášť a počet intervalů v histogramech je 8. Vektor je vytvořen z 16 histogramů, kde každý histogram má 8 intervalů, to znamená 128 hodnot. Postup tvorby vektoru je na obrázku 3.6. Aby docházelo k menšímu ovlivnění díky jasů, je nutné vektor normalizovat. Kvůli nelineárnímu osvětlení je však potřeba udělat další úpravy. Hodnoty ve vektoru přesahující hodnotu 0,2 jsou nastaveny na tuto hodnotu, tím je dána větší váha úhlu přechodu než hodnotě přechodu. Vektor je opět normalizován a tím je krok u konce [35][16].



Obrázek 3.6: Vektor popisující klíčový bod, pro přehlednost je okolí zmenšeno na 8×8 a vektor 2×2 oproti reálným 16×16 a 4×4 , modře označeno pole působení Gaussovy funkce, převzato a upraveno [35]

ORB

Druhým algoritmem je algoritmus se zkratkou ORB, znamenající *Oriented FAST and Rotated BRIEF*. Který byl vyvinut jako svobodná alternativa k patentovaným algoritmům SIFT a SURF. Patent na SIFT skončil v roce 2020, ale patent na algoritmus SURF je stále platný a to do roku 2029. Algoritmus ORB využívá k hledání klíčových bodů algoritmus FAST, *Features from Accelerated and Segments Test*. Klíčovým bodům je přidána orientace, protože algoritmus FAST ji nepřidává. Informace o klíčovém bodě nejsou uloženy jako vektor, například jako u algoritmu SIFT, ale v binární podobě a to algoritmem BRIEF, *Binary robust independent elementary feature*. Hledání klíčových bodů je několikrát rychlejší oproti algoritmu SIFT a díky binární podobě informace o klíčovém bodě je i následné hledání spojené rychlejší [34][22] [54][48].

Pro spojování klíčových bodů nalezených algoritmem ORB lze využít stejné algoritmy popsané a porovnané v předchozích odstavcích u algoritmu SIFT. Tedy hledání hrubou silou a algoritmus FLANN. S rozdílem, že vzdálenost klíčového bodu, která se bude porovnávat musí být počítána jiným způsobem, než například tomu je u algoritmu SIFT, kde je vzdálenost vektoru vypočtena L^2 normou. To je z důvodu jiného způsobu uložení vzdálenosti, jak již bylo zmíněno algoritmus ORB využívá k uložení informací o klíčovém bodě binární formu. Proto je vzdálenost počítána jako Hammingova vzdálenost, což je vlastně počet rozdílů mezi binárními čísly. Tuto hodnotu lze tedy jednoduše vypočítat operací exkluzivní disjunkce, neboli XOR a následně spočítat počet jedniček ve výsledném binárním čísle. Obě tyto operace jsou velmi rychlé, protože alespoň pro architekturu x86 pro ně existují specifické instrukce [48][39].

Vyhledávání markantů

Dalším alternativním způsobem, jak vyhledávat klíčové body je vyhledávání markantů, v angličtině *minutiae*. Tímto způsobem funguje tvorba klíčových bodů u snímku otisku prstu, kde jsou za klíčové body považovány změny tvaru v papilárních liniích. Těmito změnami mohou být rozvětvení, ukončení, ostrov, smyčka a další. Podobné body by mohlo být možné

hledat ve snímcích krevního řečiště. Toto řešení je pro krevní řečiště ruky popsáno v článku od autorů Wang, Leedham a Cho [59][5].

3.5 Spojování klíčových bodů

Spojování klíčových bodů znamená, že se ve dvou snímcích vyhledají pomocí algoritmu pro detekci klíčových bodů klíčové body. Následně jsou vyhledány nejvíce se shodující klíčové body mezi snímky. Jejich shoda je počítána pozicí klíčového bodu ve snímku a jeho vektorem nebo binární hodnotou. Toho je potřeba docílit, aby bylo možné následně pomocí spojených klíčových bodů vypočítat jak je druhý snímek potřeba transformovat, aby se tyto klíčové body překrývaly.

Hledání nejvíce se shodujících klíčových bodů bylo vyzkoušeno dvěma způsoby, hrubou silou a algoritmem FLANN. Oba algoritmy jsou již součástí knihovny OpenCV a budou tedy využity tyto varianty.

Spojování hrubou silou

Nejjednodušším způsobem jak spojovat klíčové body je hrubou silou. Klíčový bod z prvního snímku je porovnáván se všemi klíčovými body z druhého snímku. U klíčových bodů nalezených algoritmem SIFT je porovnávána vzdálenost jejich vektorů a pro výpočet vzdálenosti se používá L^2 norma. Ta je popsána vzorcem 3.2 níže, kde $norm$ je výsledná norma používaná dále jako vzdálenost, $src1$ a $src2$ jsou vstupní pole obsahující hodnoty vektorů klíčových bodů [41][42][18].

$$norm = \|src1 - src2\|_{L_2} = \sqrt{\sum_I (src1(I) - src2(I))^2} \quad (3.2)$$

FLANN

Druhým testovaným algoritmem pro spojování klíčových bodů je algoritmus se zkratkou FLANN, která znamená *Fast Library for Approximate Nearest Neighbors*. Byl vyvinut kvůli vysoké časové náročnosti vyhledávání nejbližších sousedů lineárním vyhledáváním, tedy hrubou silou. Například při snímku se 100 tisíci klíčovými body lze pomocí tohoto algoritmu dosáhnout až 1000 násobné rychlosti s 95% úspěšností nalezených spojení oproti hledání lineárně hrubou silou. Pro zrychlení se využívá algoritmu s náhodně sestavenými kd-stromy, kde je přesnost ovlivněna počtem zkontrolovaných listových uzlů a nebo stromu využívajícího algoritmu k-means, který je vytvořen rozdělováním bodů do úrovní pomocí algoritmu k-means, dokud jsou shluky vytvořené tímto algoritmem větší jak požadovaná velikost. Testovaná varianta využívala 5 náhodných kd-stromů s počtem kontrolování listových uzlů nastavených na 50. Tímto způsobem byly vyhledány pro každý klíčový bod dvě spojení s nejnižší hodnotou a následně je použita eliminace falešně pozitivních spojení poměrem jejich vzdáleností. Eliminována byla spojení, u kterých byl poměr větší jak 0,8, stejně jak bylo popsáno u hledání hrubou silou [38].

Eliminace falešně pozitivních spojení

Po porovnání jednoho klíčového bodu z prvního snímku se všemi klíčovými body z druhého snímku jsou dvě spojení s nejnižší vzdáleností uloženy a pokračuje se ve spojování dalšího

klíčového bodu. Jakmile je dokončeno porovnávání pro všechny klíčové body z prvního snímku, je provedena eliminace falešně pozitivních spojení.

Poměrem vzdáleností

Proto byla ukládána u algoritmů dvě spojení. Pro eliminaci je vypočítán poměr vzdáleností prvního a druhého spojení pro každý klíčový bod. Pokud je poměr jejich vzdáleností větší jak 0,8, jsou obě spojení eliminována, protože jsou si natolik podobná a je velká pravděpodobnost, že se bude jednat o falešně pozitivní spojení [35][41][18].

Křížovou kontrolou

Dalším způsobem jak eliminovat falešně pozitivní spojení je křížová kontrola, v originále *Cross-Check*. Spojení jsou opět hledána podle vzdálenosti a pro každý klíčový bod je vytvořen sestupný seznam spojení, kde spojení s nejnižší vzdáleností je první. Následně je provedena křížová kontrola, to znamená, že se opět provede hledání spojení, nyní ale pro klíčový bod z druhého snímku, který byl nejlepším spojením klíčového bodu z prvního snímku. Pokud je pro klíčový bod z druhého snímku nejlepším spojením klíčový bod z prvního, spojení je ponecháno. Pokud však je nalezeno spojení s nižší vzdáleností než ke zmiňovanému klíčovému bodu z prvního snímku, je originální spojení eliminováno. Například pokud má klíčový bod A ze snímku A nejnižší spojení s klíčovým bodem B na snímku B, musí platit, že pro klíčový bod B je spojení s nejnižší hodnotou právě s klíčovým bodem A, jinak je spojení z klíčového bodu A do B eliminováno. Tento způsob je vhodnou alternativou pro způsob s porovnáváním poměrů [41][18].

3.6 Odhad matice transformace pomocí klíčových bodů

Při změně úhlu pohledu na prst dochází k deformaci tvaru krevního řečiště, proto je nutné vytvořit matici transformace a tuto deformaci co nejvíce snížit. Matice vyjadřuje rozdíly mezi klíčovými body snímků v jejich translaci, rotaci a změně měřítko. Pomocí této matice bude docházet k lepšímu překrytí sousedních snímků. K vytvoření matice transformace bude využita funkce `findHomography` z knihovny `OpenCV`.

3.7 Vytvoření kompozitního snímku

Pomocí matice transformace vytvořené v předchozí části a funkce `warpPerspective` z knihovny `OpenCV` deformujeme snímky. Následně je překryjeme, aby došlo k zarovnání klíčových bodů. V překrývající se oblasti obrázku je potřeba vytvořit jejich prolínání, aby nebyl spoj příliš viditelný. Použit bude algoritmus váhového sčítání. Sčítaným snímkům je nejdříve přiřazena váha. Tato váha určí hodnotu průhlednosti snímku. Snímky s částečnou průhledností jsou nakonec sečteny. Sčítání dvojic snímků se opakuje do sečtení poslední dvojice [60].

3.8 Používané algoritmy

V této části jsou popsány vybrané algoritmy a funkce často využívané jinými algoritmy použitými v této práci.

2D Gaussův filtr a jeho použití


V algoritmech SIFT, Maximum Curvature a dalších je použit ke snížení ostrosti snímku a snížení intenzity šumu. Jedná se o nelineární dolní propust. Díky tomu dojde ke ztrátě malých detailů a je možné se zaměřit a větší. Využívána je k tomu Gaussova funkce, která má dva vstupní parametry, střední hodnotu a směrodatnou odchylku σ . Pro tvorbu filtru se vždy používá střední hodnoty 0, vrchol je tedy také v 0 [36].

K filtraci je potřeba nejdříve vytvořit matici o zadané velikosti, většinou je velikost určena jako šestnásobek směrodatné odchylky plus jedna. Protože ve vzdálenosti trojnásobku směrodatné odchylky od vrcholu má funkce velmi nízkou hodnotu a plus jedna, aby byla velikost matice lichá a tudíž bude střed v jednom bodě. Do matice jsou dosazeny hodnoty podle rovnice 2D Gaussovy funkce napsané níže. Dosazení je provedeno tak, aby střed funkce byl ve středu matice. 2D Gaussova funkce je rozšíření Gaussovy funkce o další rozměr. Tato matice je následně jádrem pro konvoluci snímku [36][23].

$$G(x, y)_\sigma = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (3.3)$$

Bilineární interpolace

Je funkce používaná k výpočtu hodnoty bodu z okolních bodů. Použita je například v algoritmu CLAHE a ve funkci pro aplikaci matice transformace na snímek, je také často využívána při změně rozlišení snímku [9].



Obrázek 3.7: Postup bilineární interpolace pro výpočet hodnoty bodu P , převzato z [9]

Následující popis fungování je převzat z [9] a vztahuje se k obrázku 3.7.

Nejdříve je vypočtena lineární interpolace mezi body Q_{11} a Q_{21} a mezi body Q_{12} a Q_{22} pomocí vzorce níže.

$$R_1 = Q_{11} \frac{x_2 - x}{x_2 - x_1} + Q_{21} \frac{x - x_1}{x_2 - x_1} \quad R_2 = Q_{12} \frac{x_2 - x}{x_2 - x_1} + Q_{22} \frac{x - x_1}{x_2 - x_1} \quad (3.4)$$

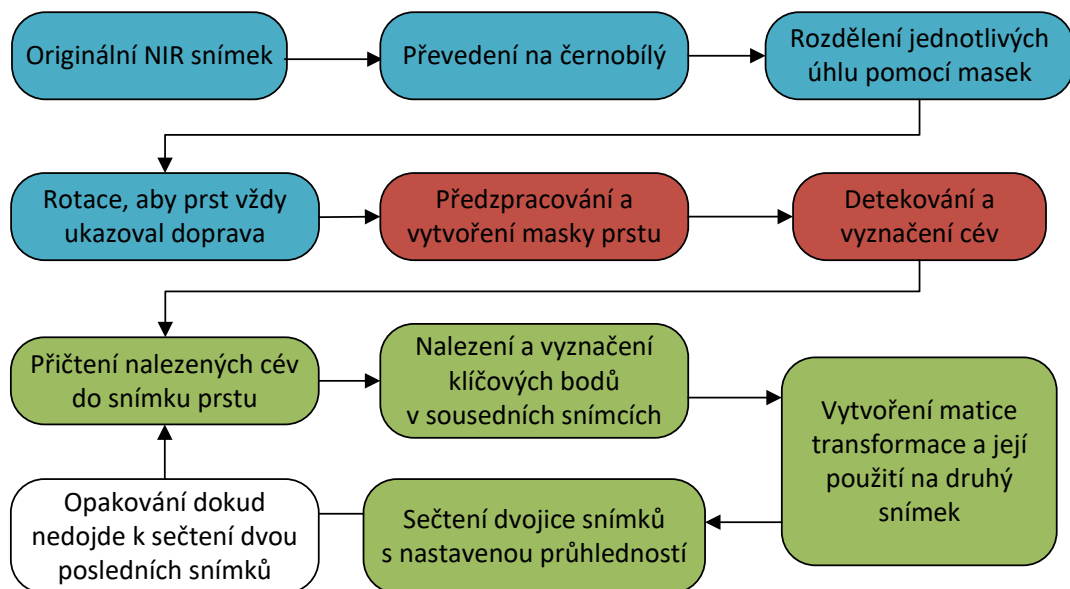
Nakonec je hodnota bodu P vypočtena další lineární interpolací z předchozích výsledků R_1 a R_2 , vzorcem níže.

$$P = R_1 \frac{y_2 - y}{y_2 - y_1} + R_2 \frac{y - y_1}{y_2 - y_1} \quad (3.5)$$

Kapitola 4

Realizace

Výsledný postup zpracování je rozdělen do tří logických částí. V první části dojde k rozdělení vstupního snímku na snímky s jednotlivými úhly a jejich rotaci. Následně jsou v druhé části vyhledáno a vyznačeno krevního řečiště. A v poslední části dojde k samotnému vytvoření kompozitního snímku.



Obrázek 4.1: Postup zpracování řešení

Obrázek 4.1 zobrazuje postup zpracování snímku. Tři části zmíněné v předchozím odstavci jsou barevně odlišeny. **Modře** je označeno zpracování vstupního snímku na jednotlivé snímky úhlů prstu. **Červeně** vyhledání a vyznačení krevního řečiště. A **zeleně** je označeno vytvoření matice transformace díky klíčovým bodům a její využití pro tvorbu kompozitního snímku. Podrobnější popis jednotlivých částí je v následujících částech této kapitoly.

Výsledné řešení se ve většině částí zásadně neliší od návrhu řešení. Pouze hledání klíčových bodů nebylo možné využít automatizované řešení, jako je například SIFT nebo ORB, ale je nutné klíčové body označovat ručně. Bližší popis tohoto problému je v části 4.5.

4.1 Použité knihovny a struktura řešení

Pro zpracování snímku a vyhledávání krevního řečiště a složení kompozitního snímku je použit skript napsaný v skriptovacím jazyce Python. Python byl zvolen z důvodu dostupnosti knihoven vhodných pro řešení práce. Hlavní skript pracuje v pořadí, které odpovídá rozdělení v úvodu této kapitoly. Lze však spustit jednotlivé části odděleni, pokud byly předchozí už spuštěny předtím. Podporuje také hromadné zpracovávání celých složek. Lze zvolit metodu předzpracování, z algoritmů CLAHE, Histogram Equalization a bez přezpracování. Také lze vybrat algoritmus pro detekci krevního řečiště a to buď Maximum Curvature nebo Wide Line. Pro skládání kompozitního snímku je implementována pouze metoda s manuálním vyznačováním klíčových bodů. Klíčové body lze načítat a ukládat ze a do souboru. Kvůli knihovně Biometric Vein Recognition Library je skript funkční pouze na systémech s operačním systémem Linux. A pro manuální vyznačování klíčových bodů je nutné mít desktopové prostředí kvůli oknu, které skript vytvoří. Použití některých algoritmů bylo převzato z dokumentace OpenCV a příkladu užití knihovny Biometric Vein Recognition Library. Bližší popis instalace knihoven, příklady užití a popis ovládání je v příloženém souboru.

OpenCV

Open Computer Vision Library je knihovna zaměřená na počítačové vidění a zpracování obrazu v reálném čase. Veškerá implementace algoritmů je psána v jazyce C++ a následně jsou wrappery pro Python generovány automaticky pomocí hlavičkových souborů C++. Manuálně musel být upraven datový typ Mat, využívaný pro matice, pro Python je nahrazen pomocí knihovny Numpy. Python modul `cv2` obsahuje veškeré zkompileované wrappery a mnoho dalších úprav pro zvýšení kompatibility. Výhodou využití wrapperů je vyšší rychlost, protože předkompilované C++ funkce jsou výrazně rychlejší než by bylo interpretování funkcí, i kdyby byly přepsány, přímo v Pythonu [45][44].

Biometric Vein Recognition Library

Jedná se o rozšíření knihovny bob.bio.base, která je součástí projektu **Bob** vyvinutým na výzkumném institutu Idiap ve Švýcarsku. Obsahuje implementaci tří způsobů detekce krevního řečiště. Repeated Line Tracking, Wide Line Detector a Maximum Curvature [7][6].

V řešení je použita metoda Maximum Curvature a Wide Line, protože dle výsledků na databázi VERA FingerVein mají největší přesnost. Porovnání metod na databázi VERA FingerVein, která má 440 snímků 110 subjektů, je vidět v tabulce 4.1[10][57].

Metoda	Čas [hh:mm]	Chybovost [%]
Repeated Line Tracking	01:16	14,6
Wide Line Detector	00:07	5,8
Maximum Curvature	03:28	2,5

Tabulka 4.1: Porovnání metod pro detekci krevního řečiště na databázi VERA FingerVein


4.2 Rozdělení úhlů do jednotlivých snímků

Převod do stupňů šedi

Prvním krokem pro práci se vstupním snímkem je jeho převedení do stupňů šedi. A to protože použité funkce, například funkce pro algoritmus CLAHE nebo z knihovny OpenCV a funkce pro detekci krevního řečiště toto vyžadují. Asi z důvodu rychlosti, protože se pracuje pouze s jedním barevným kanálem namísto tří při RGB nebo i čtyř pokud uvažujeme i alfa kanál. Převedení je provedeno klasickým způsobem, to znamená že hodnota v určitém pixelu je dána hodnotou červeného, modrého a zeleného kanálu v daném pixelu. Každý z těchto kanálů je vynásobený určitou konstantou a sečteny, viz vzorec 4.1 níže [14].

$$Y = 0,299 \cdot R + 0,587 \cdot G + 0,114 \cdot B \quad (4.1)$$

Jelikož krev pohlcuje blízké infračervené světlo více jak okolní tkáň, měla by potřebná informace, to je pozice tepen a zbytku krevního řečiště, být právě v červeném spektru, které je nejbližší blízkému infračervenému. To by mohlo zvednout kontrast tudíž by mohla být větší úspěšnost při detekci krevního řečiště. Bylo proto experimentováno s použitím pouze červeného kanálu pro převedení do stupňů šedi.




Obrázek 4.2: Rozdíly v nalezeném krevním řečišti při rozdílném způsobu převodu na odstíny šedi

Na obrázku 4.2 lze vidět, že jak v kontrastu v převedeném snímku, tak ani i počtu či kvalitě nalezených cév není znatelný rozdíl, i přes totožné nastavení detektoru krevního řečiště. Na obrázku je zobrazen pouze jeden úhel, analyzovány však byly všechny úhly s obdobnými výsledky. Tedy ani v extrémních úhlech, to je 80° a více, nedošlo k získání

žádné informace navíc. Důvodem může být jiná interpretace vlnových délek v oblasti NIR na viditelnou barvu kamerovým snímačem a zpracováním v kameře. Výsledkem tohoto experimentu je, že rozdíl ve způsobu převodu na stupně šedi není znatelný, proto je následné zpracování v řešení probíhá klasickým převodem do stupňů šedi.

Rozdělení úhlů

Dalším krokem je rozdělit vstupní snímek do snímků s jednotlivými úhly. Toho je docíleno za pomoci manuálně vytvořených binárních masek. Masky a vstupní snímek jsou použity jako argumenty funkce *bitwise_and* knihovny **OpenCV**. První dva argumenty funkce jsou matice se snímky, následující argument je pro masku, kde se bude zpracovávat. Funkce je tedy volána *bitwise_and(vstupniObrazek, vstupniObrazek, binarniMaska)*. Funkce je pro logický součin dvou matic a pokud je zadán i volitelný argument pro masku, tak se logický součin provádí pouze na místech, kde maska není nulová. Všechny argumenty musí mít, pokud jsou matice, stejný rozměr, pro snímky to znamená stejnou velikost v pixelech. Výstupem funkce je snímek s jedním oříznutým úhlem [12].



Obrázek 4.3: Ukázka využití masky pro ořez jednoho úhlu

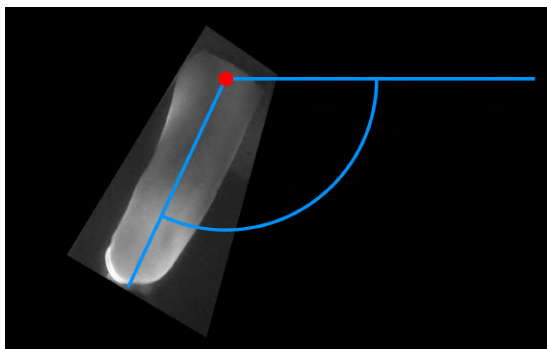
Obrázek 4.3 ukazuje vlevo vstupní snímek, uprostřed binární maska pro úhel 0° a vpravo oříznutý pouze jeden úhel. Obdobně vypadají masky i pro ostatní úhly.

Rotace


Protože algoritmus pro detekci krevního řečiště očekává prst v horizontální poloze je nutné jednotlivé snímky pootočit. Manuálně byl změřen rozdíl úhlů kam prst míří na jednotlivých snímcích oproti úhlu takovému, aby byl prst v horizontální poloze a mířil doprava. Jelikož je úhel jednotlivých odrazů prstu při pořizování vstupního snímku nezávislý na velikosti prstu, je možné tento rozdíl úhlů použít nezávisle na prstu.

Pro rotaci je dále potřeba znát bod, kolem kterého bude rotace provedena. Jako tento bod, neboli střed rotace, je zvoleno místo, kde prst vstupuje do přístroje. V této pozici není rotace závislá na délce prstu a je díky tomu určen i začátek prstu na snímku.

Posledním krokem po rotaci je ořez na maximální výšku 500 pixelů a délku 1400 pixelů. Tato velikost pojme veškeré velikosti prstů, protože delší nebo širší prst by nebyl ani celý viditelný na vstupním snímku.



(a) Červeně je označen střed rotace, modře úhel, o který bude rotováno




(b) Zpracovaný snímek jednoho úhlu

Obrázek 4.4: Snímky ukazující před a po provedení rotace, pozn. snímky jsou pro zlepšení viditelnosti důležitých částí oříznuty

Na obrázku 4.4a je vidět v minulém odstavci zmíněný střed rotace červeně a rozdíl úhlů modře. Stejným způsobem jsou rotovány všechny snímky prstu pod různými úhly. Pravý obrázek 4.4b je již konečným výstupem z této části zpracování. Dalším krokem pro tento snímek je detekce a zvýraznění krevního řečiště.

4.3 Předzpracování

Před samotným použitím algoritmu na detekci krevního řečiště, je nutné provést předzpracování. Při předzpracování dojde k dalšímu ořezu, tentokrát pomocí algoritmu, který se snaží izolovat pouze prst samotný. Následně je použita ekvalizace histogramu, s ní dochází k lepším výsledkům při samotné detekci krevního řečiště. To je z důvodu zvýšení kontrastu snímku.



Obrázek 4.5: vygenerované masky algoritmem LeeMask s odlišným druhem předzpracování, (a)(b) jsou prst 11 a (c)(d) jsou prst c

Ořez pomocí funkce LeeMask

Experimentováno bylo s použitím algoritmu s použitím dalšího předzpracování pomocí algoritmu CLAHE a bez předchozím předzpracování.


Jako vstupní hodnoty byly ponechány výchozí. Tedy výška oblasti 40 a šířka sloupce 4.

Metoda je zamýšlena pro snímky prstu, ve kterých nebude vidět konec prstu. Proto dochází u konců prstů k artefaktům, protože metoda neočekává, že by prst nebyl ve sloupci, viz obrázky 4.5 masky pro vstupní snímek 4.4b. Tyto artefakty však nijak vážně neovlivňují výsledky detekce krevního řečiště, jelikož tato oblast ve většině případech je již oříznuta z kroku, kde byly rozdělčovány úhly prstu.

Bez použití algoritmu CLAHE lze na obrázcích 4.5a a 4.5c vlevo nahoře vidět, že při nízkém kontrastu prstu a pozadí na vstupním snímku je špatně vyhodnocena hranice prstu. Tato chyba již ovlivňuje detekci krevního řečiště a horní hranice prstu a pozadí je následně nesprávně označena za část krevního řečiště. Možný způsob pro předejití tohoto jevu by bylo využít vstupní snímek s intenzivnějším prosvěcováním, na kterém by bylo detekováno méně krevního řečiště, pro vytvoření kvalitnější masky. Následně tuto masku využít k dalšímu zpracování snímku s méně intenzivním průsvitem, ale s lépe detekovatelným krevního řečiště. Tento způsob, ale nebyl testován.

S použitím algoritmu CLAHE před tvorbou masky dojde vytvoření podobné masky, ale u některých snímků dojde k výraznému zlepšení, například na obrázku 4.5d dojde k eliminaci chyby zmíněné v minulém odstavci. Ačkoliv dojde k vytvoření tenkých vertikálních čar, ty budou eliminovány erozí.

Ekvalizace histogramu




Obrázek 4.6: (a) Rozdíl v detekovaném krevním řečišti, červeně s ekvalizací histogramu, modře bez, růžová při překrytí, (b) Snímek po ekvalizaci histogramu

Ekvalizace histogramu je použita pouze v oblasti, kde má maska hodnotu jedna. Snímek po ekvalizaci histogramu je možné vidět na obrázku 4.6b, vstupní snímek je na obrázku 4.4b. Na obrázku 4.6a je možné vidět rozdíly v detekovaném krevním řečišti při použití ekvalizace histogramu a bez ní. Lze pozorovat, že došlo k výraznému zesílení šumu, což je nevýhodou ekvalizace histogramu. Při porovnání rozdílů ale nelze jednoznačně určit, která metoda je vhodnější. Většinu větších cév našli obě metody, bez ekvalizace histogramu však byla nalezena falešná vertikální céva vpravo na obrázku a pochybně spojené cévy do oblouku vpravo na obrázku, spíše se však jedná o stín kosti.


CLAHE

Algoritmus CLAHE byl použit před samotnou tvorbou masky, ale je použit i jako vstupní snímek pro detekci krevního řečiště.


Protože algoritmus požaduje velikost oblasti a hodnotu hranice, bylo experimentováno pro nalezení nejvhodnějších hodnot. Byly testovány velikosti oblastí 4x4, 8x8, 16x16 a 32x32. Také byla měněna hranice od hodnoty 1 až po 40, v rozsahu 1 až 10 s krokem 1 a v rozsahu 10 až 40 s krokem 5. Menší oblasti dosahovali většího kontrastu. Při změně hranice se u nízkých hodnot, 1 až 4 neprojevovali zásadní rozdíly v kontrastu. Naopak u vysokých hodnot, 10-40 zase docházelo k vysokému zesílení šumu. Jako nastavení byla zvolena velikost oblasti 8x8, jako kompromis mezi rychlostí a kontrastem a hranice byla nastavena na hodnotu 5, kde už dochází k zvýšení kontrastu bez výrazného zesílení šumu.




(a) Bez předzpracování



(b) Ekvalizace histogramu



(c) CLAHE



(d) Předzpracovaný snímek algoritmem CLAHE

Obrázek 4.7: Porovnání algoritmů pro předzpracování


Na obrázcích 4.7 je možné vidět jaké bylo detekováno krevní řečiště při použití různých algoritmů předzpracování a také na obrázku 4.7d je vidět snímek po zpracování algoritmem CLAHE. Na obrázcích lze pozorovat, že i při odlišném předzpracování bylo detekováno různé množství krevního řečiště. Nejvíce bylo detekováno na snímku předzpracovaném algoritmem CLAHE, proto bude použit jako výchozí algoritmus pro předzpracování.

4.4 Detekce krevního řečiště

V této části se bude vyskytovat termín céva, protože je vhodnější pro pojmenování pouze jedné cévy, která bude zobrazována jako čára nebo křivka, oproti krevnímu řečišti. Termín céva a krevní řečiště není stejný, protože krevní řečiště označuje pouze krev proudící v kardiovaskulárním systému a céva označuje pouze trubici samotnou. Protože je ale největší množství krevního řečiště obsaženo právě v cévním systému, je vlastně nepřímě detekován [31][15].

Maximum Curvature

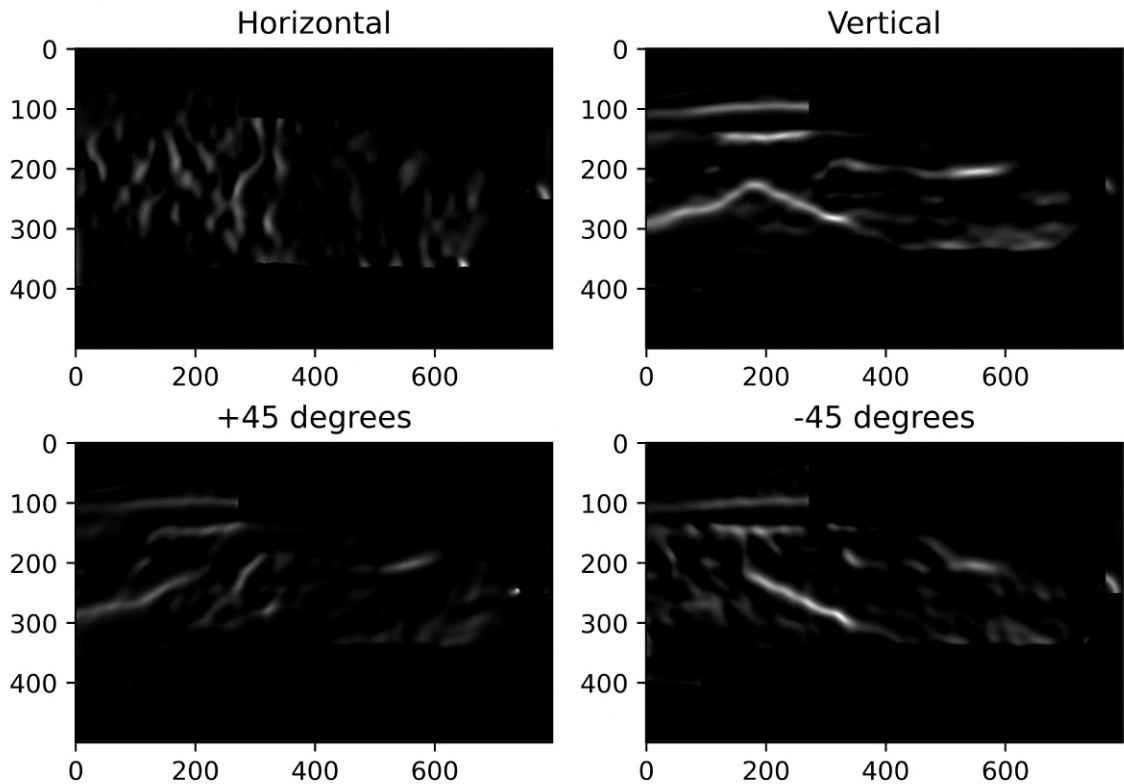
Na detekci krevního řečiště je použita třída MaximumCurvature z knihovny Biometric Vein Recognition Library. Jedná se o implementaci metody pro detekci krevního řečiště popsanou v práci autorů N. Miura, Akio Nagasaka a T. Miyatake [37].



Obrázek 4.8: Detekované krevního řečiště po odlišném nastavení směrodatné odchytky 2D Gaussova filtru σ a doba zpracování t

Tato metoda postupuje několika kroky, nejdříve je provedena konvoluce snímku s 2D Gaussovým filtrem. Tím je snímek zbaven náhodného šumu a šumu vzniklého ekvalizováním histogramu. Velikost filtru lze ovlivnit pomocí argumentu sigma, to je směrodatná odchytky, proto bylo experimentováno s různými hodnotami pro nalezení nejlepších výsledků. Na obrázku 4.8 lze pozorovat jak se zvedající se směrodatnou odchytkou je ve výsledku menší počet nalezeného krevního řečiště a zároveň dochází k výraznému prodloužení doby potřebné ke zpracování. Nevýhodou vysokých hodnot směrodatné odchytky je tedy zmíněná vysoká doba zpracování. I když by vysoká doba zpracování nevadila, filtr je už natolik intenzivní, že dochází ke ztrátě informací, není tedy nalezeno ani krevní řečiště, které by bylo nalezeno s nižší směrodatnou odchytkou. Nízké hodnoty σ jsou zpracovány podstatně rychleji, avšak obsahují mnoho falešně detekovaného krevního řečiště, například 4.8a. Proto pro veškeré předchozí i následující snímky zobrazující detekované krevní řečiště v této práci je použita směrodatná odchytky s hodnotou 10, viz například 4.8c [37].

Následně jsou hledána údolí. Toho je docíleno tím, že metoda prochází průřezem snímku horizontálně, vertikálně a pod úhly 45 a mínus 45 stupňů. Při vertikální průchodu jsou nalezeny údolí jdoucí vertikálně, při horizontálním průchodu pod 45 a mínus 45 stupňů




Obrázek 4.9: Detekovaná údolí v průchodech průřezů snímku pod různými úhly

obdobně, jak je vidět na obrázku 4.9. Každý průchod je prováděn odděleně. Každý průřez obsahuje profil určený hodnotami pixelů v daném průřezu. V této křivce profilu jsou vyhledána lokální minima, na vstupním snímku se jedná o tmavší místa, kde se nachází cévy, a jsou ohodnoceny podle jejich hodnoty a šířky údolí, které tvoří. Hodnoceny také všechny ostatní body na křivce, nejvyšší hodnotu mají však nejširší a nejhlubší údolí. Hodnocení je ukládáno do matice stejné velikosti. Normalizované hodnocení po jednotlivých průchodech lze vidět na obrázku 4.9 [37].

Další krok je detekce středů cév a jejich ohodnocení. Ohodnocené průchody z minulého kroku jsou opět procházeny ve stejném směru jako byly vytvořeny. Nyní však jsou hledány lokální maxima. Nalezená lokální maxima jsou hodnoceny v závislosti na jejich hodnotě. Vypočítané ohodnocení lokálního maxima je přičteno na příslušnou pozici do matice pravděpodobnosti krevního řečiště. Průchody všemi směry se přičítají do stejné matice pravděpodobnosti krevního řečiště. Výsledná matice je normalizována a převedena na snímek, ve kterém je vidět pravděpodobnost výskytu krevního řečiště. Úroveň pravděpodobnosti výskytu krevního řečiště je vizualizována jako křivky s měnícím se jasem, kde jasnější křivka je pravděpodobnějším výskyt krevního řečiště než křivka s nižším jasem. Takto zpracovaný snímek je zobrazen na obrázku 4.10 [37].

Následujícím krokem je spojení středů cév nalezených v minulém kroku a redukce šumu. Nejprve jsou zkontrolovány 2 pixely nalevo a 2 pixely napravo od zpracovávaného pixelu. Pokud má zpracovávaný pixel vysokou hodnotu a pixely na obou stranách mají také vysoké hodnoty, čára je nakreslena horizontálně. Pokud však mají pixely na stranách vysoké hodnoty, ale zpracovávaný pixel má nízkou hodnotu, čára má mezeru. To znamená, že hodnota




Obrázek 4.10: Pravděpodobnost výskytu krevního řečiště

zpracovávaného pixelu by měla být zvýšena pro propojení čáry. Pokud má zpracovávaný pixel vyšší hodnotu jak pixely po stranách jedná se pouze o jeden bod. Pravděpodobně se jedná o nechtěný šum, proto by měla být jeho hodnota snížena. Popis lze shrnout do vzorce 4.2, kde C_{d1} je úhel průchodu a V je pravděpodobnost výskytu krevního řečiště [37].

$$C_{d1}(x, y) = \min(\max(V(x + 1, y), V(x + 2, y)), \max(V(x + 1, y), V(x + 2, y))) \quad (4.2)$$

Spojování středů cév je počítáno pro všechny 4 úhly průchodů, to znamená horizontální, vertikální, 45 a mínus 45 stupňů. Spojování je prováděno stejným směrem jakým byly průchody vytvořeny. Následně je vybráním nejvyšších hodnot z těchto čtyř průchodů vytvořen konečný snímek z tohoto kroku. Výstupní snímek lze vidět na obrázku 4.11 [37].




Obrázek 4.11: Spojené středy cév

Posledním krokem je pouhá binarizace snímku se spojenými středy cév. Binarizace je provedena nastavením prahu, a průchodem celého snímku. Práh je vypočítán jako medián z hodnot pixelů ve snímku. Pokud má pixel hodnotu pod úroveň prahu je považován za pozadí a má výslednou hodnotu 0, naopak při vyšší hodnotě pixelu oproti prahu je pixel považován za část krevního řečiště a jeho výsledná hodnota je 1. Binarizovaný snímek lze vidět na obrázku 4.2 v pravém sloupci, nebo na obrázcích v 4.8 [37].


Wide Line Detector

Druhým algoritmem, se kterým bylo experimentováno je Wide Line Detector. Protože algoritmus obsahuje tři změnitelné konstanty, hranice rozdílu středu s porovnávaným sousedem t , hranice počtu sousedů potřebných pro označení bodu za krevní řečiště g a poloměr kruhové oblasti r , bylo provedeno několik experimentů pro zjištění nevhodnější kombinace. Výchozí hodnoty jsou $r = 5$, $g = 41$ a $t = 1$. Pomocí výchozích hodnot, se ve výstupních snímcích objevuje akorát šum. Z kódu bylo zjištěno, že u poloměru 5 je počet sousedů 81, to znamená že pro označení bodu jako krevní řečiště je potřeba poměr $41/81 \approx 0,5$. Počet všech sousedů bude značen n .


Je pravděpodobné, že samotným zvětšením poloměru dojde ke snížení nalezeného krevního řečiště, pokud hranice zůstane stejná, proto bylo experimentováno se zvětšením poloměru, ale zachováním poměru 0,5. To znamená s poloměrem zvětšovat i velikost hranice. Bylo tedy experimentováno se zvětšováním poloměru a zároveň hranicí, aby poměr zůstal 0,5. Rozsah testování byl od hodnoty poloměru 5 až 45 s krokem 5.




(a) $r = 5$, $g = 41$, $n = 81$, hodnoty stejné jako výchozí



(b) $r = 10$, $g = 159$, $n = 317$



(c) $r = 20$, $g = 629$, $n = 1257$




(d) $r = 40$, $g = 2513$, $n = 5025$

Obrázek 4.12: Detekované krevního řečiště při odlišném nastavení poloměru oblasti r a počtu sousedů g s konstantním poměrem 0,5

Na obrázku 4.12, lze pozorovat, že se zvětšující se velikostí oblastí se začínají objevovat nejširší části krevního řečiště. Se zvětšováním poloměru se zvedal čas na zpracování, protože se pro každý bod porovnávalo n hodnot a také se začala zvětšovat oblast na okrajích, protože vytvořená kruhová oblast musí být celá ve snímku je začátek posunut o r . Stále však snímky obsahují velké množství šumu.


Další experiment bude také zvedat r a g , ale bude nastaven konstantní poměr $g/n \approx 0,2$. Cílem je snížit množství šumu. Rozsah r je od 20 do 60 s krokem 10.



Obrázek 4.13: Detekované krevního řečiště při odlišném nastavení poloměru oblasti r a počtu sousedů g s konstantním poměrem 0,2

Na obrázku 4.13 došlo ke snížení šumu oproti 4.12, ale u 4.13b už dochází i k výrazné ztrátě krevního řečiště. Vhodnější budou hodnoty s nižším poměrem a poloměrem přes 20. Byl proveden i experiment s poměrem 0,1, ale už nedošlo k zásadnímu útlumu šumu, naopak celý snímek byl dále celkově utlumen.

Dalším způsobem jak snížit šum, je zvýšit hranici rozdílu porovnávaného souseda t . V následujícím experimentu zůstane hodnota poměru $g/n \approx 0,2$ a bude zvedána hodnota t od 1 do 15 s krokem 1. Poloměr bude zvedán na hodnoty 20,25 a 30. Očekává se další snížení šumu.



Obrázek 4.14: Detekované krevního řečiště při odlišném nastavení poloměru oblasti r , počtu sousedů g s konstantním poměrem 0,2 a odlišným nastavením hranice t

Obrázky 4.14 ukazují nejvhodnější výstupy z experimentu. Opět došlo ke snížení šumu a také k redukci krevního řečiště. Z experimentů se jako nejvhodnější kombinace hodnot proměnných ukazuje jako $r = 30, g = 1569$ a $t = 10$, toto platí při použití předzpracování algoritmem CLAHE. U přezpracování pomocí algoritmu ekvalizace histogramu byly výsledky s větším množstvím šumu a po podobném experimentování bylo dosaženo nejvhodnějších hodnot $r = 30, g = 500$ a $t = 1$. Při nepoužití žádného algoritmu pro předzpracování byly hodnoty nastaveny na $r = 30, g = 500$ a $t = 1$, ale díky velkým rozdílům v kontrastu mezi snímky v sadě, se množství nalezeného krevního řečiště v sadě snímků výrazně liší.


Při porovnání obou algoritmů pro detekci krevního řečiště, je jako výchozí zvolen Maximum Curvature. Hlavní důvod je kvalita nalezeného krevního řečiště oproti algoritmu Wide Line. Hlavní nevýhodou Maximum Curvature je, ale rychlost, kdy nalezení krevního řečiště ve snímku trvá průměrně pod dvojnásobek času algoritmu Wide Line. Měření bylo provedeno s předzpracováním pomocí CLAHE na sadě snímků o počtu 45 snímků. Průměrná doba na zpracování všech úhlů jednoho snímku byla u algoritmu Maximum Curvature 152 sekund, a u algoritmu Wide Line 81 sekund. Pro následující detekci klíčových bodů je použit pouze algoritmus Maximum Curvature. Skript však umožňuje spuštění i algoritmu Wide Line.

4.5 Detekce klíčových bodů a jejich spojování

Jak je psáno v *Návrhu řešení*, záměrem bylo využít jednoho z existujících algoritmů pro detekci klíčových bodů. Byly provedeny experimenty s algoritmy SIFT a ORB. S cílem zjistit vhodnější algoritmus pro řešení.

SIFT - Detekce klíčových bodů

Byl proveden experiment s algoritmem SIFT, při kterém bylo cílem zjistit zda je algoritmus schopný nalézt vhodné klíčové body v nalezeném krevním řečišti, ve snímku prstu s viditelným krevním řečištěm a ve snímku s pravděpodobností výskytu krevního řečiště. Na obrázku 4.15 lze vidět nalezené klíčové body algoritmem SIFT. Také lze u jednotlivých klíčových bodů pozorovat jejich orientaci, to je čára jdoucí od středu kružnice k jejímu obvodu a poloměr kružnice, který označuje oblast popisovanou daným klíčovým bodem [51].



(a) Oříznutý prst překrytý krevním řečištěm, nalezeno 350 klíčových bodů

(b) Krevní řečiště samotné, nalezeno 324 klíčových bodů


Obrázek 4.15: Nalezené klíčové body pomocí algoritmu SIFT

Výsledkem experimentu je, že algoritmus SIFT dokáže nalézt klíčové body jak ve snímku prstu s viditelným krevním řečištěm tak i v samotném krevním řečišti. Pouze u snímku s pravděpodobností výskytu krevního řečiště našel algoritmus SIFT pouze 10 klíčových bodů, což je velmi nedostačující, proto s ním nebude dále pracováno. Tento snímek není na obrázku 4.15, protože nalezené klíčové body nebyly dobře viditelné. Vstupní snímek pro snímek s pravděpodobností výskytu krevního řečiště je vidět na obrázku 4.10, kde lze také pozorovat možný důvod nízkého počtu nalezených klíčových bodů, a to je velmi nízký kontrast pravděpodobnosti výskytu krevního řečiště oproti pozadí. Jelikož hned v prvním kroku dojde k filtraci 2D Gaussovým filtrem, je kontrast v následných oktávách ještě nižší a nižší. Potencionální klíčové body jsou možná nalezeny, avšak díky jejich nízkému kontrastu jsou ihned v druhém kroku eliminovány.


Ani snímek s prstem na obrázku 4.15a není dokonalý, protože jak se dalo očekávat SIFT našel velké množství klíčových bodů na hraně prstu. Ačkoliv bude i tento snímek použit pro experiment se spojováním klíčových bodů, tak klíčové body na hranách prstu se budou vyskytovat u všech snímcích prstů pod různými úhly. A při následném spojování lze očekávat, že budou hrany považovány za vhodné ke spojení, i když je na snímku prst už pod jiným úhlem tudíž místo popisované klíčovými body nemůže být stejné.

SIFT - Spojování klíčových bodů


Následně bylo experimentováno s rozdílnými způsoby spojování klíčových bodů. Experimentováno bylo se snímky s oříznutým prstem s viditelným krevním řečištěm, samotným krevním řečištěm a s pravděpodobností výskytu krevního řečiště. Také byly porovnávány algoritmy pro vyhledávání spojení a to jsou vyhledávání hrubou silou a algoritmus FLANN, u každého algoritmu bylo testována i eliminace falešně pozitivních klíčových bodů pomocí algoritmů porovnávání poměrů a křížovou kontrolou.



(a) Oříznutý prst překrytý krevním řečištěm, poměr vzdáleností, 58 spojení




(b) Krevní řečiště, poměr vzdáleností, 38 spojení




(c) Krevní řečiště, křížová kontrola, 121 spojení

Obrázek 4.16: Spojení nalezená metodou hledání hrubou silou, viditelných je pouze prvních 15 spojení pro lepší přehlednost

Na obrázcích 4.16 jsou vidět nalezená spojení při hledání v oříznutém prstu překrytém krevním řečištěm a spojení nalezená ve snímcích krevního řečiště. Lze ale pozorovat, že ze zobrazených spojení, například v obrázku 4.16b je korektně nalezeno pouze jedno spojení a to je označeno modrozelenou, začínající vlevo uprostřed na snímku. Ostatní spojení nejsou správná. Obrázek 4.16a s prstem v pozadí také ukázal, že prst nepřinese žádnou pozitivní shodu. Testován byl i rozdíl mezi způsoby eliminace falešně pozitivních spojení, ale až na výrazně vyšší počet nalezených spojení u křížové kontroly, nebyla jejich správnost o nic vyšší než u poměrů vzdáleností. Rozdíly v nalezených spojení po odlišných způsobech eliminace lze pozorovat na obrázku 4.16b pro poměr vzdáleností a na obrázku 4.16c pro křížovou kontrolou. A jelikož je počet spojení po poměru vzdáleností nižší než po křížové kontrole, lze jako lepší způsob eliminace falešně pozitivních označit poměr vzdáleností než křížovou kontrolou.



(a) Oříznutý prst překrytý krevním řečištěm, 60 spojení



(b) Krevní řečiště, 37 spojení

Obrázek 4.17: Spojení nalezená algoritmem FLANN, viditelných je pouze prvních 15 spojení pro lepší přehlednost

Ani jeden z algoritmů pro spojování klíčových bodů, nebyl schopný správně spojit dostatečné množství klíčových bodů mezi sousedními snímky krevního řečiště nebo prstu s viditelným krevním řečištěm. Testovány byly algoritmy spojování hrubou silou a FLANN. Na obrázcích 4.16 a 4.17 lze pozorovat minimální rozdíl u jejich výstupu při stejných vstupních snímcích. Bylo také testováno hledání hrubou silou, což je naivní metoda, časově náročnější, při které jsou porovnávány všechny klíčové body mezi snímky a touto metodou nalezené spojení by měla mít nejnižší vzdálenost, a ani u tohoto algoritmu hledání nebyla výsledná spojení správná. Lze tedy předpokládat, že chybu netvoří samotné algoritmy hledání, ale vstupní klíčové body nemají vhodné vlastnosti pro jejich spojování.

Při testování algoritmu FLANN se výhoda, kterou je vyšší rychlost oproti hledání hrubou silou, neprojevila. Důvodem je nízký počet vstupních klíčových bodů, to je kolem 350 u snímků krevního řečiště oproti průměrného snímku krajiny, kde se počet klíčových bodů může vyskytovat v několika tisících. Při nízkých počtech klíčových bodů se zrychlení, které by měl algoritmus FLANN přinést neprojeví. Také dnešní procesory zvládají porovnávat velké množství klíčových bodů, pokud bude 350 klíčových bodů na obou snímcích bude se jednat o $350 \cdot 350 = 122500$ porovnávaní. Závěrem porovnání algoritmů pro spojování klíčových bodů nalezených algoritmem SIFT je, že počet klíčových bodů nalezených ve snímcích krevního řečiště je dostatečně malý na to, aby bylo možné použít algoritmus hledání hrubou silou pro nalezení nejlepších spojení.

SIFT - Závěr

Příčinou slabé schopnosti nalézt správné spojení může být nízký počet nalezených klíčových bodů ve vstupních snímcích. Kde pro levé snímky na obrázcích 4.16b a 4.16c bylo nalezeno pouze 324 klíčových bodů a pro pravé 341 klíčových bodů, naproti tomu, jak bylo zmíněno v minulém odstavci, tak snímek krajiny může mít tisíce klíčových bodů. Vstupní

snímky krevního řečiště nemají vysoký kontrast a ten je následně ještě snížen v prvním kroku detekce klíčových bodů algoritmem SIFT díky filtracím Gaussovým filtrem. Proto je velké množství potencionálních klíčových bodů odebráno kvůli jejich nízkému kontrastu v kroku druhém. Dalším faktorem negativně ovlivňujícím kvalitu spojení je nestálost krevního řečiště mezi snímky prstu pod různými úhly, to je zapříčiněno algoritmem detekujícím krevní řečiště a nelze ovlivnit. Algoritmus SIFT je například používán pro detekování známého snímku v jiném. Příkladem může být nalezení snímku obálky knihy na snímku místnosti se stejnou knihou, kniha tedy zůstává stejná na snímku místnosti a mění se pouze její transformace, například je položena pod úhlem a pootočena, osvětlení a velikost, s těmito změnami si SIFT poradí a klíčové body nalezené na snímku knihy tak na knize ve snímku místnosti jsou si tak dostatečně podobné pro jejich následné spojení. Avšak nalezené krevní řečiště je odlišné na sousedních snímcích, i když je oblast, kterou se sousedící snímky překrývají velická. Největší nalezené cévy se v překrývající se oblasti shodují svým tvarem a relativní polohou, avšak zbývající krevní řečiště se v překrývající oblasti výrazně liší mezi snímky. Závěr použití algoritmu SIFT pro detekci klíčových bodů v krevním řečišti je, že se ze zmíněných důvodů nehodí pro tuto aplikaci a nebude s ním dále pracováno [51].

ORB

V této části je uvedeno experimentování s algoritmem pro vyhledávání klíčových bodů ORB. Experimentováno bylo na snímcích s oříznutým prstem s viditelným krevním řečištěm, pravděpodobností výskytu krevního řečiště a krevním řečištěm samotným. Bylo porovnávána správnost nalezených spojení pomocí algoritmu hledání hrubou silou a eliminací falešně pozitivních spojení pomocí křížové kontroly.

Algoritmus detekce	Počet detekovaných	Průměr počtu
SIFT	161458	448,49
ORB	180000	500

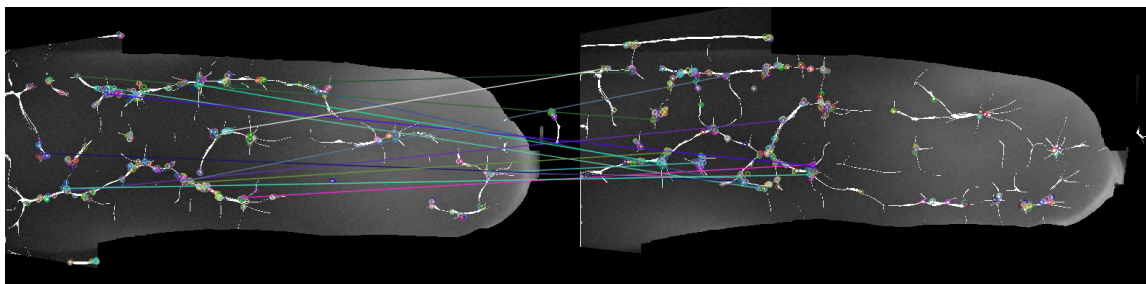
Tabulka 4.2: Počet nalezených klíčových bodů algoritmy SIFT a ORB

Algoritmus spojování	SIFT		ORB	
	n	\bar{n}	n	\bar{n}
Hledání hrubou silou s eliminací poměrem	8291	46,06	21682	120,46
Hledání hrubou silou s eliminací křížovým porovnáním	27866	154,81	21682	120,46
FLANN	8640	48	8559	47,55


Tabulka 4.3: Porovnání počtu nalezených spojení různými algoritmy, n označuje celkový počet a \bar{n} aritmetický průměr počtu spojení mezi sousedními snímky

Na obrázku 4.18 lze vidět klíčové body nalezené algoritmem ORB a spojení nalezené pomocí hledání hrubou silou s eliminací falešně pozitivních pomocí křížové kontroly. Oproti algoritmu SIFT byl algoritmus ORB schopný nalézt větší množství klíčových bodů, například pro levý i pravý snímek na obrázku 4.18c bylo nalezeno 500 klíčových bodů.

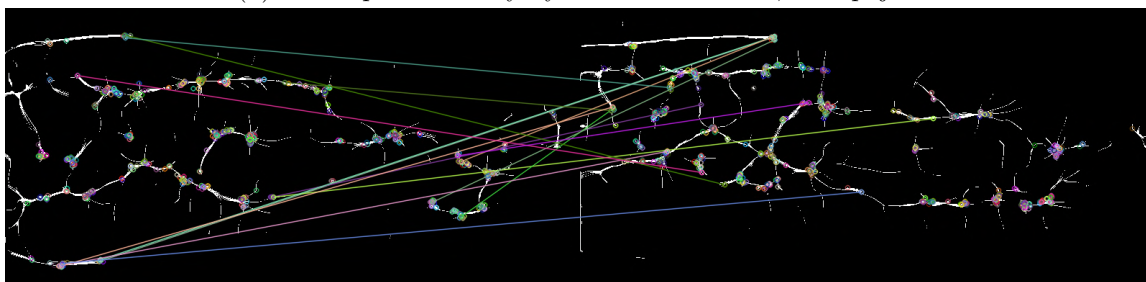
To bylo potvrzeno i hromadným testováním, jehož výsledky je vidět v tabulce 4.2, kde jsou počty nalezených klíčových bodů a v tabulce 4.3 jsou počty nalezených spojení.



(a) Oříznutý prst překrytý krevním řečištěm, 160 spojení



(b) Pravděpodobnost výskytu krevního řečiště, 100 spojení



(c) Krevní řečiště, 120 spojení

Obrázek 4.18: Spojení a klíčové body nalezené algoritmem ORB, spojování bylo provedeno hrubou silou s křížovou kontrolou, viditelných je pouze prvních 15 spojení pro lepší přehlednost

Testování bylo provedeno na sadě 45 vstupních snímků a v každém snímku byla spojení hledána ve čtyřech párech už rozdělených snímků prstu pod různými úhly.


Algoritmus ORB je velmi citlivý pro detekci klíčových bodů, pro zrychlení detekce je tedy omezen počet nalezených klíčových bodů. Tento limit je právě 500, proto se objevuje často v tabulce i v předchozích snímcích u algoritmu ORB.

Správnost nalezených spojení při použití různých algoritmů pro spojování a různých způsobů eliminace falešně pozitivních jsou podobné u obou algoritmů detekce klíčových bodů ORB a SIFT. Spojení byla seřazena od nejnižší vzdálenosti mezi klíčovými body, vzdáleností není myšlena pozice ve snímku, ale rozdíl hodnot vektorů a nebo binárních informací spojených klíčových bodů.

Spojení s nejnižšími vzdálenostmi nebyly však správné a zbylé kontrolovány nebyly. Mezi spojeními budou existovat i správně vytvořená spojení, ale nebyl testován žádný způsob jejich filtrace. Důvody nízké správnosti většiny nalezených spojení mohou být stejné jako u algoritmu SIFT, to jsou, nízký kontrast vstupních snímků a nestálost krevního řečiště. Ani tento algoritmus nebude využit pro tvorbu kompozitního snímku.

Manuální vyznačování klíčových bodů

Protože testované algoritmy pro automatizované hledání klíčových bodů nebyly schopny nalézt vhodné klíčové body a správně je následně spojit, byl problém hledání klíčových bodů vyřešen manuálně. To znamená, že člověk musí například najít dva stejné útvary krevního řečiště, které se nachází na dvou sousedních snímcích krevního řečiště pod odlišnými úhly a jejich pozice označit. Po označení několika párů bodů, při testování se počty párů pohybovali mezi 10 a 18. Pro každý pár je následně vytvořeno spojení.




Obrázek 4.19: Manuálně vyznačené klíčové body na snímcích prstu s viditelným krevním řečištěm


Obrázek 4.19 ukazuje manuálně vyznačené klíčové body a číslo jejich páru. To znamená, že bod s číslem 1 na obrázku 4.19a označuje stejné místo v krevním řečišti prstu jako bod s číslem 1 na obrázku 4.19b. Tento způsob vyznačování klíčových bodů a jejich spojení je následně použit pro následné vytvoření matice transformace.

Porovnávání šablony

Začátkem alternativního způsobu pro detekci klíčových bodů by mohlo být porovnávání jednoho snímku s oříznutou částí druhého, šablonou. Ořez by měl stačit provést z horní a dolní strany snímku, protože délka prstu mezi snímky pod různými úhly zůstává stejná nebo je délka změněná o zjiitelný násobek, protože zrcadlo není přesně pod úhlem 45° a dochází k deformaci. Toto prodloužení by bylo možné eliminovat zjištěním tohoto poměru prodloužení a změnou šířky snímku. Protože již byla provedena rotace prstu, není třeba snímek dále předzpracovávat. A stačí pouze šablonu přiložit na první snímek, spočítat jak moc se shodují a následně posunout a opakovat. Oblast s největší shodou bude oblastí, kde se snímky překrývají.



Obrázek 4.20: Porovnávání šablony




Obrázek 4.21: Snímek, ve kterém bylo hledáno je červeně a snímek, ze kterého byla vytvořena šablona je modře

Na obrázku 4.20a je možné vidět šablonu. Ta je vytvořena ořezem snímku z horní a dolní strany o 150 pixelů. Obrázek 4.20b ukazuje výstup z porovnávání šablony, ve vyznačené oblasti byla nalezena největší shoda snímku s šablonou. Míru shody lze pozorovat na obrázku 4.21, kde je součet snímku, ve kterém bylo hledáno a snímku, ze kterého byla vytvořena šablona. Protože se jedná o součet, tak vzniklá fialová barva značí tedy jejich překrytí.

Následujícím krokem by mohlo být zpracování překrývajících se částí, ze kterých by bylo možné vytvořit klíčové body. Další klíčové body by mohli být získány procházením snímku po sloupcích a v tomto profilu hledat nejbližše se vyskytující se krevní řečiště mezi snímky. Procházet snímek by mohlo stačit po sloupcích, protože délka prstu se nemění, jediná změna na snímcích je úhel, ze kterého byly pořízeny. Pokud by byla vzdálenost mezi krevními řečišti na snímcích nízká byl, by vytvořen pár klíčových bodů, každý pro daný snímek na místě krevního řečiště, zároveň by pro tento pár bylo vytvořeno spojení. Procházet snímek by bylo také možné i pod úhly $+45^\circ$ a -45° , jak je tomu při detekci krevního řečiště popsané v kapitole 4.4. Po nalezení klíčových bodů a vytvoření jejich spojení, by bylo možné nadále pokračovat stejným způsobem, jak je tomu u manuálního označení klíčových bodů. Detekce klíčových bodů nebyla však implementována a testována.


4.6 Vytvoření a použití transformační matice

Aby docházelo k dostatečně velkému překrytí krevního řečiště v překrývající se oblasti sousedních snímků, je třeba jeden ze snímků transformovat. V ideálním případě by po transformaci jednoho ze snímků a jeho sečtení s druhým došlo k přesnému překrytí klíčových bodů. Transformaci lze provést z klíčových bodů a jejich spojení nalezených v předchozí kapitole, z nichž je vytvořena přibližná matice transformace, která je použita na jeden ze snímků. V takto transformovaném snímku se budou pozice klíčových bodů více shodovat s pozicemi klíčových bodů na snímku sousedním.



(a) Snímek s viditelnými klíčovými body

(b) Transformovaný snímek s viditelnými klíčovými body



(c) Transformovaný snímek sečtený s nezměněným sousedním snímkem

Obrázek 4.22: Transformování snímku

Na obrázku 4.22b je vidět snímek po transformaci vstupního snímku, který je na obrázku 4.22a. Pro transformaci je použita funkce *warpPerspective* z knihovny OpenCV. Ta využívá vzorec popsaného níže, kde dst je výsledná matice popisující výstupní snímek a src je matice vstupního snímku. Proměnné x a y jsou souřadnice dané matice snímku a M je matice transformace [60].

$$dst(x, y) = src \left(\frac{M_{11}x + M_{12}y + M_{13}}{M_{31}x + M_{32}y + M_{33}}, \frac{M_{21}x + M_{22}y + M_{23}}{M_{31}x + M_{32}y + M_{33}} \right) \quad (4.3)$$

Tímto vzorcem jsou zpracovány všechny pixely vstupního snímku. Pixely, jejichž nová pozice by byla mimo zadané rozměry, jsou zahozeny. Při transformaci mohou při případném zvětšení nebo zkosení vznikat mezery, a proto jsou chybějící pixely v těchto mezerách dopočítány z okolních pixelů pomocí bilineární interpolace. Pokud by došlo ke zmenšení, tak na jeden nový pixel může připadat více vstupních hodnot, to je opět vyřešeno bilineární interpolací. V tomto případě budou také chybět hodnoty pro pixely v okolí, těm bude přiřazena konstanta, kterou je nula, tedy černá barva. Tyto jevy lze pozorovat na obrázku 4.22b [60].


K vytvoření matice transformace je využita funkce *findHomography*, z knihovny OpenCV. Tato funkce využívá k vytvoření matice transformace algoritmus přímé lineární transformace, v originále *direct linear transformation* se zkratkou *DLT*. Příklad vytvořené matice transformace M , z klíčových bodů na obrázku 4.22a a z klíčových bodů sousedního snímku na obrázku 4.19a, je vidět níže [19].

$$M = \begin{bmatrix} 1,02719191 & 0,182429238 & -36,3270017 \\ 9,60954558 \cdot 10^{-3} & 1,05797533 & 24,6696457 \\ 9,88095280 \cdot 10^{-5} & -2,66263075 \cdot 10^{-5} & 1 \end{bmatrix} \quad (4.4)$$

Pro vytvoření matice transformace stačí 4 páry klíčových bodů, při vyšších počtech se může přesnost zvyšovat. Při použití automatizovaného hledání klíčových bodů je počet spojení několikrát vyšší, ale spojení nemusí být vždy správná, proto funkce umožňuje využít algoritmů, které eliminují spojení nesouhlasící s ostatními. Takovými algoritmy je RANSAC, LMedS nebo PROSAC. V případě manuálně hledaných klíčových bodů se ale očekává, že byly vyhledány přesně, tudíž není třeba žádná spojení eliminovat a pro výpočet matice transformace se použijí všechna spojení [20].


4.7 Skládání snímků

Posledním krokem je složení snímku prstu s transformovaným sousedním snímkem. Před transformací je k snímkům prstu, které jsou pod různými úhly a v odstínech šedi, vyznačeno krevní řečiště, pro každý úhel odlišnou barvou, aby bylo ve výsledném kompozitním snímku jasně zřetelné odkud byla krevní řečiště přidávána. Takto upravené snímky lze vidět na obrázcích 4.22 a ve zbytku této části.




Obrázek 4.23: Pojmenování jednotlivých pohledů a z nich vytvořených snímků pod různými úhly

Snímky pod jednotlivými úhly byly vhodně pojmenovány, kdy snímek v ose prosvětlujících diod je pojmenován c , snímky nalevo od něj postupně $l1$ až $l6$ a napravo $r1$ až $r6$. Pojmenování je vidět na obrázku 4.23 a bude dále používáno pro označení specifického snímku. V předchozích částech o detekci klíčových bodů a o transformační matici byly v obrázcích vidět zejména snímky c a $l1$.



Obrázek 4.24: Nevhodné snímky pro vytvoření kompozitního snímku

Krevní řečiště bylo nalezeno na všech snímcích, avšak snímky l4-l6 a r4-r6 jsou již pod tak vysokým úhlem, že nalezené krevní řečiště je s velikou pravděpodobností falešně identifikované, protože světlo použité k prosvěcování prstu uniká i mimo prst a svoji vysokou intenzitou negativně ovlivňuje snímek. Také se u těchto snímků nepodařilo vytvořit přesnější masku, největší chyba vznikla z palmární strany prstu, kde je již nízká intenzita prosvětlujícího světla. Tyto snímky lze vidět na obrázku 4.24. Proto tyto snímky nebudou použity pro tvorbu kompozitního snímku a nadále se bude pracovat pouze se zbývajícími úhly.



Obrázek 4.25: Postupné skládání sousedních snímků

Kombinace zvolená pro postupné spojování snímku je vidět na obrázku 4.25. Také lze pozorovat, jak jsou postupným spojováním vytvořeny dva cílové snímky s viditelným krevním řečištěm. Výsledkem by měl být pouze jeden snímek, avšak při spojování dvojice je vždy nutné určit, který snímek zůstane stejný a který bude transformován, aby se klíčové body


shodovaly. Rozdíl mezi dvěma cílovými snímky je tedy odlišné pořadí vstupních snímků při jejich spojování.

Problém s výběrem, který snímek ze dvojice transformovat, a který ponechat stejný není jenom u poslední dvojice. A proto je vyřešen následovně. Pokud je ve dvojici snímek c , je vždy transformován ten druhý. U dvojice r_2 a r_3 nebo l_2 a l_3 je transformován vždy snímek s vyšším úhlem tedy l_3 a r_3 . Tímto způsobem jsou transformovány vždy snímky s vyšším úhlem.


Protože snímek c nese nejpřesnější informaci o krevním řečišti je použit dvakrát. Díky tomu ho zároveň lze použít při posledním skládání k jednoduššímu vyhledání klíčových bodů, protože se na obou skládaných snímcích bude vyskytovat na obrázku 4.25 zelenou barvou.

Dvojice snímků jsou sčítány pomocí funkce *addWeighted* z knihovny OpenCV. Ta sečte snímky stejné velikosti a každému je nastavena váha. Každý snímek je vynásoben svoji váhou a následně sečten. Funkce nabízí také možnost přičítat konstantní hodnotu. Přesný vzorec, který funkce využívá, je níže, kde dst je výsledný snímek, $src1$ a $src2$ jsou vstupní snímky, $alpha$ a $beta$ jsou váhy pro jednotlivé snímky a $gamma$ je konstantní složka [2].

$$dst(x, y) = src1(x, y) \cdot alpha + src2(x, y) \cdot beta + gamma \quad (4.5)$$



(a)



(b)

Obrázek 4.26: Hotové kompozitní snímky s viditelným krevním řečištěm

Na obrázku 4.26 je možné vidět finální kompozitní snímky, pro obě varianty posledního složení, který je vidět na obrázku 4.25. Kde obrázek 4.26a byl složen z nezměněného snímku s úhly l3, l2, l1 a c a transformovaným snímkem s úhly r3, r2, r1 a c. A snímek na obrázku 4.26b byl složen z nezměněného snímku s úhly r3, r2, r1 a c a transformovaným snímkem s úhly l3, l2, l1 a c.

Kapitola 5

Závěr

Cílem práce bylo vytvořit kompozitní snímek s viditelným krevním řečištěm. Cíl byl splněn, postupným zpracováváním vstupního snímku, na kterém je vidět prosvěcovaný prst blízkým infračerveným zářením pod různými úhly pomocí zrcadel.

Prvním krokem bylo rozdělení jednotlivých úhlů a jejich pootočení, aby všechny prsty byly ve vodorovné poloze s koncem prstu vpravo. Oříznutí bylo provedeno pomocí manuálně vytvořených masek a pootočení bylo provedeno o předem zjištěný úhel.

V dalším kroku byly zjištěny různé algoritmy pro detekci krevního řečiště a způsoby, jakým je detekováno. Byl vybrán vhodný algoritmus a byl popsán způsob, jakým funguje. Tento algoritmus byl následně použit pro detekci krevního řečiště. Bylo provedeno několik experimentů s různými metodami předzpracování snímků, aby došlo k detekci co největšího množství krevního řečiště, ale zároveň bylo omezeno nalezení falešně pozitivních částí krevního řečiště. U detekce bylo experimentováno s různými vstupními parametry pro detekování co největšího počtu krevního řečiště s malým počtem falešně pozitivních částí.

Dále bylo zjišťováno, jakým způsobem složit snímky pod různými úhly. Bylo testováno hledání klíčových bodů a z nich následný odhad matice transformace. Pro detekci klíčových bodů byla snaha využít existujících algoritmů pro tuto funkci. Jedním z nich byl algoritmus SIFT, který byl otestován a bylo popsáno jeho fungování. Ačkoliv bylo experimentováno s různými kombinacemi vstupních snímků a algoritmy pro spojování klíčových bodů, jeho výsledky neodpovídaly očekávání a nebylo by možné ho použít. Proto muselo být použito manuální vyznačování párů klíčových bodů mezi sousedními snímky pro jejich následné skládání. Byly také navrženy další způsoby pro detekci klíčových bodů.

Z párů klíčových bodů byl pomocí existujícího algoritmu vytvořen odhad matice transformace. Ta je následně použita na jeden ze snímků, ze kterých byly klíčové body. Skládání snímků je provedeno váhovým součtem sousedních snímků. Tento cyklus se opakuje pro nově složené snímky, dokud nedojde ke složení dvou posledních snímků. Výsledkem jsou dva kompozitní snímky s viditelným krevním řečištěm. Krevní řečiště je barevně označeno, podle toho z jakého počátečního snímku pocházelo.

Při práci jsem se dozvěděl mnoho o zpracování obrazu a způsobů, jakým lze detekovat krevní řečiště. Pokračování práce by mohlo obsahovat eliminaci manuálního vyznačování krevního řečiště, buď implementací nového algoritmu nebo například strojovým učením. Výsledky by mohlo být možné využít pro přesnější identifikaci či verifikaci osob, protože oproti nynějším způsobům použití krevního řečiště prstu je plocha krevního řečiště větší díky využití různých úhlů.

Literatura

- [1] SWIR/NIR-II Imaging. *Teledyne Princeton Instruments* online. 2024. Dostupné z: <https://www.princetoninstruments.com/learn/swir-nirii>. [cit. 2024-05-02].
- [2] AddWeighted. *Open Source Computer Vision* online. 2024. Dostupné z: https://docs.opencv.org/3.4/d2/de8/group__core__array.html#gafafb2513349db3bcff51f54ee5592a19. [cit. 2024-04-19].
- [3] ADÁMEK, M.; MATÝSEK, M. a NEUMANN, P. Security of Biometric Systems. *Procedia Engineering*, 2015, sv. 100, s. 169–176. ISSN 1877-7058. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1877705815003823>. 25th DAAAM International Symposium on Intelligent Manufacturing and Automation, 2014.
- [4] AL KHAFAJI, R. S. a AL TAMIMI, M. S. Vein Biometric Recognition Methods and Systems: A Review. *Advances in Science and Technology Research Journal*, 2022, sv. 16, č. 1, s. 36–46. ISSN 2080-4075. Dostupné z: <https://doi.org/10.12913/22998624/144495>.
- [5] AL QADI, Z. Analysis of fingerprint minutiae to form fingerprint identifier. *JOIV : International Journal on Informatics Visualization*, Únor 2020, sv. 4.
- [6] ANJOS, A.; GÜNTHER, M.; FREITAS PEREIRA, T. de; KORSHUNOV, P.; MOHAMMADI, A. et al. Continuously Reproducing Toolchains in Pattern Recognition and Machine Learning Experiments. In: *International Conference on Machine Learning (ICML)*. Srpen 2017. Dostupné z: http://publications.idiap.ch/downloads/papers/2017/Anjos_ICML2017-2_2017.pdf.
- [7] ANJOS, A.; SHAFEY, L. E.; WALLACE, R.; GÜNTHER, M.; MCCOOL, C. et al. Bob: a free signal processing and machine learning toolbox for researchers. In: *20th ACM Conference on Multimedia Systems (ACMMM)*, Nara, Japan. říjen 2012. Dostupné z: https://publications.idiap.ch/downloads/papers/2012/Anjos_Bob_ACMMM12.pdf.
- [8] BETTS, J. G.; YOUNG, K. A.; WISE, J. A.; JOHNSON, E.; POE, B. et al. *Anatomy and Physiology*. OpenStax, 2022. Dostupné z: <https://openstax.org/books/anatomy-and-physiology-2e/pages/1-introduction>.
- [9] SANGCHEOL, S. Bilinear interpolation. *Medium* online. 2023. Dostupné z: <https://medium.com/@sim30217/bilinear-interpolation-e41fc8b63fb4>. [cit. 2024-05-03].

- [10] Bob.bio.vein result for other baselines. *Bio.bob.vein* online. 2024. Dostupné z: <https://www.idiap.ch/software/bob/docs/bob/bob.bio.vein/stable/baselines.html#results-for-other-baselines>. [cit. 2024-03-15].
- [11] Biometry (n.). *Online Etymology Dictionary* online. 2022. Dostupné z: https://www.etymonline.com/word/biometry#etymonline_v_43038. [cit. 2023-12-20].
- [12] Bitwise_and. *Open Source Computer Vision* online. 2024. Dostupné z: https://docs.opencv.org/2.4/modules/core/doc/operations_on_arrays.html?highlight=bitwise_and#bitwise-and. [cit. 2024-03-17].
- [13] *Biometric Vein Recognition Library* online. 2023. Dostupné z: <https://www.idiap.ch/software/bob/docs/bob/bob.bio.vein/stable/index.html#>. [cit. 2023-12-29].
- [14] Color conversions. *Open Source Computer Vision* online. 2024. Dostupné z: https://docs.opencv.org/3.4/de/d25/imgproc_color_conversions.html. [cit. 2024-03-16].
- [15] Krevní cévy. *Národní zdravotnický informační portál* online. 2024. Dostupné z: <https://www.nzip.cz/rejstrikovy-pojem/772>. [cit. 2024-04-18].
- [16] DEEPANSHU, T. Introduction to SIFT(Scale Invariant Feature Transform). *Medium* online. 2019. Dostupné z: <https://medium.com/@deepanshut041/introduction-to-sift-scale-invariant-feature-transform-65d7f3a72d40>. [cit. 2024-04-02].
- [17] DRAHANSKÝ, M.; ORSÁG, F. a DOLEŽEL, M. *Biometrie*. 1. vyd. Brno: M. Drahanský], 2011. ISBN 978-80-254-8979-6.
- [18] Feature Matching. *Open Source Computer Vision* online. 2024. Dostupné z: https://docs.opencv.org/3.4/dc/dc3/tutorial_py_matcher.html. [cit. 2024-04-12].
- [19] FindHomography code. *GitHub* online. 2024. Dostupné z: <https://github.com/opencv/opencv/blob/master/modules/calib3d/src/fundam.cpp>. [cit. 2024-04-15].
- [20] Camera Calibration and 3D Reconstruction. *Open Source Computer Vision* online. 2024. Dostupné z: https://docs.opencv.org/3.4/d9/d0c/group__calib3d.html#ga4abc2ece9fab9398f2e560d53c8c9780. [cit. 2024-04-15].
- [21] Fujitsu Builds Japan's First Palm Vein Authentication System for ATMs. *Fujitsu* online. 2012. Dostupné z: <https://www.fujitsu.com/global/about/resources/news/press-releases/2012/0926-01.html>. [cit. 2023-12-05].
- [22] FUNAYAMA, R.; YANAGIHARA, H.; GOOL, L. V.; TUYTELAARS, T. a BAY, H. Patent - Robust interest point detector and descriptor. *Google Patents*. 2007. Dostupné z: <https://patents.google.com/patent/US8165401B2/en?q=US2009238460>.
- [23] Image Processing Basic: Gaussian and Median Filter, Separable 2D filter. *Medium* online. 2020. Dostupné z: <https://medium.com/jun94-devpblog/cv-2-gaussian-and-median-filter-separable-2d-filter-2d11ee022c66>. [cit. 2024-05-03].

- [24] GUDINO, M. How Do Fingerprint Scanners Work? Optical vs Capacitive. *Arrow* online. 2018. Dostupné z: <https://www.arrow.com/en/research-and-events/articles/how-fingerprint-sensors-work>. [cit. 2023-12-20].
- [25] HARRIS, C. a STEPHENS, M. A Combined Corner and Edge Detector. In: *Proceedings of the 4th Alvey Vision Conference*. 1988, s. 147–151.
- [26] Histogram Equalization in Digital Image Processing. *Geeksforgeeks* online. 2024. Dostupné z: <https://www.geeksforgeeks.org/histogram-equalization-in-digital-image-processing/>. [cit. 2024-03-22].
- [27] HUANG, B.; DAI, Y.; LI, R.; TANG, D. a LI, W. Finger-Vein Authentication Based on Wide Line Detector and Pattern Normalization. In: *2010 20th International Conference on Pattern Recognition*. 2010, s. 1269–1272.
- [28] Biometrics. *Innovatrics* online. 2023. Dostupné z: <https://www.innovatrics.com/glossary/biometrics/>. [cit. 2023-12-27].
- [29] ISRAEL, S. a IRVINE, J. Heartbeat biometrics: a sensing system perspective. *Int. J. of Cognitive Biometrics*, Leden 2012, sv. 1, s. 39 – 65.
- [30] KATHED, A.; AZAM, S.; SHANMUGAM, B.; KARIM, A.; YEO, K. C. et al. An Enhanced 3-Tier Multimodal Biometric Authentication. In: Leden 2019, s. 1–6.
- [31] Krevní řečiště. *Národní zdravotnický informační portál* online. 2024. Dostupné z: <https://www.nzip.cz/rejstrikovy-pojem/4574>. [cit. 2024-04-18].
- [32] LEE, E. C.; LEE, H. C. a PARK, K. R. Finger vein recognition using minutia-based alignment and local binary pattern-based feature extraction. *International Journal of Imaging Systems and Technology*, 2009, sv. 19, č. 3, s. 179–186. Dostupné z: <https://onlinelibrary.wiley.com/doi/abs/10.1002/ima.20193>.
- [33] LIU, L.; ZHANG, D. a YOU, J. Detecting Wide Lines Using Isotropic Nonlinear Filtering. *IEEE Transactions on Image Processing*, 2007, sv. 16, č. 6, s. 1584–1595.
- [34] LOWE, D. G. Method and apparatus for identifying scale invariant features in an image and use of same for locating an object in an image. *Google Patents*. 2000. Dostupné z: <https://patents.google.com/patent/US6711293B1/en>.
- [35] LOWE, D. G. Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*, Nov 2004, sv. 60, č. 2, s. 91–110. ISSN 1573-1405. Dostupné z: <https://doi.org/10.1023/B:VISI.0000029664.99615.94>.
- [36] MISRA, S. a WU, Y. Chapter 10 - Machine learning assisted segmentation of scanning electron microscopy images of organic-rich shales with feature extraction and feature ranking. In: MISRA, S.; LI, H. a HE, J., ed. *Machine Learning for Subsurface Characterization*. Gulf Professional Publishing, 2020, s. 289–314. ISBN 978-0-12-817736-5. Dostupné z: <https://www.sciencedirect.com/science/article/pii/B9780128177365000107>.

- [37] MIURA, N.; NAGASAKA, A. a MIYATAKE, T. Extraction of Finger-Vein Patterns Using Maximum Curvature Points in Image Profiles. *IEICE Trans. Inf. Syst.*, 2007, 90-D, s. 1185–1194. Dostupné z: <https://api.semanticscholar.org/CorpusID:16384087>.
- [38] MUJA, M. a LOWE, D. G. Fast Approximate Nearest Neighbors with Automatic Algorithm Configuration. In: *International Conference on Computer Vision Theory and Application VISSAPP'09*. INSTICC Press, 2009, s. 331–340.
- [39] MUJA, M. a LOWE, D. G. Fast Matching of Binary Features. In: *Computer and Robot Vision (CRV)*. 2012, s. 404–410.
- [40] MUSA, P.; RAFI, F. A. a LAMSANI, M. A Review: Contrast-Limited Adaptive Histogram Equalization (CLAHE) methods to help the application of face recognition. In: *2018 Third International Conference on Informatics and Computing (ICIC)*. 2018, s. 1–6.
- [41] NAIR, N. 2D Feature Tracking — Part 3: Feature Matching. *Medium* online. 2023. Dostupné z: <https://medium.com/@nikhilmair8490/2d-feature-tracking-part-3-feature-matching-72a1bc8dc58a>. [cit. 2024-04-12].
- [42] Norm types. *Open Source Computer Vision* online. 2024. Dostupné z: https://docs.opencv.org/4.x/d2/de8/group__core__array.html#gad12cefbc5291cf958a85b4b67b6149f. [cit. 2024-04-12].
- [43] *OpenCV* online. 2023. Dostupné z: <https://opencv.org/>. [cit. 2023-12-29].
- [44] OpenCV About. *Open Computer Vision Library* online. 2024. Dostupné z: <https://opencv.org/about/>. [cit. 2024-02-15].
- [45] How OpenCV-Python Bindings Works? *Open Source Computer Vision* online. 2024. Dostupné z: https://docs.opencv.org/3.4/da/d49/tutorial_py_bindings_basics.html. [cit. 2024-03-15].
- [46] Physiological and Behavioural Biometrics. *Biometrics Institute* online. 2023. Dostupné z: <https://www.biometricsinstitute.org/physiological-and-behavioural-biometrics/>. [cit. 2023-12-20].
- [47] RAK, R.; MATYÁŠ, V. a ŘÍHA, Z. *Biometrie a identita člověka ve forezních a komerčních aplikacích*. 1. vyd. Praha: Grada, 2008. ISBN 978-80-247-2365-5.
- [48] RUBLEE, E.; RABAUD, V.; KONOLIGE, K. a BRADSKI, G. ORB: An efficient alternative to SIFT or SURF. In: *2011 International Conference on Computer Vision*. 2011, s. 2564–2571.
- [49] S HARAKANNANAVAR, S.; C R, P. a K B, R. Comprehensive Study of Biometric Authentication Systems, Challenges and Future Trends. *International Journal of Advanced Networking and Applications*, Leden 2019, sv. 10, s. 3958–3968.
- [50] SALIH KUZU, R.; MAIORANA, E. a CAMPISI, P. Loss Functions for CNN-based Biometric Vein Recognition. In: *2020 28th European Signal Processing Conference (EUSIPCO)*. 2021, s. 750–754.

- [51] Introduction to SIFT (Scale-Invariant Feature Transform). *Open Source Computer Vision* online. 2024. Dostupné z: https://docs.opencv.org/4.x/da/df5/tutorial_py_sift_intro.html. [cit. 2024-04-02].
- [52] SINGH, G.; BHARDWAJ, G.; SINGH, S. V. a GARG, V. Biometric Identification System: Security and Privacy Concern. In: AWASTHI, S.; TRAVIESO GONZÁLEZ, C. M.; SANYAL, G. a KUMAR SINGH, D., ed. *Artificial Intelligence for a Sustainable Industry 4.0*. Cham: Springer International Publishing, 2021, s. 245–264. ISBN 978-3-030-77070-9. Dostupné z: https://doi.org/10.1007/978-3-030-77070-9_15.
- [53] PCI Rules for Storing Credit Card Numbers in a Database. *Globalpayments Integrated* online. 2019. Dostupné z: <https://www.globalpaymentsintegrated.com/en-us/blog/2019/11/25/pci-rules-for-storing-credit-card-numbers-in-a-database>. [cit. 2023-12-27].
- [54] TYAGI, D. Introduction to ORB (Oriented FAST and Rotated BRIEF). *Medium* online. 2019. Dostupné z: <https://medium.com/@deepanshut041/introduction-to-orb-oriented-fast-and-rotated-brief-4220e8ec40cf>. [cit. 2024-04-13].
- [55] UHL, A.; BUSCH, C.; MARCEL, S. a VELDHUIS, R. *Handbook of Vascular Biometrics*. 1st ed. 2020. Cham: Springer Nature, 2019. Advances in Computer Vision and Pattern Recognition. ISBN 3030277313.
- [56] VAN TIEN, T.; MIEN, P. T. H.; DUNG, P. T. a LINH, H. Q. Using Near-Infrared Technique for Vein Imaging. In: TOI, V. V. a LIEN PHUONG, T. H., ed. *5th International Conference on Biomedical Engineering in Vietnam*. Cham: Springer International Publishing, 2015, s. 190–193. ISBN 978-3-319-11776-8.
- [57] VANONI, M.; TOME, P. a MARCEL, S. *VERA FingerVein*. Zenodo, březem 2021. Dostupné z: <https://doi.org/10.34777/8pkt-6z66>.
- [58] Explainer: Verification vs. Identification Systems. *Biometric Update* online. 2012. Dostupné z: <https://www.biometricupdate.com/201206/explainer-verification-vs-identification-systems>. [cit. 2023-12-25].
- [59] WANG, L.; LEEDHAM, G. a SIU-YEUNG CHO, D. Minutiae feature analysis for infrared hand vein pattern biometrics. *Pattern Recognition*, 2008, sv. 41, č. 3, s. 920–929. ISSN 0031-3203. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0031320307003391>. Part Special issue: Feature Generation and Machine Learning for Robust Multimodal Biometrics.
- [60] Geometric Image Transformations. *Open Source Computer Vision* online. 2024. Dostupné z: https://docs.opencv.org/4.x/da/d54/group__imgproc__transform.html#gaf73673a7e8e18ec6963e3774e6a94b87. [cit. 2024-04-15].
- [61] WILSON, R.; NADEAU, K.; JAWORSKI, F.; TROMBERG, B. a DURKIN, A. Review of short-wave infrared spectroscopy and imaging methods for biological tissue characterization. *Journal of biomedical optics*, Březem 2015, sv. 20, s. 30901.
- [62] ÁLVAREZ, F.; HERNANDEZ ENCINAS, L. a SÁNCHEZ ÁVILA, C. Biometric Fuzzy Extractor Scheme for Iris Templates. In: Leden 2009, s. 563–569.