

SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA ELEKTROTECHNIKY A INFORMATIKY
ÚSTAV INFORMATIKY A MATEMATIKY

ING. PAVOL MARÁK

**OpenFinger: systém na daktyloskopickú
autentifikáciu s GPU akceleráciou**

Dizertačná práca

Bratislava, 2020

Ing. Pavol Marák

SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA ELEKTROTECHNIKY A INFORMATIKY
ÚSTAV INFORMATIKY A MATEMATIKY



Ing. Pavol Marák

Dizertačná práca

Téma dizertačnej práce:

OpenFinger: systém na
daktyloskopickú autentifikáciu
s GPU akceleráciou

Evidenčné číslo:

FEI-104372-50790

Školiteľ:

prof. RNDr. Otokar Grošek, PhD.

Konzultant:

Ing. Alexander Hambalík, PhD.

Forma štúdia:

denná prezenčná

Začiatok štúdia:

01. 09. 2012

Študijný program:

Aplikovaná informatika

Študijný odbor:

Informatika

Bratislava, 2020



ZADANIE DIZERTAČNEJ PRÁCE

Študent: **Ing. Pavol Marák**
ID študenta: 50790
Študijný program: aplikovaná informatika
Študijný odbor: informatika
Vedúci práce: prof. RNDr. Otokar Grošek, PhD.
Konzultant: Ing. Alexander Hambalík, PhD.
Miesto vypracovania: Ústav informatiky a matematiky

Názov práce: **OpenFinger: systém na daktyloskopickú autentifikáciu s GPU akceleráciou**

Jazyk, v ktorom sa práca vypracuje: slovenský jazyk

Špecifikácia zadania:

Cieľom práce je analyzovať, navrhnuť a implementovať biometrický systém s otvoreným zdrojovým kódom, určený na autentifikáciu pomocou odtlačkov prstov. Špecifickým zmyslom práce je vyvinúť nové a aplikovať málo preskúmané algoritmy predspracovania obrazu, klasifikácie charakteristických znakov a ich porovnávania s využitím výpočtovej sily GPU a prostredkov strojového učenia. Požiadavkou je, aby bolo výsledné riešenie implementované ako softvérová knižnica umožňujúca biometrický ako aj expertný režim fungovania na podporu výskumných experimentov. Na vyhodnotenie výsledkov práce z hľadiska úspešnosti rozpoznávania a rýchlosťi, musia byť použité verejne dostupné biometrické databázy a súčasne musí byť vhodne demonštrované nasadenie vyvinutého systému do praxe.

1. Špecifikovať výskumný problém a analyzovať súčasný stav v danej oblasti.
2. Navrhnuť systém daktyloskopickej autentifikácie.
3. Implementovať navrhnutý systém vo forme softvérovej knižnice s využitím metód strojového učenia a paralelizácie výpočtu pomocou GPU.
4. Vykonať experimenty a vyhodnotiť úspešnosť a efektívnosť implementovaného riešenia.
5. Zhodnotiť prínos práce.
6. Vytvoriť potrebnú písomnú dokumentáciu.

Zoznam odbornej literatúry:

1. LEE, H. – GAENSSLER, R. Advances in fingerprint technology, 2nd ed. 2001. LLC: CRC Press, 2001. ISBN 0-8493-0923-9.
2. JAIN, A. – MAIO, D. – MALTONI, D. Handbook of Fingerprint Recognition. Londýn: Springer – Verlag, 2009. 483 s. ISBN 978-1-84882-253-5.
3. RATHA, N. – BOLLE, R. Automatic Fingerprint Recognition Systems. New York: Springer-Verlag, 2003. 458 s. ISBN 0-387-95593-3.

Riešenie zadania práce od: 24. 08. 2012
Dátum odovzdania práce: 30. 06. 2020

Ing. Pavol Marák
riešiteľ

Dr. rer. nat. Martin Drozda
vedúci pracoviska

prof. RNDr. Gabriel Juhás, PhD.
garant študijného programu

ČESTNÉ VYHLÁSENIE

Čestne vyhlasujem, že som predloženú písomnú prácu vypracoval samostatne na základe vlastných teoretických poznatkov, praktických skúseností, odbornej pomoci svojho školiteľa a štúdia odbornej literatúry, ktorej úplný prehľad je uvedený v zozname použitej literatúry.

V Bratislave, 10. 6. 2020

.....
Ing. Pavol Marák

“Vízia je umenie vidieť neviditeľné”

Jonathan Swift

Pod'akovanie

Na tomto mieste by som rád vyjadril úprimné pod'akovanie svojmu školiteľovi prof. RNDr. Otokarovi Grošekovi, PhD. za jeho odbornú pomoc, trpezlivosť a vedenie počas písania tejto práce a rovnako aj počas môjho celého doktorandského štúdia. Moja vd'aka patrí takisto Ing. Alexandrovi Hambalíkovi, PhD., môjmu školiteľovi špecialistovi, za jeho metodické usmerňovanie, cenné pripomienky a pomoc pri tvorbe koncepcie tejto práce, ako aj dlhodobú spoluprácu na Ústave informatiky a matematiky. Nezabúdam ani na dôležitých kolegov, Lászla Kádeka a Ivana Kováča, ktorí sa významne podpísali pod výsledky tejto práce svojimi softvérovými implementáciami, nápadmi a tvorivou spoluprácou. Rovnako vyjadrujem úprimné pod'akovanie kolektívu ľudí na Kriminalistickom a expertíznom ústave Policajného zboru SR, ktorých odbornosť a skúsenosti v skúmanej problematike mi pomohli pri určení správneho výskumného smeru. Ďakujem svojim rodičom, blízkej rodine a priateľom, ktorí ma svojou trpezlivosťou a vytváraním prostredia plného motivácie nemalou mierou podporili pri písaní práce a dodali energiu do ďalšieho pokračovania môjho úsilia.

Abstrakt

MARÁK Pavol: *OpenFinger: systém na daktyloskopickú autentifikáciu s GPU akceleráciou* [Dizertačná práca] - Slovenská technická univerzita v Bratislave. Fakulta elektrotechniky a informatiky, Ústav informatiky a matematiky. Školiteľ: prof. RNDr. Otokar Grošek, PhD. Bratislava: FEI STU, 2020.

Biometrická autentifikácia prostredníctvom odtlačkov prstov je rezonujúcou tému v oblasti informačnej bezpečnosti. Aktuálny rozmach metód strojového učenia sa značnou mierou podpisuje na stále sa zvyšujúcej úspešnosti biometrie a otvára mnohé výskumné možnosti. Väčšina daktyloskopických systémov je však komerčná a neumožňuje otvorené vedecké skúmanie. Táto práca prináša návrh, implementáciu a testovanie biometrického systému s otvoreným kódom s názvom OpenFinger. OpenFinger je systém na rozpoznávanie odtlačkami prstov s využitím strojového učenia, výkonu GPU a množstvom expertných funkcií, čo vytvára inovatívne riešenie, aké v skúmanej oblasti chýba. Navyše, kvôli zvýšeniu presnosti, OpenFinger dokáže rozpoznávať aj obrazce žil na prste a môže fungovať ako multimodálny biometrický systém.

OpenFinger je zložený z viacerých vlastných softvérových knižníc. Do nášho ekosystému knižníc ako prvá zapadá knižnica na predspracovanie odtlačkov prstov. Je to zoskupenie algoritmov určených na obnovu štruktúry obrazcov tvorených papilárnymi líniemi v dôsledku nízkej obrazovej kvality. Klúčovou operáciou tejto fázy je adaptívny Gaborov filter. Vytvorili sme aj paralelnú CPU/GPU implementáciu predspracovania, ktorá markantne urýchľuje celý proces. Ďalšou knižnicou je automatizovaná extrakcia charakteristických znakov odtlačku. Zamerali sme sa na Level-2 znaky predstavujúce tvarové zvláštnosti papilárnych línií. OpenFinger systém využíva nový, doposiaľ nepublikovaný spôsob ich extrakcie založený na kombinácii konvenčných metód a konvolučnej neurónovej siete. Sieť bola natrénovaná na rozsiahlej vzorke Level-2 znakov zozbieraných vlastnou špecializovanou aplikáciou. Výsledky extrakcie sú exportované v štandardizovanom elektronickom formáte ISO/IEC 19794-2. Odhalené Level-2 znaky sú v samostatnej knižnici porovnávané algoritmami BOZORTH3 a Suprema BioMini SDK. Okrem daktyloskopických knižníc, obsahuje OpenFinger aj knižnice na spracovanie obrazcov žil, modul automatizovaného vyhodnotenia úspešnosti rozpoznávania ako aj modul fúzie potrebný na zabezpečenie multimodálneho režimu práce.

Práca dokumentuje dôležité aspekty návrhu jednotlivých algoritmov, ich implementácie ako aj testovania s dôrazom na popis použitých testovacích databáz a podrobnú diskusiu k výsledkom jednotlivých knižníc, ale aj systému ako celku. Náš systém sme vyhodnotili pomocou viacerých ukazovateľov úspešnosti ako sú ROC alebo FAR/FRR krivky a taktiež sme analyzovali rýchlosť operácií spracovania údajov. Vo výsledkoch sme sa zamerali aj na vyhodnotenie unimodálneho a multimodálneho režimu fungovania systému. Možnosti používania systému OpenFinger sú demonštrované nami vyvinutou klient-server aplikáciou, ktorá umožňuje jeho nasadenie v počítačovej sieti.

Klúčové slová: OpenFinger, daktyloskopia, biometria, konvolučná neurónová sieť

Abstract

MARÁK Pavol: *OpenFinger: an open-source fingerprint recognition system using GPU acceleration* [Dissertation thesis] - Slovak University of Technology in Bratislava. Faculty of Electrical Engineering and Information Technology. Institute of Computer Science and Mathematics. Supervisor: prof. RNDr. Otokar Grošek, PhD. Bratislava: FEI STU, 2020.

Biometric authentication based on fingerprints is an extensively studied area of information security. Present expansion of machine learning methods has a significant share in rapidly growing success of biometrics and opens up many research possibilities. However, most of fingerprint recognition systems are commercial, resulting in restricted scientific research. This thesis brings a proposal, implementation and performance evaluation of an open-source biometric system named OpenFinger. OpenFinger is the system intended for fingerprint recognition, harnessing the power of machine learning, GPU computing and providing a number of expert features that turns it into an innovative solution that is currently missing in the field of biometrics. Moreover, in order to improve its accuracy, OpenFinger is able to perform finger vein pattern recognition and thus may operate in a multimodal mode.

OpenFinger is composed of several software libraries. Fingerprint preprocessing is the first library to fit into our library ecosystem. It is a group of algorithms responsible for fingerprint pattern restoration in conditions of poor image quality. Adaptive Gabor filter is the most crucial preprocessing stage. We have created a parallel CPU/GPU preprocessing implementation, massively boosting its performance in terms of speed. Fingerprint feature extraction forms another library. Its purpose is to detect Level-2 features representing shape peculiarities of ridge pattern. OpenFinger employs a new method for their extraction based on a combination of conventional approaches and convolutional neural network. Our network has been trained on a large sample of Level-2 features collected by our specialized application. Extraction results are exported in a standardized electronic format ISO/IEC 19794-2. Level-2 features are compared in another library which delivers matching capability by means of BOZORTH3 and Suprema BioMini SDK algorithms. Besides fingerprint-related libraries, OpenFinger incorporates additional functionality, namely, finger vein processing, automated performance evaluation and fusion to ensure a multimodal operation mode.

This work documents important algorithm design aspects, their software implementation and testing with emphasis on description of test databases and comprehensive discussion on the achieved results. We evaluated our solution using well-known indicators such as ROC or FAR/FRR. Furthermore, we conducted experiments to measure processing speed. We also compared unimodal and multimodal system performance. Practical use of OpenFinger is demonstrated by our client-server application for remote network authentication.

Keywords: OpenFinger, fingerprints, biometrics, convolutional neural network

Obsah

Úvod	1
1 Ciele a motivácia práce	4
1.1 Ciele práce	4
1.2 Hlavné faktory motivácie	6
1.3 Štruktúra práce	11
2 Teoretické východiská a aktuálny stav skúmanej problematiky	13
2.1 Základné pojmy	13
2.1.1 Vlastnosti odtlačkov prstov	16
2.1.2 Fázy procesu automatizovaného rozpoznávania odtlačkami prstov	20
2.1.3 Hodnotenie úspešnosti biometrického systému	27
2.2 Automatizované daktyloskopické systémy	32
2.2.1 Architektúra	32
2.2.2 Metódy predspracovania odtlačkov prstov	34
2.2.3 Metódy extrakcie charakteristických vlastností odtlačkov prstov	37
2.2.4 Metódy porovnávania odtlačkov prstov	46
2.3 Súčasný stav v skúmanej problematike	48
2.3.1 Adaptívne predspracovanie daktyloskopických vzorov	49
2.3.2 Aplikácia metód strojového učenia vo fáze extrakcie daktyloskopických vzorov	63
2.3.3 Multimodálne biometrické systémy založené na odtlačkoch prstov a vzoroch žil na prste	71
3 Realizácia vlastného výskumu	81
3.1 Návrh systému OpenFinger	82
3.1.1 Architektúra systému	83
3.1.2 Modul spracovania odtlačkov prstov	86
3.1.3 Modul spracovania obrazcov žil prstov	87
3.1.4 Modul vyhodnotenia úspešnosti rozpoznávania osôb	88
3.1.5 Unimodálny a multimodálny režim fungovania	94
3.1.6 Použité softvérové prostriedky	96
3.1.7 Snímanie odtlačkov prstov	97
3.2 Implementované knižnice a aplikácie v rámci systému OpenFinger	100
3.2.1 Knižnica na predspracovanie obrazu odtlačku prsta	100
3.2.2 Knižnica na extrakciu charakteristických vzorov odtlačku	113
3.2.3 Knižnica na porovnávanie odtlačkov prstov	119
3.2.4 OF Sandbox: expertný systém na testovanie predspracovania	121
3.2.5 Export extrahovaných údajov do štandardizovaného dátového formátu ISO/IEC 19794-2	122

3.2.6	OF Sample Collector: vlastný softvér na zber trénovacích vzoriek pre konvolučnú neurónovú sieť	123
3.2.7	Rozšírenie systému o rozpoznávanie obrazcov žíl na prste	124
3.3	Výsledky testovania systému OpenFinger	130
3.3.1	Inštalácia a používanie knižnice	130
3.3.2	Testovacie biometrické databázy	131
3.3.3	Komplexné zhodnotenie úspešnosti a rýchlosť rozpoznávania . .	133
3.3.4	Overenie funkcionality systému formou klient-server aplikácie . .	142
4	Sumarizácia dosiahnutých výsledkov a prínos práce	144
4.1	Hlavné výsledky práce	145
4.2	Verejný Github repozitár so zdrojovými kódmi	148
Záver		149
Literatúra		150

Zoznam obrázkov

1.1	Ukážka rôznych typov daktyloskopických markantov	9
2.1	Detail papilárnych línii	14
2.2	Daktyloskopické markanty a iné významné body vo vzore odtlačku	15
2.3	Singulárne body daktyloskopického vzoru	17
2.4	Level-1 vzory	17
2.5	Daktyloskopické markanty (ukončenie a rozdvojenie)	18
2.6	Taxonómia Level-2 znakov	18
2.7	Ilustrácia všetkých troch úrovní daktyloskopických vzorov	19
2.8	Bezkontaktný senzor odtlačkov prstov	20
2.9	Výsledky segmentácie odtlačkov	22
2.10	Obnova papilárneho terénu Gaborovym filtrom	22
2.11	Smerová mapa odtlačku	23
2.12	Najčastejšie triedy odtlačkov z Galton-Henryho schémy	24
2.13	Ukážka extrakcie daktyloskopických markantov	26
2.14	Ukážka porovnávania daktyloskopických markantov	26
2.15	Vzor FAR/FRR grafu s ukážkou EER bodu	29
2.16	Vzor ROC krivky biometrického systému	30
2.17	Vzor CMC krivky biometrického systému	30
2.18	Vzor Precision-Recall grafu	31
2.19	Histogramy pre skóre podobnosti medzi odtlačkami prstov	31
2.20	Schéma biometrického systému na báze odtlačkov	32
2.21	Schéma regisračného režimu biometrického systému	33
2.22	Schéma verifikačného režimu biometrického systému	33
2.23	Schéma identifikačného režimu biometrického systému	34
2.24	Oblasti odtlačku s líšiacou sa kvalitou	34
2.25	Maska odtlačku získaná v procese segmentácie	35
2.26	Masky odtlačkov získané neurónovou sietou SegFinNet	36
2.27	Mapy kvality odtlačkov	37
2.28	Prínos adaptívneho filtrovania odtlačku	38
2.29	Odtlačok a jeho kostra	39
2.30	Detekcia markantov v kostre algoritmom Crossing Number	39
2.31	Projekcia intenzity obrazových bodov v papilárnej línii	40
2.32	Markanty odhalené na základe analýzy okrajov papilárnej línie	41
2.33	Run-length kódovanie vzoru odtlačku	42
2.34	Falošné vzory objavené v run-length kóde odtlačku	43
2.35	Detekcia ukončenia papilárnej línie pomocou metódy HMT	44
2.36	Vizualizácia amplitúdového a fázového poľa odtlačku prsta	45
2.37	Porovnávanie markantov algoritmom BOZORTH3	47
2.38	MCC algoritmus a vizualizácia cylindrov	47

2.39	Schéma adaptívneho filtrovania odtlačku pomocou Gaborovho filtra	50
2.40	Lokálny smer papilárnej línie	50
2.41	Vizualizované matice základnej a pokročilej smerovej mapy	52
2.42	Fourierove spektrum obrazového bloku odtlačku	53
2.43	Odhalenie primárnej papilárnej línie pomocou PCNN siete	53
2.44	Výstupy neurónovej siete pre odhad smeru v odtlačku	54
2.45	Ukážky frekvenčnej mapy odtlačku	55
2.46	Metóda X-signature na výpočet frekvenčnej mapy odtlačku	56
2.47	Sledovanie papilárnych línií v troch rôznych smeroch	57
2.48	Výpočet vzdialenosťi papilárnych línií Delaunayovou trianguláciou	58
2.49	Súvislosť medzi 2D sínusovým signálom a vzorom odtlačku prsta	59
2.50	Gaborove filtre s rôznymi smermi a frekvenciami	59
2.51	Kernely Gaborovho filtra pri rôznych smeroch a frekvenciách	60
2.52	Vizualizácia Gaborových kernelov	61
2.53	Periodická funkcia použitá v modifikovanom Gaborovom filtri	62
2.54	Porovnanie tradičného a modifikovaného Gaborovho filtra	62
2.55	Zakrivený Gaborov filter	63
2.56	Ukážka klasifikácie obrázku v konvolučnej neurónovej sieti	64
2.57	Znázornenie princípu konvolúcie	64
2.58	Štruktúra konvolučnej vrstvy neurónovej vrstve	65
2.59	Ukážka operácie Max pooling	65
2.60	Modifikovaná sieť Inception v4	67
2.61	Extrakcia dakyloskopických markantov s využitím siete MENet	68
2.62	Schéma siete CoarseNet	69
2.63	Schéma siete MinutiaeNet	70
2.64	Základná FingerNet sieť	70
2.65	Rozšírená FingerNet sieť	72
2.66	Úrovne fúzie v multimodálnom biometrickom systéme	73
2.67	Vizualizácia fúzie príznakov odtlačku a obrazca žíl na prste	75
2.68	Systém s fúziou vo fáze extrakcie príznakov a porovnávania	76
2.69	Tabuľka úspešnosti rozpoznávania multimodálnym systémom založeným na odtlačkoch prstov a obrazoch žíl pri rôznych typoch fúzie	77
2.70	Multimodálny biometrický systém založený na spracovaní tváre, odtlačku prsta a obrazca žíl pomocou konvolučnej neurónovej siete	78
2.71	Architektúra CNN pre extrakciu vlastností v odtlačku prsta	78
2.72	Architektúra CNN pre extrakciu vlastností v obrazci žíl	79
2.73	Architektúra CNN pre extrakciu vlastností tváre	79
2.74	Úspešnosti rozpoznávania unimodálnych systémov podľa zvoleného druhu extraktora a klasifikátora	80
2.75	Úspešnosti rozpoznávania rôznych konfigurácií multimodálneho biometrického systému rozdelené podľa zvolenej metódy fúzie skóre	80
3.1	Architektúra systému OpenFinger	85
3.2	OpenFinger: rozpoznávanie pomocou odtlačkov prstov	87

3.3	OpenFinger: rozpoznávanie pomocou obrazcov žíl na prstoch	88
3.4	Modul automatizovaného vyhodnotenia úspešnosti rozpoznávania	90
3.5	GUI aplikácia na testovanie úspešnosti a rýchlosťi	92
3.6	Unimodálne režimy systému OpenFinger	95
3.7	Multimodálny režim systému OpenFinger	96
3.8	Snímač Suprema BioMini Slim	98
3.9	Snímač Biometrika HiScan PRO	99
3.10	Snímač Futronic FS80H	99
3.11	Schéma knižnice na predspracovanie odtlačkov prstov	102
3.12	Klasifikácia obrazových blokov pri segmentácii	104
3.13	Odstránenie dier z masky odtlačku	104
3.14	Porovnanie viacerých metód segmentácie	105
3.15	Mapa kvality vypočítaná softvérom MINDTCT	105
3.16	Rýchlosť výpočtu smerovej mapy	106
3.17	Presnosť odhadu smeru	107
3.18	Smerové mapy odtlačkov v rôznych kvalitách	108
3.19	Vplyv veľkosti bloku a parametra λ na výsledok filtrovania Gaborovym filtrom	109
3.20	Princíp využitia viacvláknového Gaborovho filtra	110
3.21	Vplyv smerovej mapy na filtrovanie	111
3.22	Dopad filtrovania odtlačku na kvalitu kostry	111
3.23	Rýchlosť Gaborovho filtra na CPU/GPU	112
3.24	Závislosť rýchlosťi filtrovania od počtu CPU vláken	112
3.25	Modifikovaná sieť ResNet-18 na klasifikáciu markantov	113
3.26	Parametre modifikovanej siete ResNet-18	114
3.27	Schéma knižnice na extrakciu Level-2 znakov	116
3.28	Kombinácia neurónovej siete s metódou Crossing Number	117
3.29	Mapa klasifikácie markantov	117
3.30	Pokročilá vizualizácia extrakcie markantov	118
3.31	Schéma knižnice na porovnávanie odtlačkov prstov	120
3.32	Rýchlosť modifikovaného porovnávacieho algoritmu BOZORTH3	121
3.33	Používateľské rozhranie systému OF Sandbox	122
3.34	Štruktúra ISO/IEC 19794-2 záznamu	123
3.35	Používateľské rozhranie systému OF Sample Collector	124
3.36	Schéma predspracovania vzorov žíl	125
3.37	Výsledok SUACE metódy	126
3.38	Smerová mapa obrazca žíl	126
3.39	Obrazec žíl po prefiltrovani Gaborovym filtrom	126
3.40	GUI aplikácia na testovanie predspracovania obrazcov žíl	127
3.41	Ukážka SIFT klúčových bodov a deskriptorov	128
3.42	Ukážka porovnávania SIFT/SURF klúčových bodov	128
3.43	Ukážky obrázkov z databázy FVC 2002 DB3 a SDUMLA-HMT	132
3.44	Unimodálny systém na báze odtlačkov prstov: ROC krivky pre všetky FVC databázy	134

3.45 Unimodálny systém na báze odtlačkov prstov: porovnanie nášho systému so systémom MENet a ďalšími známymi algoritmami na databáze FVC 2002 DB1 pomocou ROC kriviek	135
3.46 Unimodálny systém na báze odtlačkov prstov: FAR/FRR krivka na databáze FVC 2002 DB3	136
3.47 Unimodálny systém na báze odtlačkov prstov: histogramy pre skóre porovnania pri deaktivovanom predspracovaní obrazu	136
3.48 Unimodálny systém na báze odtlačkov prstov: histogramy pre skóre porovnania pri aktivovanom predspracovaní obrazu	137
3.49 Unimodálny systém na báze odtlačkov prstov: priemerný čas trvania kompletného procesu rozpoznávania na všetkých FVC 2002 databázach	138
3.50 Unimodálny systém na báze odtlačkov prstov: priemerný čas trvania predspracovania v závislosti od rozmeru vstupného obrazu	139
3.51 Unimodálny systém na báze obrazcov žíl: časová náročnosť jednotlivých vnútorných operácií predspracovania jedného obrazca žíl z databázy SDUMLA-HMT	140
3.52 Unimodálny systém na báze obrazcov žíl: časová náročnosť hlavných fáz spracovania jedného obrazca žíl z databázy SDUMLA-HMT	141
3.53 Klient-server aplikácia: strana klienta	143
3.54 Klient-server aplikácia: strana servera	143

Zoznam tabuliek

3.1	Prahové hodnoty pre skóre vypočítané jednotlivými porovnávacími algoritmami	94
3.2	Vplyv veľkosti filtrovacieho kernelu a parametra λ Gaborovho filtra na výsledný obraz	110
3.3	Zoznam použitých biometrických databáz na experimenty	132
3.4	Softvérová a hardvérová konfigurácia školského servera, na ktorom boli vykonané všetky testy	133
3.5	Unimodálny systém na báze odtlačkov prstov: hodnoty ukazovateľa EER namerané pre všetky FVC 2002 databázy a obidva porovnávacie algoritmy Suprema BioMini SDK a BOZORTH3	134
3.6	Unimodálny systém na báze obrazcov žil: hodnoty ukazovateľa EER namerané na databáze SDUMLA-HMT pre rôzne druhy predspracovania a extraktorov	139
3.7	Unimodálny systém na báze obrazcov žil: celková dĺžka trvania vnútorných fáz predspracovania na všetkých obrazoch databázy SDUMLA-HMT	140
3.8	Multimodálny systém: EER ukazovateľ pre rôzne stratégie fúzie skóre .	141
3.9	Porovnanie úspešnosti rozpoznávania v unimodálnom a multimodálnom režime	142

Zoznam použitých skratiek

AFIS	Automated Fingerprint Identification System
API	Application Programming Interface
BOZORTH3	Algoritmus na porovnávanie odtlačkov prstov napísaný Allanom S. Bozorthom (FBI) v jazyku C, ktorý je súčasťou biometrického softvéru NBIS americkej inštitúcie NIST
CMC	Cumulative Match Characteristic
CNN	Convolutional Neural Network
CPU	Central Processing Unit (procesor počítača)
EER	Equal Error Rate (špecifický bod ROC krivky, v ktorom platí FMR = FNMR)
FMR	False Match Rate (typ chyby biometrického systému)
FNMR	False Non-Match Rate (typ chyby biometrického systému)
GPU	Graphics Processing Unit (grafická karta počítača)
GUI	Graphical User Interface (grafické používateľské rozhranie)
IAI	International Association for Identification
KEÚPZ	Kriminalistický a expertízny ústav Policajného zboru SR
NIST	National Institute of Standards and Technology
PPI	Pixels Per Inch (jednotka rozlíšenia obrazu)
PX	Pixel (obrazový bod)
ROC	Receiver Operating Characteristics
ROI	Region Of Interest
SIFT	Scale Invariant Feature Transform
SURF	Speeded Up Robust Features
US-VISIT	United States Visitor and Immigrant Status Indicator Technology

Úvod

Čím viac je súčasná spoločnosť elektronicky prepojená a čím viac sa do popredia dostávajú novodobé virtuálne hrozby, tým širší a hlbší význam nadobúda nebezpečenstvo krádeže identity. Žijeme v ére, v ktorej sme obklopení inteligentnými zariadeniami existujúcimi vo svete tzv. internetu vecí, ktoré zvyšujú náš komfort, využívame rôzne digitálne služby od elektronického bankovníctva, sociálne siete až po zdravotníctvo a v neposlednom rade sme vlastníkmi rôznych citlivých informácií. Všetky tieto oblasti vyžadujú určitú formu zabezpečenia. Rozpoznávanie identity človeka nesie viaceré problémy ako spoľahlivosť, rýchlosť, komfort, ako aj dopad na súkromie človeka. Prostriedky na ochranu identity by preto mali pružne reagovať na turbulentný vývoj súčasnej doby a na sofistikované hrozby by mali odpovedať účinnými metódami autentifikácie.

Na rozpoznanie identity sa ponúkajú vo všeobecnosti tri všeobecne známe možnosti. Prvou možnosťou ako preukázať alebo oznámiť tretej strane našu identitu je znalosť určitej tajnej frázy resp. hesla. Nevýhodou hesla je možnosť jeho uhádnutia, zdieľania s inou osobou, možnosť zabudnutia alebo aj jeho nesprávne uchovávanie. Každá aplikácia alebo používateľské konto by malo byť kvôli bezpečnosti zabezpečené odlišným a kvalitným heslom, čo je veľmi náročné zabezpečiť. Druhým riešením problému je vlastníctvo konkrétnego prostriedku ako napríklad občiansky preukaz, vodičský preukaz alebo rôzne druhy smart kariet. Aj tento spôsob nie je vždy ideálny nakol'ko nesie riziká vo forme klonovania kariet alebo útokov postrannými kanálmi. Navyše, to, čo heslá a karty spája je, že medzi nimi a osobou, ktorá ich vlastní neexistuje žiadna silná väzba, t.j. rovnaký bezpečnostný predmet môže použiť aj iná osoba.

Treťou možnosťou ako preukázať svoju identitu je biometrické rozpoznanie. Biometria na rozpoznanie človeka využíva rôzne fyzické a behaviorálne charakteristiky, ktoré sú považované za jedinečné, nemenné a veľmi ľahko napodobniteľné. V dnešnom svete prebieha overenie identity biometrickými technikami v mnohých oblastiach. Môžeme byť svedkami verifikácie identity biometrickým terminálom pri kontrole fyzického vstupu alebo evidencii pracovnej dochádzky. Často je biometrický znak využívaný ako vstupný kľúč pri prihlásovaní sa do PC, počítačovej siete alebo softvérovej aplikácie. Kvôli bezpečnosti a predchádzaniu rôznych podvodom sú ľudia biometricky identifikovaní pri prechode hraníc, pri vydávaní vodičských preukazov alebo pri registrácii voličov vo volbách. Otázka bezpečnosti ľudí, elektronických údajov, finančných transakcií a rôznorodé krádeže identity v dnešnej dobe nadobúdajú s používaním prostriedkov výpočtovej techniky nový význam. Moderný elektronicky prepojený svet si žiada spoľahlivú metódu osobnej autentizácie. Niektoré klasické metódy ako sú heslá alebo prístupové karty už nie sú považované za bezpečné. Obdobnou úrovňou bezpečnosti je biometria, ktorá je pri plnení svojho účelu alternatívou ku kryptografickým prostriedkom autentifikácie osôb.

Táto práca sa zaobera konkrétnie odtlačkami prstov. Odtlačky prstov predstavujú jedinečné a komplexné vzory tvorené obrazcami papilárnych línii. Používajú sa na rozpoznanie identity už niekoľko desaťročí, pričom svoje korene majú v kriminálstike. Forenzná sféra bola donedávna jediným akcelerátorom výskumu nových metód daktyloskopickej identifikácie, no dnes je kommerčný sektor tiež motorom tejto technológie. Odtlačky prstov môžu byť zanechané na rôznych predmetoch a môžu tak byť použité ako dôkaz pri vyšetrovaní trestného činu. V súčasnej dobe sú senzory odtlačkov prstov cenovo prístupné a používajú ako bezpečnostný prvok napríklad na odomknutie smartfónu, dverí alebo výber hotovosti z bankomatu pomocou karty vybavenej zabudovaným snímačom.

Vo svojej podstate je softvérové rozpoznanie odtlačkov prstov chápané ako proces spracovania digitálneho obrazu, klasifikovania komplexných vzorov a kvantifikácie ich podobnosti. Každý obraz odtlačku prsta sa musí priamo po zosnímaní vhodne predspracovať, aby sa odstránili rôzne druhy obrazových degradácií, ktoré narúšajú pôvodnú štruktúru obrazcov papilárnych línii. Následne sa v odtlačku vyhľadávajú charakteristické znaky (alebo aj daktyloskopické markanty). Väčšinou sú to lokálne tvarové anomálie v papilárnych líniah, ktorých komplex je pre daný prst vzácný a neopakovateľný. Po odhalení týchto znakov nasleduje ich porovnávanie so znakmi získanými z iného odtlačku, ktoré má za úlohu stanoviť mieru podobnosti medzi nimi. Toto sú tri základné fázy spracovania odtlačkov prstov, ktoré pozostávajú z veľkého množstva špecializovaných algoritmov, o ktorých je v literatúre množstvo publikácií, avšak len veľmi málo reálnych a predovšetkým dostupných softvérových implementácií, ktoré by preukazovali ich reálne možnosti v praxi.

Problémom je, že neexistujú takmer žiadne softvérové knižnice (a tie, ktoré existujú majú obmedzené možnosti experimentovania) s otvoreným zdrojovým kódom, ktoré by umožnili testovať aktuálne možnosti daktyloskopického rozpoznania, nadalej ich rozvíjať a testovať ich úspešnosť na odtlačkoch prstov zosnímaných v rôznych podmienkach a pomocou odlišných snímacích zariadení. V tejto práci reagujeme na tento problém pomocou vlastného otvoreného systému OpenFinger, ktorý je zoskupením viacerých softvérových knižníč napísaných v programovacom jazyku C++ umožňujúcim rýchle a presné rozpoznanie identity pomocou odtlačkov prstov. V neskorších fázach výskumu bolo naše riešenie rozšírené aj o rozpoznanie pomocou obrazcov žil na prste, čo dovoľuje nášmu systému fungovať v multimodálnom režime. V tomto režime je identita osoby tvorená fúziou jedinečnosti odtlačkov prstov a obrazcov žil. Spojením oboch biometrických znakov dochádza k zvýšeniu presnosti rozpoznania a zníženiu pravdepodobnosti falšovania identity.

Vo svojej podstate je OpenFinger kolekciou viacerých prepojených knižníc primárne určených pre operačný systém Linux, ktoré vykonávajú jednotlivé klúčové fázy procesu daktyloskopickej autentifikácie, akými je predspracovanie obrazu, extrakcia charakteristických znakov a nakoniec samotné porovnanie odtlačkov prstov. Rozdelením celého systému sme získali potrebnú modularitu, čo uľahčuje testovanie a flexibilitu,

t.j. náš systém je zostavený z malých špecializovaných modulov, ktoré sa dajú použiť aj samostatne a vedia komunikovať aj s externými knižnicami tretích strán pomocou vhodne navrhnutého komunikačného rozhrania.

V práci opisujeme všetky štandardné algoritmy prevzaté z odbornej literatúry, spôsob ich implementácie v systéme OpenFinger, ako aj nimi dosiahnuté výsledky. Do knižnice sme integrovali viacero našich vlastných algoritmov, ktoré zlepšujú celkovú úspešnosť knižnice ako napríklad aplikovanie hlbokých konvolučných sietí pri odhalovaní charakteristických znakov priamo v originále odtlačku alebo adaptívne predspracovanie odtlačkov založené na Gaborovom filtri, ktoré výrazne zlepšuje úspešnosť rozpoznávania v podmienkach nízkej obrazovej kvality, čo je v prípade odtlačkov prstov úplne bežným javom.

OpenFinger podporuje až tri známe modely snímačov odtlačkov prstov, čím sú rozšírené možnosti jeho testovania. Charakteristické znaky odtlačkov prstov, ktoré sú v priebehu činnosti odhalené sú exportované do medzinárodne akceptovaného údajového formátu ISO/IEC 19794-2, čím je možné zabezpečiť kompatibilitu s inými daktyloskopickými systémami.

Naše riešenie bolo podrobenejšie viacerým testom zameraným na vyhodnotenie úspešnosti rozpoznávania identity. Boli implementované viaceré sprievodné GUI aplikácie, ktoré dovoľujú testovať ľubovoľné konfigurácie algoritmov a obohacujú náš softvér o možnosti tvorby vlastných trénovacích vzoriek pre konvolučnú neurónovú sieť. Na testovanie sme použili verejné databázy odtlačkov prstov (predovšetkým databázu FVC) a obrazcov žil (SDUMLA-HMT). Pri prezentovaní výsledkov sme sa zamerali na vyčíslenie známych ukazovateľov chybovosti resp. úspešnosti rozpoznávania. To nám umožnilo porovnávať naše riešenie s inými existujúcimi riešeniami. Práca poskytuje diskusiu k výsledkom unimodálneho, ako aj multimodálneho režimu fungovania.

Kapitola 1

Ciele a motivácia práce

Táto kapitola obsahuje hlavné ciele našej práce spolu so zdrojmi našej motivácie. Uvádzame aj stručne zhrnutú štruktúru práce s prepojením na jednotlivé kapitoly.

1.1 Ciele práce

Hlavným problémom skúmaným v rámci tejto dizertačnej práce je návrh, vývoj a testovanie systému OpenFinger, ktorý ponúka kompletné riešenie daktyloskopickej verifikácie a identifikácie vo forme dynamickej softvérovej knižnice navrhnutej primárne pre operačný systém Linux. Tento systém bol navyše rozšírený o modul rozpoznávania identity pomocou analýzy obrazcov žíl na prste. Z toho dôvodu funguje OpenFinger ako multimodálny biometrický systém.

Ciele našej práce sú rozdelené do troch skupín:

Návrh

1. Výber existujúcich algoritmov spracovania odtlačkov prstov. Spracovanie odtlačkov prstov musí byť koncipované modulárne z dôvodu flexibility a ďalšieho rozširovania funkcionality. Základné moduly sú predspracovanie obrazu, extrakcia charakteristických vzorov a ich porovnávanie. Návrh sprievodných aplikácií, pomocou ktorých je možné experimentovať s jednotlivými modulmi.
2. Návrh rozšírenia systému OpenFinger o rozpoznávanie osoby pomocou obrazcov žíl na prste s cieľom vytvoriť a preskúmať možnosti vlastného multimodálneho biometrického systému.
3. Návrh nových, vlastných algoritmov, ktoré vylepšujú alebo odstraňujú nedostatky konvenčných prístupov predspracovania obrazu a predovšetkým extrakcie charakteristických vlastností odtlačkov prstov a taktiež obrazcov žíl na prstoch.
4. Vytvorenie diagramov funkcionality vnútorných komponentov systému OpenFinger zachytávajúcich hlavné informačné toky a architektúru riešenia.
5. Návrh špecializovanej aplikácie na zber obrazových vzoriek pre potreby trénovania hlbokej konvolučnej neurónovej siete určenej na odhalovanie daktyloskopických markantov v obrazci odtlačku.
6. Špecifikácia požiadaviek, návrh a implementácia klient-server aplikácie na demonštráciu používania knižnice v praxi.

1.1. CIELE PRÁCE

Implementácia

1. Špecifikácia softvérových/hardvérových požiadaviek a voľba softvérových knižníc tretích strán na efektívne spracovanie obrazu, využitie strojového učenia a výpočtov s podporou GPU.
2. Implementácia modulu predspracovania odtlačkov prstov ako aj obrazcov žíl na prste s využitím GPU akcelerácie a vlákien serverového procesora. Pri implementácii sa zameriať hlavne na adaptívne filtrovanie obrazu na báze efektívne implementovaného Gaborovho filtra, ktorý využije CPU a GPU výkon dedikovaného školského servera.
3. Implementácia modulu extrakcie daktyloskopických markantov v odtlačkoch prstov pomocou vlastného algoritmu založeného na špeciálne prispôsobenej konvolučnej neurónovej sieti schopnej extrakcie a klasifikácie vzorov priamo z originálneho obrazu.
4. Implementácia aplikácie na zber a prípravu trénovacích vzoriek (obrázky daktyloskopických markantov) pre konvolučnú neurónovú sieť.
5. Implementácia exportu extrahovaných charakteristických údajov z odtlačku prsta do medzinárodne akceptovaného formátu na prenos a uchovávanie biometrických údajov ISO/IEC 19794-2.
6. Implementácia extrakcie príznakov v obrazci žíl na prste (získanie SIFT a SURF deskriptorov).
7. Implementácia algoritmu na porovnávanie charakteristických údajov odtlačkov prstov (ich vlastnosťou musí byť vysporiadanie sa s rotáciou, posunom a deformáciou obrazca papilárnych línii). Využitie komerčného algoritmu Suprema BioMini SDK a open-source algoritmu BOZORTH3.
8. Implementácia porovnávacieho algoritmu pre obrazce žíl na prste (porovnávanie SIFT a SURF deskriptorov).
9. Implementácia modulu fúzie pre skóre porovnania odtlačkov prstov a obrazcov žíl na prste (rôzne metódy normalizácie a fúzie).
10. Implementácia modulu na testovanie úspešnosti rozpoznávania zvlášť v unimodálnom a multimodálnom režime fungovania. Výstupom modulu budú namerané ukazovateľ rýchlosťi a presnosti rozpoznávania na zvolenej databáze biometrických vzoriek.

Testovanie

1. Testovanie úspešnosti rozpoznávania osôb na rôznych verejne dostupných dátabázach (ROC, FAR/FRR, EER a ostatné relevantné metriky).

1.2. HLAVNÉ FAKTORY MOTIVÁCIE

2. Testovanie a porovnanie úspešnosti rozpoznávania systému v unimodálnom a multimodálnom režime.
3. Testovanie rýchlosťi rozpoznávania pri rôznych konfiguráciách knižníc a rôznych scenároch použitia (CPU vlákna, GPU podpora, štandardný laptop, výkonný server).
4. Experimentálne nasadenie systému v sieťovom prostredí formou klient-server (overenie rýchlosťi a spoľahlivosti a možností zabezpečenia prenášaných údajov kryptografickými prostriedkami).
5. Demonštrácia použitia vlastných expertných aplikácií na testovanie jednotlivých modulov a knižníc systému OpenFinger.
6. Porovnávanie vlastných dosiahnutých výsledkov s výsledkami v relevantnej literatúre.

1.2 Hlavné faktory motivácie

Náš výskum v oblasti daktyloskopie a úsilie vložené do vývoja knižníc systému OpenFinger má viacero zdrojov motivácie. V prvom rade je to vytvorenie komplexného modulárneho systému, ktorý v sebe zahrňa viaceré čiastkové algoritmy (nami navrhnuté a prevzaté z literatúry) na spracovanie odtlačkov prstov, ktoré však neboli doposiaľ v literatúre navzájom spojené do jednotného fungujúceho biometrického systému, ktorý vykonáva všetky potrebné operácie od získania obrazu odtlačku až po rozhodovanie.

Druhým najvýraznejším faktorom je snaha o integrovanie metód strojového učenia do oblasti daktyloskopie za účelom vyvinutia spoľahlivého systému na detekciu a klasifikáciu charakteristických znakov priamo v originálnom nespracovanom obraze (nedochádza k stratám obrazových detailov). Nakol'ko v súčasnosti dosahujú hlboké konvolučné neurónové siete v oblasti rozpoznávania vzorov vynikajúce výsledky, rozhodli sme sa ich použiť v práci aj my.

Nemalou mierou sa pod naše úsilie podpísal taktiež aj fakt, že v dobe písania tejto práce neexistovali obdobné open-source softvérové riešenia, pomocou ktorých by sa dali vyhodnotiť dlhodobo známe algoritmy, ktoré boli doposiaľ len v rovine teoretických definícií v literatúre.

OpenFinger bol od začiatku vyvíjaný ako knižnica na rozpoznávanie odtlačkami prstov. Avšak aktuálne trendy v biometrii nám dali jasný signál, že cestou k ďalšiemu zvyšovaniu presnosti našej knižnice je jej rozšírenie o rozpoznávanie ďalších biometrických znakov a ich fúzii s odtlačkami prstov. Konkrétnie sme náš systém doplnili o spracovanie obrazcov žil na prste.

1.2. HLAVNÉ FAKTORY MOTIVÁCIE

Rozpoznávanie odtlačkami prstov, ako aj celá biometria, je spôsob ako overiť totožnosť človeka s úspešnosťou, ktorá je vysoká, avšak k neomylnosti sa stále len približuje. Automatizované rozpoznanie identity pomocou odtlačku prsta je relatívne vyspelé, avšak neustále naráža na celý rad problémov, ktoré si vyžadujú ďalší výskum. V reakcii na tieto nedostatky sme sa snažili koncipovať aj našu prácu tak, aby prinášala odpovede a riešenia niektorých nasledujúcich problémov.

To, čo nás najviac v tejto práci motivovalo je riešenie aktuálnych otvorených otázok a hľadanie nových postupov ako sa vysporiadať s nevyriešenými problémami týkajúcimi sa rozpoznávania odtlačkami prstov.

Medzi tieto otvorené výskumné problémy a výzvy patria:

Senzory a obrazové rozlíšenie. Malá snímacia plocha senzorov a z toho prameňiaca nízka úspešnosť rozpoznávania. Náš systém navrhnutý v práci dokáže, okrem iných, komunikovať aj s FBI certifikovaným senzorom s obrazovým rozlíšením 1000 PPI.

Chýbajúce open-source riešenia. Nedostatok akademického výskumu z dôvodu nízkeho počtu riešení s otvoreným zdrojovým kódom. Náš systém je open-source a je verejne prístupný prostredníctvom GitHub repozitára. Okrem iného, je náš systém vytvorený ako knižnica a to zabezpečuje ľahké integrovanie do iných existujúcich systémov, ktoré potrebujú rozšíriť svoje zabezpečenie o rozpoznávanie identity.

Nejednotné testovanie systémov. Nemožnosť porovnávať výsledky existujúcich systémov medzi sebou z dôvodu testovania na neverejných databázach a používania rozlišných testovacích protokolov. My sme v práci použili viaceré verejne dostupné databázy biometrických vzorov, aby bolo možné naše výsledky porovnať s prácamu iných autorov. Problémom sú aj malé vzorky, na ktorých sú vyvíjané algoritmy testované. Vzorka by mala obsahovať v dostatočnom množstve rovnomerné zastúpenie všetkých faktorov variability. Nízka chybovosť biometrického systému testovaného na malej a úzko profilovanej vzorke nemusí byť zárukou jeho nízkej chybovosti na vzorke pochádzajúcej z diametrálne odlišných podmienok. Riešenia ako získať veľké množstvo testovacích odtlačkov prstov prinesla aj práca výskumníkov z University of Bologna [29], ktorí implementovali softvérový systém s názvom SFinGe, ktorý vie generovať reálne vzory odtlačkov prstov so simuláciou rôznej kvality. Týmto spôsobom je možné získať rozsiahlu testovaciu vzorku bez právnych problémov.

Odtlačky prstov v nízkej kvalite. Nízka úspešnosť automatizovaného rozpoznávania v prípadoch latentných odtlačkov (t.j. odtlačkov zosnímaných z povrchu rôznych materiálov a získaných na miestach trestného činu) alebo všeobecne odtlačkov nízkej kvality z dôvodu nedostatočného predspracovania

1.2. HLAVNÉ FAKTORY MOTIVÁCIE

obrazu (v našej práci sme implementovali robustné predspracovanie použitím adaptívnych filtrov, ako napríklad Gaborov filter).

Problémy s extrakciou vzorov. Náročnosť automatizovanej detekcie a klasifikácie charakteristických znakov odtlačku kvôli komplexnosti ich tvarov. Tieto znaky sú ľahko rozpoznateľné konvenčnými algoritmami (také, ktoré skúmajú tvarové vlastnosti papilárnych línii na úrovni obrazových bodov) kvôli ich vnútrotriednej variabilite. Z toho dôvodu sme využili v našej práci na klasifikovanie týchto komplikovaných vzorov osobitne natrénovanú neurónovú sieť, ktorá je schopná vysporiadať sa s posunom, rotáciou, škálovaním alebo inými transformáciami vzorov.

Rozpoznávanie vzorov v nespracovaných obrazoch. Mnohé systémy odhaľujú charakteristické znaky v predspracovanom obraze, čo môže mať za následok stratu klíčových informácií nakoľko v predspracovanom obraze môžu byť prítomné umelé falošné tvary alebo v nom môžu chýbať pôvodné skutočné tvary (len zlomok dostupných riešení uvádzajúce algoritmy na odhaľovanie charakteristických znakov priamo v originálnom obraze odtlačku prsta [28]). Naše riešenie využíva predspracovanie obrazu na odhalenie obrazových zón v pôvodnom obraze, v ktorých je vysoká šanca výskytu daktyloskopického markantu. Tieto zóny vymedzia oblasť v pôvodnom nespracovanom obraze a tá sa verifikuje v neurónovej sieti, ktorá rozhodne o prítomnosti a type daktyloskopického markantu.

Vnútrotriedna variabilita vzoru odtlačku. Nevyhovujúce snímacie podmienky a nestála reprezentácia rovnakého odtlačku prsta spôsobená premenlivým stavom kože, poraneniami, chorobami a taktiež nemožnosťou zosnímať rovnaký prst tak, aby boli v obraze zachytené vždy všetky potrebné detaily. Tento problém sme sa snažili vyriešiť hlavne použitím kvalitných porovnávacích algoritmov. Využili sme open-source (BOZORTH3) aj kommerčný (Suprema BioMini SDK) algoritmus porovnávania odtlačkov prstov, ktoré boli v čase písania práce literatúrou radené medzi najpresnejšie a taktiež aj cenovo dostupné algoritmy.

Chýbajúce softvérové implementácie algoritmov. Dostupné vedecké články prezentujúce rôzne algoritmy spracovania odtlačkov prstov často uvádzajú len matematické pozadie fungovania procesov, ale zanedbávajú praktické aspekty ako je ich softvérové prevedenie, inštalácia alebo návod na používanie navrhovaného softvéru, čím prakticky znemožňujú vedeckej komunité testovanie a replikáciu výsledkov na overenie ich funkčnosti a vlastností. Prevzali sme z literatúry viaceré známe algoritmy a vytvorili ich vlastnú softvérovú implementáciu, nakoľko ju ich autori neposkytovali.

Nepreskúmané využitie odtlačkov prstov v multimodálnych systémoch.

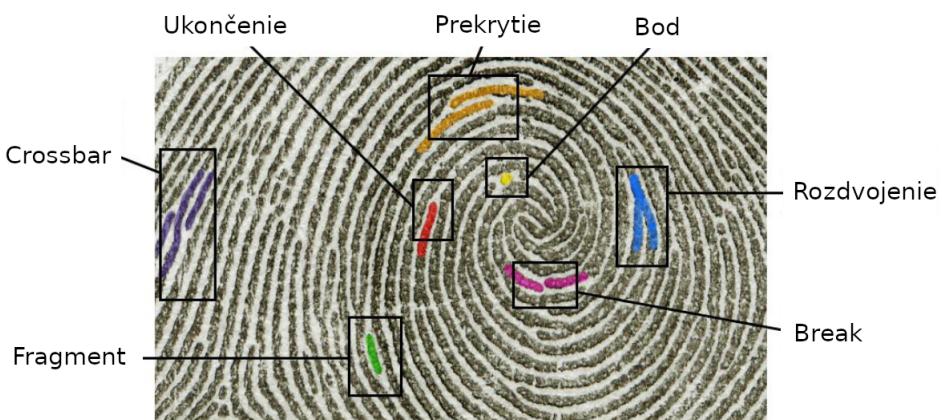
Minimálne množstvo vedeckých prác, ktoré sa zaobrajú praktickou realizáciou multimodálnych systémov, ktoré kombinujú rozpoznávanie odtlačkov prstov s iným biometrickým znakom na zvýšenie presnosti identifikácie alebo verifikácie osoby. Nás systém vie pracovať v multimodálnom režime. Ked'že v súčasnosti

1.2. HLAVNÉ FAKTORY MOTIVÁCIE

spôsobujú najväčšie turbulencie v oblasti biometrie práve multimodálne systémy, rozhodli sme sa na tento trend reagovať rozšírením našej knižnice o možnosť spracovania obrázkov zachytavajúcich vzory žíl prsta. Fúziou odtlačkov prstov a vzorov žíl dochádza k zvýšeniu úspešnosti rozpoznávania a vyššej odolnosti voči podvodným pokusom. Motiváciou tohto kroku je taktiež aj existencia technológií, ktoré dokážu v rámci jedného zariadenia naraz zosnímať odtlačok prsta ako aj vzor jeho žíl (napríklad zariadenie M2-FuseID od spoločnosti M2SYS), čím by nás multimodálny systém nadobudol aj praktický význam.

Chýbajúce paralelné GPU/CPU implementácie. Nedostatok softvérových implementácií umožňujúcich paralelné spracovanie údajov alebo spracovanie údajov na GPU. My sme kritické, časovo zložité operácie vo fáze predspracovania ako aj extrakcie vzorov akcelerovali na GPU s pomocou knižnice ArrayFire alebo sme použili paraleлизáciu výpočtov na viacerých vláknach serverového procesora.

Hľadanie najvhodnejšej reprezentácie odtlačku. Stále nie je jasné, aká reprezentácia odtlačku pri ich porovnávaní je najvhodnejšia. Každý odtlačok je zložitý vzor papilárnych línií, v ktorých sa nachádzajú prvky jedinečnosti. Jedinečnosť je ukrytá v detailoch papilárnych línií. Bežne je postavená reprezentácia odtlačku len na dvoch tvaroch papilárnych línií: rozdvojeniach a ukončeniach. Avšak okrem týchto tvarov existujú ďalšie tvary, ktoré sú vytvorené ich kombináciami a majú vyšší význam pri identifikácii. Momentálne chýbajú návrhy algoritmov, ktoré by vedeli spoľahlivo tieto ďalšie tvary rozpoznávať a vhodnou formou ich zuzitkovať v porovnávaní odtlačkov. Dlhodobým problémom je aj spracovanie nekompletných odtlačkov (chýba časť vzoru odtlačku), kde je originálny potenciál odtlačku zredukovaný a forenzný expert alebo počítačový program si musia poradiť len s údajmi, ktoré sú k dispozícii. Veľké množstvo týchto odtlačkov nespĺňa minimálne kritériá vhodnosti na identifikáciu a sú nepoužiteľné.



Obr. 1.1: Rôzne tvarové typy daktyloskopických markantov (obrázok vznikol ako jeden z výsledkov výskumnej spolupráce medzi Ústavom informatiky a matematiky FEI STU a KEÚPZ v Bratislave)

1.2. HLAVNÉ FAKTORY MOTIVÁCIE

Celý OpenFinger systém bol navrhnutý so zreteľom na jednoduchú inštaláciu a používanie a predovšetkým tak, aby mohol fungovať okrem režimu verifikácie resp. identifikácie aj v expertnom režime, v ktorom používateľ/výskumník dokáže vstupovať do vnútorného fungovania vybraných algoritmov, jednoducho nastavovať ich parametre a získať medzivýsledky, čo umožní ladenie systému a ako aj rôznorodé vedecké experimenty s cieľom sledovať vplyv parametrov systému na úspešnosť rozpoznávania alebo rýchlosť vykonania určitých operácií.

Medzi hlavné vlastnosti, ktoré odlišujú nás softvér od iných existujúcich riešení patrí najmä:

Modulárna architektúra. Nás systém nie je monolitický celok, ale zoskupenie viačích modulov a knižníc, ktoré medzi sebou komunikujú vopred dohodnutým programovým rozhraním (API). Takýmto spôsobom vieme nás systém rozdeliť na samostatné logické celky, ktoré sú ľahšie testovateľné. Každá knižnica je zodpovedná za iný druh činnosti. Nás systém obsahuje knižnice na predspracovanie obrazu, extrakciu charakteristických znakov a porovnávanie extrahovaných znakov. Tento prístup umožňuje aj experimentovanie s obmieňaním modulov, čo iné systémy neponúkajú, napr. môžeme vytvoriť kombinovaný systém, ktorý bude využívať nami vytvorený modul extrakcie charakteristických znakov, ale následné porovnávanie týchto znakov bude realizované pomocou knižnice tretej strany.

Robustné obrazové predspracovanie a extrakcia charakteristických znakov.

V návrhovej a implementačnej fáze bol kladený silný dôraz na vytvorenie účinného a efektívneho obrazového predspracovania odtlačkov (najmä adaptívny Gaborov filter a jeho GPU implementácia), ktorý sa vie vysporiadať so zníženou kvalitou vstupného obrazu. Rovnako bol dôraz kladený aj na vytvorenie presnej detekcie a klasifikácie charakteristických znakov priamo z pôvodného nespracovaného obrazu odtlačku pomocou nami špeciálne natrénovanej konvolučnej neurónovej siete.

Multimodálny systém kombinujúci odtlačky prstov so vzormi žíl na prste.

OpenFinger umožňuje taktiež autentifikáciu v multimodálnom režime, v ktorom sa využíva fúzia odtlačkov prstov a vzorov žíl na prstoch. Takáto kombinácia biometrických vzorov je v literatúre minimálne preskúmaná a jej výsledky sú neznáme. Experimenty potvrdili, že fúzia oboch biometrických vzorov priniesla zvýšenie presnosti rozpoznávania a jej ďalšie rozvíjanie má výskumný potenciál.

Systém vyhodnotenia úspešnosti rozpoznávania. Vyhodnotenie úspešnosti rozpoznávania na používateľom dodanej databáze odtlačkov prstov. OpenFinger systém dokáže okrem režimu rozpoznávania fungovať aj v režime evaluácie, t.j. dokáže vyhodnotiť svoju úspešnosť pomocou známych ukazovateľov ako sú ROC, FAR/FRR a iné na používateľom zadanej databáze. Týmto spôsobom vieme naše riešenie porovnať s inými riešeniami a taktiež vieme odhaliť slabiny resp. silné stránky násloho softvéru pri špeciálnych databázach, napr. len s odtlačkami vo

1.3. ŠTRUKTÚRA PRÁCE

veľmi nízkej kvalite. Výsledky vyhodnotenia úspešnosti sú vizualizované formou prehľadných grafov.

Open-source riešenie. Naše riešenie je verejné. Zdrojový kód je open-source a je udržiavaný vo verejnom GitHub repozitári a tak ho môže ktokoľvek použiť, diskutovať o ňom, ďalej rozvíjať ako aj testovať na ďalších vzorkách odtlačkov prstov.

Funkcionalita demonštrovaná klient-server aplikáciou. Naše riešenie nezostalo len v rovine implementovanej knižnice bez ukážky jej použitia, ale pripravili sme sprievodný testovací softvér (taktiež dostupný na GitHube) vo forme klient-server aplikácie. Tá umožní jednoducho preveriť základnú funkcionalitu systému OpenFinger. Serverová časť aplikácie predpokladá, že bude nainštalovaná na výkonný server spolu so systémom OpenFinger. Klientská aplikácia môže byť nainštalovaná na počítač v sieti. Používateľ na klientskom počítači sa následne spojí so serverom a odošle svoj odtlačok prsta (získaný napríklad z pripojeného senzora) na autentifikáciu, ktorá bude vykonaná na strane servera. Táto komunikácia je vzhľadom na citlivosť posielaných údajov kryptograficky chránená použitím známej knižnice OpenSSL.

1.3 Štruktúra práce

V nasledovných bodoch je uvedená štruktúra tejto práce spolu s referenciou na konkrétnie nosné kapitoly:

- **Kapitola 1** oboznamuje čitateľa s hlavnými cieľmi práce ako aj najpodstatnejšími zdrojmi našej motivácie.
- **Kapitola 2** sa venuje definícii základných pojmov v oblasti daktyloskopie, poskytuje ucelený pohľad na kľúčové vlastnosti odtlačkov prstov a fungovanie automatizovaných systémov na rozpoznávanie odtlačkami prstov a zaobrá sa vyhodnocovaním úspešnosti/chybovosti biometrických systémov. Najpodstatnejšou časťou sú však sekcie s prehľadom najdôležitejších techník predspracovania obrazu, extrakcie charakteristických znakov a metód porovnávania odtlačkov prstov. Záverom tejto kapitoly je prehľad vybraných vedeckých prác, ktoré poukazujú na aktuálny stav v riešenej problematike, predovšetkým v aktuálnych trendoch v adaptívnych technikách predspracovania obrazu, možnostiach aplikácie metód strojového učenia vo fáze klasifikácie vlastností odtlačku a prímosoch multimodálnych biometrických systémov.
- **Kapitola 3** opisuje koncepciu a výsledky nášho výskumu, predstavuje architektúru nášho systému OpenFinger spolu s hĺbkovou analýzou fungovania jeho modulov. Uvádzajú sa tu informácie o našich pomocných podporných aplikáciách

1.3. ŠTRUKTÚRA PRÁCE

na prispôsobené testovanie jednotlivých modulov systému OpenFinger, problematike exportu údajov ako aj navrhnutom multimodálnom systéme. V sekcií testovania je podaný kritický a objektívny pohľad na výsledky získané zo všetkých častí systému ako aj vizuálizácia ukazovateľov úspešnosti, stručná demonštrácia využitia knižnice v sietovom prostredí v scenárii klient-server a taktiež sú tu odprezentované hlavné zistenia z porovnania nášho systému s inými podobnými riešeniami dostupnými v literatúre.

- **Kapitola 4** sumarizuje najdôležitejšie výsledky nášho výskumu, dáva ich do súladu s vytýčenými cieľmi práce a identifikuje hlavné prínosy.

Kapitola 2

Teoretické východiská a aktuálny stav skúmanej problematiky

Predmetom tejto práce je biometria, konkrétniešie špecifická oblasť biometrie a to sú odtlačky prstov a možnosti ich využitia pri rozpoznávaní identity osôb. Automatizované rozpoznávanie identity jedinca nie je triviálou záležitosťou, ale jedná sa o zložitý problém, na ktorého riešení sa podielajú interdisciplinárne vplyvy. V prvom rade sú niektoré princípy hlboko zakorenene v kriminalistike alebo biológii. Samozrejme tým najdôležitejším vplyvom sú informačné technológie a ich správna aplikácia pri rozpoznávaní pomocou odtlačkov prstov. Svoju úlohu tu zohráva aj matematika, pretože srdcom množstva čiastkových algoritmov sú práve matematické postupy, ktoré nám dávajú do rúk silné nástroje na analýzu a porovnávanie odtlačkov. Do štruktúry základných poznatkov patria jednoznačne vlastnosti vzorov odtlačkov prstov, pochopenie fáz činnosti biometrického systému, ktorý využíva biometrické črty k rozpoznávaniu a jeho praktické aplikácie. Neodmysliteľnou súčasťou sú metódy vyhodnocovania chybovosti resp. úspešnosti rozpoznávania, bez ktorých by bolo nemožné reálne nasadenie tejto technológie do praxe a taktiež by nebolo možné sledovať ich pokrok.

Ústrednou myšlienkou tejto kapitoly je oboznámiť čitateľa s kľúčovými pojмami, sprostredkovať ucelený pohľad na fungovanie automatizovaného daktyloskopického systému a poskytnúť prehľad najdôležitejších a aktuálnych poznatkov v skúmanej oblasti, ktoré boli prevzaté z odbornej literatúry. Vo svetle týchto vedomostí sú následne v kapitole 3 analyzované všetky aspekty vývoja našej knižnice OpenFinger a všetkých výsledkov s tým spojeného výskumu realizovaného v období doktorandského štúdia.

2.1 Základné pojmy

Do tejto časti sme sa rozhodli zakomponovať vysvetlenie niektorých základných pojmov a hesiel, ktoré sa v práci vyskytujú a ktoré sú východiskovým bodom pre pochopenie širších súvislostí. Tieto pojmy tvoria elementárnu slovnú zásobu v mikrosvete odtlačkov prstov, ktorá je potrebná na lepšiu orientáciu a pochopenie našich výsledkov.

Odtlačok prsta. Je vizuálna reprezentácia štruktúry obrazca resp. obrazcov, ktoré sú tvorené papilárnymi líniami na bruškách prstov rúk a nôh. Iný názov, ktorý označujeme odtlačky v tejto práci sú daktyloskopické vzory alebo stopy. Sú považované za jedinečné a nemenia sa v čase [6], [5].

Papilárne línie. Sú vyvýšené časti pokožky na dlaňovej strane rúk a chodidlovej strane nôh, ich tvar pripomína striedavú postupnosť kožných priehlín

2.1. ZÁKLADNÉ POJMY

a vyvýšenín. Plnia aj hmatovú funkciu. Globálny tok papilárnych línií môže vytvárať len obmedzené množstvo vzorov (tzv. prvostupňové vzory). Individuálnita odtlačkov sa prejavuje hlavne v nespojitosti papilárnych línií, t.j. v ich lokálnych tvarových anomáliach, ktoré sa vyskytujú najmä v dvoch tvaroch: rozdvojenie a ukončenie papilárnej línie [6], [5].



Obr. 2.1: Detail papilárnych línií

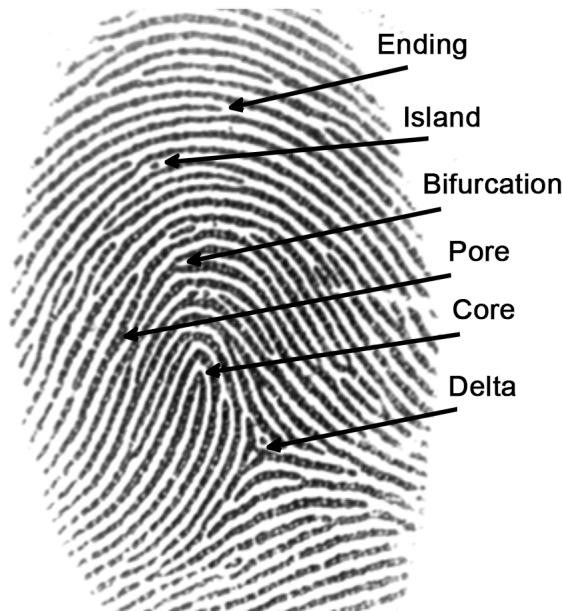
Daktyloskopia. Je veda zaoberajúca sa rozpoznávaním a skúmaním papilárnych línií na vnútornej strane článkov prstov. Pochádza z gréckych slov daktylos (prst) a skopeo (pozerať). Je to predovšetkým kriminalistická metóda, ktorá využíva odtlačky odobraté z miesta činu na spájanie osôb s miestom trestného činu.

Daktyloskopický markant. Je to pomenovanie pre charakteristický útvar v obrazci papilárnych línií. Markanty sú rôzne nespojitosti v toku papilárnych línií ako ukončenia, rozdvojenia, premostenia a iné. Markanty a ich špecifické rozmiestnenie vyjadruje jedinečnosť každého odtlačku. Iné názvy markantov sú charakteristické detaily, individuálne znaky, Galtonove body, Level-2 znaky alebo minúcie. Existujú rôzne klasifikácie markantov v rôznych krajinách, ktoré sú zväčša nekompatibilné alebo výklad tvarov markantov je odlišný. Súčasné automatizované systémy rozpoznávajú väčšinou len rozdvojenia a ukončenia papilárnych línií. Iné tvarové typy je náročné odhaliť softvérovými prostriedkami. Markanty sú takmer vo všetkých krajinách považované za jediné vlastnosti odtlačkov, na základe ktorých sa dá spoľahlivo identifikovať osoba.

Biometria. Znamená využitie jedinečných anatomických alebo behaviorálnych znakov človeka na automatizované rozpoznanie identity.

Biometrický systém. Je systém, ktorý pozostáva z hardvérových a softvérových prostriedkov, ktoré zabezpečujú identifikáciu alebo verifikáciu osôb prostredníctvom zvoleného biometrického znaku. Vo všeobecnosti sa môžeme na biometrický systém pozerať ako na pracovnú stanicu, ktorá pozostáva z autentizačnej jednotky (počítača, servera alebo jednoúčelového zariadenia), na ktorej

2.1. ZÁKLADNÉ POJMY



Obr. 2.2: Daktyloskopické markanty a iné významné body vo vzore odtlačku

sú vykonávané všetky úlohy súvisiace s analýzou biometrických údajov a ich porovnávaním. Vstupné údaje prijíma z biometrického senzora, ktorý môže byť na odlišnom mieste ako zvyšok biometrického systému. Okrem spracovania údajov umožňuje aj ich uchovávanie v databáze. Na zvýšenie úspešnosti alebo výpočtovej výkonnosti môže autentizačná jednotka komunikovať aj s inými systémami v sieti. Biometrické systémy sú väčšinou modulárne systémy, ktoré vykonávajú tieto hlavné činnosti: snímanie, predspracovanie, analýza, extrakcia príznakov a porovnávanie biometrických údajov.

Extrakcia daktyloskopických markantov. Je proces vykonávaný špecializovaným softvérovým algoritmom, ktorého cieľom je vo vstupnom obraze odtlačku odhaliť polohy a iné atribúty lokálnych tvarov papilárnych línií, ktoré sú využívané na porovnávanie dvoch odtlačkov. Algoritmy extrakcie musia analyzovať tvary, orientácie, intenzity obrazových bodov a rôzne vlastnosti štruktúry odtlačku. Existujú tri hlavné smery vývoja algoritmov extrakcie:

- algoritmy analyzujúce obrazové body predspracovaného vzoru odtlačku (napríklad hľadanie markantov v prefiltrovanom obraze alebo v kostre odtlačku)
- algoritmy analyzujúce obrazové body originálu odtlačku
- algoritmy využívajúce metódy strojového učenia (napr. umelé neurónové siete) na rozpoznávanie vzorov

AFIS. Je skratka pre Automated Fingerprint Identification System. Je to taký biometrický systém, ktorý slúži na porovnávanie a evidenciu odtlačkov predovšetkým v

2.1. ZÁKLADNÉ POJMY

policajnom alebo vládnom prostredí. Prvý výskyt bol niekedy v období okolo 1960 a ich popularita prerástla kriminalistický sektor [60]. Tieto systémy sú tak dimenzované, aby mohli zvládať obrovský nápor požiadaviek a na technickej úrovni sú to väčšinou decentralizované úložiská aj výpočtové centrá. AFIS systémy súčasnosti ponúkajú vyspelé služby ako overenie kriminálnej histórie uchádzačov o zamestnanie alebo mobilnú identifikáciu, ktorá umožňuje policajným hliadkam vykonať potrebné identifikačné úkony priamo v teréne.

2.1.1 Vlastnosti odtlačkov prstov

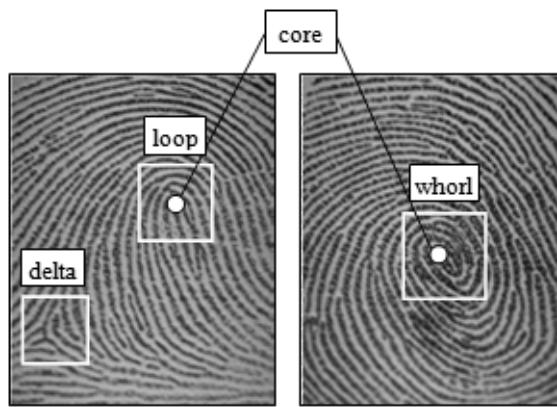
Odtlačky prstov sú reprodukcie externej štruktúry pokožky na končekoch prstov [29]. Každý odtlačok je v podstate grafický pruhový vzor, v ktorom zvyknú papilárne línie meniť svoj tvar, orientáciu a frekvenciu viacmenej náhodným spôsobom. Morfologickej proces tvorby papilárnych línií počas vývinu ľudského plodu, výskyt papilárnych línií na rôznych častiach ľudského tela a ich biologický výskum je podrobne popísaný v publikácii s názvom Ridgeology [6], ktorú napísal David R. Ashbaugh. Vrcholy papilárnych línií sú na zosnímaných digitálnych obrázkoch väčšinou zastúpené tmavou farbou a priehlbiny medzi nimi sú zasa svetlé oblasti medzi nimi. Priemerná šírka dvojice hrebeň línie - priehlbina je odhadovaná na hodnotu $500 \mu\text{m}$ [29]. Priemerná šírka papilárnej línie sa pohybuje od $100 \mu\text{m}$ až po $300 \mu\text{m}$. Usporiadanie vyvýšení a priehlbín sa zvykne nazývať aj papilárny terén. Spoločne tvoria papilárne línie komplikovaný vzor, v ktorom možno sledovať celý rad zaujímavých topologických vlastností a malých tvarových zvláštností. V odtlačkoch prstov rozlišujeme nasledujúce tri úrovne vzorov.

Level-1 (prvostupňové) znaky. Sú to globálne tvary papilárnych línií, ktoré klasifikujeme do niekoľkých kategórií a nemôžno vzhľadom na ich všeobecnosť prostredníctvom nich identifikovať osobu. Prvotný dojem pri pohľade na odtlačok vytvára súbežný tok papilárnych línií, ktorý je v niektorých miestach prerušený nadmerným zakrivením väčšieho počtu línií, chaotickou orientáciou alebo náhlym ukončením línií. Tieto globálne miesta nespojitosti sa nazývajú singulárne body [29]. Medzi singulárne body patrí vrchol ohybu slúčky (z angl. loop), delta a vírová formácia papilárnych línií (z angl. whorl). Delta je miesto v papilárnom teréne, kde sa zbiehajú papilárne línie z troch smerov do jedného bodu. Ďalším významným miestom v odtlačku je jadro (z angl. core). Je to stred odtlačkového vzoru, ktorý je často spojený so stredom singulárneho bodu.

Na tejto úrovni môžeme odtlačky klasifikovať do základných Level-1 tried. Každá z týchto tried je definovaná špecifickou polohou singulárnych bodov. Existujú rôzne klasifikácie, ale klasifikácia do troch vzorov je najčastejšia. Medzi tieto vzory patrí slúčka, oblúk a vír.

Slúčka je vzor, kde z jednej strany odtlačku vbiehajú papilárne línie do stredu odtlačku otáčajú sa okolo jadra a vracajú sa späť [29]. Oblúk je tvar, v ktorom línie vchádzajú z jednej strany do centra obrazca, v ktorom sa oblúkovito ohýbajú

2.1. ZÁKLADNÉ POJMY



Obr. 2.3: Singulárne body daktyloskopického vzoru [30]

a vychádzajú z obrazca na protiľahlej strane [29]. Obyčajný oblúk neobsahuje žiadne delty. Vír je formácia papilárnych línii, ktoré sa vo víre alebo špirále točia v smere od jadra k okrajom odtlačku. Vír zvykne mať po oboch stranách deltu.

V AFIS systémoch sú odtlačky klasifikované podľa Level-1 vzorov do niekoľkých tried. Táto klasifikácia urýchluje proces identifikácie nakoľko znižuje počet kandidátov, ktorí sa musia porovnať s neznámym odtlačkom [29]. Samotný základný vzor odtlačku však nie je postačujúci na identifikáciu, ale je postačujúci na vylúčenie zhody [34].



Obr. 2.4: Level-1 vzory (v poradí zľava oblúk, slučka, vír) [30]

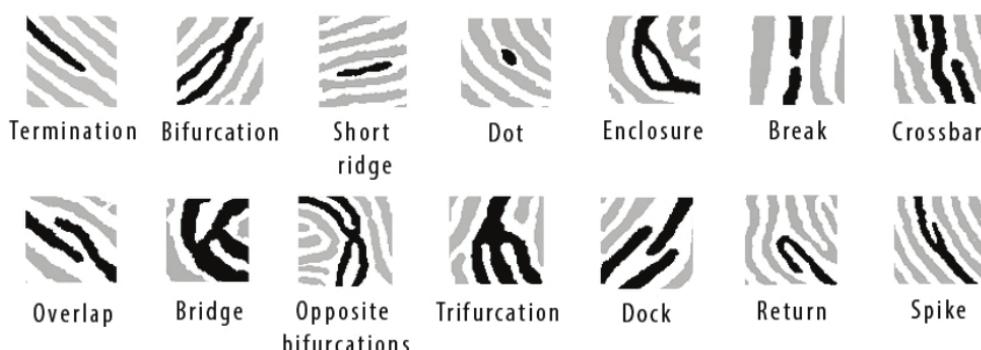
Level-2 (druhostupňové) znaky. Sú to vlastnosti odtlačkov, ktoré sa prejavujú na lokálnej úrovni. Ak sa pozrieme hlbšie do štruktúry obrazcov, objavíme prítomnosť malých nepravidelností resp. anomálií v papilárnych líniah, ktorých distribúcia a poloha sú jedinečnou charakteristikou pre každého jedinca. Tieto Level-2 znaky nesú aj názvy ako daktyloskopické markanty alebo charakteristické znaky. Sú základom pre takmer všetky biometrické systémy. Sú považované za ústredný prvok jedinečnosti odtlačkov. Najfrekventovanejšie Level-2 vzory sú rozdvojenia a ukončenia papilárnej línie. Fragmenty odtlačkov, ktoré neobsahujú dostatočný počet týchto markantov nemôžu byť na identifikáciu použité. V niektorých kriminalistických modeloch sa na potvrdenie zhody medzi odtlačkami vyžaduje určité minimálne množstvo zhodujúcich sa markantov.

2.1. ZÁKLADNÉ POJMY



Obr. 2.5: Daktyloskopické markanty (ukončenie a rozdvojenie) [29]

Každý odtlačok obsahuje iný počet markantov. Ako príklad môžeme uviesť, že odtlačky, ktoré sme získali v digitálnej forme zo zbierky KEÚPZ obsahovali v priemere 90-100 markantov na odtlačok. Množstvo odtlačkov bolo snímaných odvalením a tak sa v nich nachádzalo viac markantov ako pri klasických kontaktných odtlačkoch. Christophe Champod so spoluautormi vo svojej publikácii Fingerprints and Other Ridge Skin Impressions [56] uvádza, že priemerná hustota markantov v okolí singulárnych bodov je 0,49 markantu na 1 mm^2 a v oblastiach mimo singulárnych bodov je to 0,18 markantu na 1 mm^2 .

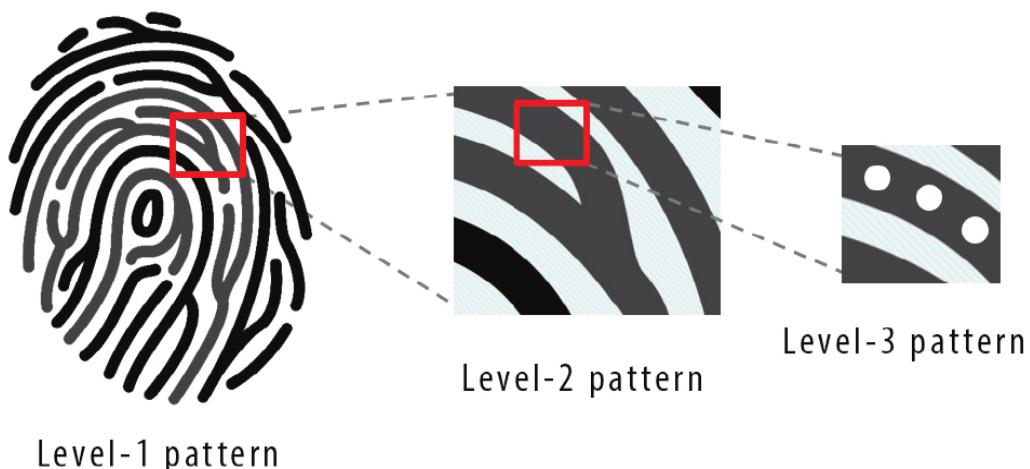


Obr. 2.6: Taxonómia Level-2 znakov [14]

Level-3 (tretostupňové) znaky. Sú to rozmerovo ešte menšie charakteristické zvláštnosti ako markanty. Vzhľadom na ich variabilitu a početnosť sú vo všeobecnosti najviac charakteristické vlastnosti odtlačku. Najväčšia bariéra,

2.1. ZÁKLADNÉ POJMY

ktorá bráni v ich širšom použití v automatizovaných systémoch je požiadavka na vysoké rozlíšenie senzorov, aby ich bolo možné rozpoznať. Druhý negatívny faktor je ich závislosť od kvality štruktúry odtlačku. Pri menšom znehodnotení odtlačku sa môže stať, že informácie tejto úrovne úplne zaniknú. Level-3 znaky zahŕňajú hlavne geometrické vlastnosti papilárnych línii ako sú jej hrúbka a obrys, rozmiestnenie potných pôrov, jazvy, škrabance a malé, tzv. vmedzerené papilárne línii (z angl. incipient ridges) [29]. V oblasti kriminalistiky sú vyvinuté dve analytické disciplíny, ktoré skúmajú 3. úroveň detailov: poroskopia a obrysoskopia. Poroskopia skúma využitie pôrov na identifikáciu a obrysoskopia zasa hľadá možnosti uplatnenia geometrických vlastností obrysov papilárnych línii [34]. Rozmer pôrov sa pohybuje v rozsahu od $60 \mu\text{m}$ až po $250 \mu\text{m}$ [29]. Zistilo sa, že priemerný počet pôrov pripadajúcich na 1 cm dĺžky papilárnej línie je v intervale 9 až 18 [29]. V literatúre od Davida Ashbaugha [42] sa dozvedáme, že na určenie identity postačuje 20 – 40 zhodných pôrov. Znaky tejto úrovne sú veľmi malé a na ich zachytenie je treba senzory s vysokým rozlíšením (1 000 PPI a viac). Bežné senzory nespĺňajú toto kritérium a takisto chýbajú presné automatizované algoritmy na identifikáciu pôrmi. Póry a geometrické atribúty papilárnych línii sú nádejou technológiou biometrie a ich využitie v AFIS systémoch by malo byť jedným zo smerov ich rozvoja.



Obr. 2.7: Ilustrácia všetkých troch úrovni daktyloskopických vzorov

Všetky tri úrovne daktyloskopických vzorov ponúkajú iný druh využiteľnej informácie pri porovnávaní odtlačkov. V zásade platí, že Level-1 vzory slúžia na prvotnú klasifikáciu a vylúčenie zhody medzi dvoma odtlačkami, Level-2 vzory sú základným stavebným kameňom jedinečnosti každého daktyloskopického vzoru a preto sú využívané ako rozhodujúci charakteristický znak pri určovaní zhody medzi odtlačkami prstov, jednak v komerčnej sfére a taktiež v kriminalistickom prostredí. Na záver Level-3 znaky sú veľmi cennou informáciou v prípade tzv. latentných odtlačkov zosnímaných vo vysokom rozlíšení (hlavne 1000 PPI a vyššie). Pri snímaní odtlačkov z rôznych materiálov

2.1. ZÁKLADNÉ POJMY

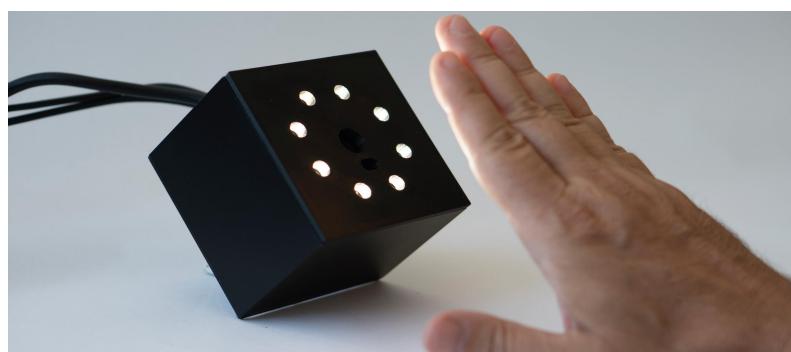
a povrchov sa stáva, že odtlačky nemusia byť kompletné, t.j. máme k dispozícii len ich fragment a práve vtedy sú Level-3 informácie jediným možným zdrojom charakteristických znakov, na základe, ktorých je možné určiť totožnosť osoby. Na obrázku 2.7 vidíme súčasne tri úrovne daktyloskopických vzorov.

2.1.2 Fázy procesu automatizovaného rozpoznávania odtlačkami prstov

Biometrický systém slúži na strojové rozpoznanie osoby pomocou zosnímanej telesnej charakteristiky. Je to celok pozostávajúci z viacerých pracovných častí, ktoré vykonávajú logicky odlišné úlohy. Vo svojej podstate je to systém rozpoznávajúci zložité vzory a ich špecifiká. V rámci biometrického systému rozlišujeme v chronologickom sledu tieto fázy činnosti:

- **Snímanie odtlačkov**

Snímanie zabezpečuje prenos informácie o grafickom vzore odtlačku na konkrétné médium, na ktorom budeme túto informáciu dlhodobo uchovávať. Rozlišujeme dve základné metódy: offline a live-scan. Offline odtlačok je získaný nanesením atramentu na pokožku prsta a následným odvalením na špeciálnu daktyloskopickú kartu. Medzi offline spôsoby snímania odtlačkov patrí aj chemické zaistovanie odtlačkov na povrchoch rôznych materiálov. Odtlačky, ktoré nie sú voľným okom viditeľné a odhaliať ich vie len určitý chemický proces, nazývame latentné stopy. Live-scan odtlačok vzniká položením prsta na plochu špeciálneho senzora, ktorý odtlačok prevedie do digitálnej podoby. Tieto senzory detegujú prítomnosť prsta na ploche senzora a začnú snímanie väčšinou automaticky. Existuje viacero technológií live-scan snímania založených na rozdielnych fyzikálnych princípoch, ktoré sú vhodné v rozdielnych snímacích podmienkach. Medzi najznámejšie technológie snímania patria optické FTIR senzory, kapacitné, tepelné, tlakové alebo ultrazvukové senzory.



Obr. 2.8: Bezkontaktný senzor štyroch odtlačkov prstov vyvinutý na rakúskom pracovisku AIT

2.1. ZÁKLADNÉ POJMY

Rozvíja sa aj bezkontaktné snímanie odtlačkov na viacerých prstoch. S prototypom riešenia pracuje napríklad rakúsky technologický inštitút AIT, ktorý vyvinul prenosný snímač určený na hraničných kontrolách schopný súčasného snímania 4 prstov (obrázok 2.8).

• Obrazové predspracovanie

Otázka reprezentácie odtlačku v biometrickom systéme je jeho základným návrhovým aspektom, ktorý má silný vplyv na presnosť rozpoznávania. Hlavným cieľom je postaviť takú schému reprezentácie odtlačku, ktorá je schopná odolávať rušivým faktorom znehodnoteného odtlačku a je zároveň dostatočne charakteristická, aby bolo možné jej prostredníctvom vykonať spoľahlivé porovnanie dvoch vzorov. Treba určiť priestor vlastností, ktoré zaradia odtlačky rovnakého prsta do odlišnej množiny ako odtlačky z rôznych prstov. Ďalšou požiadavkou je, aby boli charakteristické črty ľahko rozpoznateľné. Tu práve vzniká konflikt pretože jedinečné črty nemusia byť vždy ľahko odhaliteľné a to už vôbec nie softvérovo. Aby sa eliminoval vplyv rôznych zdrojov degradácie obrazovej kvality pri extrakcii charakteristických vlastností, prechádza originál odtlačku sériou rôznych úprav, ktoré sa nazývajú predspracovanie. Úlohou takéhoto predspracovania je obnoviť pôvodnú biometrickú informáciu v odtlačku a zároveň transformovať odtlačok do takej podoby, v ktorej bude extrakcia vlastností, čo najjednoduchšia.

Typická schéma obrazového predspracovania obsahuje tieto algoritmy:

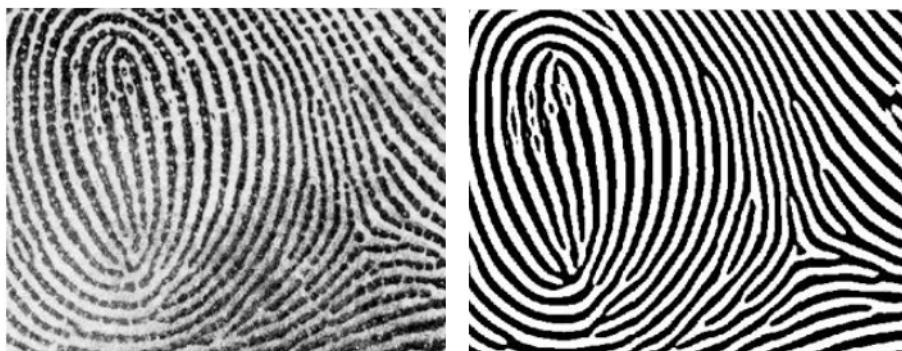
1. **Segmentácia plochy odtlačku.** Úlohou tohto algoritmu je rozhodnúť, ktoré časti originálneho obrazu patria dakyloskopickému vzoru a ktoré možno považovať za nepoužiteľné. Existujú dva principiálne odlišné prístupy k riešeniu tejto záležitosti. Prvá kategória algoritmov využíva štatistické vlastnosti obrazových bodov a na základe ich hodnôt v rôznych miestach obrazu vie body alebo celé bloky označiť za využiteľné alebo nevyužiteľné časti obrazu. Využiteľnými štatistickými ukazovateľmi sú priemer a rozpätý intenzity obrazových bodov alebo lokálna koherencia smeru papilárnych línii. Druhá kategória využíva na segmentáciu odtlačku odozvy obrazových filtrov. Najčastejšie používaným filtrom je Gaborov filter [57].
2. **Normalizácia jasu a odstránenie šumu.** Úlohou je obnoviť kontrast v odtlačkoch, v ktorých nie sú papilárne línie dostatočne zreteľné a odstrániť niektoré obrazové artefakty ako prachové časticie, šum alebo premenlivú úroveň intenzity obrazových bodov papilárnych línii.
3. **Aplikácia kontextových filtrov.** Hlavným účelom tohto procesu je obnoviť pôvodnú štruktúru odtlačku prsta. Je to najdôležitejší a taktiež výpočtovo najzložitejší proces celého predspracovania. Slovom kontext v tomto prípade označujeme najmä smer a šírku papilárnej línie v konkrétnom mieste odtlačku, t.j. kontextový filter obnovuje práve tieto vlastnosti. Tieto

2.1. ZÁKLADNÉ POJMY



Obr. 2.9: Výsledky segmentácie odtlačkov [57]

filtre zvykneme označovať aj ako adaptívne pretože prispôsobujú svoje vlastnosti odhadovanému lokálnemu kontextu. Smer a šírka papilárnych línii by sa mali meniť spojito a k turbulenciám by malo dochádzať len v blízkosti singulárnych bodov odtlačku. Kvalitatívne degradované odtlačky obsahujú také susediace segmenty, ktoré majú výrazne odlišné kontexty.



Obr. 2.10: Obnova papilárneho terénu Gaborovym filtrom (hore je pôvodný obraz a dole je prefiltrovaný obraz) [29]

Obnoviť pôvodnú štruktúru daktyloskopického vzoru znamená obnoviť vzor papilárnych línii v miestach, kde došlo k umelému prerušeniu napríklad jazvou alebo nadrozmerným potným pórom. Pôvodnú štruktúru treba obnoviť aj v prípadoch slabého alebo nadmerného tlaku prsta na senzor (vtedy vznikajú obrazy s nevyhovujúcim kontrastom a nie je možné jasne určiť papilárne línie). Aplikovaním kontextových filtrov upravujeme aj geometrické vlastnosti papilárnych línii. Filtranie môže priniesť aj neželaný účinok ak sú jeho parametre nastavené nesprávne, napríklad vplyvom filtrovania obrazu môžu zaniknúť niektoré potrebné obrazové detaily.

Najpoužívanejším kontextovým filtrom, ktorý má parametrizovateľný smer a frekvenciu je Gaborov filter. Na to, aby sme mohli aplikovať Gaborov

2.1. ZÁKLADNÉ POJMY

filter na obraz odtlačku, potrebujeme z odtlačku vypočítať smerovú a frekvenčnú mapu. Na obrázku 2.10 vidíme schopnosť filtra obnoviť poškodenú štruktúru odtlačku. Odtlačok bol rekonštruovaný do formy, ktorá sa podoberala reálnemu stavu aj v rozmiestnení markantov.



Obr. 2.11: Smerová mapa odtlačku

Smerová mapa je matica, v ktorej sú zakódované orientácie jednotlivých bodov obrazu. Tieto orientácie sa zvyknú upraviť aplikáciou Gaussovoho filtra, aby sa tak získal hladký odhad smeru neovplyvnený drobnými šumovými časticami. Metód ako vypočítať smer papilárnej línie v konkrétnom bode je viacero. Jedna z najčastejšie používaných je metóda obrazových gradientov. Na malých blokoch obrazu sa vypočíta sila zmeny intenzity úrovne šedej farby v horizontálnom aj vertikálnom smere. Z gradientov vieme matematickými úpravami odvodiť uhол, ktorý zviera papilárna línia s horizontálnou osou.

Frekvenčná mapa je matica, ktorá zachytáva číselné vyjadrenie početnosti papilárnych línií v malom obrazovom regióne v rôznych oblastiach odtlačku. Pri výpočte frekvenčnej mapy sa využíva vlastnosť striedania svetlejších a tmavších pruhov. Taký vzor obsahuje lokálne extrémy, medzi ktorými sa dá merať vzdialenosť. Takýto výpočet je blokovo orientovaný a vyžaduje si, aby sme blok, v ktorom počítame frekvenciu natočili tak, aby bol rovnobežný s okolitými papilárnymi líniemi. Následne v bloku vypočítame priemernú vzdialenosť medzi dvomi po sebe idúcimi lokálnymi extrémami (t.j. vlnovú dĺžku). Prevrátená hodnota vlnovej dĺžky určuje frekvenciu. Blok, v ktorom

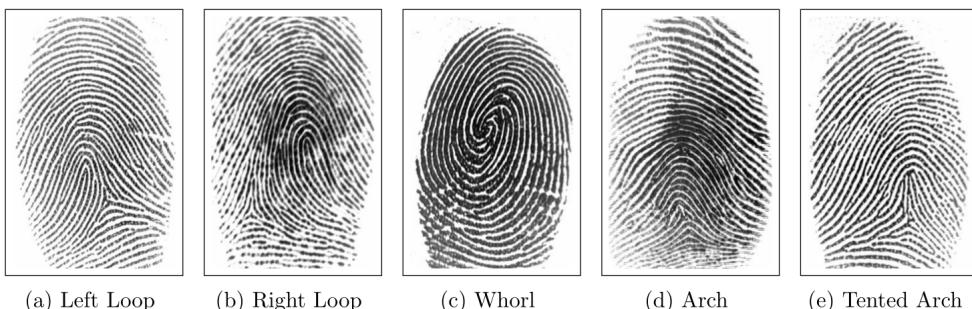
2.1. ZÁKLADNÉ POJMY

odhadujeme frekvenciu sa dá natočiť na správny uhol pomocou smerovej mapy.

4. **Binarizácia a skeletonizácia.** Binarizácia je prevod obrazu z odtieňov sivej farby do čiernobielej podoby. Následne je vykonaná skeletonizácia, ktorej cieľom je previesť obraz do podoby, v ktorej majú papilárne línie šírku 1 obrazového boda, tzv. kostry. V tejto reprezentácii sa ľahšie analyzujú tvary papilárnych línií a hľadajú daktyloskopické markanty. Kostra odtlačku nie je vždy vyžadovaná, keďže sú algoritmy, ktoré odhalujú daktyloskopické markanty priamo v nespracovanom obrazu.

- **Klasifikácia odtlačkov podľa globálneho daktyloskopického vzoru**

Klasifikácia podľa globálneho daktyloskopického vzoru je zaradenie odtlačku do triedy, ktorá je definovaná osobitým rozmiestnením singulárnych bodov. Je to dôležitou súčasťou každého biometrického systému pracujúceho v režime identifikácie. Vyhladávanie zhody v objemnej databáze môže trvať veľmi dlho a to je jedným z faktorov, ktoré bránia použitiu biometrického systému v praxi. Bežná stratégia ako urýchliť vyhľadávanie v databáze odtlačkov je rozdeliť ju do niekoľkých skupín podľa Level-1 znakov. Ak máme takto rozdelenú databázu, vyhľadávanie prebieha už len v podmnožine celej databázy. Najznámejším klasifikačným systémom odtlačkov podľa Level-1 znakov je Galton-Henryho schéma. Táto schéma obsahuje rôzne konfigurácie toku papilárnych línií, medzi ktorými sú v populácii najfrekventovanejšie vzory klenba, stanová klenba, ľavá a pravá slučka, jednoduchý vír a dvojitá slučka.



Obr. 2.12: Päť najčastejších tried odtlačkov z Galton-Henryho schémy [61]

Klasifikačné techniky rozdeľujeme podľa toho aký princíp alebo akú vlastnosť odtlačku využívajú na to, aby zaradili odtlačok do príslušnej kategórie. Jednoduchým prístupom je aj detekcia singulárnych bodov odtlačku (delta a jadro) a následná klasifikácia podľa počtu týchto bodov. Napríklad ak sa v odtlačku objaví jedno jadro a dve delty, s vysokou pravdepodobnosťou sa jedná o jednoduchý vír. Poznáme metódy, ktoré využívajú smerovú mapu odtlačku a rozdeľujú ju na niekoľko zón a zároveň dávajú tieto zóny do súvzťažnosti. Zóny

2.1. ZÁKLADNÉ POJMY

sú odlišné charakteristickým smerom. Takto sa z odtlačku extrahuje zopár charakteristických smerov a na základe ich polohy vieme určiť približný tok papilárnych línii. Neurónové siete majú vlastnosť učiť sa komplexné vzťahy na dobre zvolených trénovacích vzorkách a tieto poznatky potom aplikovať pri klasifikácii vzorov s určitou toleranciou ich vnútrotriednej variability. V literatúre [29] sú opísané techniky využívajúce viacvrstvový perceptrón, ktorý je trénovaný na vzorkách smerových máp.

• **Extrakcia charakteristických vlastností**

Po obnove štruktúry odtlačku vo fáze predspracovania prichádza na rad extrakcia markantov (Level-2 znakov), prvkov jedinečnosti. Rozvinuté sú tri hlavné metodické prístupy k extrakcii markantov:

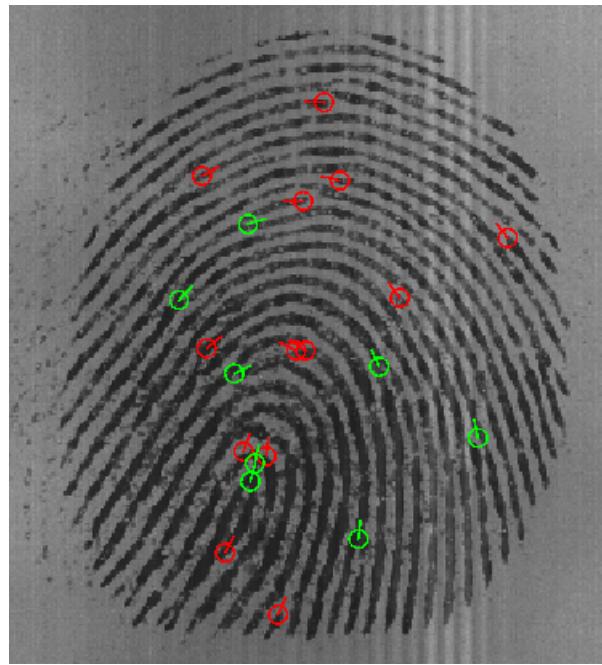
- metódy extrakcie markantov priamo v originálnom nespracovanom obraze
- metódy extrakcie markantov v kostre odtlačku
- metódy extrakcie markantov využívajúce algoritmy strojového učenia a genetického programovania

Pod pojmom extrakcie myslíme v prípade odtlačkov prstov nachádzanie určitých tvarových nepravidelností v obrazcoch tvorených papilárnymi líniami. Úlohou extrakcie je vytvorenie špecifickej neopakovateľnej reprezentácie odtlačku, ktorá sa použije na komparáciu dvoch odtlačkov. Odtlačky prstov sa v súčasných biometrických systémoch zvyknú reprezentovať prostredníctvom daktyloskopických markantov. Výsledkom extrakcie je najmä zaznamenanie polohy, tvaru a smeru daktyloskopických markantov na ploche odtlačku.

Extrahované markenty sa potom rôznymi technikami porovnávajú a počíta sa skôr podobnosti. Spoľahlivá detekcia týchto útvarov je problematická hlavne pri odtlačkoch prstov s nízkou obrazovou kvalitou. Výstupom z fázy extrakcie je dátovo úsporná forma odtlačku, ktorá na rozdiel od celého obrázku odtlačku výrazne šetrí miesto na úložnom médiu. V rámci rozpoznávania sa nemusia extrahovať len informácie o markantoch, ale môžu to byť aj iné vlastnosti odtlačkov ako sú daktyloskopický vzor, vektorové vyjadrenie smeru toku papilárnych línii, priemerná šírka papilárnych línii a iné. Tieto vlastnosti sú potrebné vo fázach klasifikácie odtlačkov do tried na zrýchlenie identifikácie alebo ich znalosť uľahčuje obrazové predspracovanie. Medzi extrahované údaje niekedy zaradujeme aj rozmiestnenie potných pôrov alebo obrys papilárnych línii, čo sú detaily mikroskopickej úrovne, ktoré poskytujú dostatočne osobité informácie avšak ich odhalenie v odtlačku je zatiaľ v automatizovanej oblasti biometrie ľažkým problémom.

V množine odhalených markantov sa nachádzajú aj niektoré falošné štruktúry, ktoré je potrebné eliminovať. Niektoré typy falošných markantov môžeme vylúčiť tak, že ešte pred samotnou extrakciou odhalíme v obraze niektoré typické umelé štruktúry a vymažeme ich priamo z obrazu. Ak falošné markenty v značnej miere pretrvávajú aj nadálej, tak na ich odstránenie môžeme použiť niektoré analytické

2.1. ZÁKLADNÉ POJMY



Obr. 2.13: Ukážka extrakcie daktyloskopických markantov (červené a zelené symboly reprezentujú polohu a smer Level-2 znakov typu ukončenie a rozdvojenie)

metódy ako odhad hustoty výskytu markantov (falošné markanty sa zvyknú vyskytovať v zhlukoch), vzdialenosť od okraja daktyloskopického vzoru (ukončenia línií na okrajoch sú prirodzené a nie sú považované za markanty) alebo odhad kvality papilárneho terénu na mieste, kde sa nachádza markant (v nekvalitných miestach je ľahké rozoznať pravý markant od falošného).



Obr. 2.14: Ukážka porovnávania daktyloskopických markantov [74]

• Porovnávanie odtlačkov

Úlohou porovnávacieho algoritmu je porovnať dve reprezentácie odtlačkov a stanoviť skôr podobnosti medzi nimi. Negatívnymi faktormi, ktoré spôsobujú problémy porovnávacím modulom sú odlišná poloha dvoch odtlačkov, rotácia vzoru, nelineárna deformácia pokožky, tlak na senzor, hygienický a zdravotný stav pokožky v čase snímania odtlačku, šum, chybný výstup z extrakčného modulu alebo príliš agresívne predspracovacie algoritmy nadmerne modifikujúce originálnu štruktúru odtlačku. Hrubá klasifikácia porovnávacích algoritmov obsahuje tieto odlišné rodiny:

- korelačné techniky - počíta sa korelácia obrazových bodov dvoch obrazov
- techniky porovnávajúce Level-2 znaky - v tomto prípade sa hľadá podobnosť v polohách a orientáciách daktyloskopických markantov alebo ich zoskupení (hlavne trojice), aby sa zabezpečila odolnosť voči distorzii pokožky (rovnaký prst môže byť vždy zosnímaný s inou deformáciou)
- techniky porovnávajúce iné vlastnosti lokálneho kontextu odtlačku (napríklad porovnanie podľa počtov papilárnych línii medzi zvolenými bodmi v odtlačku [87] alebo porovnanie príznakov odtlačku, ktoré sú získané aplikovaním rôznych filtrov)

2.1.3 Hodnotenie úspešnosti biometrického systému

Príslušom ideálneho biometrického systému je, že vždy poskytne správnu odpoveď bez ohľadu na kvalitu vstupujúcej biometrickej vzorky, variabilitu charakteristických informácií a režim, v ktorom pracuje. Avšak biometrický systém je vo svojej podstate systém rozpoznávajúci komplikované vzory, ktoré sú poznačené vnútrotriednou variabilitou. Vnútrotriedna variabilita je stav, kedy je papilárny terén konkrétneho prsta pri viacnásobnom zosnímaní reprezentovaný v mierne odlišnej podobe, čo je spôsobené hlavne deformáciou kože, nečistotami na ploche senzora, vlhkostou alebo nedostatkom snímacej technológie. V nasledujúcej časti sa pokúsime opísať najčastejšie príčiny chýb biometrických systémov, tak ako sú predstavené v [29].

Nevhodná reprezentácia odtlačku

Každý biometrický systém by mal extrahovať z biometrickej vzorky informáciu s minimálnou redundanciou a čo najvyššiu rozlišovacou hodnotou. Jedinečnosť každého odtlačku je daná predovšetkým množinou Level-2 znakov, ktoré obsahuje. Na zvýraznenie jedinečnosti odtlačku môžeme využiť aj Level-1 a Level-3 znaky doplnené o ďalšie atribúty ako vzdialenosť medzi papilárnymi líniami, počty papilárnych línii a rôzne geometrické vlastnosti. Zlyhanie pri zachytávaní biometrickej informácie nesúcej unikátnu vlastnosť a zahrnutie falošných vlastností sú typickými prejavmi nesprávne navrhnutého extrakčného algoritmu.

Chyby porovnávacieho modulu

Je to neschopnosť komparátora odtlačkov považovať rôzne odtlačky rovnakého prsta za totožné. Riešením je porovnávanie priestorových vzťahov medzi skupinami dakyloskopických markantov a nie samostatných markantov. Tento prístup totiž eliminuje vplyvy deformácií kože, nakoľko je malá šanca, že deformácia spôsobí zmenu vzájomného rozmiestnenia troch alebo viacerých bodov v papilárnom teréne.

Je veľmi dôležité, aby tvorcovia biometrických systémov používali spoločný rámec na vyhodnotenie úspešnosti svojho systému. Týmto spôsobom sa dajú viaceré riešenia medzi sebou porovnávať a jasne sa dá určiť, ktoré metódy prinášajú vyššiu úspešnosť a mali by byť d'alej rozvíjané. Snahu zdelenie tuto oblasť a zaviesť určité pravidlá má medzinárodná norma ISO/IEC 19795-2, ktorá určuje pravidlá testovania a vykazovania úspešnosti biometrického systému.

Biometrický systém sa dopúšťa dvoch kategórií chybných rozhodnutí [29]:

False Match. Je to chybné rozhodnutie systému, kedy považuje dva rozdielne odtlačky za rovnaké

False Non-Match. Je to chybné rozhodnutie systému, kedy považuje dva rovnaké odtlačky za rozdielne

Biometrický systém meria podobnosť medzi dvoma odtlačkami. Táto podobnosť je kvantifikovaná pomocou skóre, ktoré pre dvojicu odtlačkov vypočítá porovnávací algoritmus biometrického systému. Ak systému poskytneme dostatočný počet dvojíc odtlačkov rozdelených na dvojice odtlačkov z rovnakého prsta (z angl. genuine pair) a dvojice odtlačkov z rôznych prstov (z angl. impostor pair), vieme vypočítať nasledujúce ukazovatele.

- **False Match Rate (FMR)**

Jedná sa o pravdepodobnosť, s akou biometrický systém nesprávne rozhodne, že dva odtlačky prstov sú zhodné, aj keď sú v skutočnosti rozdielne. Táto chyba sa zvykne označovať aj ako False Acceptance Rate (FAR).

- **False Non-Match Rate (FNMR)**

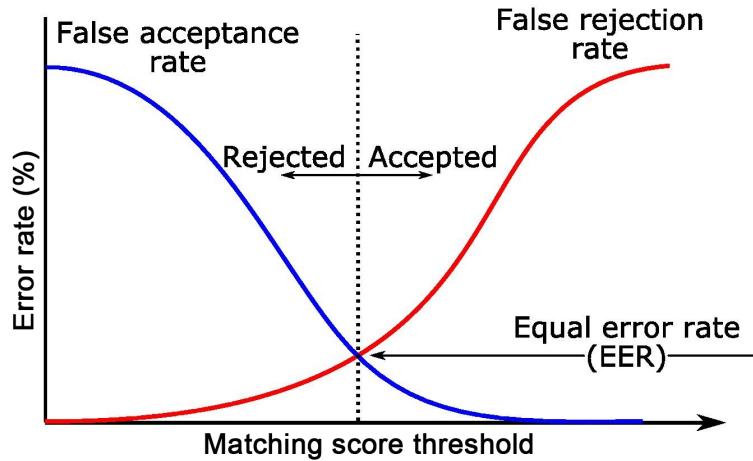
Jedná sa o pravdepodobnosť, s akou biometrický systém nesprávne zamietne dva odtlačky prstov, aj keď sú v skutočnosti rovnaké. Táto chyba sa zvykne označovať aj ako False Rejection Rate (FRR).

- **Equal Error Rate (EER)**

FMR a FNMR sa často vizualizuje v spoločnom grafe (vid' obrázok 2.15), kde x -ová os predstavuje hodnotu rozhodovacieho prahu pre vypočítané skóre podobnosti medzi dvomi odtlačkami a y -ová os reprezentuje mieru chyby. Bod, v ktorom sa FMR a FNMR krivky pretínajú sa označuje ako EER, t.j. taký rozhodovací prah systému, pri ktorom sú obe chyby rovnako vysoké. Rozhodovací prah

2.1. ZÁKLADNÉ POJMY

je určitý limit, ktorý, keď skóre podobnosti medzi dvomi odtlačkami presiahne, tak dané odtlačky sú považované systémom za zhodné.



Obr. 2.15: Vzor FAR/FRR grafu s ukážkou EER bodu

- **ROC krivka**

Jedná sa o krivku (vid' obrázok 2.16), ktorá do spoločného grafu vykresľuje hodnoty True Positive Rate (1-FNMR) a FMR pri rôznych hodnotách rozhodovacieho prahu systému. Platí, že čím je väčšia plocha pod krivkou, tým je biometrický systém presnejší pri rozhodovaní. ROC krivka je najčastejšie používaný ukazovateľ na vzájomné porovnanie viacerých biometrických systémov. Skratka ROC označuje Receiver Operating Characteristic.

- **Rank-k úspešnosť identifikácie**

Tento ukazovateľ hovorí s akou pravdepodobnosťou systém počas identifikácie umiestní hľadanú identitu medzi prvých k kandidátov zoradených podľa vypočítaného skóre pravdepodobnosti [62].

- **CMC krivka**

Jedná sa o krivku (vid' obrázok 2.17), ktorá zobrazuje úspešnosť identifikácie (počet správne identifikovaných zo všetkých pokusov) pri rôznych hodnotách rank-k (správne identifikovaná osoba sa nachádza v prvých k kandidátoch) [62]. Skratka CMC označuje Cumulative Match Characteristic.

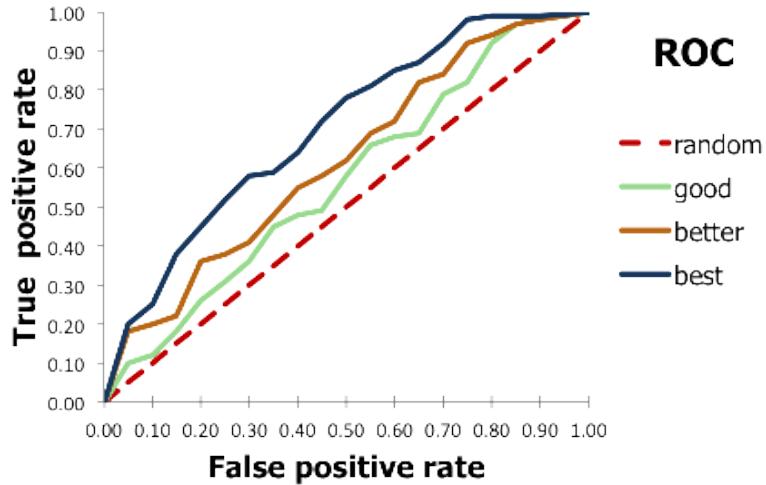
- **Positive Predictive Value** (alebo aj Precision)

Môže byť vypočítaný vzťahom $PPV = \frac{TP}{TP+FP}$, kde TP (true positives) predstavuje počet prípadov vyhlásenia skutočnej zhody a FP (false positives) predstavuje počet prípadov vyhlásenia falosnej zhody (chybné prijatie).

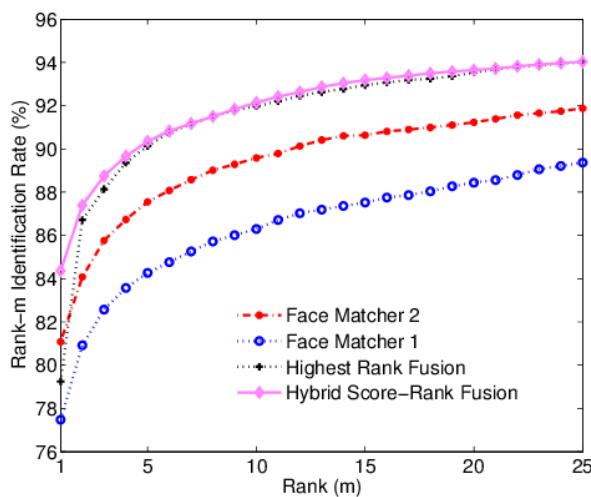
- **True Positive Rate** (alebo aj Recall)

Môže byť vypočítaný vzťahom $TPR = \frac{TP}{TP+FN}$, kde TP (true positives) predstavuje počet prípadov vyhlásenia skutočnej zhody a FN (false negatives) predstavuje počet prípadov vyhlásenia falosnej nezhody (chybné odmietnutie).

2.1. ZÁKLADNÉ POJMY



Obr. 2.16: Vzor ROC krivky biometrického systému (False Positive Rate je to isté ako FMR)

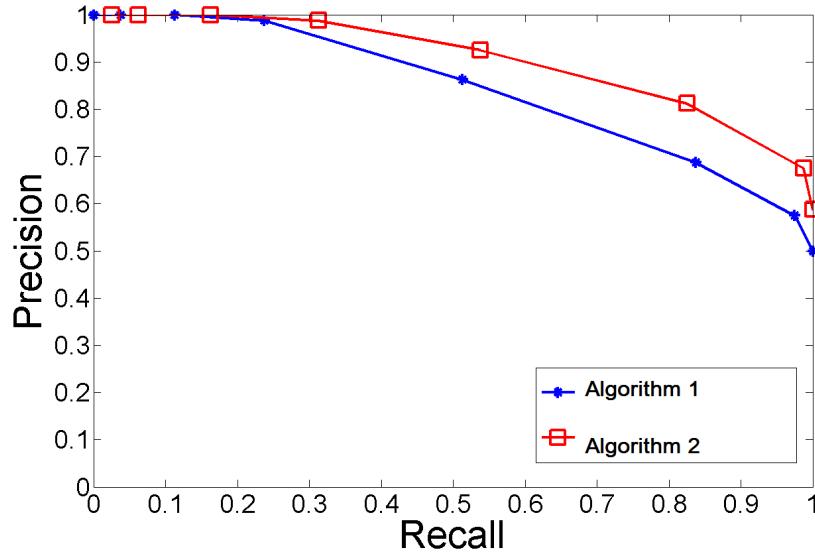


Obr. 2.17: Vzor CMC krivky biometrického systému

- **Rozdelenie skóre podobnosti**

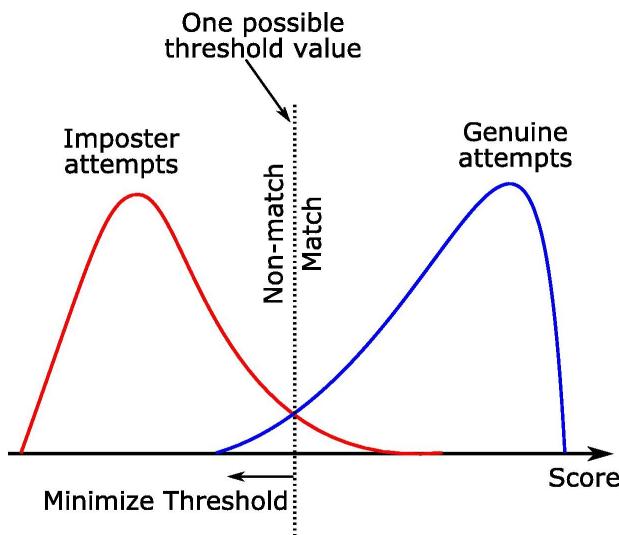
Ideálnym stavom je, keď navrhnutý biometrický systém udeľuje totožným vzorkám čo najvyššie skóre a odlišným vzorkám nulové alebo minimálne skóre. Na získanie predstavy ako dobre vie náš biometrický systém separovať skóre podobnosti pre dvojice zhodných a nezhodných odtlačkov je potrebné zostrojiť graf, v ktorom zobrazíme zvlášť histogram pre skóre podobnosti dvojíc rôznych odtlačkov (impostor distribution) a histogram pre skóre podobnosti dvojíc odtlačkov z rovnakého prsta (genuine distribution). Cieľom pri návrhu vlastného

2.1. ZÁKLADNÉ POJMY



Obr. 2.18: Vzor Precision-Recall grafu

biometrického systému je dosiahnuť minimálny prekryv týchto dvoch histogramov. Pomocou tohto grafu vieme zhodnotiť aký má vplyv napríklad úprava niektorého z algoritmov spracovania obrazu na celkovú klasifikačnú úspešnosť nášho systému.



Obr. 2.19: Distribúcia skóre podobnosti vypočítaného biometrickým systémom (červená krivka je tzv. impostor rozdelenie zachytávajúce skóre pre dvojice biometrických vzoriek pochádzajúcich od dvoch rôznych ľudí a modrá krivka je tzv. genuine rozdelenie zachytávajúce skóre pre dvojice biometrických vzoriek pochádzajúcich od rovnakého človeka)

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

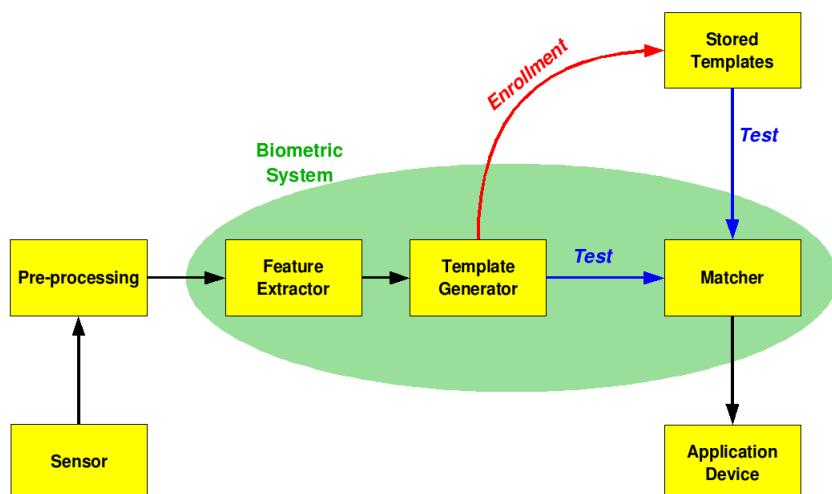
Graf s rozdelením skóre podobnosti nám ukazuje, že časť porovnávaní nezohľadujúcich sa odtlačkov, ktoré mali za výsledok skóre nad prahovou hodnotou (zvislá prerušovaná čiara) je považovaná za chybu FMR. Na druhej strane, časť porovnávaní zhodujúcich sa odtlačkov, ktoré mali za výsledok skóre pod prahovou hodnotou je považovaná za chybu FNMR. Ak chceme navrhnúť systém, ktorý vykazuje rovnakú hodnotu chyby FMR a FNMR, musíme zvoliť rozhodovaciu hranicu systému na úrovni takého skóre, ktoré zodpovedá priesecníku kriviek oboch rozdelení.

2.2 Automatizované daktyloskopické systémy

Automatizovaný daktyloskopický systém je zodpovedný za strojom realizovanú registráciu/verifikáciu/identifikáciu identity osoby. Skladá sa väčšinou z logicky oddeľených modulov, ktoré vykonávajú principiálne tri základné úlohy: predspracovanie (za účelom obnovy kvality), extrakcia charakteristických znakov a ich porovnávanie so znakmi získanými z databázy zaregistrovaných identít.

2.2.1 Architektúra

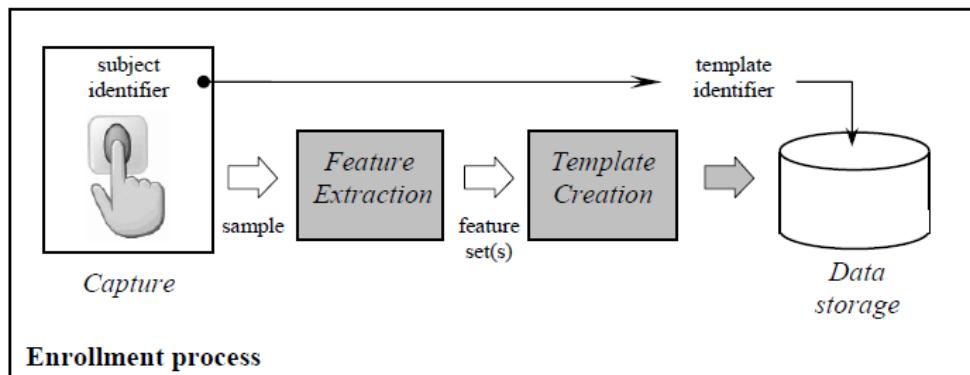
Biometrický systém je skupinou navzájom súvisiacich operácií, ktoré sú vykonávané s biometrickými údajmi od ich zosnímania až po rozhodnutie o rozpoznaní. Biometrický systém je kombináciou hardvérových a softvérových prostriedkov, ktoré umožňujú snímať, uchovávať, spracúvať a porovnávať odtlačky prstov za účelom rozpoznávania identity v rozumnom čase a pri optimálnej presnosti pre danú oblasť použitia. Biometrický systém môže pracovať v režime registrácie, verifikácie a identifikácie. Režim, v ktorom bude biometrický systém pracovať závisí od konkrétneho aplikačného kontextu.



Obr. 2.20: Všeobecná schéma biometrického systému na báze odtlačkov

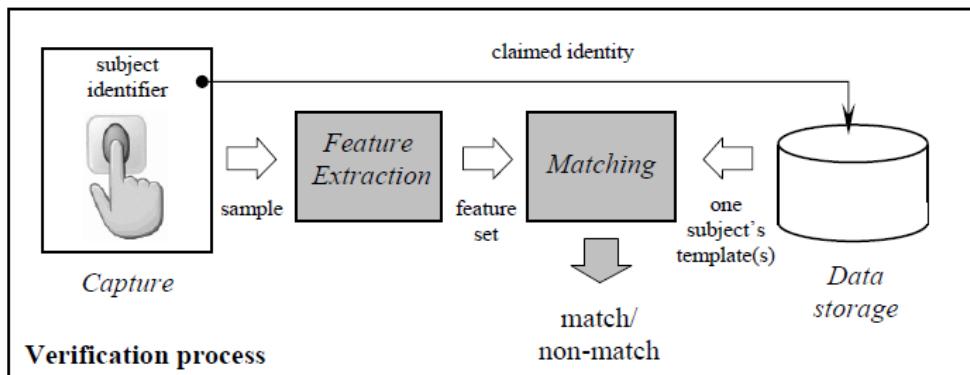
2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

Registračný režim je proces, v ktorom je subjektu najprv zosnímaný a digitalizovaný odtlačok a následne je overená jeho kvalita, aby sme sa uistili, že v ďalších fázach budeme pracovať s neskreslenými údajmi. Surové zosnímané dátá sú vstupom do modulu extrakcie, kde sa zmenšuje dimenzionalita dát a vyberajú sa špecifické dátá potrebné na objektívne rozpoznanie. V prípade odtlačkov prstov sa hľadajú polohy a orientácie daktyloskopických markantov. Tieto údaje sú uložené vo forme biometrických vzoriek v biometrických databázach. Takéto vzorky sú veľmi kompaktné, ale informácia, ktorá je v nich obsiahnutá má veryšokú výpovednú a diferenciačnú hodnotu. K biometrickej vzorke sa priradí určitý identifikátor, ktorý spája vzorku s identitou subjektu a inými demografickými údajmi. Po uvedení systému do prevádzky sa vzorky v databázach porovnávajú so zosnímaným odtlačkom, ktorý je prevedený do rovnakého formátu, v akom sú spomínané vzorky.



Obr. 2.21: Bloková schéma registračného režimu biometrického systému [29]

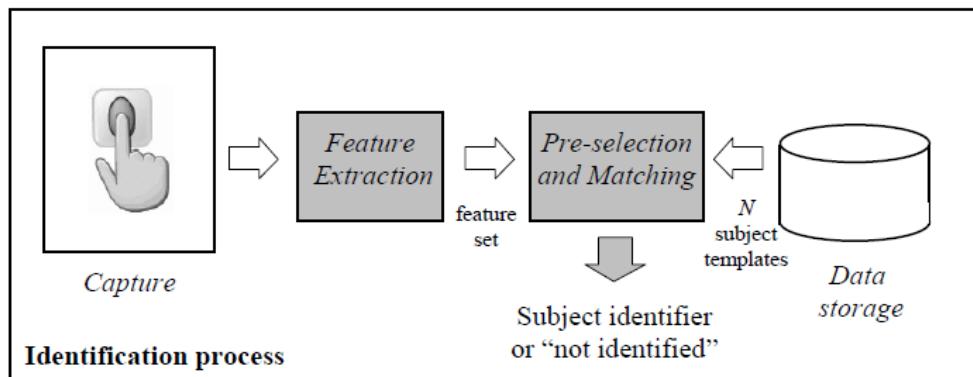
Verifikačný režim predstavuje porovnanie 1:1, v ktorom sa zosnímaný odtlačok osoby porovná s jedným jediným odtlačkom v databáze, ktorý patrí danej osobe. Rozhodovací modul biometrického systému bud' identitu potvrdí alebo zamietne.



Obr. 2.22: Bloková schéma verifikačného režimu biometrického systému [29]

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

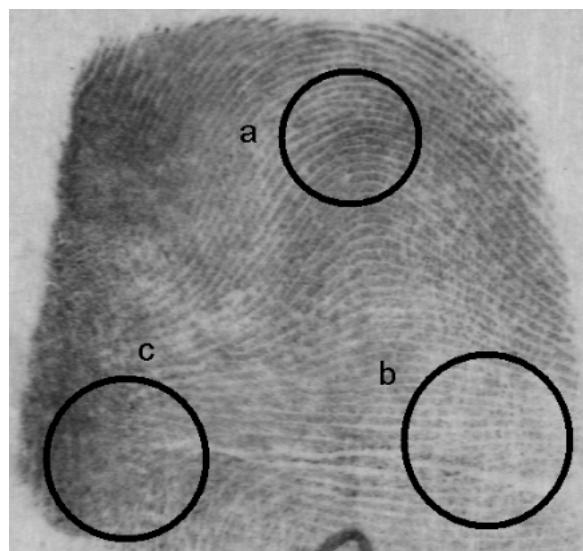
Identifikačný režim hľadá identitu neznámenho jedinca prehľadávaním celej databázy a hľadaním adekvátnej zhody. Jedná sa o porovnanie 1:N. Identifikačné systémy častokrát odpovedajú zoznamom najpravdepodobnejších kandidátov na zhodu.



Obr. 2.23: Bloková schéma identifikačného režimu biometrického systému [29]

2.2.2 Metódy predspracovania odtlačkov prstov

Cieľom predspracovania odtlačkov prstov je zvýšenie obrazovej kvality a obnova štruktúry daktyloskopických obrazcov. Obrázok odtlačku obsahuje oblasti s vysokou kvalitou, nízkou kvalitou (obnoviteľné) a neobnoviteľné oblasti, ktoré by pri ďalšom spracovaní mali byť ignorované (vid' obrázok 2.24).



Obr. 2.24: Oblasti odtlačku s lísiacou sa kvalitou (a - vyhovujúca, b -obnoviteľná, c - neobnoviteľná) [61]

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

Prehľad základných techník používaných v rámci predspracovania odtlačkov prstov:

- **Segmentácia daktyloskopického vzoru**

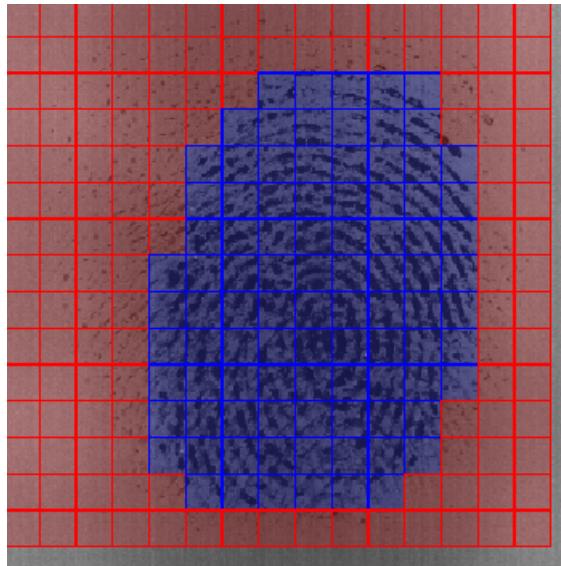
Úlohou segmentácie daktyloskopického vzoru je oddelenie vzoru odtlačku od nepotrebného pozadia. Týmto spôsobom sa šetrí výpočtový čas tým, že sa nespracovávajú nepotrebné obrazové body a taktiež sa redukuje počet falošných útvarov, kde by mohlo dôjsť k odhaleniu falošných daktyloskopických vzorov. V literatúre existujú tieto základné skupiny metód na segmentáciu odtlačkov [63]:

1. **Metódy založené na analýze jednotlivých obrazových bodov**

Pri týchto metódach sa vyšetruje každý pixel obrazu a určí sa či patrí do odtlačkového vzoru alebo do nepotrebného pozadia.

2. **Metódy založené na analýze obrazových blokov**

Tieto metódy znižujú výpočtovú náročnosť tým, že sa neklasifikujú jednotlivé pixely, ale celé obrazové bloky. Obraz odtlačku je rozdelený do malých blokov a v každom z nich je vypočítaný rozptyl jasu jednotlivých obrazových bodov. Následne sa bloky s nízkym rozptylom považujú za nepotrebné pozadanie. Z blokov s vysokým rozptylom sa vytvorí maska odtlačku (vid' obrázok 2.25)



Obr. 2.25: Maska odtlačku získaná v procese segmentácie (modré bloky označujú plochu masky)

3. **Metódy založené na strojovom učení**

V literatúre sa čoraz častejšie vyskytujú segmentačné techniky, ktoré využívajú prístupy strojového učenia. Autori v [64] vytvorili konvolučnú neurónovú sieť s názvom SegFinNet, ktorej vstupom je pôvodný obraz odtlačku a výstupom je binárna maska, ktorá definuje oblasť odtlačku v obraze.

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

Ich riešenie je založené na architektúre siete Faster RCNN. Trénovanie siete prebehlo za pomocí 1000 ručne vyznačených masiek odtlačkov, ktoré slúžili ako správne odpovede pre trénovanú sieť. Výsledky segmentácie pomocou tejto metódy je možné vidieť na obrázku 2.26.



Obr. 2.26: Masky odtlačkov získané neurónovou sieťou SegFinNet [64]

- **Normalizácia kontrastu obrazu**

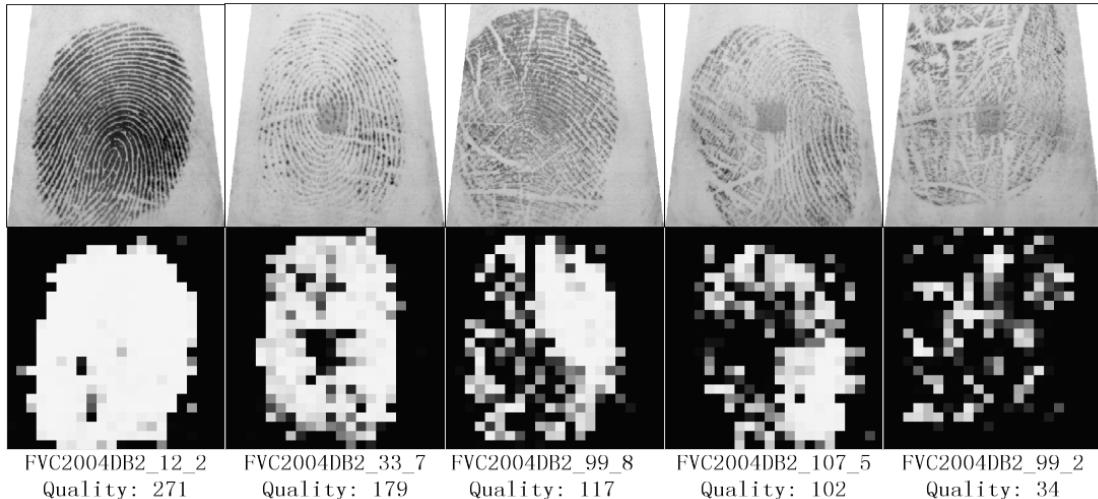
Normalizácia kontrastu slúži na zvýraznenie jasových rozdielov medzi papilárnymi líniami a pozadím obrazu. Najčastejšie sa na tento účel využíva vyrovnávanie histogramu. Snahou je, aby boli papilárne línie ľahko odlišiteľné od okolia.

- **Výpočet mapy kvality obrazu**

Kvalita odtlačku je významná charakteristika, ktorá určuje mieru znehodnotenia obrazovej informácie odtlačku. Známe algoritmy počítajú tzv. mapu kvality, ktorá priraduje obrazovým blokom ich kvalitu. Nízka kvalita sa prejavuje hlavne v nemožnosti rozoznať tvary papilárnych línií. V takýchto prípadoch by sa mali zóny obrazu s nízkou kvalitou buď ignorovať alebo im priradiť nižšiu dôležitosť napríklad pri hľadaní alebo porovnávaní daktyloskopických markantov. Jedným zo známych riešení odhadu kvality odtlačku je NFIQ, čo je algoritmus z balíku biometrických nástrojov NBIS od amerického NIST-u. Jadrom algoritmu je viacvrstvový perceptrón, ktorý na základe vstupného vektora (smery papilárnych línií a kvalita markantov) vypočíta odhadovanú úroveň celkovej kvality odtlačku. Výstupom je mapa, ktorá obsahuje hodnoty 1 (najvyššia kvalita) až 5 (najnižšia kvalita) pre každý blok obrazu. Iné riešenie výpočtu mapy kvality dokumentuje práca autorov v [65]. V ich prístupe sa najprv vypočíta lokálny smer papilárnych línií v malom obrazovom bloku. Následne sa z obrazového bloku vypočíta 11 charakteristických príznakov, ktoré sú ako vstupný vektor poslané do neurónovej siete na to, aby potvrdili korektnosť vypočítaného smeru. Sieť odpovedá na bloky

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

so správne vypočítaným smerom vysokými hodnotami. Bloky neobsahujúce papilárne línie majú pridelené nízke hodnoty. Na obrázku 2.27 vidíme odtlačky rôznej kvality a k nim zodpovedajúce mapy kvality.



Obr. 2.27: Mapy kvality odtlačkov [65]

- **Filtrovanie odtlačku adaptívnym filtrom**

Daktyloskopické systémy porovnávajú odtlačky prstov pomocou nájdených markantov papilárnych línií. Nízka kvalita obrazu však zabráňuje spoľahlivému objaveniu markantov. Aby sa dali markanty spoľahlivo získať v ľubovoľnom mieste odtlačku, je potrebné využiť adaptívne filtrovanie, ktoré zabezpečí obnovu stratenej kvality obrazu. Papilárne línie sú určené svojim tvarom, smerom a frekvenciou. Ak vieme tieto vlastnosti presne odhadnúť v znehodnotených oblastiach obrazu, tak ich môžeme použiť na konfiguráciu filtrov, ktoré dokážu obnoviť kvalitu. Adaptívne filtrovanie funguje na princípe existencie filtrov, ktoré majú smerovo a frekvenčne selektívne vlastnosti a vedia sa tak prispôsobiť lokálnemu tvaru odtlačku a odstrániť z neho neželané obrazové informácie a zosilniť tak skutočnú štruktúru obrazov. Najznámejším predstaviteľom týchto filtrov v oblasti predspracovania odtlačkov prstov je Gaborov filter, ktorému sa podrobne venujeme v sekcií 2.3.1. Na obrázku 2.28 vidíme prínos adaptívneho filtrovania, ktoré viditeľne zvyšuje kvalitu obrazu (použitý bol Gaborov filter).

2.2.3 Metódy extrakcie charakteristických vlastností odtlačkov prstov

Po predspracovaní obrazu prichádza na rad extrakcia charakteristických znakov, ktorej výsledkom je vytvorenie deskriptora odtlačku, pomocou ktorého sa bude dať odtlačok porovnať s inými odtlačkami. Deskriptor odtlačku by mal pozostávať z

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY



Obr. 2.28: Ukážka prínosu adaptívneho filtrovania odtlačku prsta. Vľavo je originál a vpravo je prefiltrovaný odtlačok.

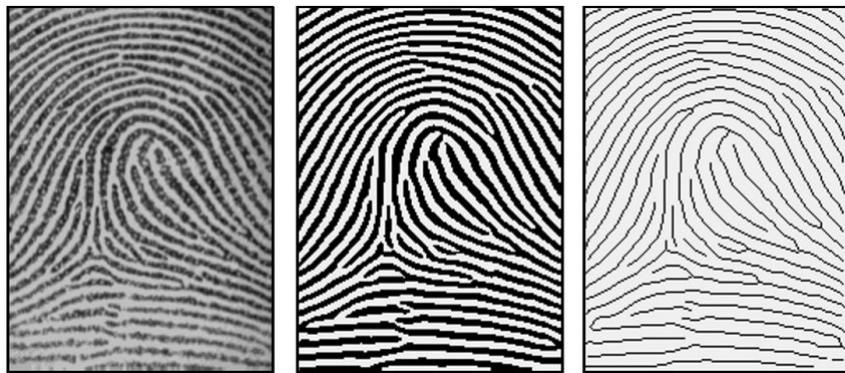
údajov, ktoré by mali byť ľahko odhaliteľné v každom odtlačku a zároveň by mali byť pre každého jedinca unikátne. V literatúre existuje veľké množstvo reprezentácií odtlačku od takých, ktoré sa koncentrujú na markanty a ich vlastnosti až po také, ktoré sú orientované na vlastnosti ako zakrivenie papilárnych línii, ich hustota, smerové mapy odtlačku, potné póry, grafy vytvorené zo siete markantov alebo aj Delaunayova triangulácia. Prehľad najznámejších reprezentácií odtlačkov prstov je dostupný v [70].

V tejto sekcii uvádzame prehľad v literatúre najrozšírenejších a najdiskutovanejších techník extrakcie charakteristických vlastností s opisom ich základného princípu fungovania. Všetky opisované techniky majú spoločné, že sa špecializujú výlučne na Level-2 znaky a teda ich zameranie je podobné ako naše. Tieto metódy reflektujú súčasný stav technológie.

A. Hľadanie markantov algoritmom Crossing Number

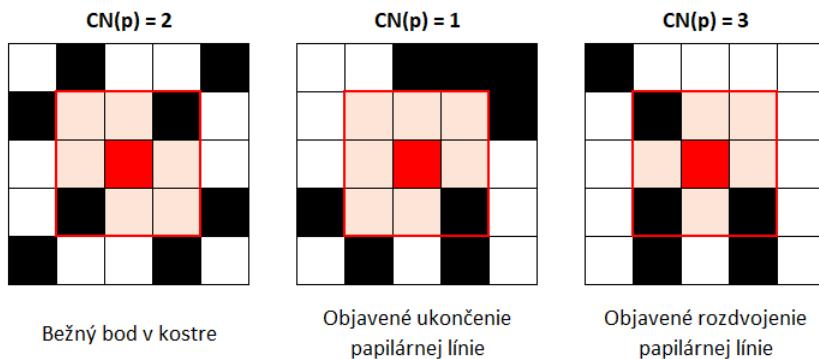
Väčšina existujúcich extrakčných techník je založená na skúmaní a vyšetrovaní štruktúry odtlačkov prstov, kde sa očakáva, že papilárne línie sú v obraze zastúpené tmavšími čiarami ako prieplavy medzi nimi. Niekoľko sa kvôli zjednodušeniu práce uvažuje aj o inverznej reprezentácii obrazu. Vtedy sa význam papilárnych línii zamení s medzerami medzi nimi a vyšetruje sa štruktúra medzier, ktorá rovnako hodnotne vyslovuje o polohách charakteristických znakov. Algoritmus Crossing Number (CN) pracuje s reprezentáciou odtlačku, v ktorom sú všetky papilárne línie na úrovni hrúbky jedného obrazového bodu. Konverzia odtlačku do takejto kostry je však proces náhodný na chyby. Papilárne línie sú pri vyššom tlaku prsta na senzor hrubšie ako medzery nimi a tým pádom je proces zúženia medzier vhodnejšou alternatívou na vytvorenie kostry [58].

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY



Obr. 2.29: Odtlačok a jeho kostra (vpravo) [58]

V súčasných systémoch sú daktyloskopické markanty obmedzené len na dve tvarové triedy: rozdvojenie a ukončenie. Metóda CN si žiada prvotnú binarizáciu vstupného obrazu odtlačku a jeho následnú transformáciu do podoby kostry. Keď obraz obsahuje len čierne (hodnota 0) a biele body (hodnota 1), algoritmus začne postupne vyšetrovať všetky body kostry a v okolí každého bodu p vytvorí lokálny blok veľkosti 3×3 a analyzuju sa susedné body (vyšetrovaný bod p je v strede bloku). Pre každý takýto blok sa vypočíta číslo $CN(p) = 0,5 \sum_{i=1}^8 |p_i - p_{i+1}|$, kde p_i predstavuje susedný bod bodu p . Indexovanie susedných bodov je bud' v smere alebo proti smeru hodinových ručičiek. Inými slovami, algoritmus CN vie na základe počtu prechodov z 0 do 1 zistiť, kol'ko papilárnych línií vstupuje alebo vystupuje z bodu p . Tento počet potom jasne určuje existenciu a tvar markantu.



Obr. 2.30: Algoritmus Crossing Number a odhalovanie základných typov markantov v kostre odtlačku

Ak $CN(p) = 1$, potom bolo v kostre objavené miesto ukončenia papilárnej línie a ak $CN(p) = 3$, bolo objavené rozdvojenie papilárnej línie. $CN(p) = 2$ predstavuje priebežnú papilárnu líniu bez prítomnosti markantu. Tento algoritmus vie veľmi rýchlo a spoľahlivo odhaliť ukončenia a rozdvojenia. Vzhľadom na to, že pracuje s veľkosťou

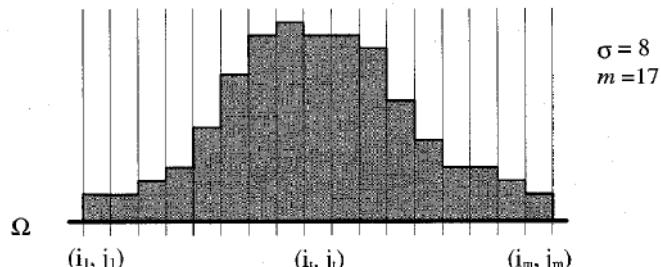
2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

bloku 3×3 , vie rozpoznávať len tieto dva typy markantov. Obrázok 2.30 znázorňuje obrazové bloky veľkosti 3×3 zachytávajúce rôzne miesta v kostre odtlačku a k nim prislúchajúci výsledok algoritmu CN.

B. Detekcia markantov priamo v originálnom obraze

Autori tejto techniky prezentujú diametrálne odlišný prístup na riešenie problematiky v porovnaní s metódou CN. Metódu CN kritizujú hlavne kvôli tomu, že považujú tvorbu kostry, z ktorej CN vychádza za proces, v ktorom vzniká množstvo umelých falošných útvarov, ktoré sú podobné markantom a na druhej strane, množstvo reálnych markantov zaniká [28]. Ďalší nedostatok vidia v nedostatočnej presnosti pri obrázkoch s nižšou obrazovou kvalitou.

Základná myšlienka ich metódy je postupné sledovanie papilárnych línii v smere všeobecného toku všetkých okolitých línii. V tomto prípade je potrebné, aby sme mali k dispozícii smerovú mapu odtlačku. Algoritmus začína rozmiestnením určitého počtu štartovacích bodov v obraze. Z každého štartovacieho bodu algoritmus postupne inkrementálne sleduje priebeh línie až pokial' nenašazí na rozdvojenie a ukončenie. Aby sa zabránilo opakovanému viacanásobnému sledovaniu rovnakej papilárnej línie, algoritmus si pomáha značkovacou stratégiou.



Obr. 2.31: Projekcia intenzity obrazových bodov v smere kolmom na papilárnu líniu [28]

Na sledovanie papilárnych línii je potrebné poznať presné miesto, kde sa nachádza línia. Z matematického pohľadu je papilárna línia sekvenciou bodov vyjadrujúcich lokálne maximum intenzity obrazových bodov v smere, ktorý je kolmý na orientáciu papilárnej línie. Spojením lokálnych maxímov dostávame polygonálnu approximáciu vzorov. Formálne môžeme celý algoritmus zapísť v týchto bodoch [28]:

1. Tvorba prierezov kolmých na papilárne línie a určenie lokálneho maxima intenzity (detekcia vrcholu papilárnej línie, vid' obrázok 2.31).
2. Výpočet smeru dotyčnice k papilárnej líniu a nastavenie bodu pokračovania - v tomto kroku sa z aktuálne vyšetrovaného bodu algoritmus posunie o určitý počet bodov v smere lokálnej orientácie papilárnej línie.

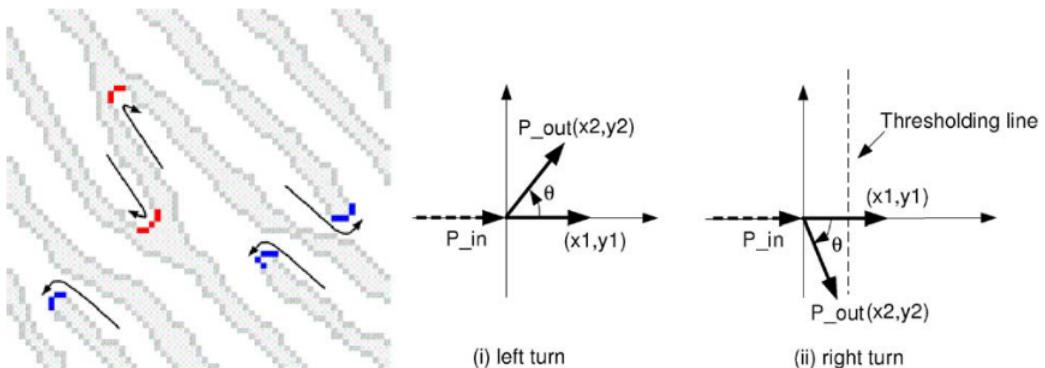
2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

3. Kontrola splnenia ukončovacieho kritéria stopovania. Definované sú tieto ukončovacie kritériá:

- vyšetrovaný bod vychádza mimo platný rozsah súradníc
- narazili sme na ukončenie papilárnej línie, ktoré sa prejaví absenciou lokálneho maxima
- narazili sme na bod rozdvojenia papilárnej línie, ktorý sa prejaví v označení už raz označeného bodu v obraze
- nadmerné zakrivenie papilárnej línie na malom obrazovom segmente, t.j. sledovanie priebehu papilárnej línie vstúpilo do nekvalitnej zóny obrazu

C. Extrakcia na základe reprezentácie obrysov papilárnych línií vo forme reťazového kódu

Autori v [59] navrhli efektívnu alternatívnu metódu detekcie markantov, ktorá vychádza z čiernobielej reprezentácie odtlačku. Najprv sa obraz vyšetri postupným prezeraním obrazových bodov zhora nadol a zprava doľava a detegujú sa miesta prechodov z čiernej farby do bielej. Tieto kontúry sú d'alej stopované proti smeru hodinových ručičiek a kódované vo forme reťazovej postupnosti elementov. Každý element takto vytvoreného odtlačkového deskriptora obsahuje súradnice obrazového bodu kontúry, informácie o lokálnom smere a zakrivení.



Obr. 2.32: Polohy markantov odhalené na základe reťazového kódu okrajov papilárnej línie a ilustrácia matematického vyjadrenia smeru zakrivenia [59]

Tento reťazový kód má oproti kostre odtlačku jednu podstatnú výhodu a to, že z reťazového kódu môžeme obnoviť pôvodný papilárny terén. Stopovanie kontúr podáva informácie o zakrivení papilárnej línie. Základná myšlienka extrakcie markantov spočíva v kvantifikácii zakrivenia okraju papilárnej línie. Ukončenie papilárnej línie je dané signifikantným otočením doľava a rozdvojenie je dané signifikantným zakrivením doprava. Majme vektor kontúrových elementov P_{IN} vstupujúcich do vyšetrovaného bodu P a vektor kontúrových elementov P_{OUT} vystupujúcich z vyšetrovaného bodu. Významnosť

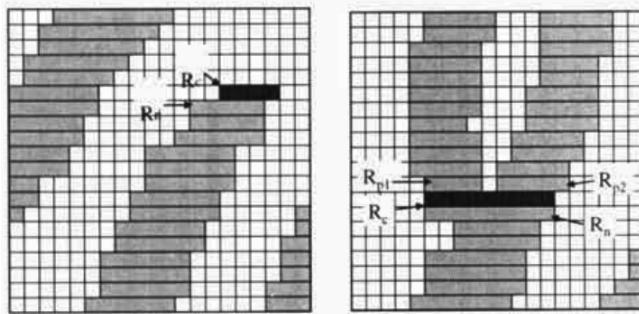
2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

zakrivenia v bode P je daná uhlom, ktorý zviera vektor P_{IN} a P_{OUT} . Výpočet uhlu sa dá vyjadriť nasledovným zápisom $\theta = \arccos \frac{P_{IN} \cdot P_{OUT}}{|P_{IN}| \cdot |P_{OUT}|}$. Obrázok 2.32 zachytáva reťazový kód odtlačku so zvýraznenými kritickými zakriveniami (miesta markantov) a taktiež aj ilustráciu konfigurácie vektorov P_{IN} a P_{OUT} v prípade rôzneho zakrivenia kontúry.

D. Run-length encoding

Jedná sa o metódu extrakcie markantov, ktorá nepracuje s kostrou odtlačku. Namiesto toho vychádza z binárneho obrazu (len biele a čierne obrazové body) odtlačku prsta so zachovanými šírkami papilárnych línii. Táto reprezentácia je výhodná, pretože kostra odtlačku vzniká v procese, ktorý môže významne zmeniť dôležité detaily obrazu.

Autori v [71] navrhli spôsob automatizovaného odhalenia markantov, ktorý je schopný odhalenia ukončení a rozdvojení papilárnych línii v tzv. run-length kóde. Run-length kódovanie je úsporné vyjadrenie binárneho obrázku. V prípade odtlačkov prstov, run-length kódovanie vyjadruje papilárnu líniu ako sekvenču po sebe idúcich horizontálnych alebo vertikálnych rezov (z angl. runs). Každý rez je definovaný len štartovacím a koncovým bodom. Obrázok 2.33 znázorňuje papilárnu líniu vyjadrenú ako postupnosť horizontálnych rezov pomocou run-length kódovania a miesta odhalených markantov.

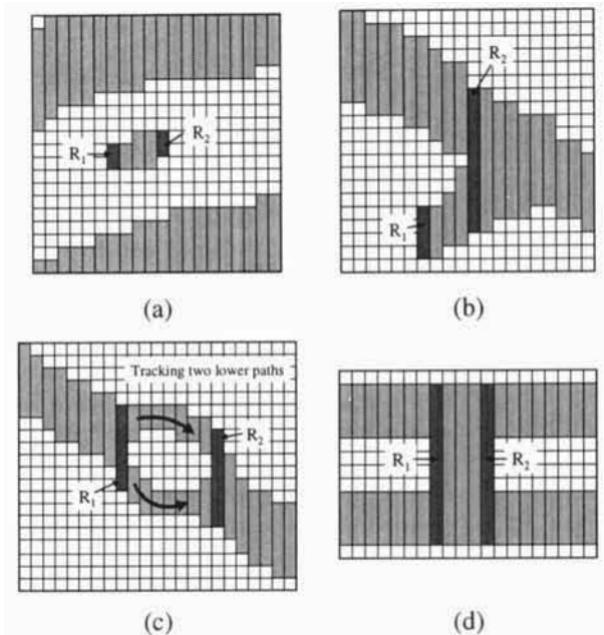


Obr. 2.33: Run-length kódovanie vzoru odtlačku a miesta s odhalenými markantami [71]

Algoritmus hľadá markanty takým spôsobom, že analyzuje odtlačok postupne po riadkoch zhora nadol a deteguje všetky horizontálne rezové papilárne línii. Každý rez je vyhodnotený ako regulárny (t.j. taký, ktorý má nad sebou aj pod sebou prítomný práve jedene susediaci rez) alebo singulárny (t.j. taký, ktorý nie je regulárny). Singulárne rezové sú kandidátmi na miesta s daktyloskopickými markantami. V prípade, že sme odhalili rez, ktorý má len jeden susediaci rez, tak sme našli miesto ukončenia papilárnej línie. Ak sme objavili rez, ktorý má dva samostatné prilahlé rezové súčasne na jednom riadku (pod alebo nad aktuálne vyšetrovaným rezom), objavili sme rozdrobenie papilárnej línie.

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

Samozrejme prvotná detekcia singulárnych rezov, ešte nestačí na potvrdenie výskytu markantu. Singulárne rezy treba validovať, aby sme vylúčili detekciu falošných markantov ako sú krátke výbežky, očká, premostenia v papilárnych líniah a podobné útvary. Validuje sa dĺžka singulárneho rezu (musí byť dostatočne krátky) a vzdialenosť medzi dvomi po sebe idúcimi singulárnymi rezmi. Obrázok 2.34 znázorňuje falošné singulárne rezy, ktoré sú jednoducho odhaliteľné v procese validácie.



Obr. 2.34: Falošné singulárne rezy objavené v run-length kóde odtlačku (a-b sú falošné ukončenia, c-d sú falošné rozdvojenia) [71]

E. Extrakcia markantov pomocou morfologických operácií

Autori v práci [72] predstavili algoritmus extrakcie daktyloskopických markantov založený na Hit or Miss transformáciu (HMT). Je to morfologická operácia, ktorej zmyslom je odhalenie určitého tvaru v binárnom obrazu pomocou štrukturálnych elementov. Autori navrhli niekoľko štrukturálnych elementov, ktoré vyjadrujú rôzne variácie tvarov ukončenia a rozdvojenia papilárnej línie. HMT využíva operáciu erózie, kde sa na pôvodný obraz aplikuje štrukturálny element vyjadrujúci obrazové body markantu a na komplementárny obraz sa aplikuje štrukturálny element vyjadrujúci obrazové body pozadia markantu. Musia sa tak vopred vytvoriť páry štrukturálnych elementov. HMT pracuje s kostrou odtlačku.

Pomocou HMT sa dajú extrahovať nasledovné typy markantov:

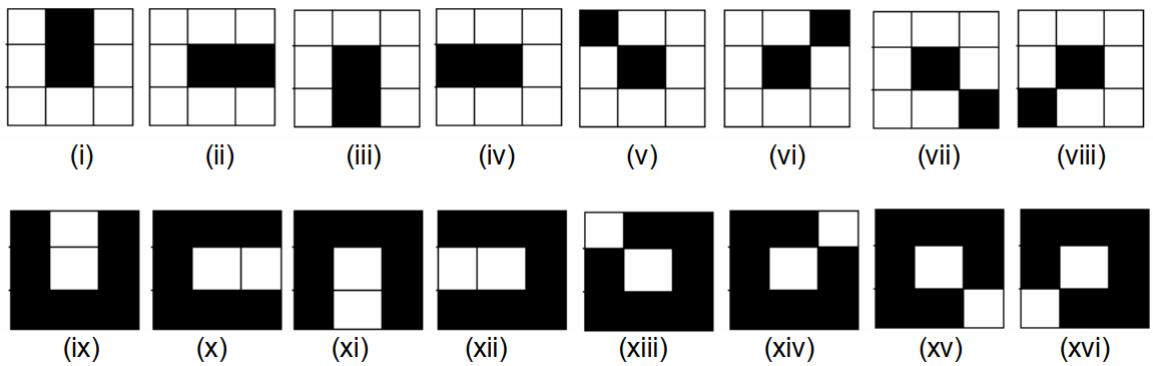
- **Ukončenia papilárnej línie.** Nech M_1 je obrázok s extrahovanými ukončeniami. M_1 získame ako $M_1 = I \otimes J$, kde I je kostra odtlačku a J

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

je postupnosť párov štrukturálnych elementov (J_1, J_2), ktoré vyjadrujú rôzne tvary ukončenia papilárnej línie. Operáciu vieme ďalej zapísat ako $I \otimes J = (I \ominus J_1) \cap (I^C \ominus J_2)$, kde \ominus predstavuje operáciu erózie.

- **Rozdvojenia papilárnej línie.** Obrázok M2 s extrahovanými rozdvojeniami získame analogicky s tým, že zameníme štrukturálne elementy v J za také, ktoré vyjadrujú tvary rozdvojení.

Na obrázku 2.35 môžeme vidieť štrukturálne elementy a ich komplementárne verzie pre detekciu ukončenia papilárnej línie.



Obr. 2.35: Štrukturálne elementy na detekciu ukončenia papilárnej línie pomocou metódy HMT spolu s ich komplementárnymi tvarmi [72]

F. Extraktia markantov pomocou Gaborovho amplitúdovo-fázového modelu

V práci [73] bol navrhnutý algoritmus extrakcie markantov využívajúci reprezentáciu odtlačku prsta pomocou tzv. Gaborovho amplitúdovo-fázového modelu. Jadrom fungovania algoritmu je konvolúcia komplexného Gaborovho filtra a obrázku odtlačku. Výsledok tejto konvolúcie rozkladá obraz odtlačku do amplitúdového a fázového poľa. Markanty sú odhalované vo fázovom poli a amplitúdové pole slúži ako mapa kvality odtlačku.

Komplexný Gaborov filter je reprezentovaný ako:

$$g_{\omega,\theta}(x, y) = \frac{1}{\sqrt{\sigma_{\theta_\perp}}} e^{-\frac{v^2}{2\sigma_{\theta_\perp}^2}} \cdot \frac{1}{\sqrt{\sigma_\theta}} e^{-\frac{u^2}{2\sigma_\theta^2}} e^{i w u} \quad (2.1)$$

$$u = x \cos \theta + y \sin \theta \quad (2.2)$$

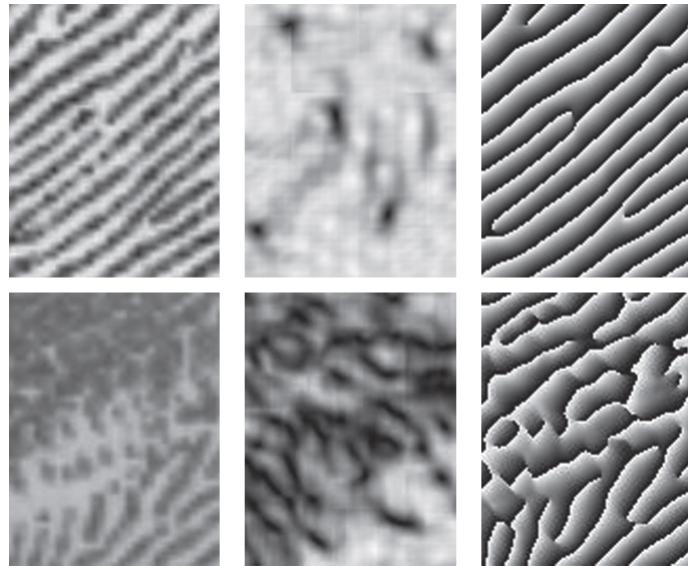
$$v = -x \sin \theta + y \cos \theta \quad (2.3)$$

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

Parametre ω a θ predstavujú frekvenciu a smer filtra. Parametre σ_θ a $\sigma_{\theta \perp}$ predstavujú škálovanie filtra v smere papilárnych línií a v smere kolmom. Konvolúcia filtra s obrazom sa vypočíta:

$$I_g(x_0, y_0) = \int_D f(x, y) g_{\omega, \theta}(x, y) dx dy = A(x_0, y_0) e^{i\varphi(x_0, y_0)} \quad (2.4)$$

$A(x_0, y_0)$ je amplitúdový člen, $\varphi(x_0, y_0)$ je fázový člen, $f(x, y)$ je lokálny vstupný obraz a D predstavuje lokálnu oblasť. Na obrázku 2.36 vidíme vizualizáciu amplitúdového a fázového poľa pri dvoch odtlačkoch rôznej kvality. Tmavé oblasti v amplitúdovom poli predstavujú oblasti s nízkou kvalitou. Markanty sa dajú odhaliť vo fázovom poli, kde predstavujú ukončenia a prerušenia kriviek fázovej diskontinuity.



Obr. 2.36: Vizualizácia amplitúdového (druhý stĺpec) a fázového (tretí stĺpec) poľa pri dvoch odtlačkoch rôznej kvality [73]

Autori navrhli detektor fázovej diskontinuity určený na hľadanie markantov vo fázovom poli. Myšlienka detektora je hľadanie signifikantnej fázovej diskontinuity v okolí jednotlivých obrazových bodov. Detektor sa teda aplikuje na každý bod obrazu a na všetkých 8 susedných bodov $P_k, k = 1, 2, \dots, 8$ sa aplikuje vzťah:

$$s(\psi_k, \psi_{k+1}) = \operatorname{sgn}\left(\frac{|\psi_{k+1} - \psi_k|}{\alpha 2\pi} - 1\right) \quad (2.5)$$

$$\operatorname{sgn}(x) = \begin{cases} 1, & x \geq 0 \\ -1, & x < 0 \end{cases} \quad (2.6)$$

Parameter α predstavuje prahovú hodnotu. Detektor diskontinuity bude mať hodnotu 1 len pri dostatočnej fázovej zmene (približne 2π).

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY

Následne sa použije detektor markantov podľa vzťahu:

$$S_P = \sum_{k=1}^8 \frac{s(\psi_k, \psi_{k+1}) + 1}{2} \quad (2.7)$$

Jedná sa v podstate o počítadlo fázových diskontinuít medzi susedmi zvoleného obrazového bodu. Ak $S_P = 1$, bolo nájdené ukončenie papilárnej línie. Ak $S_P = 3$, bolo nájdené rozdvojenie papilárnej línie.

Výhodou tejto metódy oproti iným metódam hľadania markantov je to, že nie je potrebné vykonať binarizáciu a skeletonizáciu obrazu, počas ktorých dochádza k stratám potrebných detailov.

2.2.4 Metódy porovnávania odtlačkov prstov

Existujú tieto kategórie porovnávacích algoritmov:

- **Algoritmy založené na porovnávaní globálnych štruktúr**

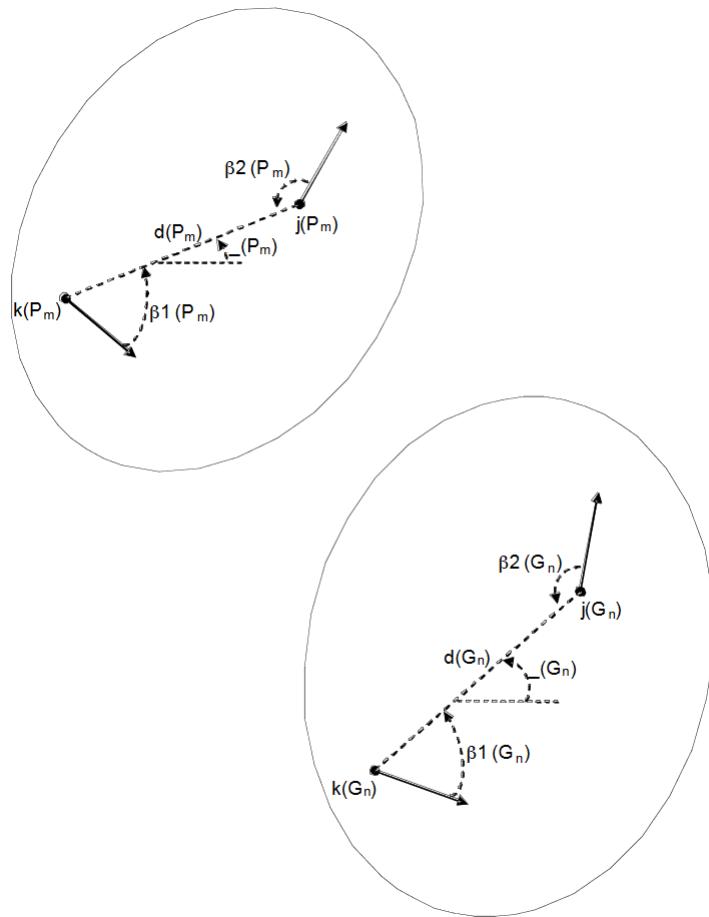
Tieto algoritmy sa koncentrujú na vyhodnocovanie podobnosti takých vlastností akými sú celoplošný tok papilárnych línií alebo Level-1 vzor. Porovnávajú odtlačky ako celok a nie ako množinu charakteristických znakov. Ich nevýhodou je slabá odolnosť voči rotácii alebo deformácii odtlačkov.

- **Algoritmy založené na porovnávaní lokálnych štruktúr**

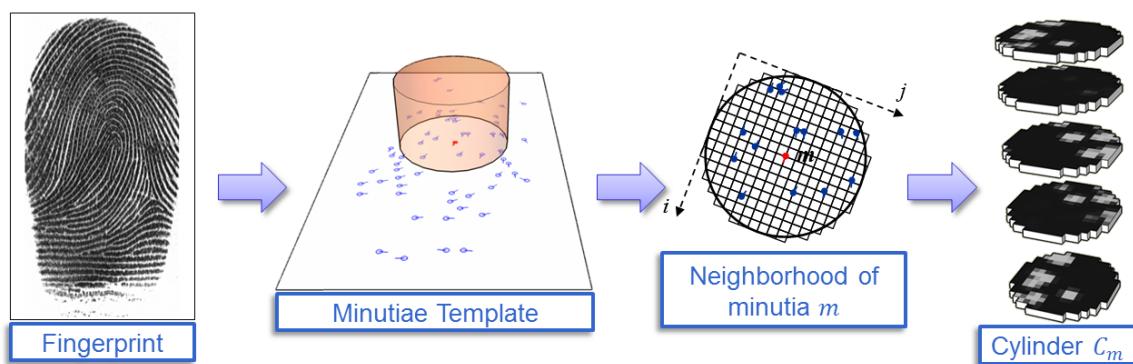
Lokálne štruktúry sú väčšinou tvorené zoskupeniami daktyloskopických markantov pretože sa preukázalo, že vzájomné vzťahy v rámci takéhoto skupín sú odolné voči rotácii a deformácii kože. Navyše, každý markant má svoj tvarový typ a smer, čo vytvára neopakovateľný súbor informácií spojený s konkrétnym odtlačkom prsta. Medzi najznámejšie a najúspešnejšie algoritmy s dostupným technickým popisom patria:

- **BOZORTH3.** Algoritmus využívajúci smer a polohu daktyloskopických markantov. Skonštruujú sa tabuľky so vzťahmi medzi markantami pre každý odtlačok (tzv. intra-fingerprint tabuľka) a následne sa tieto tabuľky porovnávajú štýlom každý riadok s každým. Detegujú sa kompatibilné zhľuky markantov, tie sa zapíšu do tzv. inter-fingerprint tabuľky a vypočítajú sa skôre podobnosti. Obrázok 2.37 znázorňuje kompatibilné dvojice daktyloskopických markantov v dvoch odtlačkoch (kompatibilita závisí od podobnosti vzdialenosť a orientácie markantov).
- **MCC (Minutiae Cylinder Code).** Algoritmus vyvinutý na University of Bologna, ktorý predstavuje jedinečnú reprezentáciu odtlačku. Každý markant má vyjadrenú charakteristiku svojho okolia formou tzv. cylindrov (obrázok 2.38). Cylinder predstavuje vrstvy kruhových obrazových výrezov, ktoré zachytávajú charakteristiky ako smer a frekvencia okolia markantu. Celková miera podobnosti medzi dvoma odtlačkami je vypočítaná porovnávaním cylindrov.

2.2. AUTOMATIZOVANÉ DAKTYLOSKOPICKÉ SYSTÉMY



Obr. 2.37: Kompatibilné dvojice markantov medzi dvoma odtlačkami prstov, ktoré vyhľadáva porovnávací algoritmus BOZORTH3 (body k a j sú polohy markantov, P (probe) a G (gallery) sú označenia odtlačkov) [69]



Obr. 2.38: MCC algoritmus a vizualizácia cylindrov

2.3 Súčasný stav v skúmanej problematike

Dnes sa zaoberá výskumom odtlačkov prstov a softvérových algoritmov veľké množstvo záujmových skupín počnúc univerzitami, nezávislými výskumníkmi, malými firmami až po veľké nadnárodné spoločnosti, ktoré poskytujú biometrické riešenia pre všetky segmenty spoločnosti. Medzi najznámenjšie automatizované daktyloskopické systémy súčasnosti patria tieto riešenia:

- VeriFinger SDK od spoločnosti Neurotechnology
- Minutia Cylinder-Code SDK od výskumníkov z University of Bologna, Biometric Research Laboratory
- ABIS multimodálny systém od spoločnosti Innovatrics
- BioMini SDK od spoločnosti Suprema
- NBIS balík nástrojov od amerického NIST-u
- GrFinger SDK od spoločnosti Griaule
- Futronic Fingerprint Recognition SDK od spoločnosti Futronic
- SourceAFIS od slovenského softvérového vývojára Roberta Važana [74]

Univerzitné kruhy rovnako nie sú pozadu a dalo by sa povedať, že väčšina z biometrických systémov nasadených v praxi vychádza z nápadov a inovatívnych myšlienok vedcov, ktorí sa tejto problematike aktívne venujú. Univerzita v Bologni v Taliansku, konkrétnie pracovisko Biometric System Laboratory v rámci ústavu Department of Computer Science and Engineering, je jedným z najaktívnejších centier výskumu biometrie využívajúcej odtlačky prstov. Vedúcimi postavami tohto pracoviska sú tri uznávané osobnosti, Davide Maltoni, Dario Maio a Raffaele Cappelli, ktorí sú autormi mnohých publikácií o extrakcii daktyloskopických markantov, tzv. large-scale biometrických systémoch a počítačovej syntéze obrazov odtlačkov. Naša práca vo svojich počiatkoch prebrala z ich publikácií značnú mieru inšpirácie a kvôli ich neúnavnej práci ju preberá dodnes. Biometric System Laboratory prevádzkuje aj online evaluáciu biometrických algoritmov s názvom FVC-onGoing. Odoslané algoritmy sú testované a sú pre ne vypočítané známe ukazovatele ako spotrebovaná pamäť, rýchlosť výpočtu, FMR, FNMR, ROC a grafy rozdelenia vypočítaného skóre podobnosti pre všetky odtlačky v testovacej databáze. Takýmto spôsobom sa udržuje rebríček algoritmov a vieme tak lepšie určiť akú presnosť momentálne dosahuje technológia rozpoznávania odtlačkami prstov.

Veda a aplikovaný výskum sú teda v tejto oblasti naozaj prítomné a potrebné. Aj napriek zdanlivej dokonalosti všetkých týchto metód, techník a postupov stojí ich úspešnosť na bode, ktorý zabezpečuje krehkú rovnováhu medzi úspechom a

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

neúspechom. V tejto časti práce sa zameriavame na analýzu súčasného stavu vo vybraných oblastiach, ktoré skúma naša práca. Podávame tu prehľad existujúcich riešení v relevantnej literatúre, aby bolo čitateľovi tejto práce jasné aké výsledky sa v skúmanom smere doposiaľ dosiahli a aká je ich úroveň. Pri mapovaní súčasného stavu sme sa zameriali najmä na analýzu existujúcich riešení v úzko špecializovaných oblastiach, v ktorých naša práca dosahuje najväčšie prínosy:

- adaptívne predspracovanie obrazov odtlačkov prstov
- využitie metód strojového učenia v daktyloskopickom systéme
- možnosti paralelizácie výpočtov pri spracovaní odtlačkov prstov
- multimodálne biometrické systémy využívajúce odtlačky prstov a obrazce žil prsta

2.3.1 Adaptívne predspracovanie daktyloskopických vzorov

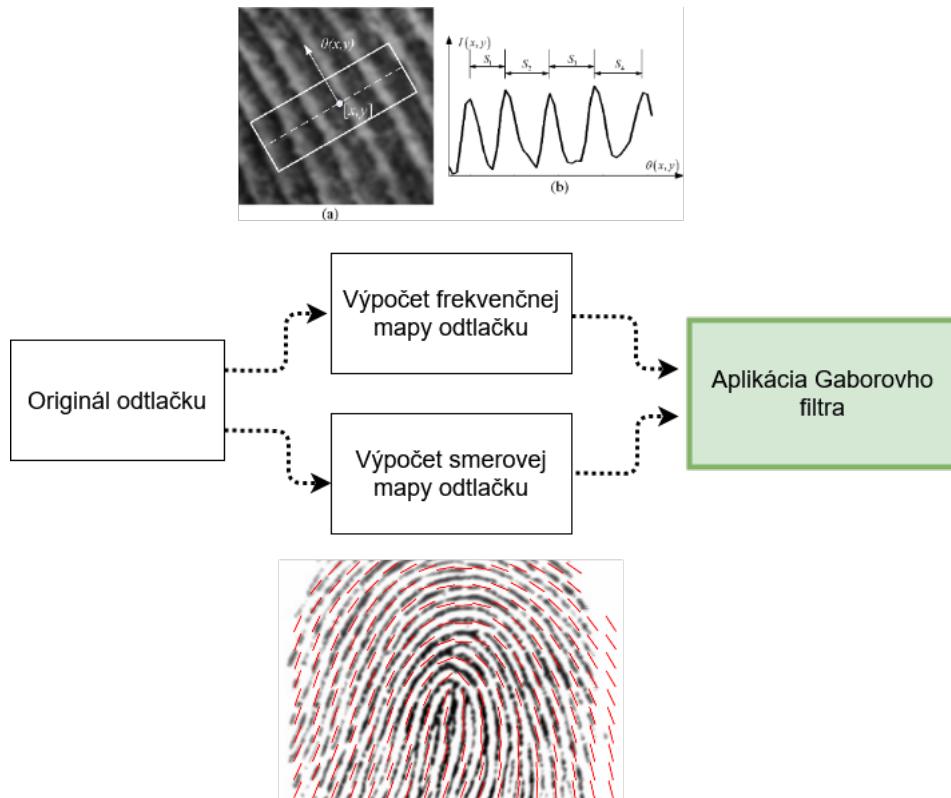
V tejto sekcií sa budeme venovať adaptívному Gaborovmu filtrovi, čo je jeden z najdôležitejších algoritmov používaných vo fáze predspracovania obrazu odtlačku. Označujeme ho slovom adaptívny resp. kontextový nakoľko vie svoj účinok prispôsobiť lokálnym vlastnostiam (kontextu) odtlačku. Úlohou tohto filtra je odstrániť celkovú degradáciu obrazu (šum, slabý kontrast, nízka kvalita senzora) a zvýrazniť pôvodnú štruktúru papilárnych línii, aby sme v ďalších fázach mohli bez problémov lokalizovať daktyloskopické markanty. Avšak, aby sme mohli Gaborov filter použiť musíme predtým vykonať dve kľúčové operácie: výpočet smerovej a frekvenčnej mapy odtlačku. Tieto mapy kódujú smery a hustoty papilárnych línii v rôznych častiach obrazu a vytvárajú tak odhad lokálneho kontextu, ktorý filter využíja na obnovu vlastností obrazu. Výhodou tohto filtra je možnosť jeho paralelnej implementácie, či už na viac-vláknovom CPU alebo GPU. Obrázok 2.39 znázorňuje blokovú schému filtrovania Gaborovym filtrom.

Smerová mapa

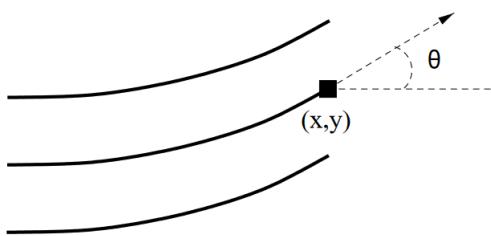
Jeden z najdôležitejších krokov predspracovania je čo najpresnejšie určenie smerov papilárnych línii. Smerová mapa je nevyhnutná pre správne nastavenie Gaborovho filtra a počas extrakcie markantov na určenie smeru markantov. Nasledovný opis vychádza z práce Raymonda Thaia [41].

Počas výpočtu obrázok odtlačku rozdelíme na menšie štvorcové bloky s rozmermi $W \times W$ a smer budeme počítať pre stredný obrazový bod v každom bloku. Vypočítaný smer bude platný pre celý blok, kde orientáciu bodu predstavuje uhol zvieraný dotyčnicou k papilárnej línií s osou x (vid' obrázok 2.40).

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE



Obr. 2.39: Schéma adaptívneho filtrovania odtlačku pomocou Gaborovho filtra (pomocou smerovej a frekvenčnej mapy vieme prispôsobiť Gaborov filter tak, aby maximálne obnovil kvalitu a pri tom zachoval lokálny smer a šírku papilárnych línii)



Obr. 2.40: Lokálny smer papilárnej línie [41]

Smerová mapa bude matica obsahujúca vypočítané hodnoty v radiánoch v rozsahu $\langle 0, \pi \rangle$ a bude mať šírku a výšku, ktoré sa rovnajú počtom blokov, kolko sa zmestí bez prekrytia do obrázku na šírku a na výšku.

Kroky výpočtu smerovej mapy:

1. Stred $W \times W$ bloku je v bode (i, j) (pre správnu funkčnosť treba zvoliť nepárne číslo pre veľkosť bloku)

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

2. Vypočítame gradienty $\delta_x(i, j)$ a $\delta_y(i, j)$ pre každý pixel v danom bloku, na tento účel je možné využiť Sobelove operátory z knižnice OpenCV v prípade CPU spracovania a podobnú funkciu z knižnice ArrayFire v prípade GPU spracovania
3. Odhad lokálnej orientácie θ v bode (i, j) sa vypočíta pomocou nasledujúcich vzťahov:

$$V_x(i, j) = \sum_{u=i-\frac{W}{2}}^{i+\frac{W}{2}} \sum_{v=j-\frac{W}{2}}^{j+\frac{W}{2}} 2\delta_x(u, v)\delta_y(u, v) \quad (2.8)$$

$$V_y(i, j) = \sum_{u=i-\frac{W}{2}}^{i+\frac{W}{2}} \sum_{v=j-\frac{W}{2}}^{j+\frac{W}{2}} \delta_x^2(u, v)\delta_y^2(u, v) \quad (2.9)$$

$$\theta(i, j) = \frac{1}{2} \tan^{-1} \frac{V_y(i, j)}{V_x(i, j)} \quad (2.10)$$

4. Aby sa eliminovala nespojitosť medzi jednotlivými blokmi, smerová mapa sa rozdelí na sínusové a kosínusové komponenty, ktoré sa následne vyhľadia Gaussovym filtrom s rozmerom $w_\phi \times w_\phi$.

$$\phi_x(i, j) = \cos(2\theta(i, j)) \quad (2.11)$$

$$\phi_y(i, j) = \sin(2\theta(i, j)) \quad (2.12)$$

$$\phi'_x(i, j) = \sum_{u=-\frac{w_\phi}{2}}^{\frac{w_\phi}{2}} \sum_{v=-\frac{w_\phi}{2}}^{\frac{w_\phi}{2}} G(u, v)\phi_x(i - uw, j - vw) \quad (2.13)$$

$$\phi'_y(i, j) = \sum_{u=-\frac{w_\phi}{2}}^{\frac{w_\phi}{2}} \sum_{v=-\frac{w_\phi}{2}}^{\frac{w_\phi}{2}} G(u, v)\phi_y(i - uw, j - vw) \quad (2.14)$$

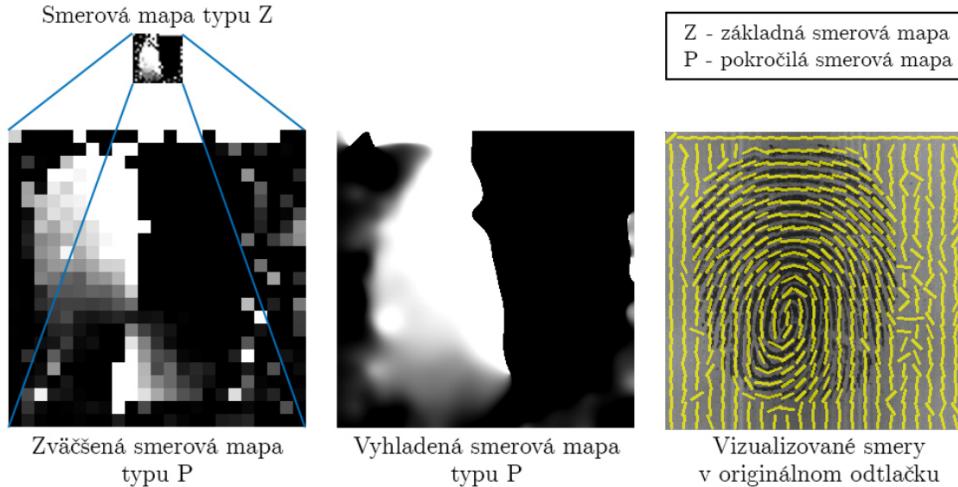
5. Výsledná smerová mapa sa vypočíta nasledujúcim vzťahom (smer pre pixel so súradnicami (i, j)):

$$O(i, j) = \frac{1}{2} \tan^{-1} \frac{\phi'_y(i, j)}{\phi'_x(i, j)} \quad (2.15)$$

Smerová mapa rozdelená do blokov nevhodnej veľkosti môže mať negatívny vplyv na predspracovanie, vzniká tzv. blokový efekt, kedy sa smer medzi susednými blokmi skokovo mení. Z toho dôvodu sme v našej práci vypočítali dva druhy smerovej mapy.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

- *Mapa Z* (základná), vyjadruje smery v blokoch odtlačku, je menej presná.
- *Mapa P* (pokročilá), vyjadruje smer každého jedného obrazového bodu, veľmi presná a v neskoršej fáze tak dovoľuje Gaborovmu filtrovi obnoviť aj oblasti v nadmerným zakrivením papilárnych línii.

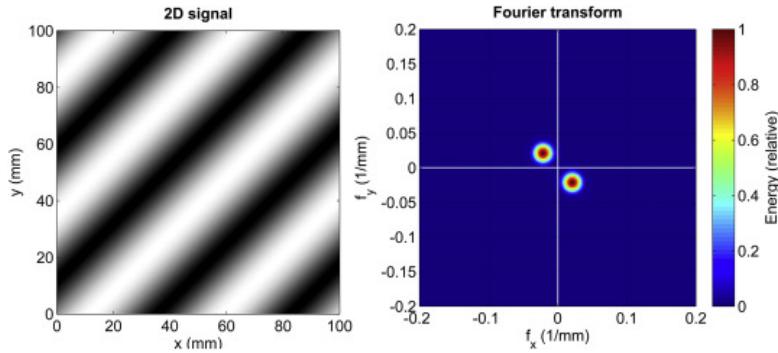


Obr. 2.41: Vizualizované matice základnej (Z) a pokročilej (P) smerovej mapy

V literatúre existujú aj iné prístupy k výpočtu smerovej mapy. Väčšina z nich je založená na odhade smeru získanom z výpočtu obrazových gradientov, podobne ako vyššie spomínaný popis. Iné metódy využívajú rôzne smerové filtre. Vytvorí sa sada rôzne orientovaných filtrov a všetkými sa prefiltrujú obrazové bloky odtlačku. Dominantný smer v bloku odtlačku sa určí pomocou nájdenia filtra, ktorý dosiahol po aplikácii na obraz najvyššiu odozvu. Výhodou tohto prístupu je, že je odolnejší voči šumu.

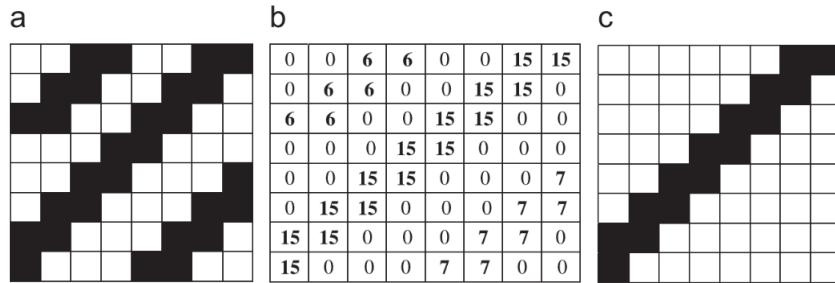
V literatúre sa však objavujú aj metódy vychádzajúce z frekvenčného spektra obrazu. Napríklad autori v [75] sa pozerajú na obrázok odtlačku ako na povrch, ktorý je výškovo modulovaný funkciou sínus. Fourierove spektrum obrazu odtlačku má preto dva významné vrcholy, ktoré sú symetrické podľa stredu obrazu (vid' obrázok 2.42). Smer kolmý na spojnicu spájajúcu tieto dva vrcholy určuje smer papilárnych línii. Obrázok najprv rozdelili na malé bloky 32×32 . Aplikovali rýchlu Fourierovu transformáciu na každý jeden z nich. Detegovali dve maximá v spektre bloku a vypočítali smer kolmice na spojnicu, ktorá ich spájala.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE



Obr. 2.42: Fourierove spektrum (vpravo) obrazového bloku odtlačku (vľavo)

Iným prístupom odhadu smeru je využitie projekcie papilárnych línií [76]. Najprv sa obrázok odtlačku rozdelí na malé štvorcové bloky a potom sa pomocou PCNN (z angl. pulse coupled neural network) neurónovej siete odhalí tzv. primárna papilárna línia v bloku (dominantná línia určujúca smer bloku). PCNN odhaluje primárne línie v binarizovaných obrazových blokoch. Neurónová sieť je skonštruovaná tak, aby jej výstupné neuróny reagovali na obrazové body primárnej papilárnej línie vysokými hodnotami (viď obrázok 2.43). Následne sa určia 4 základné smery v bloku (horizontálny, vertikálny a dva diagnoálne). Vypočítá sa projekcia primárnej papilárnej línie na každý jeden zo 4 základných smerov (vypočítajú sa vzdialenosť obrazových bodov). Konečný smer primárnej línie sa určí ako ten zo základných smerov, ktorý dosiahol projekciu s najmenším rozptylom vzdialenosť od primárnej línie.



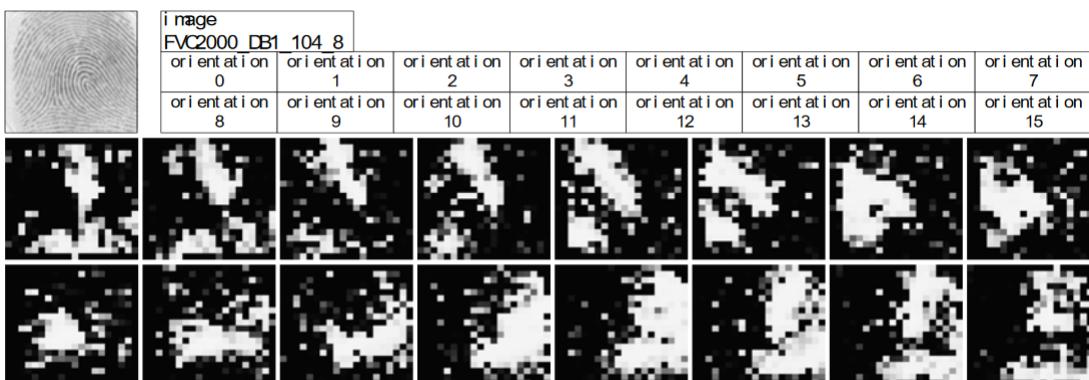
Obr. 2.43: Odhalenie primárnej papilárnej línie pomocou PCNN siete, (a) pôvodný obrazový blok, (b) matica výstupu PCNN siete a (c) blok s odhalenou primárhou papilárnu líniou [76]

Smerová mapa odtlačku sa dá vypočítať s pomocou neurónovej siete aj iným spôsobom. Jeden z najznámejších algoritmov využívajuci tento princíp [77] využíva doprednú sieť s 11 vstupnými, 11 skrytými a 1 výstupným neurónom na klasifikáciu smeru papilárnej línie. Obraz je rozdelený do blokov a pre každý blok je vypočítaný vektor príznakov s 11 prvkami $\langle C_1, C_2, \dots, C_{11} \rangle$. Príznaky tohto vektora majú blízky vzťah s orientáciou línií v bloku. Každý blok je 16-krát zrotovaný, pričom k -ta rotácia sa dá vyjadriť ako

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

$k\pi/16$, kde $0 \leq k < 16$. Dokopy sa teda pre jeden obrazový blok vypočíta 16 vektorov príznakov pre každú rotáciu bloku zvlášť. Algoritmus postupne prechádza bloky obrazu a pri každom bloku odovzdá 16 vypočítaných príznakových vektorov do neurónovej siete a získa sa 16 výstupných hodnôt. Dobre natrénovaná sieť zvykne odpovedať vysokými hodnotami na tie vektory, ktoré zodpovedajú skutočnej orientácii papilárnych línií v bloku. Autori práce opisujú svoj postup v týchto krokoch:

1. Rozdelenie obrazu do blokov, výpočet 16 príznakových vektorov (rôzne rotácie bloku) pre každý blok a aplikovanie neurónovej siete na každý vektor (vid' obrázok 2.44). Týmto spôsobom sa získa 16 výstupných matíc. Každá matica obsahuje bloky s vyššími hodnotami, ktoré odhaľujú miesta so správne odhadnutým smerom.
2. Filtrovanie výstupov z neurónovej siete pomocou tzv. low-pass filtra na odstránenie šumu.
3. Každý obrazový blok má pridelených 16 hodnôt z neurónovej siete, pričom každá hodnota zodpovedá inému smeru. Výber správneho smeru sa vykoná zvolením najvyššej z týchto hodnôt a zistením, pre ktorý príznakový vektor bola vypočítaná.



Obr. 2.44: Výstupy neurónovej siete určenej na odhad smeru v odtlačku (neurónová sieť bola aplikovaná na príznakové vektory blokov obrazu, každý blok bol 16-krát zrotovaný a tak sa vytvorilo 16 verzií príznakových vektorov a každá výstupná matica neurónovej siete tak odhaľuje miesta v odtlačku, kde sa nachádza konkrétny smer)[77]

Frekvenčná mapa

Počas analýzy odtlačkov zistujeme ďalšiu dôležitú vlastnosť a tou je frekvencia papilárnych línií. Frekvencia papilárnych línií hovorí o hustote výskytu línií v malom obrazovom bloku. Využívaju ju Gaborov filter ako jeden zo svojich vstupných parametrov. Jeden z komponentov Gaborovho filtra je aj funkcia kosínus, ktorá musí byť nastavená na správnu frekvenciu, aby filtrovanie nepoškodilo papilárne

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

línie (umelé zúženie alebo rozšírenie línie). Výstupom algoritmu na odhad frekvencie papilárnych línií je tzv. frekvenčná mapa. Na obrázku 2.45 vidíme odtlačky prstov a k nim prislúchajúce frekvenčné mapy. Svetlé farby označujú miesta s vyššou hustotou papilárnych línií.



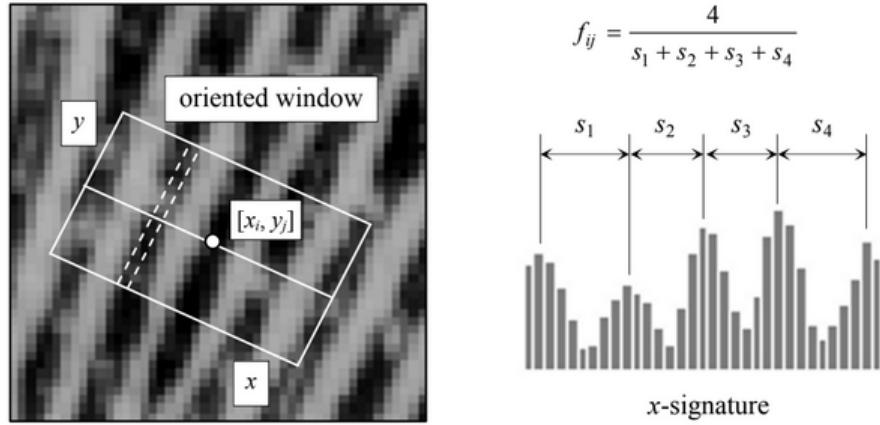
Obr. 2.45: Ukážky frekvenčnej mapy odtlačku (svetlé miesta vo frekvenčnej mape určujú oblasti s vysokou hustotou papilárnych línií)[29]

Najznámejšou metódou výpočtu frekvenčnej mapy odtlačku je metóda označovaná ako X-signature [29]. Lokálna frekvencia f_{ij} v bode (i, j) sa vypočíta podľa tohto postupu:

1. Vytvorí sa virtuálne orientované okno s rozmermi 32×16 so stredom v bode (i, j) . Toto okno je tak otočené, aby jeho y-ová os bola súbežná so smerom papilárnych línií.
2. Následne sa vypočíta vektor $x-signature$, ktorý predstavuje profil lokálneho jasu odtlačku v smere kolmom na papilárne línie v bloku. Hodnoty tohto vektora sú získané scítaním všetkých jasových úrovní v jednotlivých stĺpcoch orientovaného okna. Takýmto spôsobom sa zvýši odolnosť metódy voči šumu.
3. Konečná hodnota f_{ij} sa určí ako prevrátená hodnota priemernej vzdialenosť medzi dvomi po sebe idúcimi vrcholmi papilárnych línií.

Táto metóda môže byť nepresná v prípade obrazu s vysokou mierou šumu, kde je obtiažne získať hodnoverný profil jasu vo vektorze $x-signature$. Preto sa odporúča do tohto postupu zakomponovať nízko-priepustné filtrovanie a interpoláciu. Orientované okno spolu s vektorom $x-signature$ sú znázornené na obrázku 2.46.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

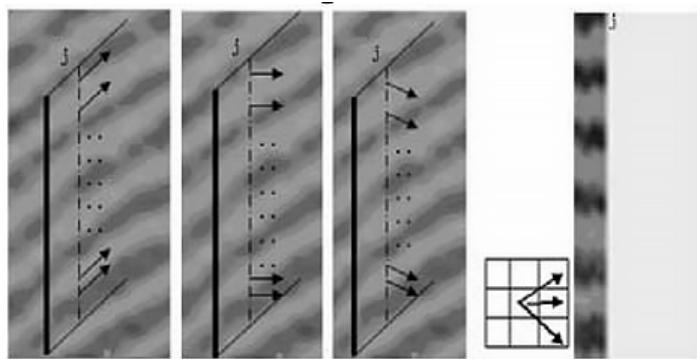


Obr. 2.46: Metóda X-signature na výpočet frekvenčnej mapy odtlačku. Vľavo vidíme orientované okno a vpravo je znázornený vektor x – *signature* s vrcholmi jasového profilu vo vybranom mieste odtlačku [29]

S vylepšením tejto metódy prišli autori Zhang, L. a kol. v práci [80]. Predstavili metódu výpočtu frekvencie papilárnych línií založenú na sledovaní priebehu papilárnej línie. Hlavné kroky ich algoritmu sú:

1. Rozdelenie obrazu do blokov a určenie štartovacej úsečky pre každý blok. Táto úsečka by mala prechádzať čo najväčším počtom papilárnych línií. V každom bloku sú na výber dve úsečky, jedna horizontálna a jedna vertikálna. Pre ďalšie fázy algoritmu sa zvolí tá úsečka, ktorej obrazové body dosahujú najvyšší rozptyl.
2. Pomocou sledovacej funkcie vieme sledovať tvar papilárnej línie. Štartovacia úsečka tvorí štartovaciu líniu, od ktorej začíname sledovať všetky papilárne línie, ktoré z nej vychádzajú. Pri sledovaní sa vždy pohneme do jedného z 3 rôznych smerov: rovno alebo do diagonálnych smerov. Výber smeru sledovania určí výsledok globálnej optimalizačnej funkcie. Postupným sledovaním papilárnych línií vyplňame tzv. smerové okno obrazovými bodmi, ktoré nakoniec bude predstavovať priebeh papilárnych línií v malom obrazovom bloku. Výhodou tohto smerového okna je, že aj zakrivené papilárne línie sa v ňom javia ako rovné a to nám následne pomôže ľahko určiť ich hustotu. Obrázok 2.47 ukazuje 3 rôzne smery sledovania papilárnych línií a postupné vyplňanie smerového okna.
3. Transformačný model aplikovaný na smerové okno. Zakrivenie papilárnych línií spôsobí, že vzdialenosť medzi líniami v smerovom okne sú skreslené. Autori navrhli matematický prepočet vypočítanej vzdialosti na skutočnú vzdialosť.

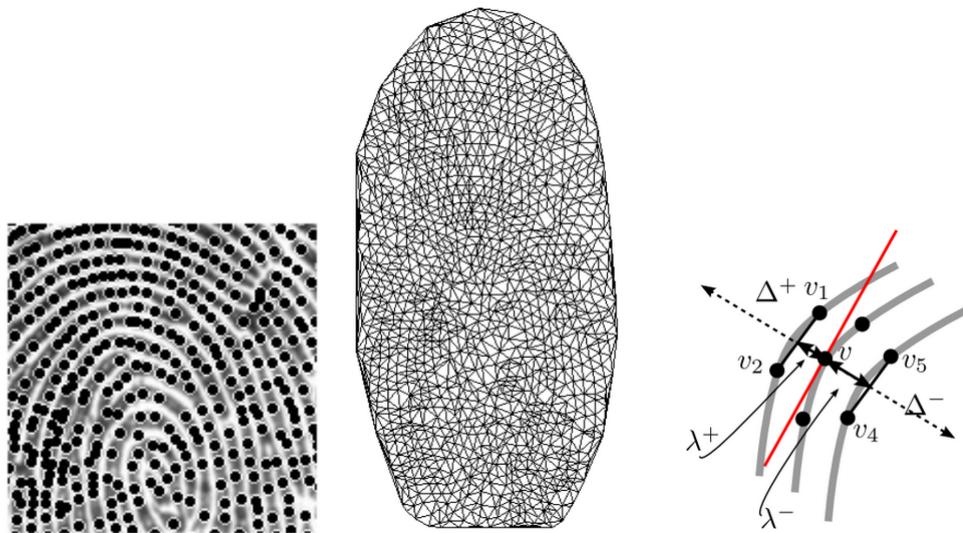
2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE



Obr. 2.47: Sledovanie papilárnych línii v 3 rôznych smeroch a postupné vyplňanie smerového okna (úplne vpravo) slúžiaceho na výpočet vzdialenosť medzi papilárnymi líniami [80]

Ďalšia, principiálne odlišná metóda na výpočet frekvencie papilárnych línii v odtlačku bola prezentovaná v práci [81]. Tu bol navrhnutý kompletný algoritmus predspracovania odtlačku založený na anizotropnom filtrovi, ktorý na dosiahnutie svojho účinku potrebuje byť parametrizovaný práve lokálnou frekvenciou papilárnych línii. Tá je vypočítaná tak, že sa v obrazu lokalizujú body s lokálnym minimom jasu (vrcholy papilárnych línii) a z nich sa vytvára Delaunayova triangulácia. Postup výpočtu frekvenčnej mapy sa dá zhrnúť do nasledovných bodov:

1. Extraktia bodov s lokálnym minimom jasu. Obraz sa rozdelí do malých štvorcových blokov a v každom bloku sa zvolí jeden bod s najmenším jasom. Tieto body by mali s vysokou pravdepodobnosťou ležať na papilárnej líni. Na obrázku 2.48 vľavo vidíme rozmestnenie bodov s lokálnym minimom jasu.
2. Z bodov s lokálnym minimom jasu sa následne štandardným spôsobom skonštruuje Delaunayova triangulácia a získame tak grafový model odtlačku vo forme navzájom prepojených vrcholov. Na obrázku 2.48 v strede vidíme Delaunayovu trianguláciu pokrývajúcu plochu odtlačku.
3. Výpočet frekvencie papilárnych línii. Každý bod v Delaunayovej triangulácii je prepojený s viacerými bodmi, ktoré budú patria do rovnakej papilárnej línie alebo do protiľahlej súbežnej línie. Cieľom je zmerať vzdialosť medzi zvoleným bodom v z triangulácie a všetkými susediacimi bodmi, ktoré ležia na protiľahlých líniah. V tomto procese zohráva dôležitú úlohu smerová mapa, pomocou ktorej určí smer kolmý na papilárnu líniu a podľa toho vieme približne v akom smeri sa nachádzajú protiľahlé línie v okolí bodu v . Najprv sa vytvorí virtuálna čiara orientovaná kolmo na priebeh papilárnej línie, na ktorej sa nachádza bod v . Táto čiara v určitom momente pretne susedné hrany triangulácie na obidvoch stranách. Zmeria sa vzdialosť medzi priesčníkmi a bodom v . Táto vzdialosť je považovaná za vzdialosť medzi susednými papilárnymi líniami a frekvencia je jej prevrátenou hodnotou. Celú situáciu vizualizuje obrázok 2.48 vpravo.



Obr. 2.48: Rozmiestnenie bodov s lokálnym minimom jasu (vľavo), korešpondujúca De-launayova triangulácia (v strede) a ilustrácia výpočtu vzdialenosť medzi papilárnymi líniami λ^+ a λ^- (vpravo) [81]

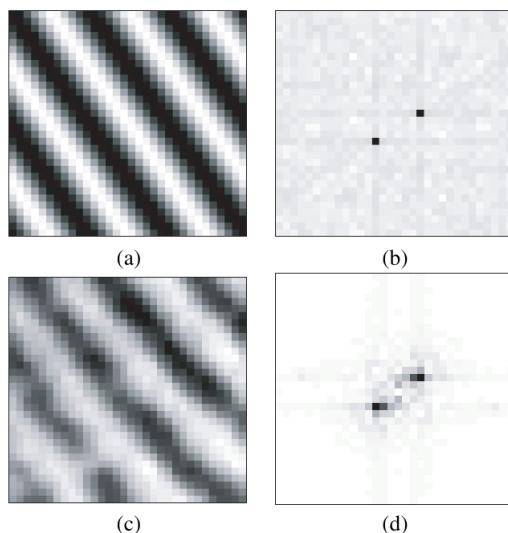
Adaptívny Gaborov filter

Predstavuje najdôležitejší krok v predspracovaní obrazu odtlačku prsta. Adaptívne filtre sú rodinou filtrov, ktorých vlastnosti sa dajú nastaviť podľa lokálneho kontextu odtlačku, t.j. smeru a frekvencie papilárnych línii a dosiahnu tak obnovu pôvodného vzoru. Obtiažne je však správne odhadnúť lokálny kontext odtlačku. Odtlačok je v prípade adaptívneho filtra reprezentovaný ako signál, ktorého parametre je potrebné správne odhadnúť. Obrázok 2.49 znázorňuje smerovú a frekvenčnú podobnosť medzi 2D sínusovým signálom a papilárny terénom. Ak sme schopní presne odhadnúť lokálny smer a frekvenciu v ľubovoľnom mieste odtlačku, tak dokážeme vyfiltrovať nevyhovujúce zložky obrazu a zvýrazniť pôvodný vzor.

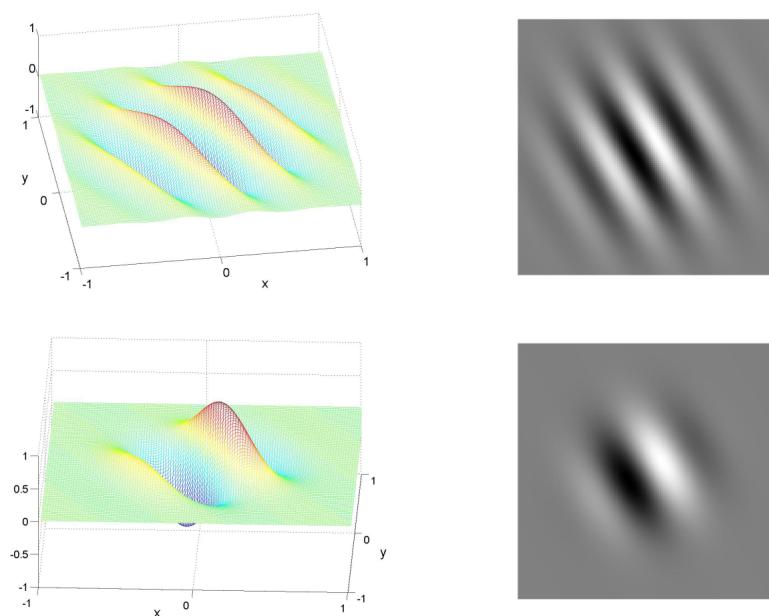
Najznámejším predstaviteľom je Gaborov filter, ktorý sa vie prispôsobiť lokálnej orientácii a frekvencii papilárnych línii a dosiahnuť tak obnovu znehodnotených vzorov. Filtrovanie prebieha po blokoch. Na každý blok obrazu je aplikovaný osobitný Gaborov filter (špeciálna matica koeficientov nazývaná aj kernel). Filtrovanie je teda výsledkom konvolúcie obrazového bloku odtlačku a Gaborovho kernelu vygenerovaného podľa odhadovaného lokálneho kontextu v danom mieste odtlačku. Obrázok 2.50 zachytáva Gaborove filtre s rozlišnými frekvenciami a smermi.

Gaborov filter funguje ako dolnopásmovej (z angl. low-pass) filter, ktorý eliminuje vysoké frekvencie (spôsobené najmä šumom) a naopak zvýrazňuje frekvencie zodpovedajúce hustote papilárnych línii. Filtrovací účinok Gaborovho filtra je zosilnený aj tým, že je ho možné prispôsobiť lokálnej orientácii papilárnych línii získanej zo smerovej mapy.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE



Obr. 2.49: Súvislosť medzi 2D sínusovým signálom a vzorom odtlačku prsta využívaná v adaptívnych filtroch (a/c obrázok 2D signálu/odtlačku, b/d frekvenčné spektrá 2D signálu/odtlačku) [66]



Obr. 2.50: Gaborove filtre s rôznymi smermi a frekvenciami [67]

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

Gaborov filter sa bežne požíva v spracovaní obrazu na detekciu rôznych obrazových príznakov takým spôsobom, že sa vypočíta jedna matica koeficientov filtra (kernel) a tá sa pomocou konvolúcie aplikuje na celý obraz. Takýto spôsob môžeme označiť ako neadaptívny, pretože sa filter použil na rôzne miesta v odtlačku s rovnakými parametrami.

V prípade adaptívneho filtrovania je situácia odlišná. Matica koeficientov Gaborovho filtra je vypočítaná individuálne pre každý obrazový bod, čo má za výsledok adaptáciu filtra aj v oblastiach s rôzny zakrivením a hrúbkou papilárnych línií. Uvedená vlastnosť filtra zabezpečuje presnosť obnovy papilárneho terénu, avšak na druhej strane je takýto spôsob filtrovania časovo náročný.

Matematický vzťah pre symetrický 2D Gaborov filter vyzerá nasledovne [20]:

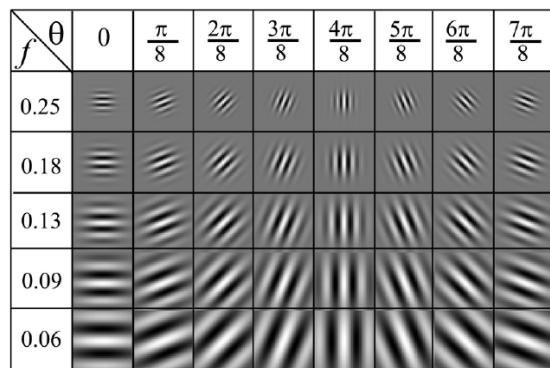
$$g(x, y : \theta, f) = \exp \left\{ -\frac{1}{2} \left[\frac{x_\theta^2}{\sigma_x^2} + \frac{y_\theta^2}{\sigma_y^2} \right] \right\} \cos(2\pi f x_\theta) \quad (2.16)$$

$$x_\theta = x \cos \theta + y \sin \theta \quad (2.17)$$

$$y_\theta = -x \sin \theta + y \cos \theta \quad (2.18)$$

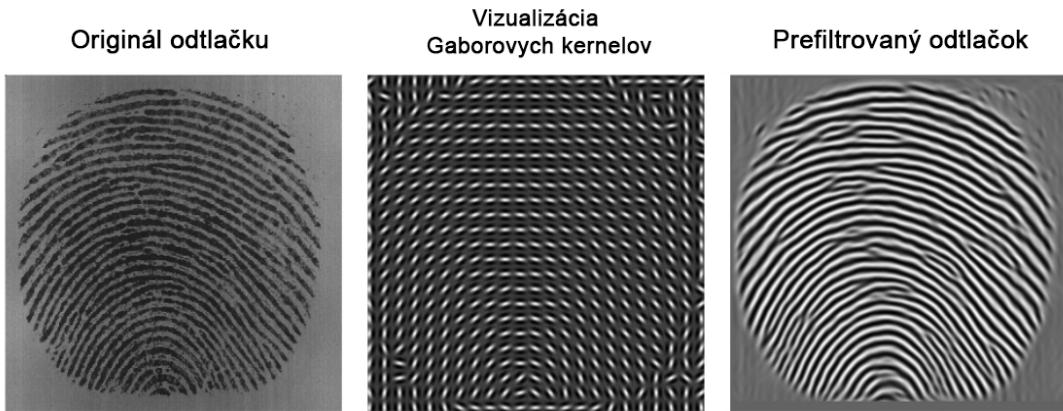
Popis parametrov vo vzťahu 2.16:

- θ je odhadovaný lokálny smer papilárnych línií
- f je odhadovaná lokálna frekvencia papilárnych línií ($f = 1/\lambda$), kde λ predstavuje priemernú lokálnu šírku papilárnej línie
- σ_x a σ_y sú smerodajné odchýlky Gaussovej krivky v smere osi x a y



Obr. 2.51: Kernely Gaborovho filtra pri rôznych smeroch a frekvenciách

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

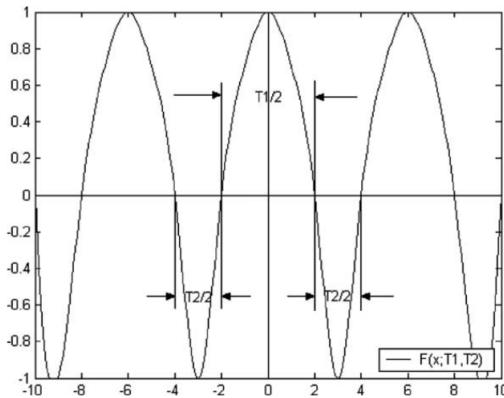


Obr. 2.52: Vizualizácia Gaborových kernelov v jednotlivých blokoch obrazu a výsledok filtrovania

V literatúre sa vyskytlo viacero modifikácií tohto filtra. Jednou z nich sú tzv. Log-Gabor filtre. Tieto filtre sú postavené na mierne odlišnom matematickom základe, ktorý odstraňuje limitácie pôvodného Gaborovho filtra. Obmedzením klasického Gaborovho filtra je, že nie je možné skonštruovať filter s ľubovoľnou šírkou pásma a pritom zachovať rozumne nízku hodnotu DC komponentu (vysoká hodnota DC komponentu spôsobuje, že odozva filtra závisí od priemerného jasu obrazu a to znamená, že odtlačky rôznych jasov nie sú prefiltrované rovnako kvalitne) [78]. Riešením je tzv. Log-Gabor funkcia, ktorá nemá žiadny DC komponent a je zložená z dvoch komponentov: radiálny a uhlový. Ich vynásobením získame Log-Gabor funkciu.

Podobne, autori v [79] upravili pôvodný Gaborov filter, aby zlepšili jeho možnosti prispôsobenia sa lokálnemu kontextu odtlačku. Nazvali ho ako modifikovaný Gaborov filter. Tento filter nastavuje svoje parametre podľa konkrétneho miesta v obraze a zlepšuje zachovanie pôvodnej obrazovej štruktúry. Pôvodný Gaborov filter využíva predpoklad, že papilárna línia je v priemere rovnako široká ako medzera medzi líniami. Avšak v praxi je tento predpoklad nesprávny, hlavne v miestach, kde bol odtlačok zosnímaný s vyšším prítlakom prsta na senzor. Na odstránenie tohto nedostatku bola v matematickej reprezentácii filtra nahradená funkcia kosínus novou periodickou funkciou. Nová periodická funkcia je zložená z ďalších dvoch kosínusových funkcií, pričom každá má inú períodu T_1 a T_2 , čo umožňuje prispôsobiť tvar filtra tak, aby mohol filtrovať obraz, v ktorom sa lísi šírka papilárnej línie od šírky medzery medzi líniami (viď obrázok 2.53). Aby bolo možné správne určiť T_1 a T_2 , musíme vedieť pre ľubovoľné miesto v odtlačku automatizované vypočítať šírku papilárnej línie a šírku prislúchajúcej medzery medzi dvoma líniami. Toto autori považujú za netriviálne a zostalo to len v rovine diskusie. Z toho dôvodu zostáva praktické nasadenie tohto typu filtra otázne a vyžaduje sa ďalší výskum. Na obrázku 2.54 vidíme výstup filtrovania tradičným a modifikovaným Gaborovym filtrom. Modifikovaný filter dosahuje viditeľne lepsie výsledky v miestach s premenlivou šírkou papilárnych línii.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

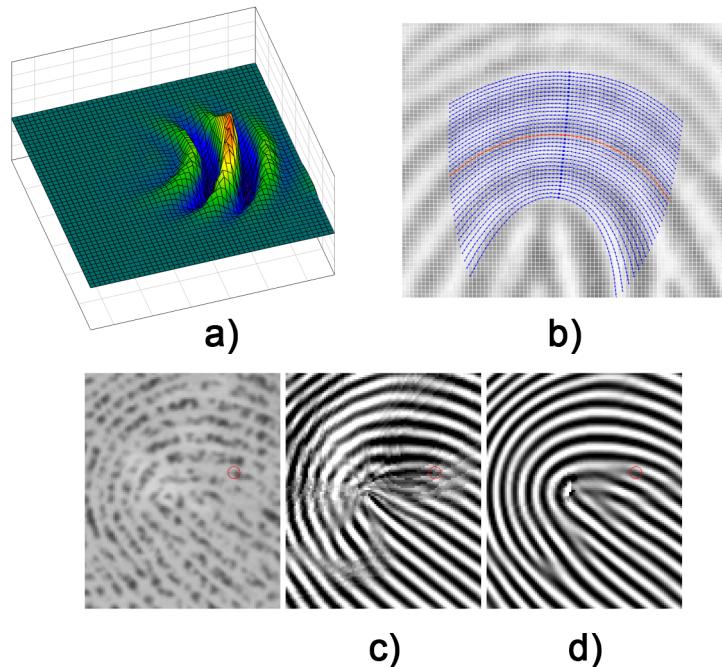


Obr. 2.53: Periodická funkcia s periódami T_1 a T_2 použitá v návrhu modifikovaného Gaborovho filtra [79]



Obr. 2.54: Porovnanie filtrovania odtlačku pomocou tradičného (vľavo) a modifikovaného (vpravo) Gaborovho filtra [79]

Nevýhodou štandardného Gaborovho filtra je jeho nedostatočný účinok v oblastiach odtlačku, kde dochádza k výraznému zakriveniu papilárnych línií. Odpoved'ou na tento problém sa stal tzv. zakrivený Gaborov filter predstavený v práci [68]. Zakrivený Gaborov filter dokáže lepšie prispôsobiť svoj tvar k tvaru papilárnych línií. Idea filtrovania je v tomto prípade založená na tzv. zakrivených regiónoch. Zakrivený región si môžeme predstaviť ako tradičný obdlžníkový blok, ktorého tvar je zakrivený podľa smeru prislúchajúcich papilárnych línií. Zakrivený región a jeho súradnice sa dajú matematicky vyjadriť. Obrazové body na súradničiach imaginárneho zakriveného bloku sa následne prenesú do klasického obdlžníkového bloku (matice) a prebehne štandardná konvolúcia tohto bloku s príslušným Gaborovym filtrom. Najnáročnejší je proces tvorby zakrivených regiónov. Na obrázku 2.55 vidíme zakrivený región, výsledok štandardného filtrovania odtlačku a filtrovania s použitím zakrivených blokov.



Obr. 2.55: Zakrivený Gaborov filter (a), zakrivený súradnicový systém (b) a výsledky filtrovania odtlačku zakriveným (c) a klasickým filtrom (d) [68]

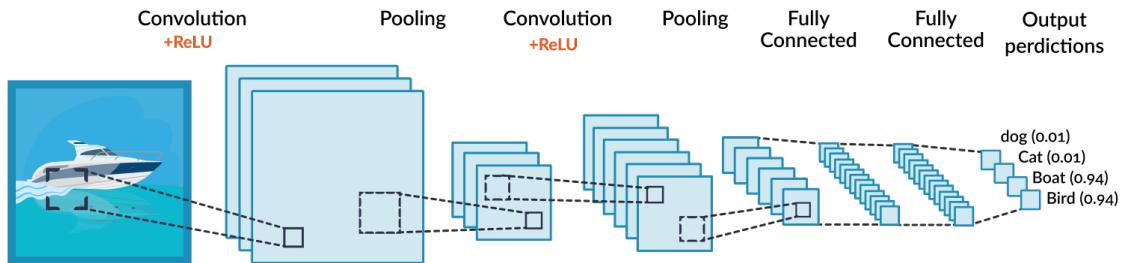
2.3.2 Aplikácia metód strojového učenia vo fáze extrakcie dakyloskopických vzorov

Neurónové siete nachádzajú čoraz väčšie uplatnenie aj v biometrii pri analýze a klasifikácii obrazových vzorov. V tejto práci sa zaobráme extrakciou dakyloskopických markantov a využívame pri tom hlbokú neurónovú sieť. Z toho dôvodu sme sa rozhodli v krátkosti priblížiť základné koncepty konvolučnej neurónovej siete a priblížiť výsledky vybraných prác, ktoré sú povahovo blízke nášmu výskumu.

Základné poznatky o hlbokých sieťach.

Jeden zo základných problémov počítačového videnia je klasifikácia obrázkov do preddefinovaných tried. V posledných rokoch sa ukázalo, že hlboké siete využívajúce viaceré vrstvy nelineárneho spracovania informácií túto výzvu dokážu prekonáť. Ako obzvlášť efektívne, sa pri analýze obrazových údajov preukázali konvolučné siete, ktoré na základe operácie konvolúcie obrazu s rôznymi typmi filtrov dokážu extrahovať vysoko-úrovňovú jedinečnú reprezentáciu, ktorá nezávisí od posunu, vzdialenosťi, rotácie alebo deformácie. Vo všeobecnosti hlboké konvolučné neurónové siete pozostávajú z konvolučných a prevzorkovacích (z angl. pooling) vrstiev, ktoré sú zoskupené viackrát za sebou, aby vytvorili hlboký model (ako ukazuje aj obrázok 2.56). Po nich nasleduje jedna alebo viac plne prepojených vrstiev, z ktorých posledná vytvára výstupnú triedu klasifikovania.

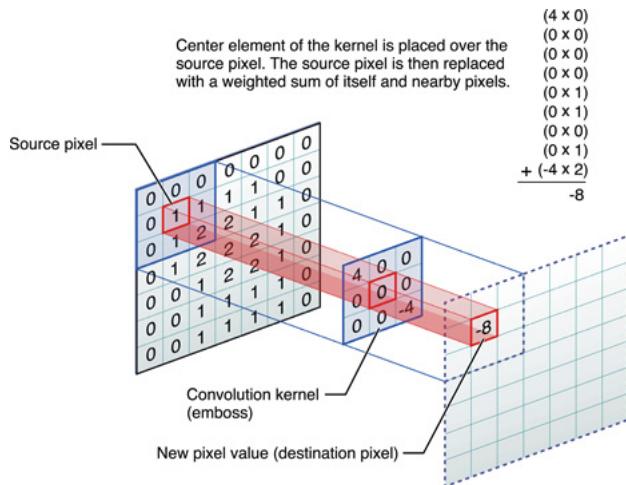
2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE



Obr. 2.56: Ukážka klasifikácie obrázku v konvolučnej neurónovej sieti

Konvolučné neurónové siete sa v prvých vrstvách snažia naučiť jednoduché vlastnosti, ako sú hrany a prechody medzi farbami. V ďalších vrstvách už reprezentujú čoraz komplexnejšie objekty a tvary.

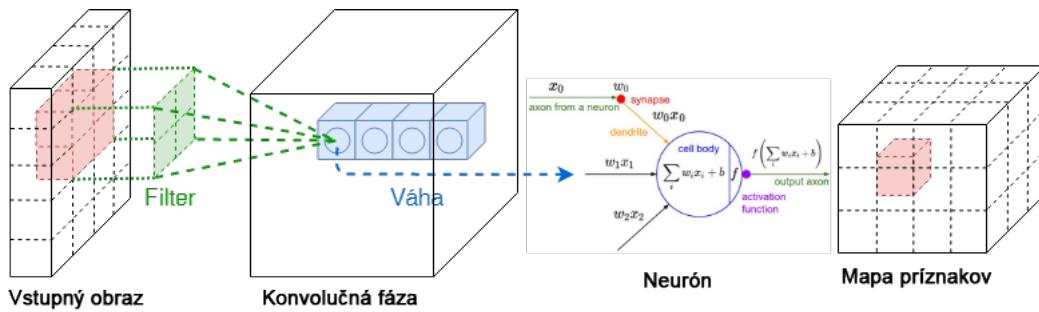
Konvolučná vrstva. Všetky konvolučné vrstvy obsahujú sadu filtrov. Každý filter má malé rozmer (niekoľkokrát menšie ako pôvodný obrázok). Operácia konvolúcie filtra a obrazu je znázornená na obrázku 2.57. Zopakovaním postupu zobrazeného na obrázku pre každý pixel prefiltrujeme celý vstupný obraz. Výsledkom konvolúcie každého použitého filtra je tzv. mapa príznakov (z angl. feature map). Takýmto spôsobom dokáže neurónová sieť zistiť, ktoré filtre sa aktivujú, keď odhalia nejaký typ vizuálnej charakteristiky (napr. hranu). Prvky v mape príznakov sú spracované pomocou neurónov, kde je každý neurón lokálne prepojený so susednými neurónmi v predchádzajúcej vrstve cez váhy. Na obrázku 2.58 je znázornená štruktúra konvolučnej vrstvy.



Obr. 2.57: Znázornenie princípu konvolúcie

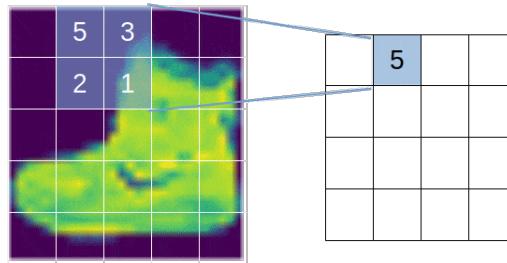
Prevzorkovacia vrstva. Táto vrstva sa zvyčajne umiestňuje medzi konvolučné vrstvy. Slúži na zmenšenie vstupu, znižuje množstvo parametrov a výpočtov v sieti.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE



Obr. 2.58: Štruktúra konvolučnej vrstvy neurónovej vrstve

Významom je zabezpečiť odolnosť vstupných dát voči transformáciám ako sú posun a rotácia. Najčastejšie využíva operáciu *Max* a veľkosť filtra 2×2 (obrázok 2.59).



Obr. 2.59: Ukážka operácie Max pooling pri využití filtra s veľkosťou 2×2

Plne prepojená vrstva. Názov tejto vrstvy hovorí o tom, že každý neurón vo vrstve je spojený s každým neurónom v nasledujúcej vrstve. Výstupy z konvolučných a prevzorkovacích vrstiev predstavujú vysoko-úrovňové vlastnosti vstupného obrazu. Plne prepojená vrstva využíva tieto vlastnosti na klasifikáciu obrazu do rôznych tried. Suma výstupných pravdepodobností všetkých tried bude mať vždy hodnotu 1. Toto zaručuje aktivačná funkcia *Softmax* vo výstupnej vrstve plne prepojenej časti hlbokej siete.

Okrem spomínaných vrstiev existujú aj ďalšie vrstvy (napr. ReLU) v niektorých architektúrach hlbokých neurónových sietí. Dôvodom vzniku nových sofistikovaných architektúr je snaha o zlepšenie presnosti klasifikácie obrázkov ako aj skrátenie času potrebného na trénovanie siete. Medzi najznámejšie architektúry patria: LeNet, AlexNet, ZF Net, Inception, VGG, ResNet, ResNeXt, Xception, DenseNet, RetinaNet a YOLO.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

Vybrané vedecké práce zamerané na využitie neurónových sietí v extrakcii daktyloskopických markantov

Spomedzi existujúcich riešení sme analyzovali tieto 4 aktuálne riešenia, ktoré demonštrujú rôzne spôsoby ako sa dajú využiť hlboké neurónové siete v oblasti extrakcie charakteristických vlastností odtlačku.

- **Modifikovaná Inception v4 sieť na reprezentáciu odtlačkov vo vektore príznakov s fixnou dĺžkou.** Autori v [82] použili hlbokú sieť na extrakciu viačerých vlastností ako sú daktyloskopické markanty, Level-1 znaky a informácie o textúre. Výhodou tohto riešenia je, že výstupom ich algoritmu je vektor príznakov s fixne určenou dĺžkou, čo zjednoduší následné porovnanie.
- **Hlboká sieť MENet určená na extrakciu markantov** popísaná v [83]. Jej autori zaviedli aj inovatívny spôsob tvorby trénovacích vzoriek, kde použili kombináciu existujúcich algoritmov na extrakciu markantov. Toto umožňuje bezproblémové a rýchle natrénovanie siete na ľubovoľnej databáze obrazov odtlačkov.
- **Dvojfázová hlboká sieť MinutiaeNet** popísaná v [84]. Táto sieť pracuje v dvoch fázach. V prvej fáze sa použije menšia sieť CoarseNet na odhalenie potenciálnych miest markantov (tzv. minutiae score map) a iných sekundárnych vlastností ako sú smerová mapa a segmentačná maska odtlačku. Následne v druhej fáze sa použije sieť FineNet, ktorá zo všetkých kandidátov na markanty vyberie len tie skutočné.
- **Hlboká sieť FingerNet** popísaná v [85]. Autori vytvorili komplexnú sieť, ktorá je primárne určená na extrakciu markantov. Prínosom tejto siete je, že jej autori pretransformovali tradičné algoritmy obrazového predspracovania do problémov, ktoré sú vyriešiteľné pomocou špeciálnych konvolučných sietí. Týmto spôsobom vznikla jedna sieť, ktorá v jednom celku integruje predspracovanie spolu s extrakciou a nepotrebuje žiadne pomocné externé algoritmy.

A. Modifikovaná Inception v4 sieť na reprezentáciu odtlačkov vo vektore príznakov s fixnou dĺžkou

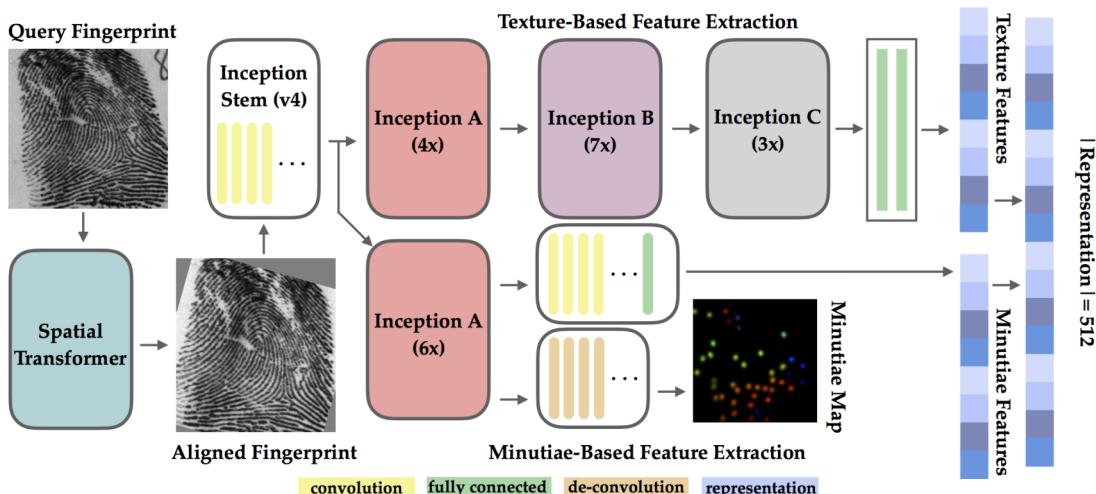
Hlavným prínosom práce [82] je neurónová sieť, ktorá je schopná sa naučiť jedinečnú reprezentáciu odtlačku pomocou príznakov s pevne stanovenou dĺžkou. Takéto riešenia sú zriedkavé, nakoľko je takmer vždy výstupom extrakcie vždy iný počet charakteristických príznakov.

Bola navrhnutá vlastná architektúra hlbokej neurónovej siete, ktorá bola odvodená od známej architektúry Inception v4. Vstupom do siete je obraz odtlačku s rozmermi 448×448 . Ten je následne odovzdaný do modifikovanej Inception v4 siete, ktorá bola rozdelená do 2 vetiev. Prvá vetva siete sa učí extrahovať informácie o textúre. Výsledkom je 256 prvkový vektor. Druhá vetva je určená na predikciu polohy a smeru daktyloskopických markantov. Výstupom druhej vetvy je mapa markantov, ktorá

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

pozostáva zo 6 matíc o rozmere 128×128 (v každej matici sú zachytené markanty iných smerov) a 256 príznakov odvodnených od vlastností markantov. Vyjadrenie odtlačkov prostredníctvom markantov je hlavný deskriptor odtlačku doplnený o pomocnú spomínanú informáciu o textúre. Výstupy oboch vetiev sú spracované v plne prepojených vrstvách a potom sú spojené. Finálna reprezentácia odtlačku je 512-rozmerný vektor (spojenie dvoch 256 prvkových príznakových vektorov), ktorý vznikne zlúčením oboch čiastkových reprezentácií z oboch vetiev siete.

Sieť je schopná aj porovnávať vypočítané príznakové vektory v Softmax vrstve, ktorá vypočíta pravdepodobnosť s akou patrí zvolený príznakový vektor do danej triedy (identita osoby). Autori na testovanie použili databázu odtlačkov NIST SD4 a dosiahli na nej úspešnosť identifikácie 97.9 %. Architektúra tejto siete je znázornená na obrázku 2.60.



Obr. 2.60: Modifikovaná sieť Inception v4 určená na extrakciu informácie o textúre a daktyloskopických markantoch v odtlačku [82]

B. MENet

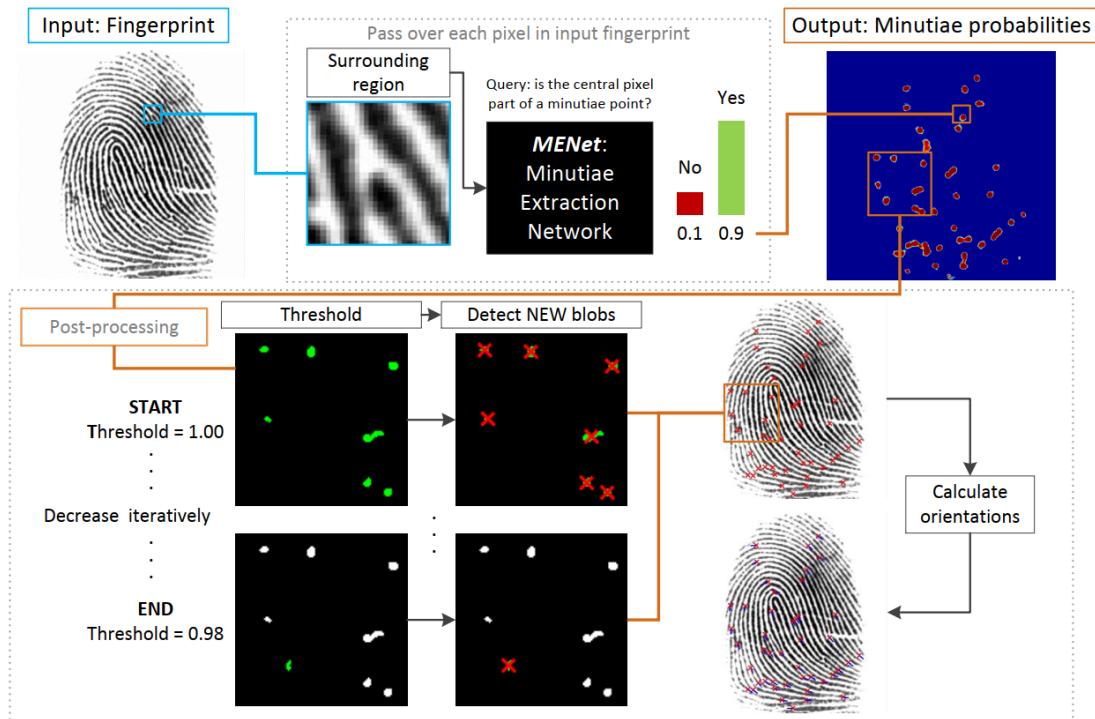
V tejto práci je extrakcia markantov realizovaná pomocou hľbokej siete MENet. Učenie neurónovej siete vychádza zo vzoriek, ktoré neboli zbierané ručne, ale softvérovo za pomoci kombinácie viacerých extrakčných SDK. Takto je možné automatizované natrénovať sieť prakticky okamžite na dodanej databáze odtlačkov.

Na obrázku 2.61 vidíme schému predloženej metódy. Algoritmus postupuje po jednotlivých bodoch odtlačku.

1. Najprv sa okolo každého bodu vytvorí lokálne okno zachytávajúce blízke okolie.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

2. Následne je toto okno privedené na vstup MENet siete, ktorá pomocou dvoch Softmax vrstiev rozhodne o tom, či je centrálny bod okna bodom, ktorý tvorí daktyloskopický markant. Takto sa vytvorí mapa pravdepodobností pre každý obrazový bod odtlačku.
3. Nasleduje tzv. post-processing, v ktorom sa určia presné pozície markantov. Mapa pravdepodobností je prefiltrovaná mediánovým filtrom a následne je iteratívne aplikované prahovanie za účelom získania stredov zhlukov s vysokými pravdepodobnosťami. Tie sú na obrázku 2.61 znázornené červenými krížmi.
4. Na záver sa vypočítajú smery markantov klasickou gradientovou metódou, ktorá bola popísaná v tejto práci v sekcii 2.3.1.



Obr. 2.61: Schéma extrakcie daktyloskopických markantov s využitím siete MENet [83]

Sieť MENet je skonštruovaná z 5 konvolučných vrstiev, po ktorých nasledujú 2 plne prepojené vrstvy (každá 1024 neurónov). Softmax predstavuje výstupnú vrstvu. Každá konvolučná vrstva má 32 filtrov veľkosti 5×5 . Pooling je aplikovaný na výstupy prvých dvoch konvolučných vrstiev. Všetky neuróny okrem výstupnej vrstvy využívajú ReLU aktivačnú funkciu. Vstupom siete je obrazový blok s rozmerom 30×30 . Na implementáciu bola použitá softvérová knižnica TensorFlow.

Zber trénovacích vzoriek pre sieť MENet je automatizovaný použitím 4 komerčných a 1 open-source extraktora markantov. Každý extraktor nájde markanty v trénovacom

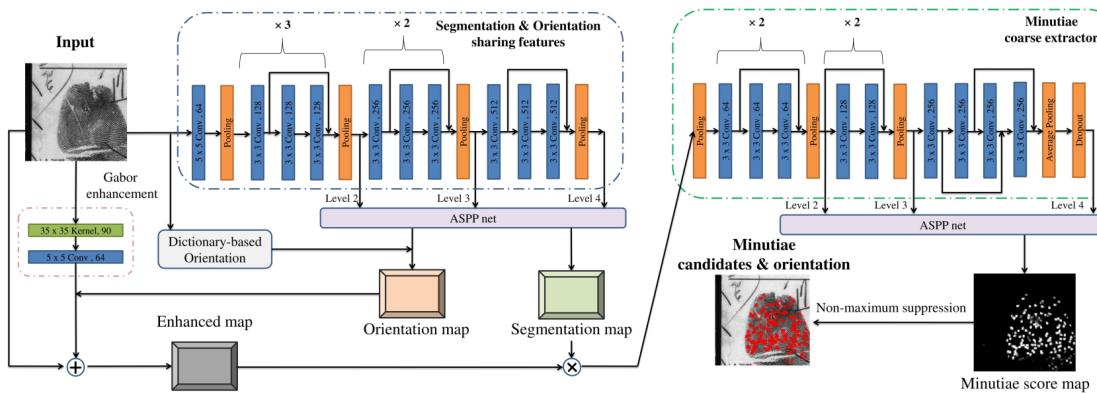
2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

obraze a okolo každého nájdeného markantu sa vytvorí kruhová maska reprezentujúca približné miesto výskytu markantu. Masky všetkých extraktorov sú spriemerované a za skutočné markanty sa zvolia tie oblasti v obrazu, kde sa všetky masky prekrývajú. Miesta, kde žiadny z extraktorov neodhalil markant sú použité ako negatívne trénovacie vzorky (miesta s absenciou markantu).

C. MinutiaeNet

MinutiaeNet je hlboká neurónová sieť pozostávajúca z 2 menších sietí:

- **CoarseNet.** Úlohou tejto siete je vypočítať mapu skóre markantov, t.j. mapu kandidátov na markanty. CoarseNet je konvolučná sieť založená na reziduálnom učení. Vstupom je celý obraz odtlačku. Na to, aby CoarseNet dokázal odhaliť kandidátov na markanty vykonáva niektoré postranné operácie ako segmentácia a odhad lokálneho smeru papilárnych línií, ktoré potom vstupujú do Gaborovho filtra. Všetky tieto operácie predspracovania sú vykonané špecializovanými modulmi konvolučnej siete. Podrobnú architektúru CoarseNet-u vidíme na obrázku 2.62.

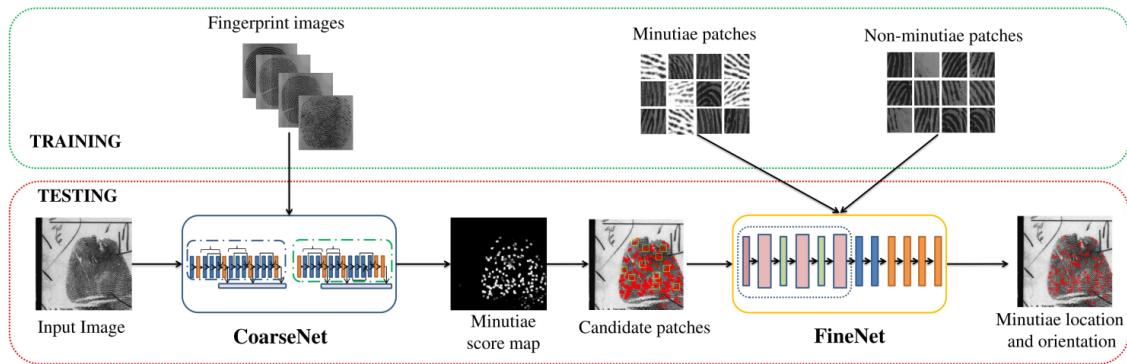


Obr. 2.62: Schéma siete CoarseNet [84]

- **FineNet.** Jej úlohou je klasifikovať každého kandidáta na markant a vytvoriť tak konečnú mapu markantov. FineNet je architektonicky postavená na báze známej siete Inception-ResNet. FineNet neurčuje tvarový typ markantu, len vyprodukuje mapu tvarovo nedefinovaných markantov.

Celková schéma extrakcie pomocou MinutiaeNet je ilustrovaná na obrázku 2.63. Takto navrhnutý systém bol testovaný na dvoch databázach FVC 2004 a NIST SD27. Úspešnosť rozpoznávania bola 85.9 % na databáze FVC 2004 a 71.2 % na databáze NIST SD27.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE



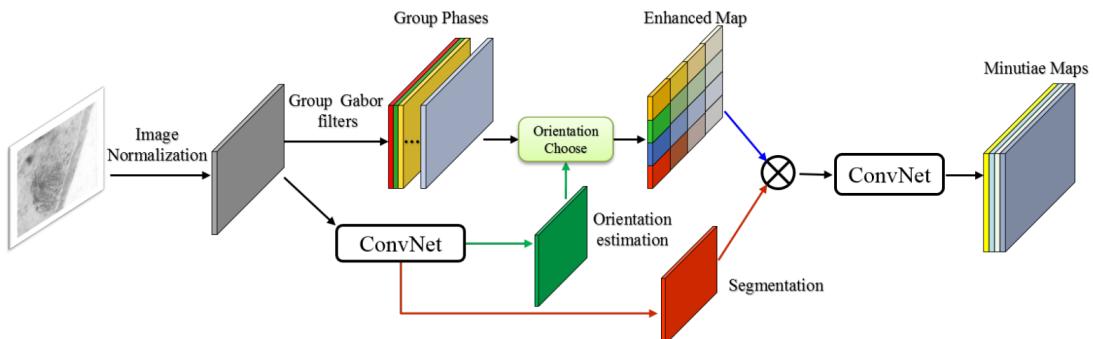
Obr. 2.63: Schéma siete MinutiaeNet [84]

D. FingerNet

Sieť FingerNet [85] bola vyvinutá predovšetkým za účelom spoľahlivej extrakcie markantov v latentných odtlačkoch. Autori tvrdia, že ich motiváciou bolo vytvorenie jednej siete, v ktorej sú integrované tradičné prístupy predspracovania odtlačkov prstov spolu s reprezentačnou schopnosťou hlbokej siete. Ich riešenie je zložené z dvoch časťí:

- **Základná FingerNet sieť.** V tejto sieti je skombinovaných viacero tradičných krokov (modulov):
 - segmentácia obrazu
 - výpočet smerovej mapy
 - filtrovanie obrazu
 - extrakcia markantov

Tieto operácie boli pretransformované do procesu konvolúcie so špeciálnymi kernelmi (maticami koeficientov filtra). Táto siet je pomerné plytká, neobsahuje veľký počet vrstiev. Výstupom je mapa markantov. Základnú siet vidíme na obrázku 2.64.



Obr. 2.64: Základná FingerNet siet [85]

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

- **Rozšírená FingerNet sieť.** Presnosť základnej siete nestačí pri spracovaní latentných odtlačkov, ktoré obsahujú množstvo šumu a plytká architektúra základnej siete nemá dostatočnú schopnosť vyjadriť dôležité vlastnosti odolné voči šumu. Preto bola základná sieť rozšírená o ďalšie konvolučné vrstvy, ktoré boli vložené do jednotlivých čiastkových modulov (obrázok 2.65):

- výpočet smerovej mapy - v rozšírenej verzii bol vytvorený odhad smeru pomocou tzv. multi-scale extrakcie príznakov.
- segmentácia obrazu - segmentácia zdieľa niektoré príznaky s odhadom smeru, v rozšírenej verzii sa umožnilo segmentácii zdieľať s odhadom smeru všetky multi-scale príznaky.
- filtrovanie obrazu - v tomto prípade sa používa rovnaký postup ako v základnej verzii FingerNet.
- extrakcia markantov - vstupom do tejto fázy sú výstupné mapy segmentácie a filtrovania obrazu a tie sú spracované v 3 konvolučných-pooling blokoch. Na výstupe sú vygenerované 4 mapy. Prvá mapa je tzv. minutiae score mapa, ktorá reprezentuje pravdepodobnosť, že bod (i, j) obsahuje markant. Druhá a tretia mapa sú mapy pravdepodobnosti správnej x-ovej a y-ovej súradnice. Vo štvrtej mape sú zakódované uhly markantov. Definitívny zoznam markantov sa získa prefiltrovaním minutiae score mapy s vhodnou prahovou hodnotou.

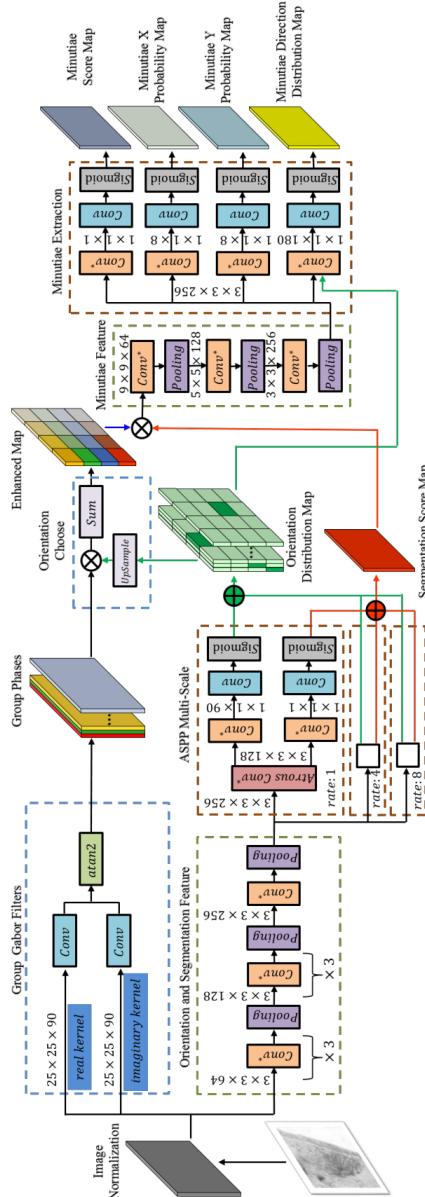
Celá FingerNet sieť bola natrénovaná na 8 000 tisíc párov zhodujúcich sa odtlačkov (pár tvoril klasický a latentný odtlačok). Obrázky mali rozmer 500×500 a rozlíšenie 500 PPI. Na každom obrázku expert vyznačil polohy markantov. Testovanie sa uskutočnilo na známych databázach FVC 2004 a NIST SD27. Na databáze FVC 2004 bola nepresnosť určenia polohy na úrovni 4.4 obrazového bodu a nepresnosť určenia smeru bola na úrovni 5° . Na databáze NIST SD27 bola nepresnosť určenia polohy na úrovni 3.4 obrazového bodu a nepresnosť určenia smeru bola na úrovni 6.4° .

2.3.3 Multimodálne biometrické systémy založené na odtlačkoch prstov a vzoroch žíl na prste

Multimodálne systémy sú v oblasti biometrie aktuálne veľmi populárnu tému. Zmyslom ich existencie je zvyšovanie presnosti rozpoznávania formou kombinácie viacerých biometrických vstupov (odtlačky prstov, vzory žíl, tvár, dúhovka, sietnica a ďalšie). Sú postavené na predpoklade, že súčasné využitie rôznych typov biometrických znakov dokáže vytvoriť reprezentáciu identity človeka, ktorej neopakovateľnosť je výraznejšia ako reprezentácia identity len pomocou jedného typu biometrického znaku. Navyše sú tieto systémy prirodzene odolnejšie voči falšovaniu identity.

V multimodálnych systémoch prichádza k fúzii viacerých biometrických znakov v rôznych fázach činnosti. Rozlišujeme nasledovné druhy fúzie [88].

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE



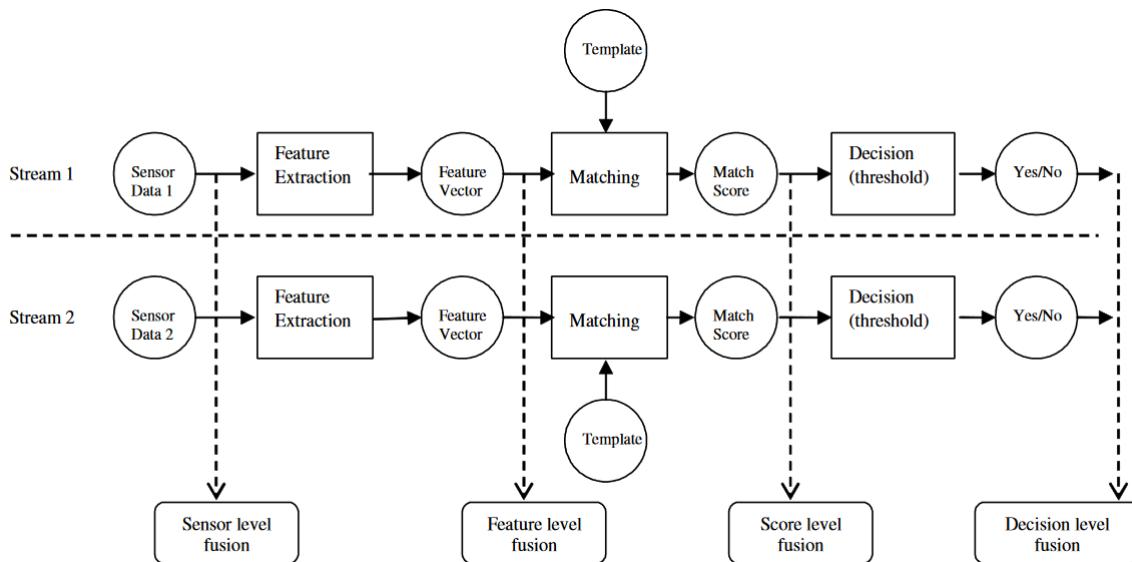
Obr. 2.65: Rozšírená FingerNet siet [85]

- fúzia na úrovni snímania (jeden typ biometrického znaku je zosnímaný rôznymi senzormi za účelom získania čo najvyššej kvality vstupu a odhalenia rôznych druhov vlastností)
- fúzia na úrovni extrakcie (využívajú sa rôzne typy biometrických znakov, pre každý typ znaku sa použije špecializovaný extraktor, ktorý vytvorí vektor príznakov a takto vytvorené vektory sa následne spoja do jedného spoločného)
- fúzia na úrovni porovnávacieho skóre (pre každý typ biometrického znaku existuje separátny porovnávací algoritmus, ktorý vypočíta svoje skóre podobnosti, finálne

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

porovnávacie skóre multimodálneho systému je získané kombináciou výstupov z porovnávacích algoritmov určených pre každý typ znaku)

- fúzia na úrovni rozhodovania (každý typ biometrického znaku má samostatný extraktor aj porovnávací algoritmus a vlastné rozhodnutie o rozpoznaní, k fúzii v tomto prípade dochádza pri tvorbe finálneho rozhodnutia, kde sa kombinujú jednotlivé rozhodnutia pre každý biometrický znak a určí sa spoločné definitívne rozhodnutie pomocou známych stratégii ako sú Majority Voting, Weighted Majority Voting, AND, OR a podobne).



Obr. 2.66: Úrovne fúzie v multimodálnom biometrickom systéme [88]

V rámci vlastného výskumu sme implementovali multimodálny biometrický systém (ako rozšírenie modulu na spracovanie odtlačkov prstov), ktorý je kombináciou spracovania odtlačkov prstov a obrazcov žíl na prste. Pri vývoji sme sa inšpirovali poznatkami prevzatými z niekoľkých vedeckých prác, ktorých prehľad uvádzame v nasledujúcich častiach. Pomocou nich vieme zhodnotiť aktuálny stav v problematike a dať našu prácu do kontrastu s inými publikovanými riešeniami. Práce zamerané na tému využívania kombinácie odtlačok prsta - vzor žíl na prste je minimálne množstvo a preto sme si zvolili práve túto výskumnú trajektóriu. Naša motivácia sa opiera taktiež aj o fakt, že na trhu sa objavili nové senzory umožňujúce zosnímať súčasne odtlačok prsta a jeho vzor žíl, čo dáva násemu výskumu aj rozmer praktického využitia. Populárnym senzorom tohto druhu je zariadenie M2-FuseID od spoločnosti M2SYS.

V nasledujúcim texte uvádzame prehľad vybraných prác zameraných na multimodálny systém založený na kombinácii odtlačku prsta a vzoru žíl na prste.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

A. Multimodálny systém kombinujúci odtlačky prstov a obrazce žíl s fúziou na úrovni extrakcie

Autori v práci [89] navrhli multimodálny systém, ktorý je založený na využití Level-2 znakov odtlačkov prstov a obrazových vlastností obrazcov žíl. Bola použitá fúzia na úrovni extrakcie, t.j. spojenia vektora Level-2 znakov a vlastností obrazcov žíl.

Vektor charakteristických znakov odtlačkov prstov pozostával z dvojíc Level-2 znakov (každý Level-2 znak tvoril dvojicu s ostatnými Level-2 znakmi v odtlačku). Pri každej dvojici bol zaznamenaný tvar, poloha a smer znakov, dĺžka spojnice medzi nimi a uhol, ktorý zviera smer Level-2 znaku so spojnicou.

V prípade spracovania obrazca žíl na prste sa najprv vykonalo jeho predspracovanie. Najprv sa extrahovala len tá časť obrazu, kde sa nachádzal vzor žíl (jednalo sa o obdĺžnikovú zónu). Následne sa zvýšil konvenčnými technikami kontrast. Extrakcia charakteristických príznakov bola realizovaná aplikovaním 40 rôzne nastavených Gaborových filtrov. Výsledkom bol vektor obsahujúci 983 040 ($256 \times 96 \times 40$) hodnôt. Na redukciu počtu hodnôt bola použitá lineárna diskriminačná analýza.

Takto vypočítané príznakové vektory boli binárne zakódované a následne spojené pomocou jednej z troch možností.

Možnosť 1. Obidva binárne kódované vektory sú spojené do nového vektora, ktorý je vstupom najprv do vlnkovej transformácie a následne do EP-DFT transformácie (Enhanced Partial Discrete Fourier Transform).

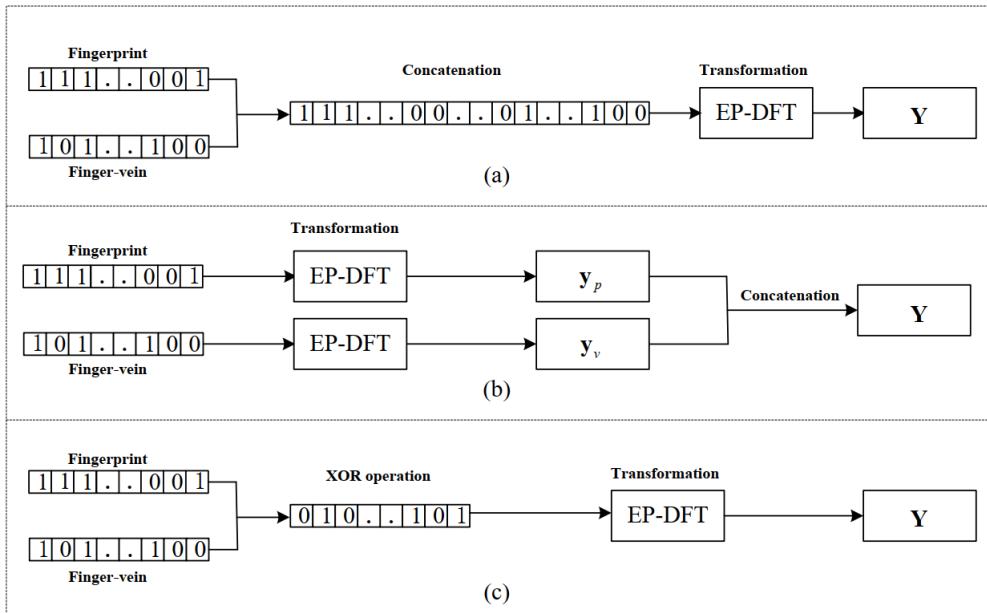
Možnosť 2. Každý binárne kódovaný vektor sa najprv spracuje samostatne pomocou vlnkovej a EP-DFT transformácie a takto získané výstupy sa spoja do jedného.

Možnosť 3. Obidva binárne kódované vektory sa spoja pomocou operácie XOR. Výsledok operácie je vstupom najprv do vlnkovej a potom do EP-DFT transformácie.

B. Hybridná fúzia odtlačkov prstov a obrazcov žíl na prste

V práci [90] bola predstavená hybridná fúzia na úrovni extrakcie aj porovnávania. Je založená na spojení vektorov extrahovaných príznakov z oboch typov biometrických znakov (odtlačok prsta aj obrazec žíl) a taktiež aj získaného skóre podobnosti vypočítaného porovnávacím algoritmom. Ako autori tvrdia, takýto druh fúzie zmenšuje výsledný vektor spoločných príznakov oboch biometrických znakov. Výsledky tejto práce sme analyzovali aj z toho dôvodu, že experimenty popísané v ich práci boli vykonané na multimodálnej databáze SDUMLA-HMT, ktorá bola použitá aj v tejto dizertačnej práci a tak vieme objektívne porovnať naše nadobudnuté výsledky s výsledkami nadobudnutými iným algoritmom.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE



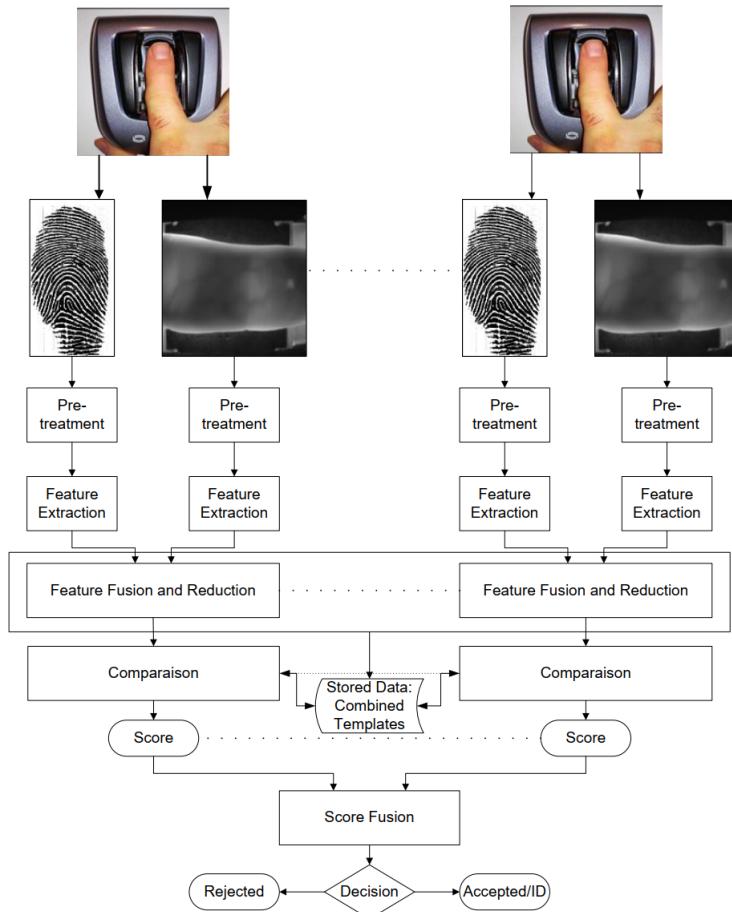
Obr. 2.67: Vizualizácia troch možností fúzie vektora príznakov odtlačku a obrazca žil na prste [89]

Návrh ich multimodálneho systému (znázornený blokovým diagramom na obrázku 2.68) spočíva v niekoľkých krokoch:

1. Predspracovanie odstraňujúce šum a extrakcia ROI (Region of Interest).
2. Extrakcia príznakov, ktoréj výsledkom je vektor, ktorého prvky vyjadrujú jedinečnosť oboch biometrických znakov. Bola použitá technika filtrovania Gaborovym filtrom. Boli použité viaceré orientácie a frekvencie filtra na zachytenie rôzne veľkých kontúr v obrazu. Konkrétnie sa zvolilo 40 filtrov (8 orientácií a 5 frekvencií). Po aplikácii filtrov sa zlúčia všetky nadobudnuté amplitúdové frekvenčné charakteristiky prefiltrovaných obrazov a normalizujú sa tak, aby ich stredná hodnota bola 0 a rozptyl 1. Táto technika sa použije pre odtlačky prstov aj obrazce žil a vzniknú tak dva samostatné vektory, ktoré sú vstupom do ďalšieho kroku.
3. Fúzia a redukcia vlastností, ktorej úlohou je spojiť nadobudnutý vektor odtlačku prsta a obrazca žil. Po spojení vznikne množstvo redundantných údajov, ktoré je nutné redukovať. Na redukciu bola použitá metóda PCA (Principal Component Analysis) nasledovaná použitím metódy KFD (Kernel Fisher Discriminant Analysis).
4. Meranie vzdialenosť charakteristických vektorov pomocou Mahalanobisovej vzdialenosť. Táto technika sa použije na zmeranie vzdialenosť medzi dvomi vektormi, ktoré vzniknú po spojení opísanom v predchádzajúcim kroku.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

5. Fúzia výsledného skóre porovnania pomocou jednoduchých kombinačných metód ako sú súčet, priemer, súčin, minimim, maximum alebo medián.



Obr. 2.68: Blokový diagram multimodálneho systému, ktorý vykonáva fúziu vo fáze extrakcie príznakov a porovnávania [90]

Na experimenty sa použili údaje z databázy SDUMLA-HMT. Jedna identita bola vyjadrená pomocou 8 obrazov (2 zosnímané prsty z oboch rúk, pričom pri každom prste bol zaznamenaný obraz odtlačku ako aj obrazec žíl). Databáza obsahovala 106 rôznych identít. Každý biometrický znak bol zosnímaný 6 krát. Spolu bolo na experimenty použitých 5 088 obrazov ($8 \times 6 \times 106$). Polovica týchto údajov tvorila trénovaciu množinu a druhá polovica testovaciu množinu.

Experimenty boli vykonané v 5 scenároch:

1. scenár spočíval v testovaní unimodálneho režimu, v ktorom sa nevykonával ani jeden typ fúzie.
2. scenár spočíval v testovaní multimodálneho systému, v ktorom bola použitá len fúzia extrahovaných vlastností z odtlačku aj obrazca žíl daného prsta. Nakol'ko

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

bola každá osoba zastúpená pomocou 4 prstov, v experimente sa zvolil jeden z prstov.

3. scenár bol podobný ako 2. scenár, avšak nadobudnuté spojené vektory vlastností odtlačku prsta a obrazca žíl pre každý prst boli taktiež spojené do jedného výsledného vektora vlastností (všetky 4 prsty boli vyjadrené jedným spojeným vektorom vlastností).
4. scenár spočíval v testovaní multimodálneho systému, v ktorom bola použitá fúzia na úrovni porovnávacieho skóre. Pre odtlačky aj pre obrazce žíl bolo vypočítané samostatné skóre, ktoré sa nakoniec spojilo do jedného skóre.
5. scenár demonštruje hybridnú fúziu, ktorá je hlavným výsledkom danej práce. Spočíva v testovaní multimodálneho systému, v ktorom sú vykonané obidva druhy fúzie, Najprv sa spoja vektory vlastností odtlačkov prstov a obrazcov žíl pre každý prst (vzniknú tak 4 spojené vektory). Následne sa tieto vektory porovnajú s vektormi z databázy a vzniknú 4 hodnoty skóre, ktoré sa následne skombinujú do jedného spoločného skóre.

Výsledky unimodálneho systému ukázali, že obrazce žíl dosiahli lepsiu rozpoznávaciu úspešnosť ako odtlačky prstov. Testy multimodálneho systému zase odhalili, že fúzia extrahovaných vektorov dosiahla lepšie výsledky ako fúzia porovnávacieho skóre. Hlavným výsledkom bolo pozoruhodné zistenie, že hybridná fúzia (naraz použité obidva typy fúzie) dosiahla 0% chybovosť rozpoznávania na databáze SDUMLA-HMT. Tabuľka na obrázku 2.69 sumarizuje dosiahnuté výsledky v scenároch 3 až 5.

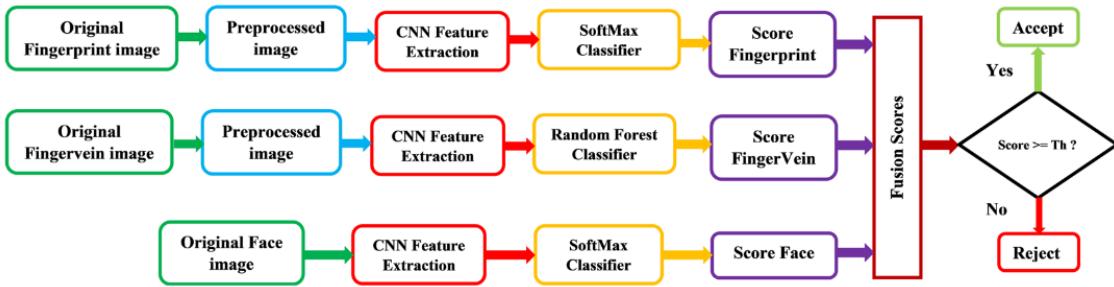
	Recognition Rate (%)	Equal Error Rate (%)	Verification Rate at 1% of False Acceptances Rate (%)	Verification Rate at 0.1% of False Acceptances Rate (%)	Verification Rate at 0.01% of False Acceptances Rate (%)
Features level fusion	100	0	100	100	100
Score level fusion	96.54	1.82	98	96	91
Hybrid	100	0	100	100	100

Obr. 2.69: Tabuľka úspešnosti rozpoznávania multimodálnym systémom založeným na odtlačkoch prstov a obrazoch žíl pri rôznych typoch fúzie [90]

C. Multimodálny biometrický systém založený na spracovaní tváre, odtlačku prsta a obrazca žíl pomocou konvolučnej neurónovej siete

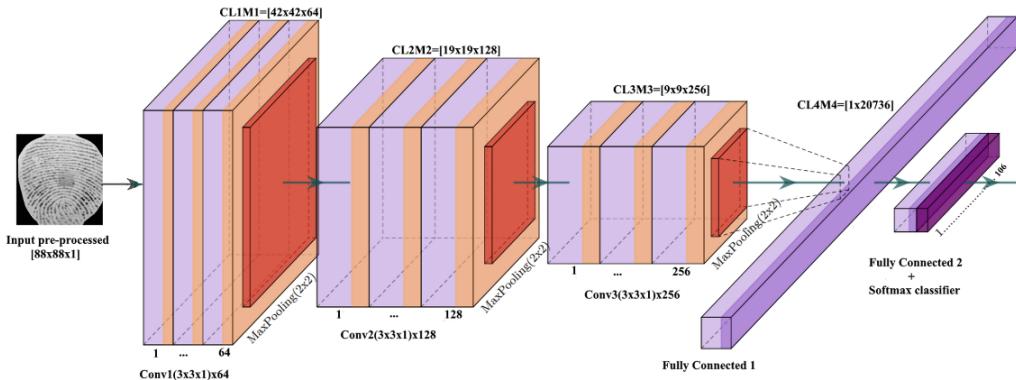
V práci [91] autori vytvorili hybridný multimodálny biometrický systém, ktorý kombinuje účinky troch známych metód v oblasti biometrie. Spomínané metódy sú konvolučné neurónové siete (CNN), Softmax a Random Forest (RF) klasifikátory. Multimodálny systém (obrázok 2.70) pracoval s odtlačkami prstov, obrazcami žíl na prste a obrazom tváre.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE



Obr. 2.70: Blokový diagram pre multimodálny biometrický systém založený na spracovaní tváre, odtlačku prsta a obrazca žíl pomocou konvolučnej neurónovej siete [91]

- Unimodálny systém pre odtlačky prstov najprv predspracoval obraz a pomocou algoritmu K-means a DBSCAN určil, ktoré časti obrazu patria do vzoru odtlačku, tzv. extrakcia ROI (Region of Interest). Charakteristické znaky odtlačku boli získané pomocou CNN a dropout techniky (technika vynechávania neurónov v sieti na prevenciu voči pretrénovaniu). Vstupná vrstva CNN mala rozmer 88×88 . CNN bola zložená z 3 konvolučných, 3 max-pooling, 3 ReLU a 2 plne prepojených vrstiev. Dropout pravdepodobnosť bola zvolená na úrovni 20 %. Znaky boli klasifikované pomocou Softmax funkcie (vrstva siete, ktorá priraduje každej triede jej pravdepodobnosť klasifikovania). Architektúra siete je na obrázku 2.71.



Obr. 2.71: Architektúra CNN pre extrakciu vlastností v odtlačku prsta [91]

- Unimodálny systém pre obrazce žíl na prste najprv extrahuje ROI pomocou Canbyho detektora, ktoré je následne odovzdané do CNN. Ako klasifikátor je použitá Random Forest metóda. Architektúra siete je znázornená tabuľkou na obrázku 2.72.
- Unimodálny systém pre tvár vytvorí a klasifikuje charakteristické vlastnosti pomocou CNN a Softmax funkcie. Architektúra siete je znázornená tabuľkou na obrázku 2.73.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

Type	Number of filter	Size of feature map	Filter size/stride
Convolution	64	58 × 150 × 1	3 × 3/1
ReLU	–	58 × 150 × 1	–
Max-pooling	1	29 × 75 × 64	3 × 3/2
Convolution	128	27 × 73 × 128	3 × 3/1
ReLU	–	27 × 73 × 128	–
Max-pooling	1	13 × 36 × 128	3 × 3/2
Convolution	256	11 × 34 × 256	3 × 3/1
ReLU	–	11 × 34 × 256	–
Max-pooling	1	5 × 17 × 256	3 × 3/2
Fully-connected	1	1 × 21760	–
Fully-connected	1	1 × 106	–

Obr. 2.72: Architektúra CNN pre extrakciu vlastností v obrazci žil na prste [91]

Type	Number of filter	Size of feature map	Filter size/stride
Convolution	32	88 × 88 × 1	3 × 3/1
ReLU	–	88 × 88 × 1	–
Max-pooling	1	44 × 44 × 32	3 × 3/2
Convolution	64	42 × 42 × 64	3 × 3/1
ReLU	–	42 × 42 × 64	–
Max-pooling	1	21 × 21 × 64	3 × 3/2
Convolution	128	19 × 19 × 128	3 × 3/1
ReLU	–	19 × 19 × 128	–
Max-pooling	1	9 × 9 × 128	3 × 3/2
Fully-connected	1	1 × 10388	–
Fully-connected	1	1 × 106	–

Obr. 2.73: Architektúra CNN pre extrakciu vlastností tváre [91]

Skóre nadobudnuté pomocou všetkých troch unimodálnych systémov bolo skombinované do jednej hodnoty. Boli použité 2 metódy fúzie skóre podľa vzťahov 2.19 a 2.20 (vážený súčet $Score_{ws}$ a vážený súčin $Score_{wp}$). Ak spojené skóre presiahlo rozhodovaciu prahovú hodnotu, tak osoba bola rozpoznaná, v opačnom prípade zamietnutá.

$$Score_{ws} = w_1 S_{FP} + w_2 S_{FV} + w_3 S_{FA} \quad (2.19)$$

$$Score_{wp} = S_{FP}^{w_1} \times S_{FV}^{w_2} \times S_{FA}^{w_3} \quad (2.20)$$

Testy boli vykonané na multimodálnej databáze SDUMLA-HMT. Celkovo bolo použitých 41 340 obrazov (všetky 3 druhy biometrických znakov). Z toho 33 072 na trénovanie, 4 134 na validáciu a 4 134 na testovanie. Testovali sa zvlášť všetky unimodálne systémy a z výsledkov sa dá dospieť k dvom hlavným záverom: úspešnosť rozpoznania bola vždy vyššia pri použití predspracovania a úspešnosť trénovania bola vždy vyššia pri použití dropout techniky.

Tabuľka 2.74 sumarizuje namerané úspešnosti rozpoznávania jednotlivých unimodálnych systémov v závislosti od použitého typu extraktora a klasifikátora.

2.3. SÚČASNÝ STAV V SKÚMANEJ PROBLEMATIKE

Tabuľka 2.75 sumarizuje namerané úspešnosti rozpoznávania rôznych verzií multi-modálneho systému (rôzne kombinácie troch biometrických znakov) v závislosti od použitej metódy fúzie skóre podobnosti jednotlivých biometrických znakov.

Table 10 The result of proposed system recognition unimodal biometric using CNN with different classifiers.

Classifiers	Fingerprint	Finger vein	Face
CNN & SoftMax	99.48%	99.27%	99.13%
CNN & SVM	97.65%	99.33%	97.88%
CNN & LR	85.61%	84.14%	92.43%
CNN & RF	97.33%	99.53%	91.95%

Obr. 2.74: Úspešnosti rozpoznávania unimodálnych systémov podľa zvoleného druhu extraktora a klasifikátora (SVM - Support Vector Machine, LR - Logistic Regression) [91]

Table 11 The result of proposed recognition systems using CNN with rules fusion.

Algorithms	Rules fusion	
	Weighted sum	Weighted product
Fingerprint _{CNN} & Fingervein _{CNN}	99.59	99.58
Fingerprint _{CNN} & Face _{CNN}	99.30	99.28
Fingervein _{CNN} & Face _{CNN}	99.20	99.17
Fingerprint _{CNN} & Fingervein _{CNN} & Face _{CNN}	99.73	99.70

Obr. 2.75: Úspešnosti rozpoznávania rôznych konfigurácií multimodálneho biometrického systému rozdelené podľa zvolenej metódy fúzie skóre podobnosti pre jednotlivé biometrické znaky [91]

Celkovo výsledky tejto práce ukazujú, že kombinácia odtlačkov prstov a obrazcov žil na prste môže byť základom veľmi presného biometrického systému. My sme sa rozhodli do tejto oblasti prispieť vlastným open-source multimodálnym systémom, ktorý extra-huje Level-2 znaky pomocou CNN a znaky obrazca žil sú extrahované SIFT/SURF metódami. Využili sme fúziu na úrovni porovnávania, t.j. spojenia skóre porovnania pomocou známych stratégií normalizácie a fúzie. Náš systém má navyše modulárnu architektúru, ktorá umožňuje bezproblémové testovanie kombinácií rôznych druhov predspracovania, extrakcie a porovnávania. Naše experimenty boli vykonané taktiež na známej SDUMLA-HMT databáze, čo dovoľuje priame porovnanie našich výsledkov s inými multimodálnymi systémami. Všetky dôležité návrhové a implementačné aspekty sú opísané v časti 3.

Kapitola 3

Realizácia vlastného výskumu

Táto kapitola práce obsahuje opis hlavných návrhových, implementačných ako aj testovacích aspektov nami vyvinutého autentifikačného systému OpenFinger, ktorý vie rozpoznať identitu osoby pomocou odtlačkov prstov, obrazcov žíl na prste alebo pomocou ich kombinácie. Konkrétnie nosné časti tejto kapitoly sú:

- Blokové diagramy reprezentujúce architektonickú stavbu celého systému v unimodálnom ako aj multimodálnom režime.
- Schémy jednotlivých unimodálnych subsystémov (zvlášť pre odtlačky prstov a obrazce žíl na prste) so špecifikáciou všetkých vnútorných procesov od predspracovania až po rozhodovanie o rozpoznaní. Výstupy kľúčových procesov sú dokumentované formou obrázkov, napr. výsledky filtrovania pomocou adaptívneho Gaborovho filtra alebo výsledky klasifikácie odhalených Level-2 znakov v obraze odtlačku prsta.
- Opis špecializovaného subsystému na automatizované vyhodnotenie úspešnosti rozpoznávania na dodanej databáze odtlačkov prstov a obrazcov žíl. Vieme tak jednoducho vyčísiť známe ukazovatele ako sú ROC, FAR/FRR a pod. na ľubovoľnej dodanej databáze biometrických údajov bez nutnosti použiť externý vyhodnocovací softvér. Zahrnutie vyhodnocovacieho/diagnostického systému takéhoto typu považujeme za značný prínos do skúmanej oblasti, nakoľko vieme nenáročnou a používateľsky prívetivou formou získať publikovateľné výsledky úspešnosti rozpoznávania osôb v štandardizovanej forme ako aj získať komplexnú spätnú väzbu pri uprávach a pridávaní novej funkcionality počas vývoja.
- Opis použitých softvérových a hardvérových prostriedkov pri vývoji a testovaní, postup pri inštalovaní.
- Opis použitých testovacích databáz obrazov odtlačkov prstov a obrazcov žíl na prste. Navyše, OpenFinger podporuje komunikáciu s vybranými senzormi odtlačkov prstov, čo rozširuje možnosti experimentovania.
- Opis expertných sprievodných aplikácií, ktoré sme vytvorili, aby bolo možné konfigurovať parametre systému OpenFinger bez nutnosti zásahov do zdrojového kódu a vizualizovať medzivýstupy spracovania. Práca obsahuje opis nášho vlastného interaktívneho nástroja na zber vlastných vzoriek pre účely trénovania konvolučnej neurónovej siete využitej v práci, konfiguráciu jej parametrov trénovania ako aj automatizovaná/manuálna kontrola predikcie natrénovaného modelu siete na vlastných údajoch s vizuálnou indikáciou výsledku presnosti klasifikácie.

3.1. NÁVRH SYSTÉMU OPENFINGER

- Zhodnotenie nadobudnutých výsledkov z pohľadu rýchlosťi spracovania údajov a presnosti rozpoznávania. Vyhodnotené sú CPU/GPU implementácie niektorých algoritmov ako aj namerané časy trvania operácií na bežnom laptopu a výkonného serveri. Pri vyhodnotení presnosti rozpoznávania sme sa zamerali na výčislenie štandardných ukazovateľov využívaných v biometrii ako sú ROC, FAR/FRR, Precision-Recall krivky alebo distribúcie skóre porovnávania. Presnosť rozpoznávania bola vyhodnotená zvlášť v unimodálnom a multimodálnom režime pri použití viacerých známych biometrických databáz. V prípade multimodálneho systému boli vykonané viaceré experimenty s použitím rôznych extraktorov vlastností obrazcov žil na prste a použitím odlišných metód normalizácie a fúzie porovnávacieho skóre.
- Vlastná klient-server aplikácia, v rámci ktorej bol náš systém OpenFinger nainštalovaný na školský výkonný server a preskúmali sa tak možnosti autentifikácie klientov vzdialene pripojených k serveru. Takýto scenár preukazuje vhodnosť nášho riešenia na priame aplikovanie do praxe.

3.1 Návrh systému OpenFinger

Táto práca sa zaoberá návrhom, implementáciou a testovaním systému OpenFinger s otvoreným zdrojovým kódom, ktorý slúži na rozpoznávanie osoby pomocou jej odtlačkov prstov a obrazcov žil na prstoch. Systém je koncipovaný ako zoskupenie 4 modulov.

- **Biometrický modul spracovania odtlačkov prstov** predstavuje kompletnej samostatne fungujúci unimodálny systém.
- **Biometrický modul spracovania obrazcov žil na prste** predstavuje kompletnej samostatne fungujúci unimodálny systém.
- **Modul fúzie**, ktorý spája skóre porovnania z obidvoch unimodálnych systémov a umožňuje tak multimodálny režim činnosti.
- **Modul automatizovaného vyhodnotenia úspešnosti** jednotlivých unimodálnych systémov ako aj multimodálneho systému (zloženého z oboch unimodálnych systémov, pri ktorých je využitá fúzia na úrovni porovnávania). Vypočítané ukazovatele sú vizualizované vo forme interaktívnych grafov.

Obidva biometrické moduly pracujú v troch hlavných fázach: predspracovanie, extrakcia charakteristických vlastností a ich porovnanie. Každá pracovná fáza je implementovaná ako samostatná dynamická softvérová knižnica, ktorá má jasne definované vstupné a výstupné komunikačné rozhranie, pomocou ktorého si vymieňa údaje s okolitými knižnicami.

3.1. NÁVRH SYSTÉMU OPENFINGER

Takáto modulárna architektúra umožňuje jej dobré testovanie, rýchle možnosti zámeny ktoréhokoľvek modulu alebo len niektornej pracovnej fázy modulu a možnosti bezproblémovej integrácie do iných systémov z dôvodu existencie jasne definovaného komunikačného rozhrania všetkých knižníc.

OpenFinger je kombináciou viacerých známych prístupov z relevantnej literatúry, ktorých implementácia bola k dispozícii. Využívame tiež prístupy dostupné v literatúre, ktoré boli zatiaľ len v teoretickej rovine a museli sme tak vytvoriť ich vlastnú softvérovú implementáciu. V práci sme navrhli a implementovali taktiež niekoľko vlastných algoritmov ako je modifikované adaptívne predspracovanie odtlačkov, vlastná schéma na extrakciu Level-2 znakov využívajúca hlbokú neurónovú sieť, vlastný kompletný algoritmus na predspracovanie obrazcov žil alebo vlastnú viac-vláknovú implementáciu známeho porovnávacieho algoritmu BOZORTH3. Inovatívny krokom bolo aj spojenie implementovaných biometrických modulov s modulom ich automatizovaného vyhodnotenia, čo umožňuje jednoducho publikovať výsledky testovania pri použití rôznych databáz a nastavení. Odborné komplexné open-source biometrické riešenia neboli v literatúre v čase písania tejto práce dostupné. OpenFinger bol vyvinutý pre 64-bitový operačný systém Linux. Testovanie prebehlo na distribúcii Debian a Manjaro.

3.1.1 Architektúra systému

V tejto časti sa zameriame na vysvetlenie základných princípov fungovania nášho autentifikačného systému OpenFinger z globálneho pohľadu. Celú architektúru systému OpenFinger zloženú zo 4 hlavných modulov zachytáva bloková schéma na obrázku 3.1. Systém je komplexom logicky prepojených dynamických knižníc, ktoré komunikujú medzi sebou a externým softvérom pomocou API rozhrania. Bloková schéma znázorňuje tieto logické prepojenia a môžeme pomocou nej pochopiť všetky dôležité procesy a štruktúru celého navrhnutého softvéru. Bloková schéma určuje komponenty, ktoré tvoria unimodálny aj multimodálny systém, znázorňuje prepojenie modulu automatizovaného vyhodnotenia úspešnosti s okolitými knižnicami ako aj prepojenie so senzormi odtlačkov prstov. Nás systém je nainštalovaný na vlastnom výkonného serveri (vybavenie servera je opísané v časti 3.3.3) s operačným systémom Debian 10, čo je hlavné testovacie prostredie. Vrstva externých knižníc, ktoré nás systém nevyhnutne potrebuje k svojmu behu zahŕňa knižnice ako Qt, OpenCV, Caffe, ArrayFire a iné.

Podrobnejší opis modulov systému OpenFinger:

- **Modul spracovania odtlačkov prstov (viac v sekcií 3.1.2).** Vstupom je obrázok odtlačku získaný priamo z jedného z externých USB senzorov alebo z databázy obrazov. Obrázok prejde transformáciou v knižnici predspracovania, kde je kľúčovou operáciou aplikovanie adaptívneho Gaborovho filtra. Takto kvalitatívne upravený obrázok smeruje do knižnice na extrakciu, ktorá využíva nami natrénovanú hlbokú konvolučnú sieť odvodenú zo známej architektúry ResNet-18,

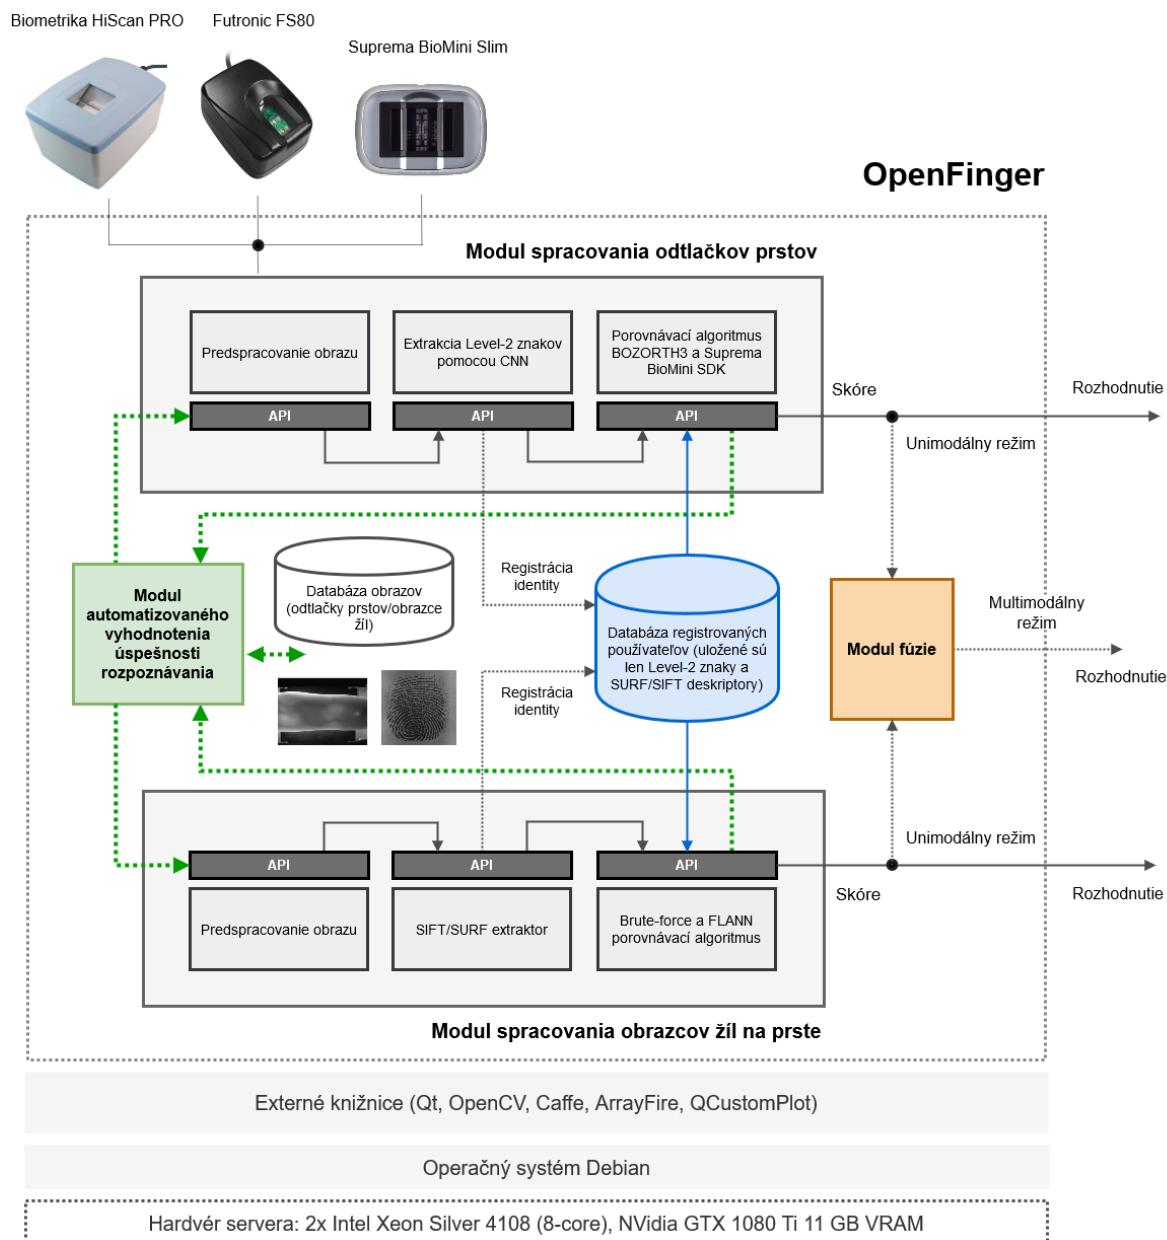
3.1. NÁVRH SYSTÉMU OPENFINGER

ktorá bola natrénovaná pomocou vzoriek Level-2 znakov zozbieraných vlastným softvérovým nástrojom OF Sample Collector na interaktívny zber a úpravu (z angl. data augmentation) rôznych druhov trénovacích vzoriek zo zvolenej databázy obrazov. Konvolučná sieť odhalí v obraze Level-2 znaky a tie sú následne buď zaslané na uloženie do databázy registrovaných používateľov (v režime registrácie) alebo sú posланé do knižnice určenej na porovnávanie. Podľa toho, či systém pracuje v režime verifikácie alebo identifikácie, sa odhalené Level-2 znaky porovnajú s jednou alebo viacerými identitami uloženými v databáze. Porovnanie je realizované jedným z dvoch algoritmov, ktoré sú na výber: BOZORTH3 (a taktiež nami vytvorená viac-vláknová verzia tohto algoritmu) a Suprema Biomini SDK.

- **Modul spracovania obrazcov žíl na prste (viac v sekcii 3.1.3).** Vstupom je obrázok získaný z databázy SDUMLA-HMT (počas výskumu sme nezískali vhodný a cenovo dostupný senzor na snímanie žíl na prste). Obrázok prejde nami navrhnutou transformáciou vo fáze predspracovania, kde sa vyznačí ROI, následne sa extrahujú SIFT/SURF deskriptory, ktoré sú porovnané pomocou FLANN/Brute-force porovnávacieho algoritmu, ktorý je súčasťou knižnice OpenCV. V prípade fungovania systému v režime registrácie sa SIFT/SURF deskriptory ukladajú do databázy registrovaných používateľov.
- **Modul fúzie,** v ktorom je normalizované a spájané skóre podobnosti pre odtlačky a obrazce žíl. Ak systém funguje v multimodálnom režim, tak sa dve osoby porovnajú zvlášť pomocou odtlačkov prstov a zvlášť pomocou obrazcov žíl na prste. Výsledkom sú dve hodnoty vypočítanej podobnosti (skóre) vzoriek, ktoré sa spoja do jedinej hodnoty. Fúzia je teda vykonaná na úrovni porovnávania. Výstupom modulu fúzie je spoločné normalizované skóre podobnosti odtlačku prsta a obrazca žíl. Podľa toho, či výška skóre prekročí stanovený prah sa určí výsledok rozpoznania. Tento modul dovoľuje nášmu systému fungovať v multimodálnom režime a vytvára možnosť doplniť náš systém o ďalšie moduly (napríklad spracovanie obrazov tváre alebo dúhovky).
- **Modul automatizovaného vyhodnotenia úspešnosti (viac v sekcii 3.1.4),** ktorý slúži na výpočet ukazovateľov ako ROC krivka, FAR/FRR grafy a ďalšie ukazovatele. Pomocou tohto modulu vieme zmerať akú presnosť rozpoznania identity systém OpenFinger dosahuje pri zvolených nastaveniach a na ľubovoľnej dodanej databáze biometrických vzoriek odtlačkov a obrazcov žíl. Modul je vybavený vlastným testovacím algoritmom, ktorý v prvej fáze zašle sériu obrazov odtlačkov a sériu obrazov obrazcov žíl do príslušných unimodálnych systémov na spracovanie s cieľom uložiť extrahované vektory príznakov (Level-2 znaky a SIFT/SURF deskriptory). Následne sa vytvoria množiny dvojíc vektorov, ktoré budú medzi sebou porovnané takým spôsobom, aby sa dali vypočítať ukazovatele úspešnosti (vyčísiť mieru chyby I. a II. druhu a k nim asociovaných ukazovateľov používaných v biometrii). Ukazovatele úspešnosti sú vizualizované pomocou knižnice QCustomPlot. Počas výskumu nám tento modul poskytoval cennú

3.1. NÁVRH SYSTÉMU OPENFINGER

spätnú väzbu a boli sme tak schopní určiť najvhodnejšie hodnoty parametrov systému a testovať náš systém pri rôznych konfiguráciach, porovnať unimodálny a multimodálny režim fungovania, vyhodnotiť úspešnosť s použitím obrazového predspracovania a bez neho, ako aj porovnať úspešnosť s využitím oboch dostupných porovnávacích algoritmov.



Obr. 3.1: Architektúra systému OpenFinger

3.1. NÁVRH SYSTÉMU OPENFINGER

Náš školský biometrický server, na ktorom je nainštalovaný OpenFinger bol rozšírený aj o rozhranie, ktoré umožňuje vykonávať verifikáciu a identifikáciu v počítačovej sieti pomocou šifrovaného TCP sieťového spojenia (zabezpečenie protokolom SSL pomocou knižnice OpenSSL). Ako nadstavbu nad systémom OpenFinger sme implementovali vlastnú klient-server aplikáciu, ktorá povoľuje vzdialené pripojenie klientov, ktorí môžu posielat požiadavky na verifikáciu/identifikáciu. Klientom je počítač v LAN/WAN sieti, ktorý sa pripojí na port a IP adresu servera. Klient odošle sietou zašifrovaný obrázok odtlačku/obrazca žil, ktorý server spracuje. Systém OpenFinger má aj expertný mód fungovania, ktorý umožňuje vzdialenému klientovi konfigurovať systém (nastavovať vnútorné parametre algoritmov) a zobrazovať podrobne medzivýstupy jednotlivých algoritmov. Takýto režim fungovania slúži na odhalenie chýb, identifikovanie zdrojov nepresnosti a experimentovanie s parametrami algoritmov s cieľom ich vylepšenia. Navyše možnosť okamžitého nasadenia nášho systému vo forme klient-server demonštruje jeho praktické využitie a nezostáva tak len v teoretickej rovine.

3.1.2 Modul spracovania odtlačkov prstov

Spracovanie odtlačkov prstov pozostáva z 3 nasledujúcich vzájomne komunikujúcich knižníc.

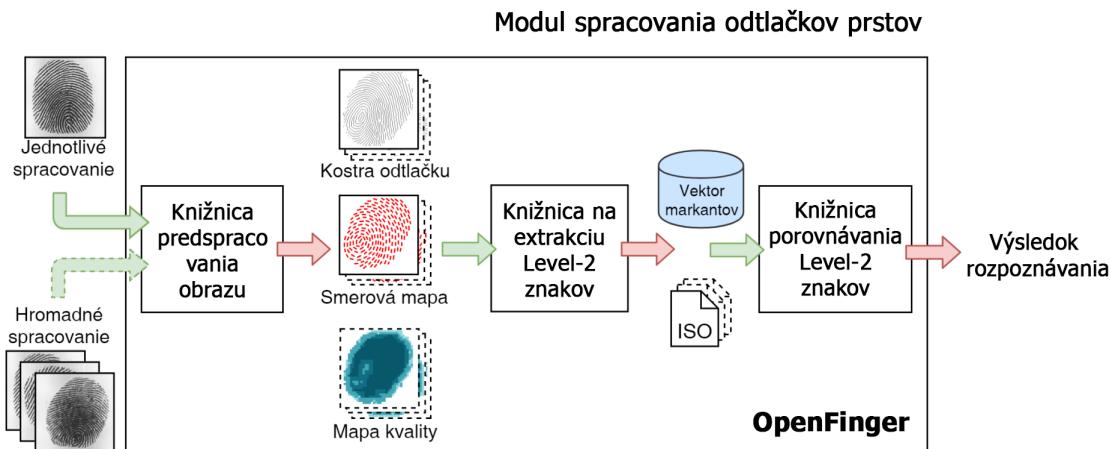
- **Knižnica na predspracovanie obrazu.** Po získaní obrazu odtlačku prsta nasleduje jeho predspracovanie, ktorého hlavným poslaním je zvýšenie kvality obrazca papilárnych línií pomocou rozličných globálnych ako aj adaptívnych techník, ktoré upravujú obraz do podoby vhodnej na spoľahlivé rozpoznanie charakteristických znakov. Klúčovou fázou je adaptívny Gaborov filter efektívne implementovaný na GPU prostredníctvom knižnice ArrayFire a na CPU využívajúc vlákna procesora, čo výrazne urýchľuje celý proces predspracovania. Gaborov filter a jeho kvalitná implementácia sa počas výskumu preukázali ako najdôležitejšie aspekty celého rozpoznávacieho systému, nakoľko systém dosahuje bez jeho použitia signifikantne horšie výsledky (predovšetkým v databázach obrazov s veľmi nízkou kvalitou, napr. FVC 2002 DB3a). Navyše je do knižnice zabudovaná podpora komunikácie s 3 modelmi snímačov odtlačkov prstov, menovite Suprema Bio-Mini Slim, Biometrika HiScan Pro a Futronic FS-80, čím sa výrazne zvyšuje praktické využitie nášho systému a značne to zvýrazňuje možnosti nášho testovania (predovšetkým simulácia premenlivej kvality snímania). Na komunikáciu s nimi využívame výrobcom dodávané SDK. Obrazy zosnímané pomocou senzora je možné exportovať v rôznych obrazových formátoch ako aj vo formáte polabajtov uloženého priamo v pamäti počítača.
- **Knižnica na extrakciu charakteristických znakov.** V rámci tejto knižnice sa vykoná najprv prvotné odhalenie kandidátov na daktyloskopické markanty (Level-2 znaky) pomocou metódy Crossing Number, ktorá analyzuje štruktúru kostry odtlačku a odhaluje geometrické anomálie. Miesta odhalené touto metódou

3.1. NÁVRH SYSTÉMU OPENFINGER

slúžia ako súradnice blokov obrazu, ktoré sa vyberú priamo z originálneho obrázku odtlačku a odošlú sa na klasifikáciu do konvolučnej neurónovej siete. Využili sme modifikovanú populárnu architektúru siete s názvom ResNet-18. Nami použitá sieť bola natrénovaná pomocou vlastnej aplikácie OF Sample Collector, ktorá slúži na zber trénovacích vzoriek daktyloskopických markantov a umožňuje konfigurovať a spustiť trénovanie siete ako aj následné interaktívne overenie predikcie siete na neznámych testovacích vzorkách. Sieťou odhalené markanty odtlačku sú následne voliteľne exportované do formátu ISO/IEC 19794-2.

- **Knižnica porovnávania odtlačkov.** V tejto fáze dochádza k porovnávaniu odtlačkov pomocou odhalených Level-2 znakov. Knižnica funguje v režime verifikácie (porovnanie 1:1) a identifikácie (porovnanie 1:N). Základom je komerčný porovnávací algoritmus prevzatý zo Suprema Biomini SDK a voľne dostupný algoritmus BOZORTH3 vyvíjaný americkým NIST-om. V prípade algoritmu BOZORTH3, sme vyvinuli vlastnú implementáciu v jazyku C, ktorá využíva viaceré vlákna serverového procesora, čo sa patrične odzrkadlilo na zvýšenej rýchlosti rozpoznávania.

Na obrázku 3.2 vidíme blokovú schému zachytávajúcu hlavné kroky spracovania odtlačku. Pri jednotlivých vnútorných knižniciach sú vizualizované výstupy, ktoré sú nevyhnutné pri spracovaní v nasledujúcom kroku. Modul dokáže fungovať v móde spracovania jedného odtlačku prsta ako aj v móde hromadného paralelného spracovania viacerých obrazov. Podrobnejší opis je k dispozícii aj v súvisiacej diplomovej práci [31].



Obr. 3.2: OpenFinger v unimodálnom režime rozpoznávania pomocou odtlačkov prstov

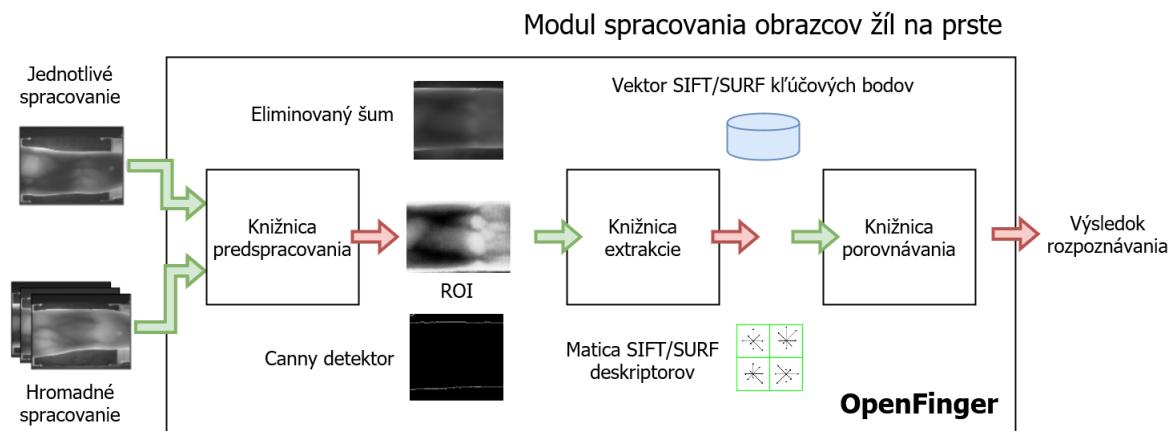
3.1.3 Modul spracovania obrazcov žíl prstov

Na ďalšie zvýšenie presnosti sme OpenFinger rozšírili o ďalší prídavný modul, ktorý vykonáva spracovanie obrazcov žíl na prstoch. Analogicky ako spracovanie odtlačkov, aj spracovanie obrazcov žíl je rozložené do 3 separátnych vzájomne komunikujúcich knižníc.

3.1. NÁVRH SYSTÉMU OPENFINGER

- **Knižnica na predspracovanie.** V rámci tejto knižnice dochádza k postupnému spracovaniu obrázkov obrazcov žíl na prstoch ako je lokalizácia prsta v obraze (pomocou bilaterálneho filtrovania, Cannyho detektora, hľadania kontúr a koncových bodov kontúr) a úprava histogramu na zvýšenie kontrastu.
- **Knižnica na extrakciu príznakov.** Extrakcia kľúčových bodov a ich deskriptorov pomocou algoritmov SIFT a SURF z knižnice OpenCV. Kľúčové body sú odhalované len v oblasti ROI získanej ako výstup z knižnice predspracovania.
- **Knižnica na porovnávanie.** Porovnávanie deskriptorov algoritmami FLANN a Brute-Force z knižnice OpenCV.

Na obrázku 3.3 vidíme architektúru unimodálneho systému na rozpoznávanie pomocou obrazcov žíl na prste. Podobne ako v prípade odtlačkov prstov, aj tento modul dokáže spracovať samostatné obrazy, ako aj dávky obrazov. Podrobnejší opis krokov spracovania obrazcov žíl je v časti 3.2.7, ako aj v súvisiacej bakalárskej práci [32].



Obr. 3.3: OpenFinger v unimodálnom režime rozpoznávania obrazcov žíl na prstoch

3.1.4 Modul vyhodnotenia úspešnosti rozpoznávania osôb

Základným predpokladom pre používanie a publikovanie biometrického systému je poznanie jeho úspešnosti a rýchlosť pri rozpoznávaní identity. Na to, aby sme získali celistvý a objektívny pohľad na silné a slabé stránky nášho systému, musíme tento podrobiť sérii testov zameraných na kvantifikáciu najdôležitejších a všeobecne uznávaných ukazovateľov, ktoré vypovedajú o vlastnostiach nášho biometrického systému. Počas vývoja bolo nutné systém priebežne testovať na viacerých databázach obsahujúcich biometrické vzorky z rôznych snímačov a osôb. Požiadavka rýchleho a jednoduchého testovania bola pre nás motiváciou na to, aby sme vyvinuli okrem biometrických modulov aj ďalší modul, určený na automatizované vyhodnotenie. Vyvinutý modul komunikuje s biometrickými modulmi a databázou biometrických vzoriek (obrazy odtlačkov prstov a obrazcov žíl) a podľa požiadavky používateľa vykonáva testy s cieľom vyhodnotiť rýchlosť a presnosť verifikácie alebo identifikácie.

3.1. NÁVRH SYSTÉMU OPENFINGER

Takýmto spôsobom náš systém nie je závislý od testovacieho softvéru tretej strany a je tak plnohodnotne pripravený na rozličné formy experimentov, ktoré preveria jeho vlastnosti.

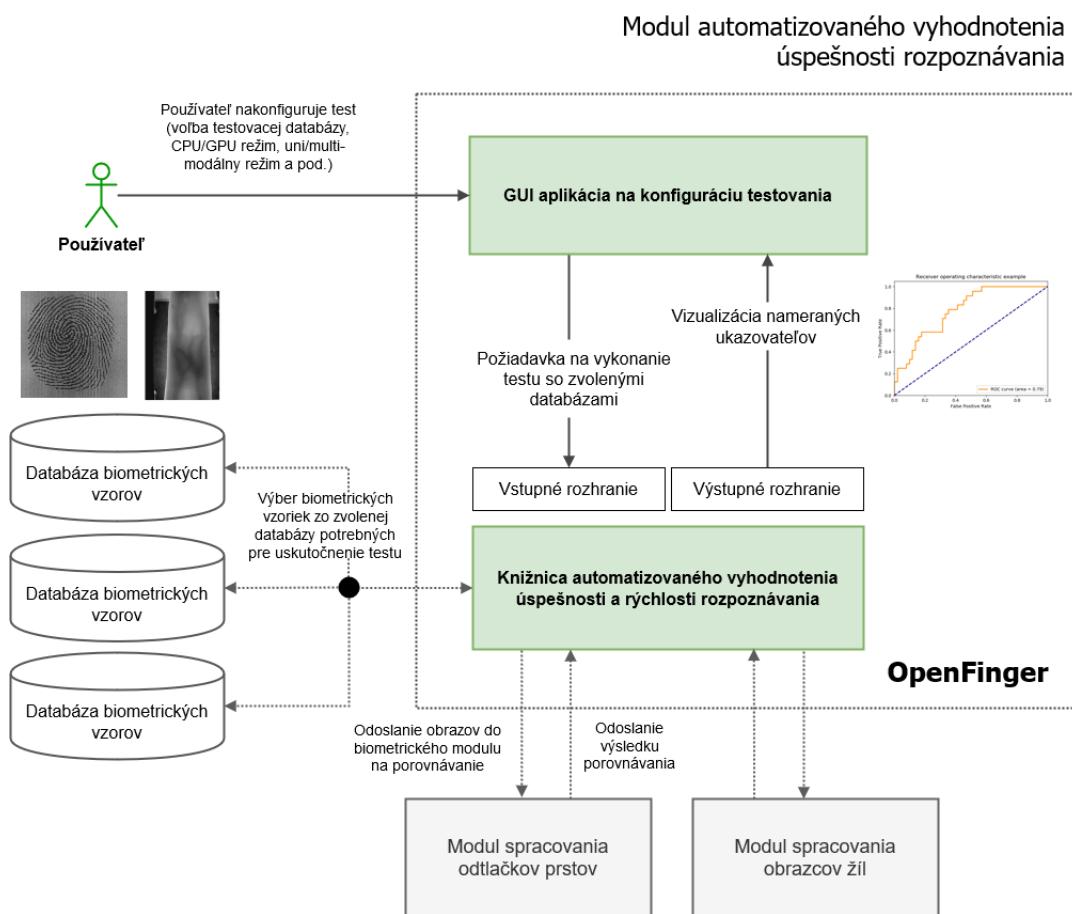
Prínosy nášho modulu automatizovaného hodnotenia:

- Podpora pri písaní vedeckej publikácie a ďalšom výskume. Môžeme tak v pri publikovaní použiť relevantné výsledky a grafy, ktoré sme namerali pri konkrétnych nastaveniach systému a môžeme ich porovnať s riešeniami iných autorov.
- Rýchla spätná väzba, diagnostika a hľadanie chýb počas vývoja. Pri vývoji sa pridávajú, modifikujú alebo odstraňujú rôzne algoritmy, ktoré pracujú s biometrickými údajmi a majú určitý dopad na presnosť rozpoznávania. Modul vyhodnotenia nám pomôže určiť aký konkrétny dopad majú akékol'vkej implementačné zásahy.
- Určenie vhodnosti algoritmov. Niektoré procesy v rámci biometrického systému môžu byť vykonané pomocou rôznych metód, napr. rôzne techniky extrakcie alebo porovnávania odtlačkov. Na určenie, ktorý algoritmus je vhodnejší, nám pomôže analýza výsledkov rozsiahleho testovania.
- Hľadanie optimálnych parametrov. Veľké množstvo operácií, predovšetkým vo fáze predspracovania, je možné ovplyvniť pomocou rôznych parametrov. Avšak je obvykle určiť aké hodnoty parametrov sú optimálne. Ako príklad môžeme uviesť filtrovanie Gaborovym filtrom, pri ktorom sa nastavajú parametre ako smer, frekvencia papilárnych línii, veľkosť a štandardné odchýlky filtra a o mnohé iné. Komplexný test na rozsiahlej databáze môže prezradiť aké hodnoty parametrov sú optimálne.
- Modul vyhodnotenia je konfigurovateľný pomocou prehľadného grafického používateľského rozhrania, v rámci ktorého sú po dokončení testov výsledky vizualizované formou grafov s možnosťou ich uloženia do súboru.
- V literatúre chýbajú také biometrické systémy, ktoré sú vybavené možnosťou testovania svojej úspešnosti. Ak chceme skúmať cudzie riešenia alebo sa dopracovať k výsledkom z nejakej vedeckej práce, musíme si vytvoriť svoj vlastný testovací softvér špeciálne prispôsobený na mieru. Navyše, nie je doposiaľ známe open-source biometrické riešenie, ktoré by disponovalo grafickým rozhraním na testovanie a meranie rôznorodých ukazovateľov pri rôznych konfiguráciach vnútorných parametrov. Takéto pokročilé experimentovanie v oblasti spracovania odtlačkov prstov ako aj obrazcov žil chýba. Ak by sme sa takýto typ experimentov chceli vykonať s bežne dostupnými systémami, vyžadovalo by to zásahy do zdrojových kódov a niekedy až úkony na hranici reverzného inžinierstva. Na odstránenie uvedených nedostatkov sme sa rozhodli náš biometrický systém rozšíriť o tieto pokročilé testovacie možnosti a preto považujeme náš výsledok v tejto oblasti za mimoriadny prínos.

3.1. NÁVRH SYSTÉMU OPENFINGER

- Pri dodržaní formátu komunikačného protokolu, vie náš modul automatizované testovať aj cudzie biometrické systémy, čo by viedlo maximálne objektívemu porovnaniu viacerých systémov.

Modul automatizovaného vyhodnotenia úspešnosti rozpoznávania je implementovaný ako dynamická knižnica a k nej asociovaný podporný softvér s grafickým používateľským rozhraním, pomocou ktorého vieme nastavovať parametre testovania. Na obrázku 3.4 vidíme diagram, ktorý znázorňuje štruktúru celého modulu a použitie pomocou jeho vstupno-výstupného rozhrania.



Obr. 3.4: Modul automatizovaného vyhodnotenia úspešnosti rozpoznávania

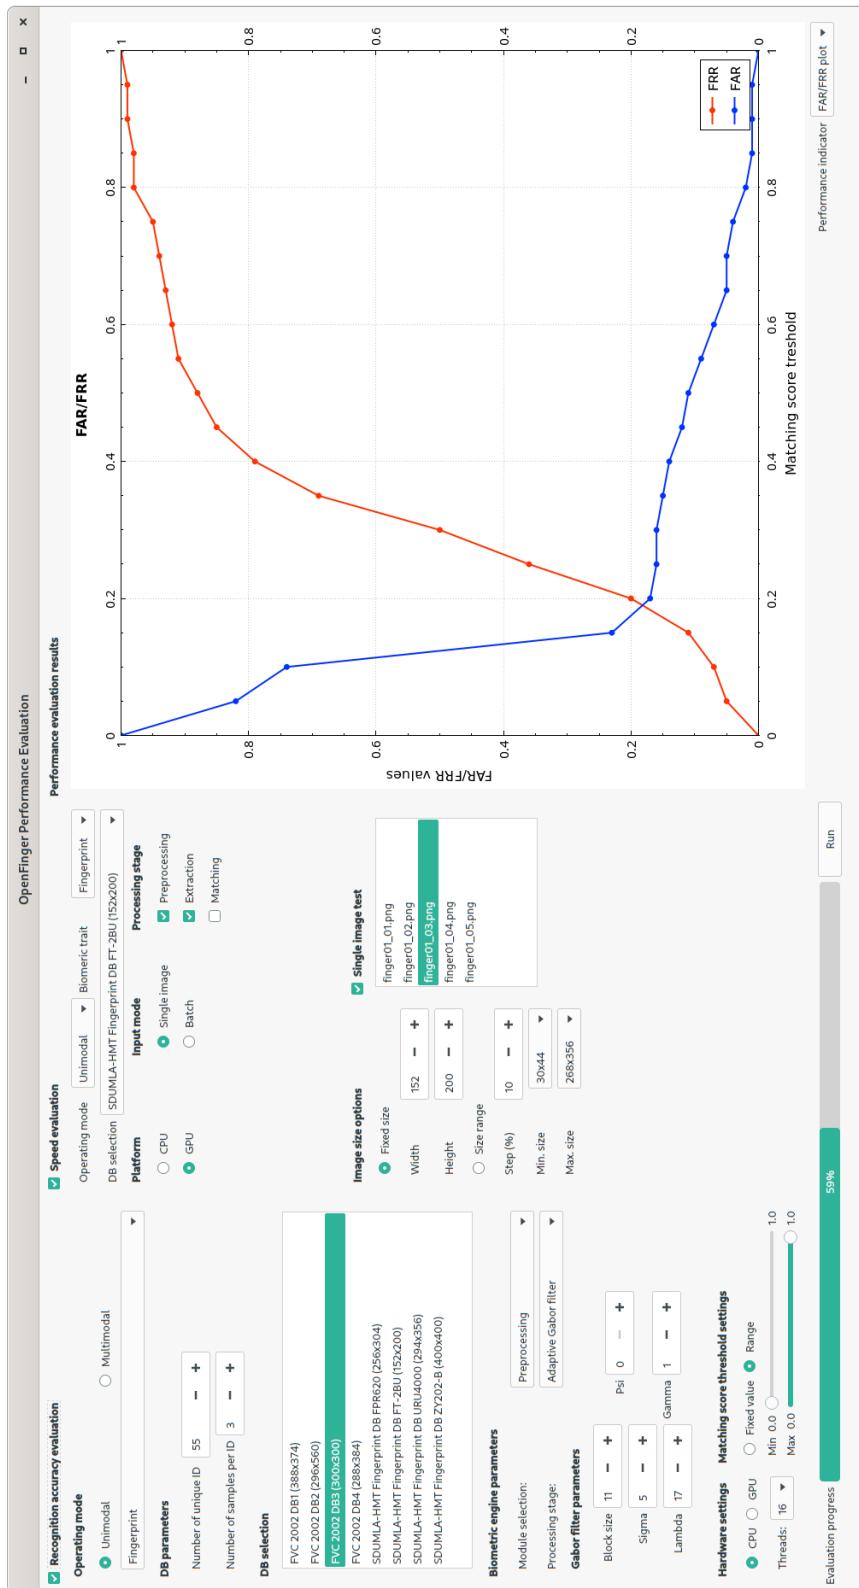
3.1. NÁVRH SYSTÉMU OPENFINGER

Podporná GUI aplikácia, ktorá je súčasťou modulu umožňuje používateľovi vykonať nasledovné úkony:

- Zvoliť testovaciu databázu obrazov a parametre každej testovacej databázy:
 - Počet osôb zastúpených v databáze (môžeme určiť koľko unikátnych identít budeme používať pri testovaní, osoby sa zvolia náhodne alebo manuálne).
 - Počet vzoriek na osobu (môžeme tak testovať vysporiadanie sa systému s vyššou vnútrotriednou variabilitou, napr. určíme koľko prstov na jednu osobu a koľko zosnímaných odtlačkov jedného prsta chceme použiť).
- Zvoliť prah pre skóre porovnania. Používateľ môže určiť, či chce testovať systém pre konkrétny rozsah prahových hodnôt alebo jednu pevne zvolenú hodnotu. Prahová hodnota, je číslo, pomocou, ktorého sa určí, či sa dva porovnávané odtlačky resp. obrazce žil zhodujú. Ak dosiahnuté skóre podobnosti vypočítané porovnávacím algoritmom je pre dve vzorky vyššie ako prahová hodnota, vzorky sú považované za totožné. V opačnom prípade sú považované za odlišné.
- Zvoliť režim činnosti biometrického systému (používateľ si zvolí, či chce preveriť konkrétny unimodálny systém alebo vyhodnotiť multimodálny systém). Ak sa zvolí multimodálny režim, identita osoby bude vyjadrená dvojicou odtlačok prsta-obrazec žil na prste a po procese porovnania sa skóre podobnosti obidvoch biometrických znakov zlúči v module fúzie.
- Nastaviť parametre biometrického modulu. Tu si dokáže používateľ zvoliť aké parametre biometrického modulu chce meniť. Aplikácia dáva kompletnejšiu kontrolu nad všetkými dôležitými parametrami predspracovania, extrakcie a porovnávania. Programátor vie tak ladiť softvér, detegovať potenciálne chyby a získať okamžitú spätnú väzbu pre konkrétnu konfiguráciu systému. Spúšťaním testovania a vyhodnocovania pre rôzne konfigurácie parametrov tak vieme nájsť správny smer pri programovaní a vylepšovaní systému. Zaujímavou funkciou je aj možnosť úplne deaktivovať predspracovanie (nakol'ko je vypočítovo najnáročnejšou fázou spracovania) a sledovať dopad tohto stavu na presnosť rozpoznávania.
- Nastaviť hardvérovú platformu, na ktorej budú testy realizované. Používateľ určí, či chce proces rozpoznávania vykonať pomocou GPU alebo CPU (v tomto prípade zvolí aj počet využívaných vlákien procesora).
- Nastaviť parametre merania rýchlosťi výpočtov. Umožňuje merať rýchlosť s akou systém vykonáva predspracovanie, extrakciu a porovnávanie v závislosti od rozmeru vstupného obrazu. Rýchlosť je meraná ako čas potrebný na vykonanie požadovanej operácie pre jeden zvolený obraz daného rozmeru.

Na obrázku 3.5 vidíme používateľské rozhranie našej GUI aplikácie na konfiguráciu testovania a vizualizáciu nameraných výsledkov.

3.1. NÁVRH SYSTÉMU OPENFINGER



Obr. 3.5: Naša GUI aplikácia slúžiaca ako rozhranie na konfigurovanie testov úspešnosti a rýchlosť rozpoznávania

3.1. NÁVRH SYSTÉMU OPENFINGER

Po dokončení používateľom prispôsobeného testovania na zvolenej databáze, sa získajú tieto dôležité ukazovatele:

Ukazovatele zamerané na zhodnotenie úspešnosti rozpoznávania identity

- Histogramy pre tzv. genuine/impostor skóre. Zvlášť sa porovnávali biometrické vzorky, ktoré pochádzali z rovnakého prsta a zvlášť také, ktoré pochádzali z rôznych prstov. Výsledný histogram vypovedá o schopnosti biometrického systému jasne odlišovať charakteristické znaky získané viacnásobným zosnímaním rovnakého prsta od znakov prstov iných osôb.
- FAR/FRR graf. Jedná sa o frekventovanú chybovú metriku, ktorá vypovedá o tom, ako často rozpoznávací systém mylne určí dve rôzne identity za rovnaké (z angl. false acceptance) a dve rovnaké identity zase omylom označí za rozdielne (z angl. false rejection). Tento ukazovateľ sa nameria pre všetky zvolené prahové hodnoty skóre porovnania. Vznikne tak graf, z ktorého vidíme ako sa systém správa pri odlišných úrovniach prísnosti akceptovania zhody a vieme z neho určiť bod EER (Equal Error Rate), t.j. takú prahovú hodnotu, pri ktorej systém dosahuje rovnaké chyby FAR aj FRR
- ROC krivka. Ukazovateľ, ktorý hovorí ako dobre rieši systém konkrétny klasičkáčný problém pri rôznych rozhodovacích prahových hodnotách (t.j. prahových hodnotách pre skóre podobnosti medzi dvomi vzorkami, ktoré keď je presiahnuté, dve vzorky sú prehlásené za totožné). ROC krivka je tvorená vykreslením metriky TPR (True Positive Rate) vzhľadom na FPR (False Positive Rate) pri rôznych prahoch.
- Precision-Recall krivka. Ďalší známy ukazovateľ, ktorý dáva do vzťahu metriku PPV (Positive Predictive Value) a TPR (True Positive Rate).

Ukazovatele zamerané na zhodnotenie rýchlosťi zvolených operácií v rámci celého systému OpenFinger

- rýchlosť výpočtov v jednotlivých fázach spracovania vykonaných na GPU/CPU (aj rôzne počty vlákien)
- rýchlosť rozpoznávania v unimodálnom a multimodálnom režime činnosti
- rýchlosť jednotlivých modulov (odtlačky aj obrazce žíl) v závislosti od toho, či pracujú v režime spracovania jedného obrazu alebo dávkového spracovania.
- závislosť trvania jednotlivých meraných operácií od rozmeru vstupného obrazu

3.1. NÁVRH SYSTÉMU OPENFINGER

3.1.5 Unimodálny a multimodálny režim fungovania

OpenFinger dokáže pracovať v unimodálnom (využíva len odtlačky alebo obrazce žíl) aj multimodálnom režime (využíva súčasne odtlačky aj obrazce žíl). V multimodálnom režime sme museli pred fúziou pristúpiť k normalizácii skóre, nakoľko porovnávacie algoritmy odtlačkov prstov a obrazcov žíl produkovali skóre podobnosti v rozdielnych rozsahoch. Zmyslom normalizácie bolo transformovať výsledné skóre do intervalu $\langle 0, 1 \rangle$.

Skóre porovnávacích algoritmov v module spracovania odtlačkov prstov:

- BOZORTH3 počíta podobnosť medzi dvomi množinami Level-2 znakov a výsledné skóre podobnosti bolo v intervale $\langle 0, 499 \rangle$ (nenamerali sme počas experimentov vyššiu hodnotu ako 499)
- Suprema BioMini SDK počíta taktiež podobnosť medzi Level-2 znakmi a výsledné skóre bolo v intervale $\langle 0, 1 \rangle$ (normalizácia v tomto prípade nebola potrebná).

Skóre porovnávacích algoritmov v module spracovania obrazcov žíl na prste:

- Brute-Force algoritmus počíta vzdialenosť medzi SIFT/SURF deskriptormi. Rozsah vzdialenosť bol v intervale $\langle 0, 400 \rangle$.
- FLANN algoritmus počíta taktiež vzdialenosť medzi SIFT/SURF deskriptormi a rozsah jeho vzdialenosť bol $\langle 0, 200 \rangle$.

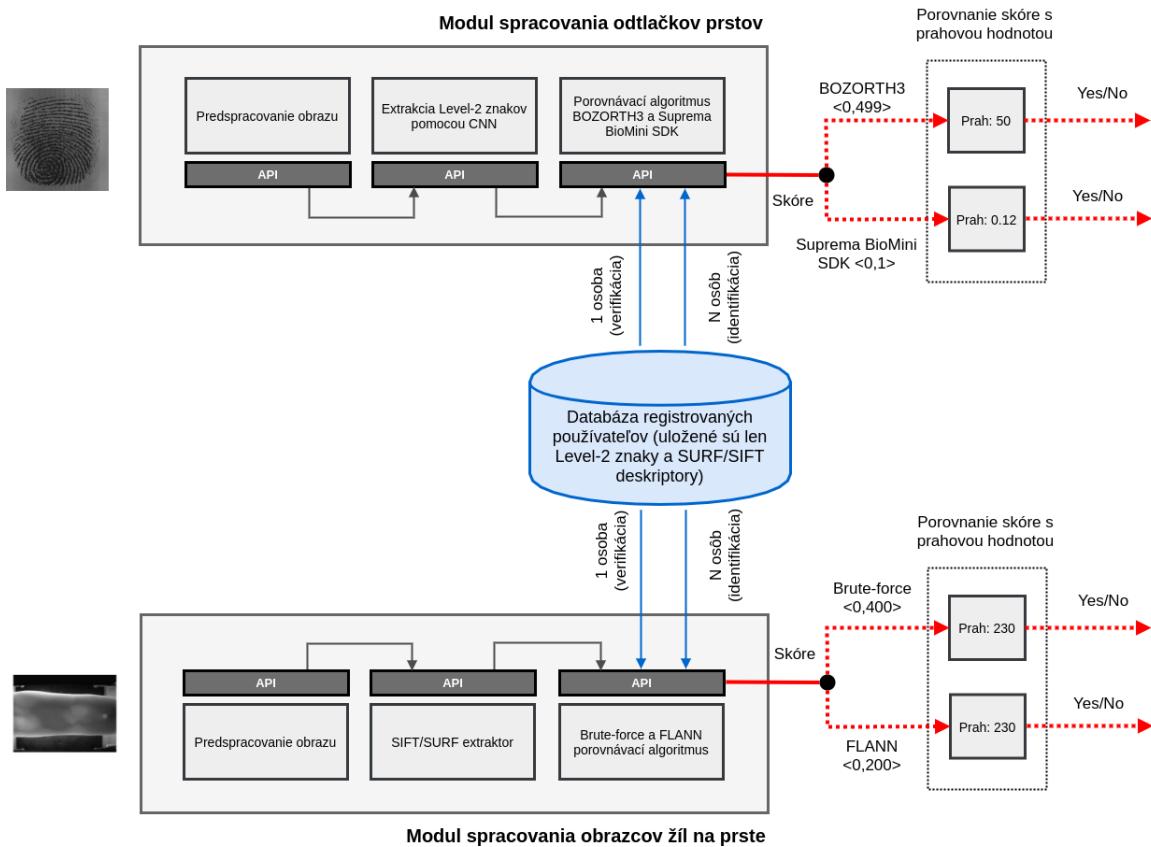
Navyše v prípade porovnávania obrazcov žíl, zvolený Brute-force/FLANN porovnávací algoritmus z knižnice OpenCV počíta Euklidovskú vzdialenosť dvoch vzoriek, čo nie je miera podobnosti, ale odlišnosti. Z tohto dôvodu sme museli pri fúzii skóre použiť prevrátenú hodnotu Euklidovskej vzdialenosť. Tabuľka 3.1.5 sumarizuje prahové hodnoty pre vypočítané skóre podobnosti, ktoré sa použili pri rozhodovaní (skóre presahujúce prahovú hodnotu signalizuje zhodu biometrických vzoriek).

Tabuľka 3.1: Prahové hodnoty pre skóre vypočítané jednotlivými porovnávacími algoritmami

Odtlačky prstov		Obrazce žíl		Multimodálny režim
Bozorth3	50	Brute-force	230	
Suprema	0.12	FLANN	230	0.35

Obrázok 3.6 zachytáva obidva unimodálne režimy fungovania systému OpenFinger s naznačením procesov verifikácie aj identifikácie ako aj určenia finálneho rozhodnutia o rozpoznaní osoby.

3.1. NÁVRH SYSTÉMU OPENFINGER

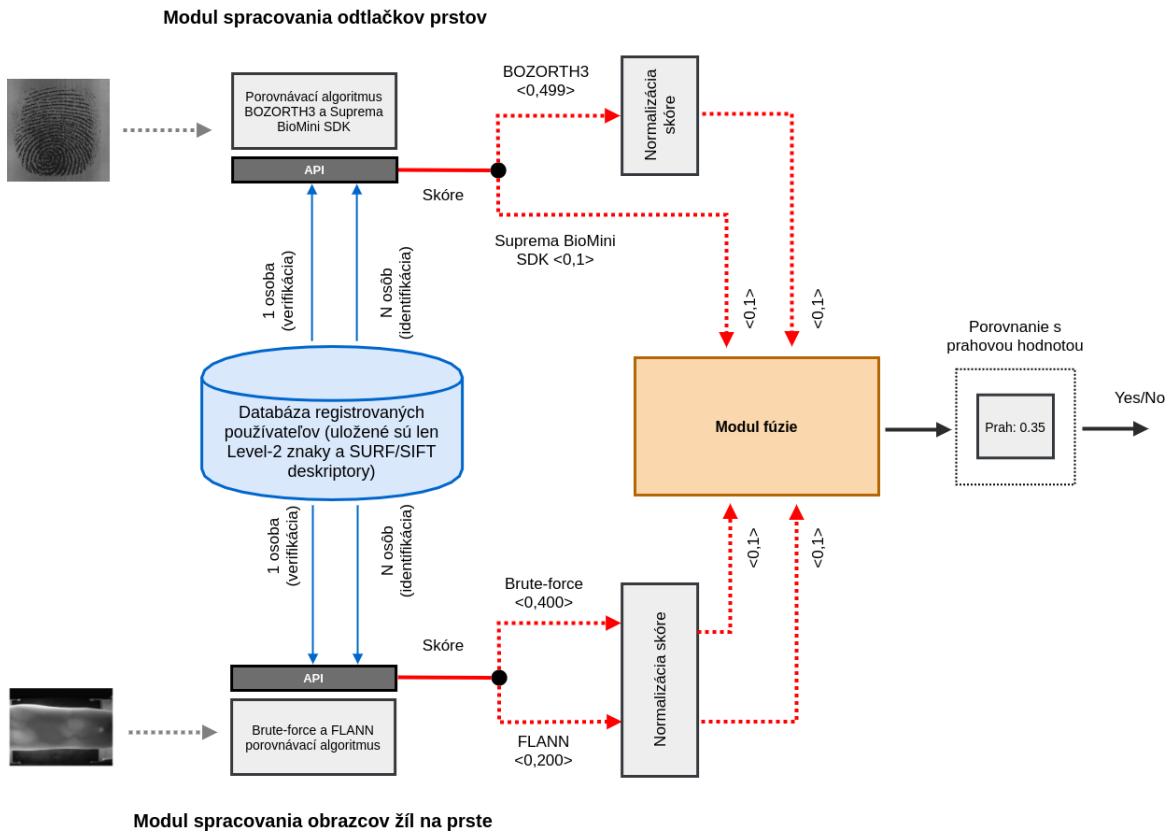


Obr. 3.6: Proces rozpoznávania v unimodálnych režimoch systému OpenFinger

Počas experimentovania sme testovali viaceré metódy normalizácie (double-sigmoid, hyperbolický tangens, Z-score, Min-Max) a fúzie skóre (min, max, hyperbolický tangens, sum, product a mean). Ich podrobnejší opis je v časti 3.2.7.

Obrázok 3.7 zachytáva multimodálny režim fungovania systému OpenFinger s dôrazom na proces normalizácie a fúzie skóre. Na obrázku je zámerne vynechaná fáza predspracovania a extrakcie príznakov z odtlačkov prstov ako aj obrazcov žíl a naopak podrobne je tu znázorný postup od momentu ako je vypočítané skóre v obidvoch moduloch. Skóre vstupuje do fázy normalizácie, kde je upravené do rozsahu $\langle 0, 1 \rangle$ (okrem prípadu, kedy je skóre vypočítané systémom Suprema BioMini Slim, ktoré poskytuje skóre v správnom rozsahu). Po normalizácii dochádza k fúzii skóre prostredníctvom jednej z vyššie spomenutých fúznych stratégii. Výstupné zlúčené skóre je porovnané s prahovou hodnotou na úrovni 0,35, ktorá sa počas testov javila ako optimálna.

3.1. NÁVRH SYSTÉMU OPENFINGER



Obr. 3.7: Proces rozpoznávania v multimodálnom režime systému OpenFinger

3.1.6 Použité softvérové prostriedky

Náš systém aktívne využíva tieto externé knižnice:

- **OpenCV**

Knižnica na spracovanie obrazu, počítačové videnie a strojové učenie. Obsahuje množstvo optimalizovaných algoritmov na rýchlu manipuláciu s obrazom ako aj aplikácie filtrov, načítavanie/ukladanie súborov a vizualizáciu. Funkcie tejto knižnice sme využili vo fáze predspracovania pri načítavaní obrazu, reprezentácií obrazu vo forme dátového typu `cv::Mat` a taktiež na realizáciu zložitejších pred-spracovacích techník, ktoré sme implementovali pomocou elementárnych funkcií knižnice OpenCV. Táto knižnica nám pomohla aj pri spracovaní obrazov žil na prste, kde sme ju využili vo fáze extrakcie SIFT/SURF deskriptorov, ako aj pri ich porovnávaní (Brute-force a FLANN porovnávací algoritmus).

- **ArrayFire**

Knižnica podporujúca paralelizované výpočty na CPU a GPU pomocou platformy OpenCL a CUDA. Táto knižnica bola využitá na implementovanie výpočtovo najnáročnejších operácií, hlavne výpočtu smerovej mapy, adaptívneho filtrovania pomocou Gaborovho filtra ako aj pri dávkovanom spracovaní viacerých obrazov.

3.1. NÁVRH SYSTÉMU OPENFINGER

- **Caffe**

Knižnica napísaná v C++ umožňujúca hlboké učenie a definovanie vlastných architektúr konvolučných neurónových sietí. Použili sme ju vo fáze extrakcie Level-2 znakov. Pomocou nej sme boli schopní definovať architektúru siete (modifikovaná ResNet-18 sieť), trénovať, testovať a exportovať natrénovanú sieť.

- **Qt**

Knižnica napísaná v C++ na všeobecné účely programovania a tvorbu grafického používateľského rozhrania. Umožňuje kvalitnú prácu s obrazom, prístup k súborovému systému a zabezpečenú sieťovú komunikáciu. Využili sme ju pri tvorbe všetkých knižníc, grafických používateľských rozhranií, prácu so súborovým systémom, viac-vlákновé programovanie, komunikáciu medzi vnútornými softvérovými komponentami pomocou mechanizmu signálov a tzv. slotov a v neposlednom rade aj na šifrovanú sieťovú komunikáciu pomocou TCP a SSL protokolu. Celý systém OpenFinger bol vyvinutý v programovacom prostredí Qt Creator, ktoré je voliteľnou súčasťou knižnice Qt.

- **BioMini SDK**

Platený balík kommerčných knižníc na snímanie, extrakciu a porovnávanie odtlačkov prstov. Z tohto SDK sme využili len funkcia na získanie obrazu zo senzora a porovnávanie odtlačkov prstov.

- **FxISO SDK Light**

Knižnica od talianskej firmy Biometrika na komunikáciu s USB senzorom odtlačkov HiScan PRO. Použili sme ju na získavanie obrazu z tohto senzora.

- **ftrScanAPI**

Knižnica od firmy Futronic na komunikáciu s USB senzorom odtlačkov Futronic FS80H. Použili sme ju na získavanie obrazu z tohto senzora.

- **QCustomPlot**

C++ knižnica na tvorbu responzívnych grafov a vizualizáciu údajov určená pre Qt programy. Použili sme ju v module automatizovaného vyhodnotenia na vizualizáciu rôznych typov grafov a ukazovateľov.

3.1.7 Snímanie odtlačkov prstov

Predspracovacia knižnica modulu odtlačkov prstov mala do svojho API rozhrania zahrnuté funkcie, ktoré inicializujú konkrétny typ senzora a po zosnímaní odtlačku získajú obrazové údaje. OpenFinger podporuje nasledujúce snímače odtlačkov prstov.

- Suprema BioMini Slim
- Biometrika HiScan PRO
- Futronic FS80H

3.1. NÁVRH SYSTÉMU OPENFINGER

Suprema BioMini Slim

FBI certifikovaný snímač od spoločnosti Suprema, podporuje štandardizované formáty na výmenu biometrických informácií ANSI/INCITS 378, ISO/IEC 19794-2/4 a využíva MDR technológiu, čo pomôže senzor použiť pod priamym slnečným žiareniom. Je odolný voči falzifikovaným odtlačkom, keďže pomocou strojového učenia sleduje optické vlastnosti obrazových vzorov počas snímania. Suprema vlastníkom senzora BioMini Slim poskytuje aj SDK, ktoré využíva 256 bitové AES šifrovanie, dovoľuje komunikáciu so senzorom a ponúka porovnávací algoritmus pre identifikáciu a verifikáciu.

Medzi najdôležitejšie vlastnosti snímača patria:

- Rozmery nasnímaného odtlačku: 320×480 px, 500 PPI
- Certifikáty: FBI PIV a FBI Mobile ID FAP 20
- Podpora rôznych formátov pre ukladanie daktyloskopických informácií: proprietárny formát Suprema, štandard ISO/IEC 19794-2 a ANSI/INCITS 378



Obr. 3.8: Snímač Suprema BioMini Slim

Biometrika HiScan PRO

Snímač od spoločnosti Biometrika podporujúci rozlíšenie 500 a 1 000 PPI. Je certifikovaný FBI (PIV-IQS) a k snímaču je dostupné FxISO SDK umožňujúce kompletnú biometrickú autentifikáciu. My v práci využívame odľahčenú verziu SDK s názvom FxISO SDK Light, ktorá poskytuje API len na komunikáciu so senzorom a získavanie obrazu. Snímacia plocha má rozmer 25×25 mm, senzor je optický a rozhranie je USB 2.0.

3.1. NÁVRH SYSTÉMU OPENFINGER



Obr. 3.9: Snímač Biometrika HiScan PRO

Futronic FS80H

Snímač od spoločnosti Futronic s rozlíšením 500 PPI a veľkosťou obrazu 480×320 px. Umožňuje detekciu živého prsta na povrchu senzora. Nemá FBI certifikáciu. Snímacia plocha má rozmer 16×24 mm, obsahuje optický CMOS senzor a infračervené LED osvetlenie.



Obr. 3.10: Snímač Futronic FS80H

3.2 Implementované knižnice a aplikácie v rámci systému OpenFinger

Systém OpenFinger má dva biometrické moduly: modul spracovania odtlačkov prstov a modul spracovania obrazcov žíl na prste. Každý z týchto modulov je vnútorné tvorený troma samostatnými a kompatibilnými knižnicami zodpovednými za vykonanie hlavných fáz činnosti, ktorými sú predspracovanie obrazu, extrakcia charakteristických znakov a ich následné porovnávanie. Časiskom nasledujúcich častí je opis implementovaného modulu spracovania odtlačkov prstov nakoľko tvorí jadro celého systému a je vnímaný ako hlavná téma aj prínos tejto práce. Modul pre spracovanie obrazcov žíl je vnímaný ako rozšírenie, ktoré plní v systéme OpenFinger sekundárnu podpornú funkciu a umožňuje multimodálny režim činnosti.

3.2.1 Knižnica na predspracovanie obrazu odtlačku prsta

Úlohou knižnice predspracovania je lokálizácia vzoru odtlačku prsta v obrázku (určenie tzv. ROI), určenie jeho kvality (výpočet mapy kvality) a následná eliminácia obrazových degradácií (slabý kontrast, rozmazanie, šum, artefakty kompresie alebo nevhodné podmienky pri snímaní). V skratke, úlohou predspracovania je odstrániť nežiadúce vlastnosti obrazu a zvýrazniť pôvodnú štruktúru daktyloskopického vzoru so zachovaním všetkých jeho charakteristických detailov. Hlavným výstupom tejto knižnice je kostra odtlačku, ktorá je nevyhnutným podkladom pre následnú detekciu daktyloskopických markantov. Na predspracovanie sa môžeme pozerať ako na nami navrhnutú sériu transformácií, ktoré postupne menia vstupný originálny obraz. Všetky dôležité fázy tohto spracovania sú predmetom tejto kapitoly.

API rozhranie knižnice na získanie vstupného obrazu poskytuje tieto možnosti:

- *Načítanie jedného obrázku.* Knižnica dokáže načítať zo súborového systému jeden obraz vo formáte `cv::Mat` (toto je predvolený dátový typ pre reprezentáciu obrazu v knižnici OpenCV).
- *Načítanie viacerých obrázkov.* Knižnica vie načítať viaceré obrazy vo formáte vektora matíc typu `cv::Mat`. V prípade takto zadefinovaného vstupu knižnica spracúva všetky obrázky hromadne. Takýto dávkový mód je povolený len v prípade vykonávania výpočtov pomocou GPU (dá sa nastaviť pomocou API).
- *Zadanie cesty k adresáru.* Knižnica povolojuje načítať obrazy z používateľom zadaného adresára, ktorý obsahuje obrázky odtlačkov prstov. V tomto prípade sa automaticky načítajú všetky obrazové súbory so štandardnými príponami ako `*.bmp`, `*.png`, `*.jpg` a `*.tif`. Ak cesta neukazuje na adresár, ale kompatibilný obrazový súbor, dôjde k načítaniu tohto jediného obrazu.

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

- *Získanie obrazu zo senzora.* Knižnica dokáže nadobudnúť obraz aj priamou komunikáciou s pripojeným USB senzorom. Podporované sú senzory Suprema BioMini Slim, Futronic FS80 a Biometrika HiScan PRO.

API rozhranie knižnice na nastavovanie parametrov predspracovania poskytuje tieto možnosti:

- Funkcia `setPreprocessingParams`. Umožňuje nastaviť kľúčové parametre predspracovania ako sú:
 - veľkosť obrazového bloku pri blokovo-orientovaných technikách spracovania obrazu
 - parametre pre výpočet smerovej mapy a filtrovanie Gaborovym filtrom
 - parameter pre algoritmus na odstraňovanie obrazových kazov v binarizovanom obrázku odtlačku (priemer umelo-vytvorených dier vo vnútri papilárnych línii)
- Funkcia `setFeatures`. Umožňuje nastavenie:
 - expertného módu (v tomto móde fungovania sú výsledky predspracovania obohatené o čiastkové výsledky jednotlivých transformácií, ktorými obrázok v knižnici prechádza)
 - určenie, či sa má počas predspracovania použiť mapa kvality, frekvenčná mapa, maska odtlačku, pokročilý odhad smerovej mapy a aplikovanie úpravy kontrastu.
- Funkcia `setFrequencyMapParams`. Umožňuje definovanie parametrov pre externú neurónovú sieť v Caffe formáte, ktorá slúži na výpočet frekvenčnej mapy
- Funkcia `setMaskParams`. Umožňuje definovanie parametrov pre externú neurónovú sieť v Caffe formáte, ktorá slúži na segmentáciu odtlačku
- Funkcia `setCPUOnly`. Umožňuje určiť, aby sa všetky výpočty vykonali len na CPU s použitím stanoveného počtu vlákien (pri predvolenom nastavení sa používa aj výkon GPU)

Výstupy knižnice:

- *V štandardnom režime.* V tomto režime získame len nevyhnutné výstupy, ktoré sú následne vyžadované knižnicou extrakcie markantov a sú to:
 - kostra odtlačku (hľadajú sa v nej markanty metódou Crossing Number)
 - mapa kvality (vieme pomocou nej ignorovať odhalené markanty, ktoré boli nájdené v oblastiach s nízkou kvalitou obrazu)

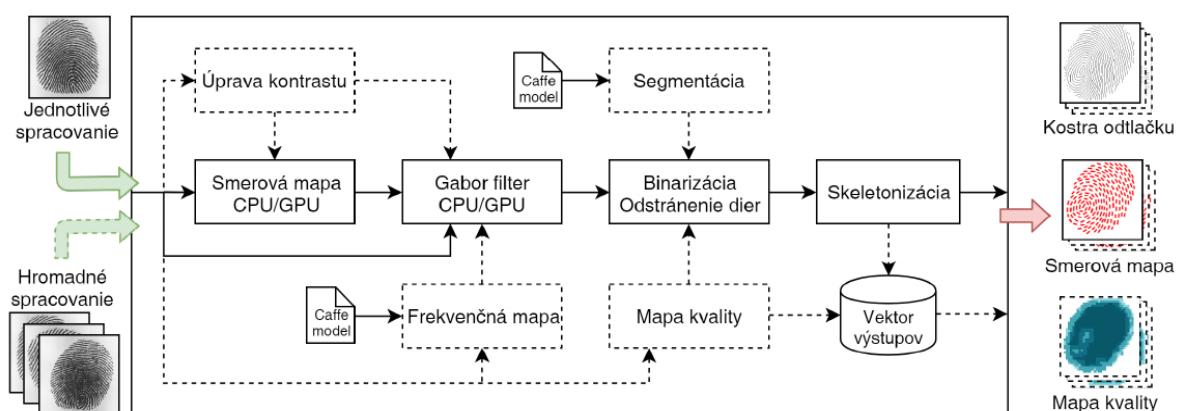
3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

- smerová mapa (vieme pomocou nej určiť smer odhalených markantov)
- *V expertnom režime.* V tomto režime získame okrem štandardných výsledkov aj tieto ďalšie výstupy na lepšiu analýzu vnútorných fáz predspracovania:
 - obraz po úprave kontrastu
 - frekvenčná mapa a maska odtlačku
 - výstup filtrovania Gaborovym filtrom
 - binarizovaný obrázok

Diagnostické výstupy:

- *Notifikácie o vzniknutých chybách.* Knižnica sa môže dostať do chybového stavu a vtedy je jej činnosť zastavená a volajúcemu programu je zaslaný Qt signál s chybovým kódom.
- *Notifikácie o priebehu spracovania.* Knižnica emituje priebežne signály o percentuálnej miere dokončenia všetkých operácií. Vhodné hlavne pre dlho trvajúce operácie.
- *Notifikácie o časoch trvania jednotlivých operácií vyjadrených v ms.* Po tom, ako knižnica dokončí svoju prácu tak je vyslaný Qt signál s trvaním jednotlivých fáz spracovania, aby sme mali prehľad o tom ako sa podielali jednotlivé operácia na celkovom čase výpočtov.

Na nasledujúcej schéme sú znázornené jednotlivé kroky v module predspracovania. Prerušenými čiarami sú označené voliteľné možnosti.



Obr. 3.11: Schéma knižnice na predspracovanie odtlačkov prstov (viac technických detailov je k dispozícii v diplomovej práci [31])

Segmentácia odtlačku prsta

Segmentácia je proces oddelenia nepotrebnnej obrazovej informácie (napr. snímací povrch) od miest, ktoré obsahujú daktyloskopický vzor odtlačku. Tento krok je potrebný najmä preto, aby sme v nasledovných fázach pracovali len s tou časťou obrazu, v ktorej je prítomný odtlačok. Využívaním segmentácie zmenšujeme počet preskúmaných obrazových bodov, čo vedie k výraznému skráteniu výpočtového času.

Zóny obrázku, kde je prítomný vzor odtlačku sa vyznačujú prevažne nižšou hodnotou jasu ako okolie (pretože papilárne línie sú tmavé). Techniky, ktoré využívajú lokálnu alebo globálnu prahovú hodnotu intenzity sivej farby na oddelenie pozadia od popredia nie sú spoľahlivé, keďže obrázky odtlačkov väčšinou majú rôzne kvality v rôznych častiach toho istého odtlačku a navyše snímané pozadie nemusí byť homogénne. Raymond Thai v [41] využil fakt, že pozadie odtlačku má väčšinou oveľa nižší lokálny rozptyl intenzity obrazových bodov, ako pruhový vzor odtlačku.

Výstupom segmentácie je tzv. maska, ktorá pozostáva z tých obrazových bodov, ktoré ležia vo vzore odtlačku. My sme zvolili odlišnú stratégiu pri vytváraní masky: použili sme strojové učenie. Natrénovali sme konvolučnú neurónovú sieť odvodenú z architektúry siete AlexNet, ktorá má 5 konvolučných a 3 plne prepojené vrstvy. Táto sieť predstavuje minimálne nároky na súčasný hardvér (nepotrebovali sme hlbšiu architektúru kvôli šetreniu zdrojov) a jej stavba postačovala na vyriešenie problému segmentácie. Sieť klasifikovala obrazové bloky do 2 tried: pozadie (z angl. background) a vzor odtlačku (z angl. foreground).

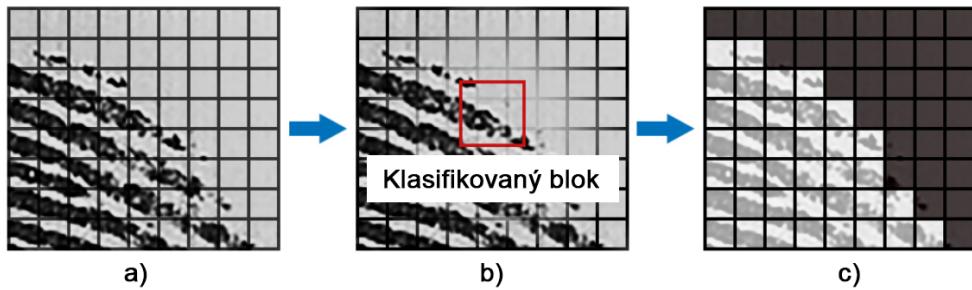
Táto sieť bola natrénovaná približne na 100 000 ručne vyzbieraných trénovacích vzorkách, ktoré mali rozmery 19×19 obrazových bodov.

Počas segmentácie sme postupovali nasledujúcim spôsobom:

1. Obrázok sme rozdelili na malé neprekryvajúce sa obrazové bloky b_{ij} s rozmerom $W \times W$. V našom prípade sme zvolili $W = 9$ px (vid' obrázok 3.12a). Táto hodnota bola zámerne nižšia ako veľkosť bloku B_{ij} , pre ktorú bola natrénovaná neurónová sieť. Veľkosti blokov sú platné pre obrázok v rozlíšení 500 PPI.
2. Okolo každého bloku $W \times W$ sme definovali väčšie bloky B_{ij} s veľkosťou $K \times K$ (vid' obrázok 3.12b). Tieto bloky boli určené pre nuerónovú sieť. Pre správnu funkčnosť treba dodržať, aby $W \leq K$. V našom prípade $K = 19$. K je väčšie z toho dôvodu, že sieť skúma širšie okolia bloku, ktorý skutočne klasifikuje. Tento systém sme zaviedli z toho dôvodu, že sme v praxi veľa krát natrafili na obrazové bloky b_{ij} , ktoré neobsahovali dostatočné informácie na posúdenie, či patria do popredia alebo pozadia odtlačku. Takýmto spôsobom vieme vytvoriť jemnú masku odtlačku, ktorá je zároveň veľmi presná.

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

3. Bloky B_{ij} s veľkosťou $K \times K$ sme poslali do siete na klasifikáciu, výstupnú hodnotu sme priradili každému obrazovému elementu v príslušnom bloku b_{ij} (viď obrázok 3.12c).



Obr. 3.12: Klasifikácia obrazových blokov pri segmentácii [31]

Po získaní masky sme odstránili diery, ktoré mohli vzniknúť nepresnosťou klasifikácie. Na obrázku 3.13a vidíme dieru v maske. Na obrázku 3.13b vidíme masku po odstránení diery. Diery sme odstraňovali morfologickými operátormi knižnice OpenCV.

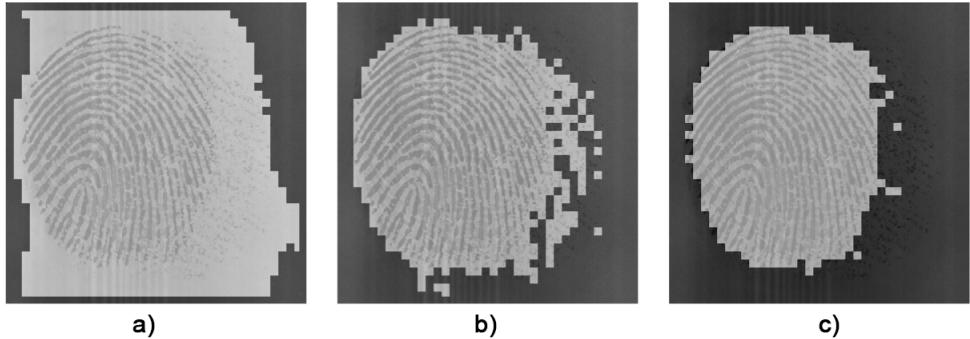
Následne sme masku vyhladili pomocou polygonálnej approximácie, aby nebola na okrajoch hranatá (viď obrázok 3.13c). Avšak v niektorých prípadoch to mohlo spôsobiť aj zbytočne veľkú stratu užitočnej časti odtlačku, preto sme sa nakoniec rozhodli vyhľadenie masky nevyužiť.



Obr. 3.13: Odstránenie dier z masky odtlačku a vyhľadenie okrajov masky [31]

Na obrázku 3.14 sú porovnané rôzne spôsoby vytvárania masky pre rovnaký obrázok odtlačku pri veľkosti bloku 8×8 px. Môžeme si všimnúť, že naša metóda (vpravo) dosiahla najlepší výsledok.

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

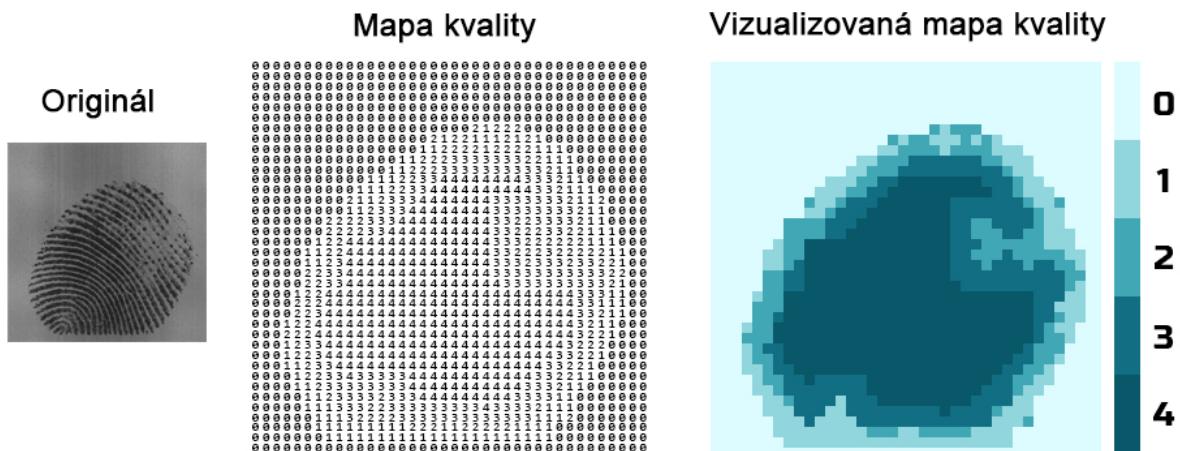


Obr. 3.14: Porovnanie viacerých metód segmentácie (a - maska získaná globálnym prahovaním, b - maska získaná prahovaním lokálneho rozptylu, c - naša metóda) [31]

Mapa kvality

Mapa kvality odtlačku je matica, pomocou ktorej vieme zakódovať zreteľnosť papilárnych línií odtlačku. Túto informáciu vieme následne zužitkovať pri extrakcii markantov, kde vieme označiť odhalené markanty ako nespoľahlivé ak sa nachádzajú v zónach, ktoré mapa kvality vyhodnocuje ako nekvalitné. Rovnako sa dá mapa kvality použiť na vytvorenie masky odtlačku.

Na vytvorenie mapy kvality sme využili algoritmus MINDTCT [86] z balíku softvérových nástrojov od NIST-u s názvom NBIS (NIST Biometric Image Software). Tento algoritmus rozdelí vstupný obraz do štvorcových blokov s rozmerom 8×8 a každému bloku priradí číselnú hodnotu v rozsahu 0-4, kde 0 predstavuje najnižšiu a 4 najvyššiu kvalitu. Príklad mapy kvality vypočítanej pomocou MINDTCT vidíme na obrázku 3.15.



Obr. 3.15: Mapa kvality vypočítaná softvérom MINDTCT [31]

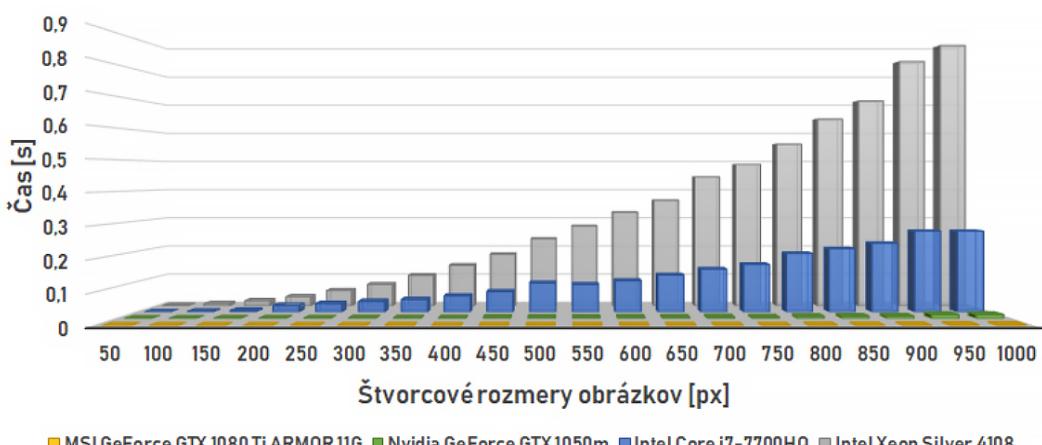
Smerová mapa

Pri návrhu a implementácii smerovej mapy odtlačku sme vychádzali z teórie uvedenej v časti 2.3.1. Smerová mapa určuje uhly naklonenia papilárnych línií v rôznych častiach obrazu a je nevyhnutná pre správne nastavenie Gaborovho filtra a počas extrakcie markantov na určenie smeru markantov. Výpočet smerovej mapy sme realizovali aj na procesore (CPU), aj na grafickom procesore (GPU).

Pri výpočte smerovej mapy je nutné dbať na to, aby boli nami vypočítané smery kompatibilné so štandardnými formátmi určenými na uchovávanie daktyloskopických údajov. Najdôležitejšie formáty a ich požiadavky uvádzame v nasledovnom prehľade.

- **XYT formát** využívaný softvérom NBIS, ktorý je kompatibilný s normou ANSI/NIST-ITL 1-2007: uhol 0° definuje v horizontálnom smer doprava a granularita smerov je 1° (smery sú kódované číslami 0-359).
- **ISO/IEC 19794-2** formát: uhol 0° definuje v horizontálnom smer doprava a granularita smerov je 1.40625° (smery sú kódované v rozsahu 0-255).
- **ANSI INCITS 378** formát: uhol 0° definuje v horizontálnom smer doprava a granularita smerov je 2° (smery sú kódované v rozsahu 0-179).

Výpočet smerovej mapy vykonaný na CPU bol výpočtovo náročný krok a z toho dôvodu sme smerovú mapu implementovali aj na GPU. CPU implementácia využíva knižnicu OpenCV a GPU implementácia používa knižnicu ArrayFire. Z našich experimentov sme došli ku globálному záveru, že GPU implementácia je rýchlejšia približne od veľkosti obrázku 250×250 px. Malé smerové mapy sú rýchlejšie vypočítané na CPU. Graf na obrázku 3.16 ukazuje, ako závisí doba výpočtu smerovej mapy od rozmerov vstupného obrazu na CPU a GPU.



Obr. 3.16: Rýchlosť výpočtu smerovej mapy pre rôzne rozmery obrázkov [31]

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

Je zjavné, že GPU bežného laptopu alebo výkonné GPU s množstvom CUDA jadier vykoná výpočet smerovej mapy rýchlejšie ako CPU. Serverové dva 16-vláknové procesory Intel Xeon Silver 4108 dokonca dosiahli najhorší výsledok, čo môžeme odôvodniť faktom, že jeho taktovacia frekvencia je len 1,80 GHz. Pri multi-vláknovej implementácii smerovej mapy by mohla byť doba výpočtu na tomto procesore porovnateľná s testovanými GPU.

Pri experimentoch sme sa zamerali hlavne na vplyv parametrov smerovej mapy na výsledný odhad smeru. Na obrázku 3.17 uvádzame ukážku, v ktorej je vidieť ako vplyvá veľkosť bloku na presnosť odhadu smeru.



Obr. 3.17: Vplyv veľkosti bloku smerovej mapy na presnosť odhadu smeru (vľavo - originál, v strede - blok 13×13 , vpravo - blok 41×41)

Taktiež uvádzame ukážku demonštrujúcu smerové mapy pre obrázky rôznej kvality 3.18.



Obr. 3.18: Smerové mapy odtlačkov v rôznych kvalitách

Adaptívny Gaborov filter

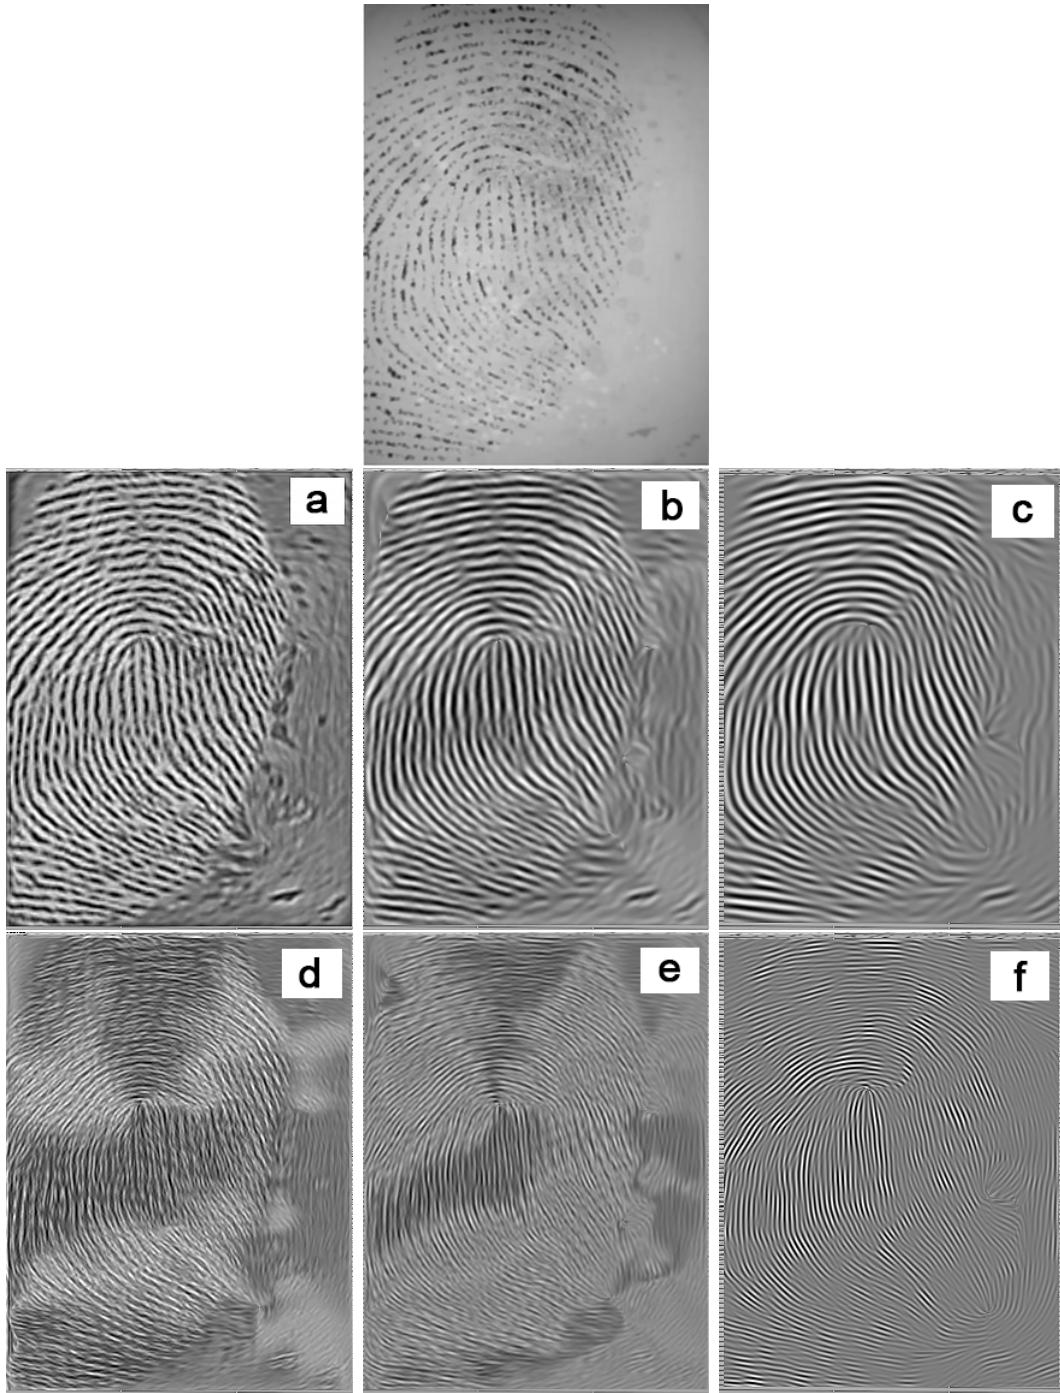
Gaborov filter je najdôležitejším algoritmom nášho predspracovania, pretože významne vylepšuje kvalitu obrázkov, obnovuje štruktúru nevýrazných papilárnych línii a odstraňuje šum. Vzhľadom na jeho výpočtovú náročnosť sme vytvorili okrem štandardnej CPU implementácie aj jeho GPU implementáciu spolu s viac-vláknovou CPU implementáciou. Týmto spôsobom vie naša knižnica využiť maximálnu výpočtovú silu hardvéru počítača.

Implementácia Gaborovho filtra využíva matematický aparát popísaný v časti 2.3.1. Na základe našich pozorovaní počas experimentov sme parametre Gaborovho filtra nastavili tak, aby boli vhodné pre obrázky s rozlíšením 500 PPI a to konkrétnie:

- veľkosť filtrovaného bloku (veľkosť filtrovacieho kernelu) 31×31
- šírka papilárnej línie $\lambda = 9$ (frekvencia f sa určí ako $f = \frac{1}{\lambda}$), tento parameter sa používa globálne pre celý obraz v prípade ak nepoužívame frekvenčnú mapu
- smerodajná odchýlka Gaussovej krivky v smere x-ovej a y-ovej osi $\sigma = 3$, určuje priestorovú silu filtrovania (resp. dosah filtrovacieho účinku)
- pomer strán filtra $\gamma = 1$
- fázový posun $\psi = 0$

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

Ak používalať nezadá iné hodnoty, tieto parametre sú v knižnici prednastavené . Vplyv rôznych parametrov filtrovania na výsledný obraz môžeme vidieť na obrázku 3.19.



Obr. 3.19: Vplyv veľkosti bloku a parametra λ na výsledok filtrovania Gaborovym filtrom (najlepší výsledok bol dosiahnutý na obrázku c, kde bol použitý blok 31×31 a $\lambda = 9$)

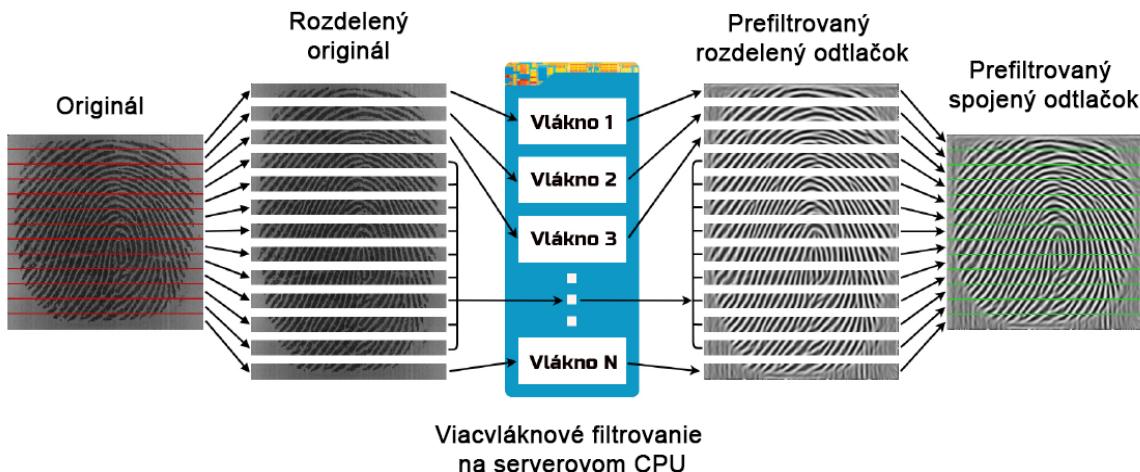
3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

Pri jednotlivých prefiltrovaných obrazoch na obrázku 3.19 boli použité parametre dané nasledujúcou tabuľkou.

Tabuľka 3.2: Vplyv veľkosti filtrovacieho kernelu a parametra λ Gaborovho filtra na výsledný obraz

Označenie obrazu na obrázku 3.19	λ	Veľkosť bloku (kernelu)
a	9	7
b	9	13
c	9	31
d	4	7
e	4	13
f	4	31

Pri filtrovaní pomocou CPU sme na výpočet využili vlákna procesora. Obrázok sme rozdelili na menšie časti a každé vlákno spracovalo iba jednu takúto časť.

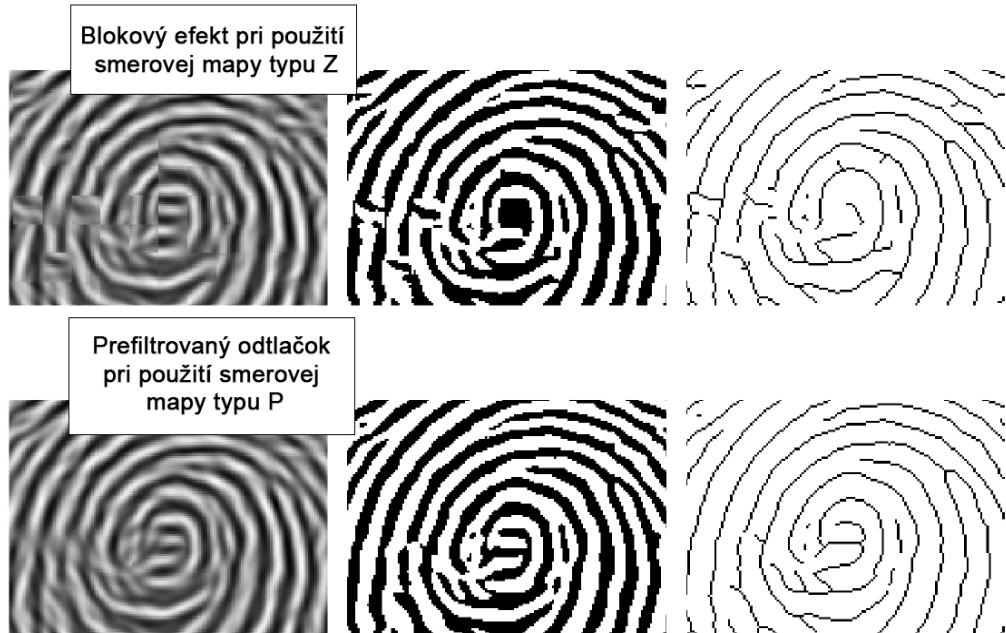


Obr. 3.20: Princíp využitia viacvláknového Gaborovho filtra [31]

Gaborov filter sme naprogramovali tak, aby bol schopný vytvoriť filtrovaný obrázok aj pomocou smerovej mapy typu Z (smery sú pridelené blokom) a taktiež pomocou smerovej mapy typu P (smery sú pridelené jednotlivým bodom) a to prostredníctvom CPU alebo GPU. Filtrovanie pomocou smerovej mapy typu P je pomalšie pretože Gaborov kernel musí byť vypočítaný zvlášť pre každý jeden obrazový bod (nakol'ko sa líšia smerom). Na druhej strane použitie mapy P pri filtrovaní prinieslo očakávaný efekt a to hladké prefiltrovanie odtlačku aj v oblastiach, kde boli papilárne línie príliš zakrivené. V prípade použitia mapy Z vznikal neželaný blokový efekt, ktorý vytváral nespojitosti v toku papilárnych línií, čo môže viest' k tvorbe falošných markantov. Rozdiel medzi filtrovaním s použitím smerovej mapy Z a P vidíme na obrázku 3.21.

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

Kostra odltačku, ktorá vznikla v prípade použitia smerovej mapy Z obsahuje množstvo falošných útvarov.



Obr. 3.21: Účinok smerovej mapy typu Z a P vo fáze filtrovania Gaborovym filtrom (horný riadok ukazuje slabé výsledky predspracovania s použitím mapy Z, spodný riadok ukazuje odstránenie blokového efektu pri použití mapy P) [31]

Dôležitosť využitia Gaborovho filtra v procese predspracovania potvrzuje aj obrázok 3.22. Vidíme, že kostra odtlačku, v ktorej sa neskôr odhalujú markanty je bez použitia filtra znehodnotená a pôvodná štruktúra odtlačku v nej zanikla. Naopak, s použitím filtra sme získali kostru, ktorá verne reprezentuje skutočný vzor odtlačku.

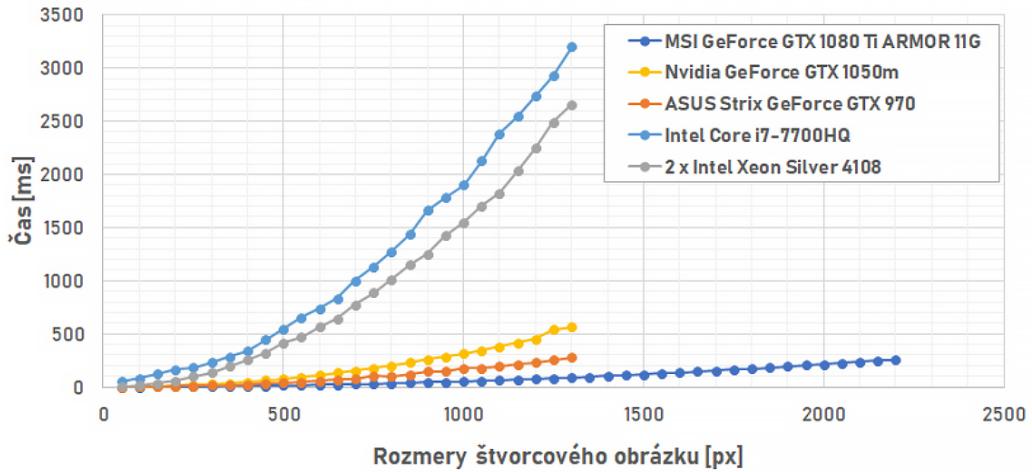


Obr. 3.22: Filtrovanie odtlačku a jeho dopad na kvalitu kostry odtlačku [31]

Na obrázku 3.23 vidíme ako závisel čas filtrovania Gaborovym filtrom od rozmeru obrazu na rôznych GPU a CPU. Najlepší čas dosiahla naša implementácia na NVidia

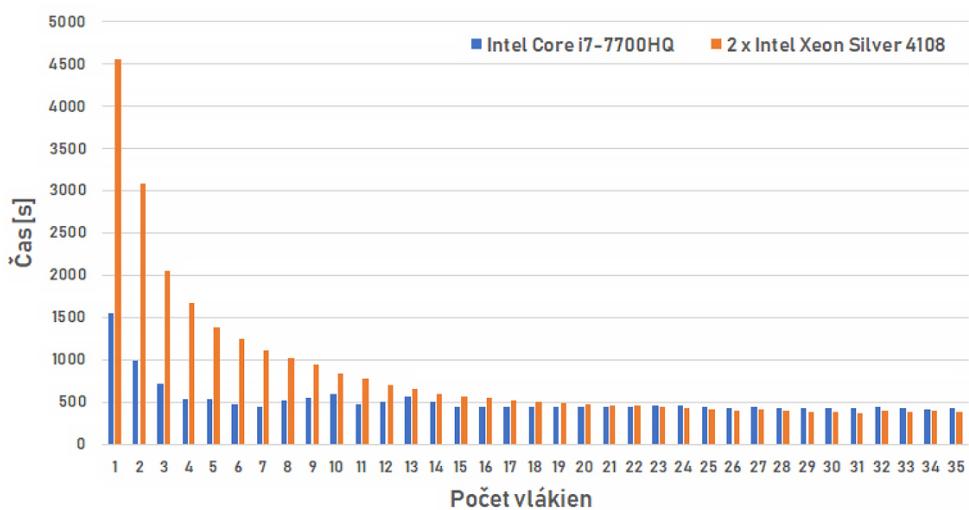
3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

GeForce GTX 1080 Ti. Tento výsledok svedčí o značnom prínose našej GPU implementácie v knižnici ArrayFire.



Obr. 3.23: Porovnanie rýchlosí filtrovania Gaborovým filtrom na rôznych GPU a CPU (1 vlákno) v závislosti od rozmeru vstupného obrazu [31]

Obrázok 3.24 ukazuje graf porovnania rýchlosí aplikovania Gaborovho filtra na odtlačok s rozmermi 300×300 pri využití viac-vlákrovej CPU implementácie a implementácie na GPU. Prvé spracovanie odtlačku pri využití GPU trvalo vždy dlhšie z dôvodu ukladania údajov do cache pamäte. Z tohto dôvodu sme zaviedli tzv. zahrievajúci beh, ktorý sme počas testovania rýchlosí ignorovali, aby sme mohli získať objektívne výsledky. Vidíme, že približne od 13 vlákin je rýchlosť na CPU a GPU porovnateľná.

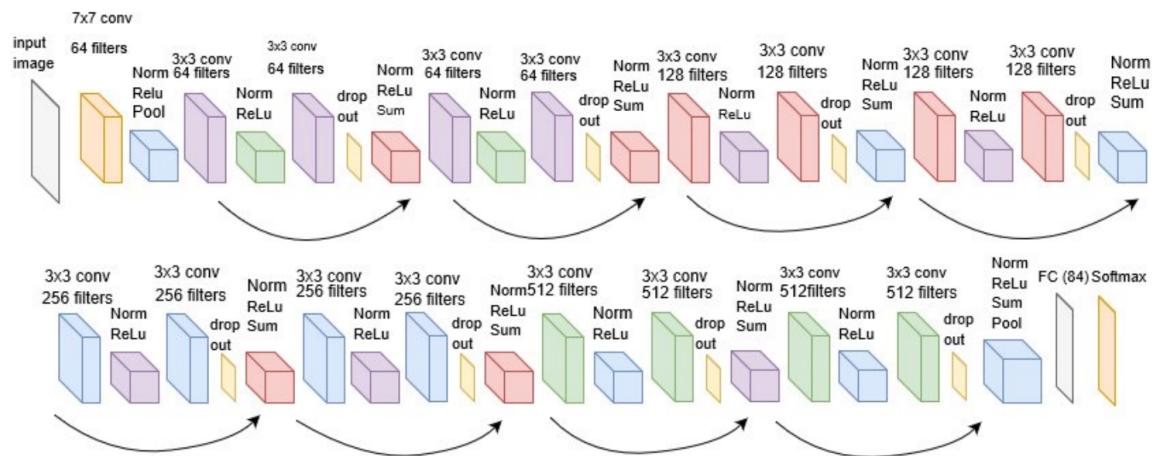


Obr. 3.24: Závislosť trvania filtrovania Gaborovým filtrom od počtu CPU vlákin [31]

3.2.2 Knižnica na extrakciu charakteristických vzorov od tlačku

Táto knižnica slúži na extrakciu daktyloskopických markantov nachádzajúcich sa vo vzore odtlačku prsta. Hlavnou myšlienou nášho algoritmu je ich odhalovanie v originále obrazu, nakoľko predspracovanie dokáže značne modifikovať drobné detaile v štruktúre odtlačku. Avšak výsledok predspracovania je potrebný na určenie kandidátov na markanty.

Na extrakciu daktyloskopických markantov používame vlastnú konvolučnú neurónovú sieť implementovanú v prostredí knižnice Caffe, natrénovanú na vlastných obrazových vzorkách vytypovaných markantov, ktoré boli zozbierané našim softvérom s názvom OF Sample Collector. Konvolučná sieť, ktorú používame je modifikovaná verzia známej reziduálnej konvolučnej siete ResNet-18. Myšlienou reziduálnych sietí je zámerné vynechávanie prepojení medzi vrstvami a prepájanie vrstiev, ktoré nie sú susedmi. Takéto skákanie cez viaceré vrstvy umožňuje riešiť problém známy ako vanishing gradient (problém kedy sa spomaľuje adaptácia váh počas trénovalia, čo spomaľuje až znemožňuje zvyšovanie klasifikačnej presnosti).



Obr. 3.25: Nami použitá modifikovaná sieť ResNet-18 určená na klasifikáciu daktyloskopických markantov

Modifikácia siete spočívala v úprave vstupnej vrstvy siete tak, aby bola kompatibilná s rozmermi obrazov z našich databáz. Ďalšou modifikáciou je pridanie dropout vrstvy za konvolučnú vrstvu. Dropout vrstvy sa zvyčajne v rôznych architektúrach pridávajú za vrstvy, ktoré obsahujú veľké množstvo pracovných parametrov a dropout spôsobuje ich vynechávanie, aby sa zamedzilo pretrénovaniu. Obdobnú modifikáciu siete ResNet urobilo viacero autorov v literatúre a daným počinom dospeli k lepším výsledkom počas trénovalia. Architektúra našej siete je znázornená na obrázku 3.25. Všetky parametre konvolučných vrstiev siete sú znázornené v tabuľke na obrázku 3.26.

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

Layer	Output	Layer Information
Conv1	112×112	$7 \times 7, 64$ stride 2
Conv2.1	56×56	$3 \times 3, \text{maxpool}$ stride 2 $3 \times 3, 64$
Conv2.2	56×56	$3 \times 3, 64$
Conv3.1	28×28	$3 \times 3, 128$
Conv3.2	28×28	$3 \times 3, 128$
Conv4.1	14×14	$3 \times 3, 256$
Conv4.2	14×14	$3 \times 3, 256$
Conv5.1	7×7	$3 \times 3, 512$
Conv5.2	7×7	$3 \times 3, 512$
FLOPs	1×1	Average pooling, 84-d, FC, Softmax 1.8×10^9

Obr. 3.26: Parametre konvolučných vrstiev modifikovanej siete ResNet-18

Extrakcia v skratke prebieha tak, že sa vstupný obraz odtlačku prsta predspracuje a v kostre odtlačku sa algoritmom Crossing Number odhalia prvotné potenciálne pozície markantov, ktoré sa následne klasifikujú v neurónovej sieti. Odhalené markanty môžu byť exportované do formátu ISO/IEC 19794-2 kvôli kompatibilite s ostatnými systémami.

API rozhranie knižnice na získanie vstupných údajov ponúka nasledovné možnosti:

- Dodanie jednotlivých nevyhnutných vstupov: originál odtlačku, kostra odtlačku, mapa kvality, smerová mapa. Tieto údaje sú knižnici poskytnuté ako samostatné matice dátového typu `cv::Mat`.
- Dodanie všetkých výstupov predspracovania v jednom balíku. Balíkom je štruktúra dátového typu `PREPROCESSING_RESULTS`.
- Dodanie výstupov predspracovania viacerých obrazov v jednom balíku. Balíkom je mapa, v ktorej sú na názvy obrázkov namapované výsledky predspracovania vo formáte `PREPROCESSING_RESULTS`. Toto vstupné rozhranie umožňuje extrakciu markantov z viacerých obrazov naraz.

API rozhranie knižnice na nastavovanie parametrov extrakcie ponúka nasledovné možnosti:

- Funkcia `setCPUOnly`. Umožňuje povoliť spracovanie len na CPU. V predvolenom nastavení prebieha extrakcia na GPU.
- Funkcia `setFeatures`. Umožňuje nastaviť, či chceme, aby boli objavené markanty prevedené do formátu ISO/IEC 19794-2 a či chceme klasifikovať markanty pri viacerých rozmeroch vstupného bloku, čo zvyšuje presnosť, ale na druhej strane je to pomalšia operácia.

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

- Funkcia `setExtractionParams`. Umožňuje zadanie parametrov použitej neurónovej siete, ktorá bude slúžiť na klasifikáciu markantov a veľkosť bloku, ktorý bude neurónová sieť počas klasifikácie skúmať. Takýmto spôsobom vieme testovať extrakciu pomocou rôznych architektúr sietí. V súčasnosti podporuje naše riešenie len externú knižnicu Caffe, pomocou ktorej definujeme, trénujeme a testujeme siete.

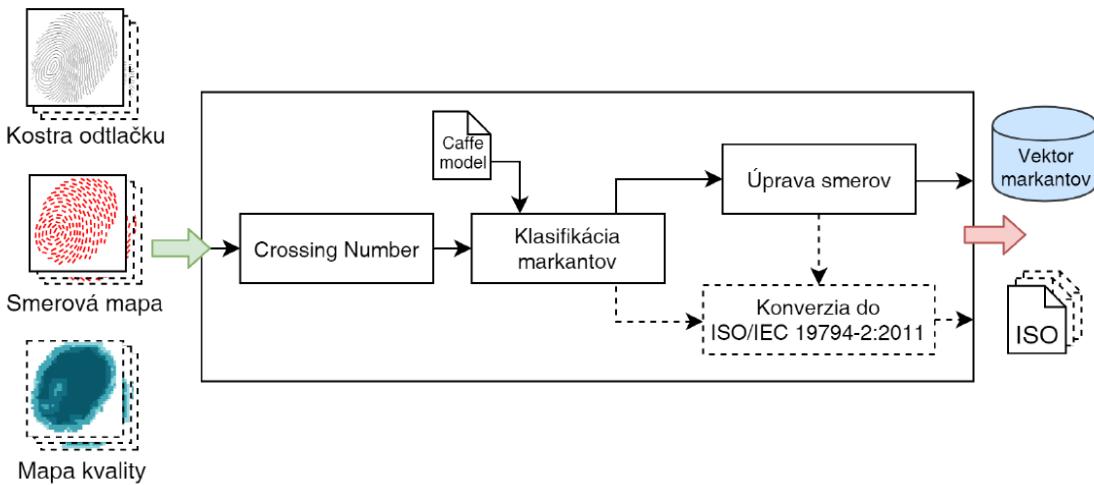
Výstupy knižnice:

- *Režim extrakcie markantov v jednom odtlačku:*
 - vektor odhalených markantov, pričom pre každý markant evidujeme jeho súradnicu, uhol, tvarový typ a kvalitu
 - záznam o odhalených markantoch zakódovaný podľa formátu ISO/IEC 19794-2
- *Režim extrakcie markantov v dávke odtlačkov:*
 - vektor odhalených markantov pre každý odtlačok, pričom pre každý markant evidujeme jeho súradnicu, uhol, tvarový typ a kvalitu
 - záznam o odhalených markantoch pre každý odtlačok zakódovaný podľa formátu ISO/IEC 19794-2

Diagnostické výstupy:

- emitovaný Qt signál, ktorý obsahuje záznamy o dĺžke trvania vnútorných procesov priebehajúcich v knižnici počas extrakcie
- emitovaný Qt signál informujúci o priebehu extrakcie (nesie percentuálnu mieru dokončenia všetkých operácií)
- emitovaný Qt signál o vzniknutej chybe (ak knižnica nemôže pokračovať vo svojej práci, ukončí spracovanie a vyšle chybový kód)

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER



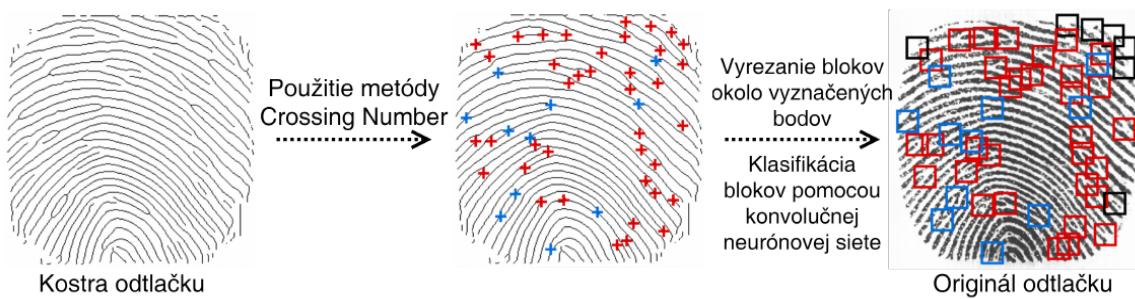
Obr. 3.27: Schéma knižnice na extrakciu charakteristických znakov odtlačkov prstov (podrobný technický popis je k dispozícii v diplomovej práci [31])

Navrhnutý algoritmus extrakcie markantov:

1. Vykoná sa algoritmus Crossing Number 2.2.3. Jeho výstupom je odhalenie všetkých ukončení a rozdvojení papilárnej línie v kostre odtlačku. Vznikne tak množina kandidátov na markanty. Jedná sa o kandidátov z toho dôvodu, že boli odhalené v kostre odtlačku, ktorá nie je úplne presnou reprezentáciou odtlačku. Finálne klasifikovanie vykoná neurónová sieť, ktorá určí prítomnosť a typ markantu. Neurónová sieť neprehľadáva celý obraz, ale len miesta identifikované algoritmom Crossing Number.
2. Vykoná sa finálna klasifikácia markantov pomocou našej konvolučnej neurónovej siete. Na vstup siete je privedený obrazový blok, ktorého súradnice stredu korešpondujú so súradnicou kandidáta na markant, ktorý bol určený algoritmom Crossing Number. Neurónová sieť odpovie, či blok obsahuje markant a akého je tvarového typu.
3. Upravia sa smery a súradnice markantov tak, aby boli kompatibilné s formátom ISO/IEC 19794-2.
4. Odhalené markanty sa voliteľne enkapsulujú do formátu ISO/IEC 19794-2 (výsledkom je blok bajtov organizovaný podľa špecifikácie štandardu)

Proces detektie markantov v kostre odtlačku a ilustrácia blokov, ktoré sú zaslané do neurónovej siete na klasifikáciu je znázornená na obrázku 3.28.

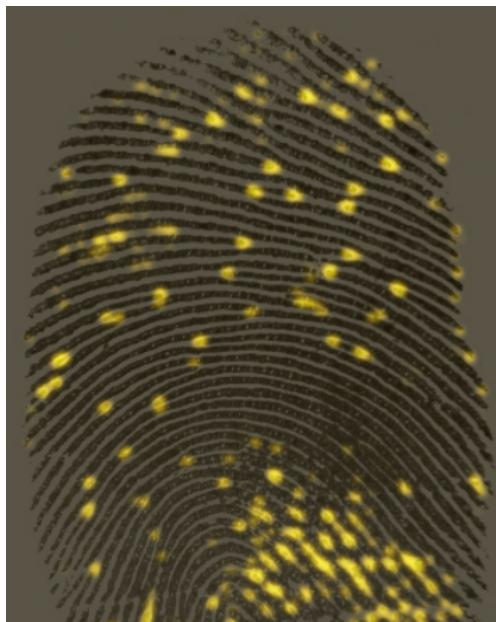
3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER



Obr. 3.28: Schéma kombinovania konvolučnej neurónovej siete s metódou Crossing Number

Na globálne zhodnotenie presnosti neurónovej siete pri klasifikácii markantov je potrebné vykonať rozsiahle experimenty, pri ktorých vidíme ako neurónová sieť odhaľuje markanty v rôznych miestach odtlačku a pri rôznych obrazových kvalitách. Preto naša knižnica disponuje možnosťou zaklasifikovať každého obrazového bloku v odtlačku. Získame tak mapu výsledkov klasifikácie pre odtlačok. Týmto spôsobom vidíme, v ktorých oblastiach sieť vidí markanty a v ktorých necharakteristické miesta.

Na to, aby sme túto mapu mohli skonštruovať, sme potrebovali zaklasifikovať bloky okolo všetkých obrazových bodov v odtlačku. Pravdepodobnosť klasifikácie do jednotlivých tried sme farebne kódovali a vznikla tak tzv. tepelná mapa ako ju môžeme vidieť na obrázku 3.28.



Obr. 3.29: Tepelná mapa vyjadrujúca výsledky klasifikovania každého obrazového bodu v odtlačku (intenzita žltej farby signalizuje pravdepodobnosť prítomnosti markantu)

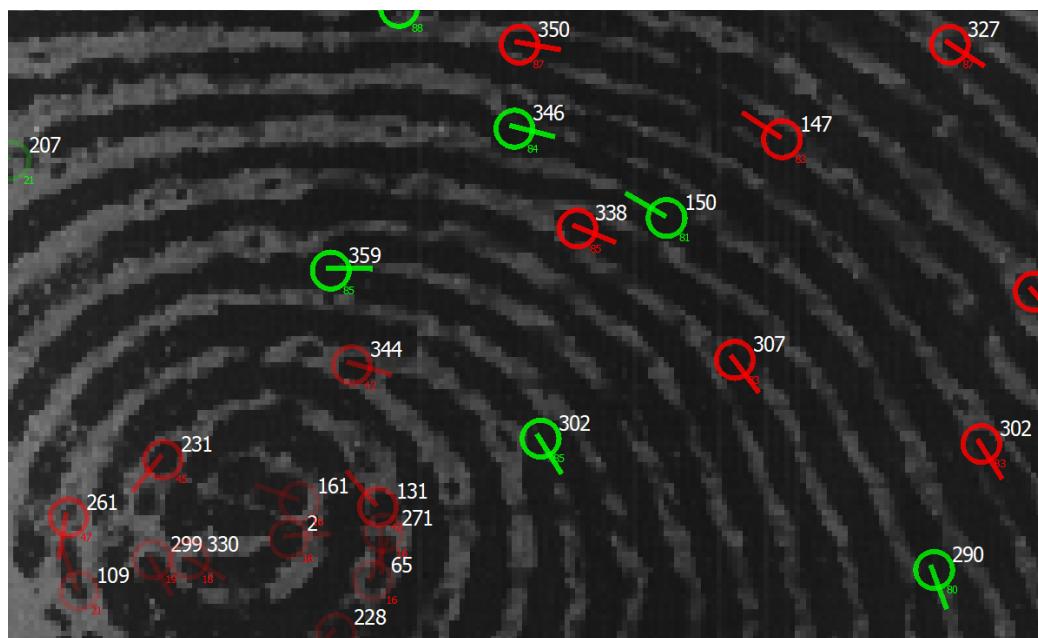
3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

Konvolučná neurónová sieť klasifikuje vstupný obrazový blok s rozmerom 19×19 (platné pre rozlíšenie 500 PPI) do týchto tried:

- ukončenie papilárnej línie
- rozdvojenie papilárnej línie
- blok, ktorý neobsahuje daktyloskopický markant

Na trénovanie našej siete sme použili 28 760 ručne vyzbieraných blokov pre každú triedu. Trénovacie vzorky sme vytvárali za pomocí nášho vlastného interaktívneho softvéru OF Sample Collector na zber obrazových blokov z obrázkov.

Správnosť extrakcie markantov vieme overiť aj pomocou našej pokročilej vizualizácie výsledkov extrakcie (obrázok 3.30), ktorá je schopná rozlišovať typ markantu (farba kružnice), kvalitu (priehľadnosť kružnice a číslo v rozsahu $\langle 0, 100 \rangle$ umiestnené vpravo dole od kružnice) a smer markantu (orientovaná úsečka a číslo vpravo hore od kružnice, ktoré vyjadruje uhol v stupňoch).



Obr. 3.30: Pokročilá vizualizácia výsledkov extrakcie markantov

3.2.3 Knižnica na porovnávanie odtlačkov prstov

Porovnávanie odtlačkov podľa markantov získaných vo fáze extrakcie je záverečným krokom nášho modulu na rozpoznávanie odtlačkami prstov. Výstupom porovnávania je skôr určujúce podobnosť medzi dvoma odtlačkami. Pod pojmom podobnosť uvažujeme pravdepodobnosť, s akou podľa porovnávacieho algoritmu dve množiny Level-2 znakov pochádzajú z rovnakého prsta. Táto miera býva rôznymi porovnávacími algoritmami rôzne kvantifikovaná (napr. rozsahom hodnôt v intervale $\langle 0, 1 \rangle$ alebo $\langle 0, 100 \rangle$, kde nízke hodnoty znamenajú nevýznamnú a vysoké hodnoty naopak významnú podobnosť).

Na porovnávanie sme použili dva známe algoritmy:

- komerčný porovnávací algoritmus z BioMini SDK od firmy Suprema
- open-source porovnávací algoritmus BOZORTH3 z balíka softvérových nástrojov NBIS vyvinutého americkým NIST-om.

Naša porovnávacia knižnica dokáže pracovať v dvoch režimoch:

- *Verifikácia* - jedná sa o režim porovnávania 1:1, kde sa odtlačok vstupujúci do knižnice porovnáva s odtlačkom vybratým z databázy odtlačkov pomocou postrannej informácie, napr. mena alebo ID čísla.
- *Identifikácia* - jedná sa o režim porovnávania 1:N, kde sa vstupný odtlačok porovnáva so všetkými odtlačkami v databáze a nás systém určí identitu odtlačku podľa najvyššieho dosiahnutého porovnávacieho skóre.

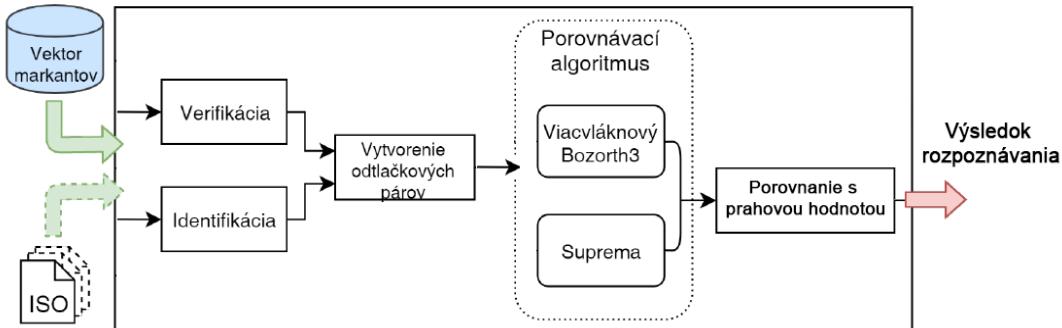
Našim vlastným prínosom v tejto fáze bolo použitie dvôch rôznych algoritmov (komerčný a open-source) porovnávania a taktiež naša vlastná modifikácia algoritmu BOZORTH3, ktorého zdrojový kód sme mali k dispozícii.

Modifikácia algoritmu BOZORTH3 spočívala v týchto aspektoch:

- Prepísanie algoritmu tak, aby využíval viaceré vlákna serverového procesora. Pôvodná verzia nevyužívala vlákna a pri odtlačkoch prstov, ktoré obsahovali veľký počet markantov bol BOZORTH3 extrémne pomalý (vzhľadom na jeho brute-force metodiku porovnávania). Ako sa neskôr ukázalo, dokázali sme tak niekoľkokrát zrýchliť porovnávanie odtlačkov prstov.
- Vytvorenie dynamickej knižnice. V pôvodnej verzii bol BOZORTH3 napísaný ako konzolová spustiteľná aplikácia, čo výrazne znižovalo jeho schopnosť integrácie do inej softvérovej aplikácie. Preto sme prepísali jeho zdrojový kód tak, aby bol vo forme knižnice, ktorá poskytuje funkcionality prostredníctvom svojho API rozhrania.

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

Schéma fungovania našej knižnice porovnávania je daná diagramom na obrázku 3.31.



Obr. 3.31: Schéma knižnice na porovnávanie odtlačkov prstov (viac technických detailov je k dispozícii v diplomovej práci [31])

API rozhranie knižnice na porovnávanie odtlačkov prstov ponúka tieto možnosti:

- *Funkcia na volbu porovnávacieho algoritmu.* Pomocou nej vieme zvoliť, či sa budú získané markanty odtlačku porovnávať algoritmom BioMiniSDK (vyžadujú sa markanty vo formáte ISO/IEC 19794-2) alebo našim modifikovaným viacvláknovým porovnávačom BOZORTH3.
- *Funkcie na verifikáciu.* Umožňujú špecifikovať pár odtlačkov prstov vyjadrený pomocou ich markantov, ktorý sa bude knižnicou porovnávať. Markanty dokážeme reprezentovať vlastným vnútorným formátom alebo štandardizovaným formátom ISO/IEC 19794-2. Keďže osoba zaregistrovaná v databáze mohla mať zosnímaný rovnaký prst viackrát, dokážeme vstupný odtlačok porovnať s kolekciou odtlačkov patriacich rovnakému prstu.
- *Funkcie na identifikáciu.* Umožňujú špecifikovať odtlačok a k nemu asociovanú množinu odtlačkov, s ktorými sa bude porovnávať. Porovnávanie vráti odtlačok s najvyššou zhodou.

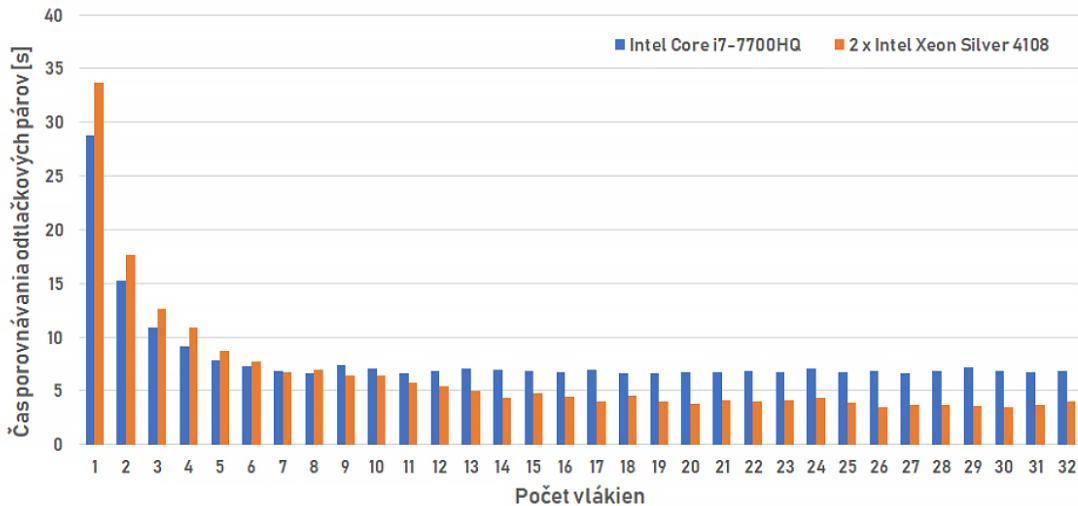
Diagnostické výstupy:

- Knižnica emituje Qt signál, ktorý oznamuje stav priebehu porovnávania vyjadrený v percentuálnej miere dokončenia všetkých úloh.
- Knižnica emituje Qt signál, v momente vzniku chyby a podľa vráteného chybového kódu vieme zistiť, aká chybová situácia nastala.

Na obrázku 3.32 vidíme ako sa vyvíjal čas potrebný na porovnanie 7 750 odtlačkových párov algoritmom BOZORTH3, ktorý sme modifikovali, aby využíval vlákna serverového procesora. Nás server, na ktorom prebiehalo testovanie, bol vybavený 2 procesormi Intel Xeon Silver 4108, čo predstavovalo spolu 32 pracovných vláken. Z

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

grafu vidíme, že najjdeálnejší výkon bol dosiahnutý pri využití všetkých 32 vláken. Našim prínosom bolo približne 11-násobné zrýchlenie porovnávania.



Obr. 3.32: Rýchlosť nami modifikovaného porovnávacieho algoritmu BOZORTH3 v závislosti od počtu vláken CPU (bol meraný čas porovnania 7 750 odtlačkových párov, kde každý odtlačok mal rozmer 300×300) [31]

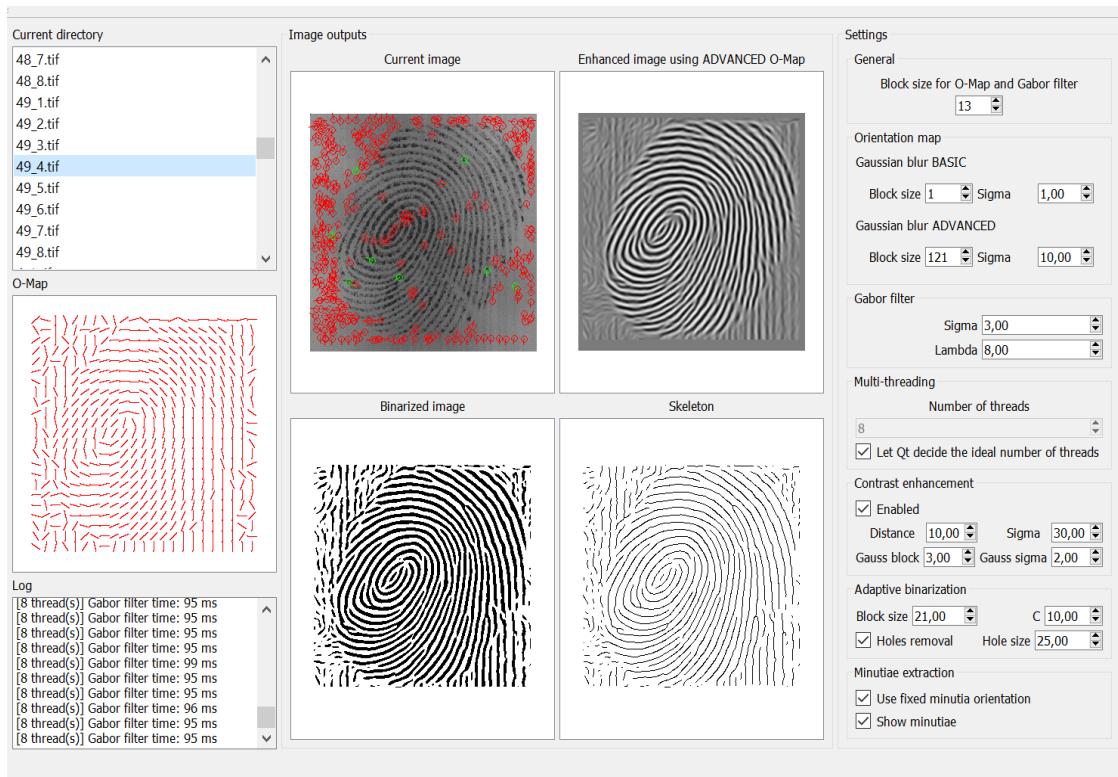
3.2.4 OF Sandbox: expertný systém na testovanie predspracovania

Vyvinuli sme Qt GUI aplikáciu s názvom OF Sandbox na testovanie knižnice predspracovania odtlačkov prstov. Pomocou nej vieme ladiť náš softvér a dosiahnuť tak, čo najoptimálnejšie obrazové výstupy. Klúčovou vlastnosťou tohto softvéru je možnosť vykonať tieto úkony:

- volba vlastnej databázy obrazov odtlačkov prstov a volba konkrétnych obrázkov
- nastaviť parametre úpravy kontrastu, adaptívnej binarizácie, výpočtu smerovej mapy (typ Z aj P)
- nastaviť parametre viacvláknového adaptívneho Gaborovho filtra a počet vláken, ktoré filter využije na svoju akceleráciu
- získanie informácie o trvaní jednotlivých operácií
- možnosť spustiť extrakciu markantov vo zvolenom predspracovanom odtlačku a ukázať objavené markanty (veľmi užitočná funkcia, ktorá priamo vypovedá o kvalite zvolenej konfigurácie predspracovania)
- vizualizácia medzivýstupov

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

Aplikácia dovoľuje výber vstupného obrázku zo zvoleného adresára a vizualizuje medzivýstupy predspracovania a časy trvania výpočtov. Pomocou tejto aplikácie sme stanovili všetky ideálne parametre predspracovania pre obrazy v rozlíšení 500 PPI, ktoré sú taktiež nastavené v knižnici ako predvolené parametre.



Obr. 3.33: Používateľské rozhranie systému OF Sandbox určené na testovanie predspracovania obrazu

3.2.5 Export extrahovaných údajov do štandardizovaného dátového formátu ISO/IEC 19794-2

Náš softvér podporuje export údajov o odhalených daktyloskopických markantoch do medzinárodne akceptovaného a štandardizovaného dátového formátu ISO/IEC 19794-2:2005 (posledná revízia je z roku 2011). Týmto je zabezpečené univerzálné použitie našej extrakčnej knižnice, keďže údaje budú môcť byť prečítané inými systémami rôznych výrobcov, ktoré sú rovnako kompatibilné s daným dátovým štandardom. Popis jednotlivých dátových polí celého ISO/IEC 19794-2 záznamu je uvedený na obrázku 3.34.

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

	Field	Size	Valid Values	Notes
One per Record	Format Identifier	4 bytes	0x464D5200 ('F' 'M' 'R' 0x0)	"FMR" – finger minutiae record
	Version of this standard	4 bytes	n n n 0x0	"XX", with XX = 20 or greater
	Length of total record in bytes	4 bytes	24 - 4294967295	either 0x0018 to 0x0000FFFFFF
	Capture Equipment Certification	4 bits		compliance with Annex B or future ISO standards
	Capture Device Type ID	12 bits		Vendor specified
	Image Size in X	2 bytes		in pixels
	Image Size in Y	2 bytes		in pixels
	X (horizontal) Resolution	2 bytes		in pixels per cm
	Y (vertical) Resolution	2 bytes		in pixels per cm
	Number of Finger Views	1 byte	0 to 255	
	Reserved byte	1 byte	00	0 for this version of the standard (reserved for future use)
One per View	Finger Position	1 byte	0 to 10	
	View Number	4 bits	0 to 15	
	Impression Type	4 bits	0 to 3 or 8	
	Finger Quality	1 byte	0 to 100	0 to 100
	Number of Minutiae	1 byte		
One per minutiae	X (minutiae type in upper 2 bits)	2 byte		Expressed in image pixels
	Y (upper 2 bits reserved)	2 byte		Expressed in image pixels
	θ	1 byte	0 to 255	Resolution is 1.40625 degrees
	Quality	1 byte	0 to 100	1 to 100 (0 indicates "quality not reported")
One per view	Extended Data Block Length	2 bytes		0x0000 = no private area

Obr. 3.34: Štruktúra ISO/IEC 19794-2 záznamu o daktyloskopických markantoch

3.2.6 OF Sample Collector: vlastný softvér na zber trénovacích vzoriek pre konvolučnú neurónovú sieť

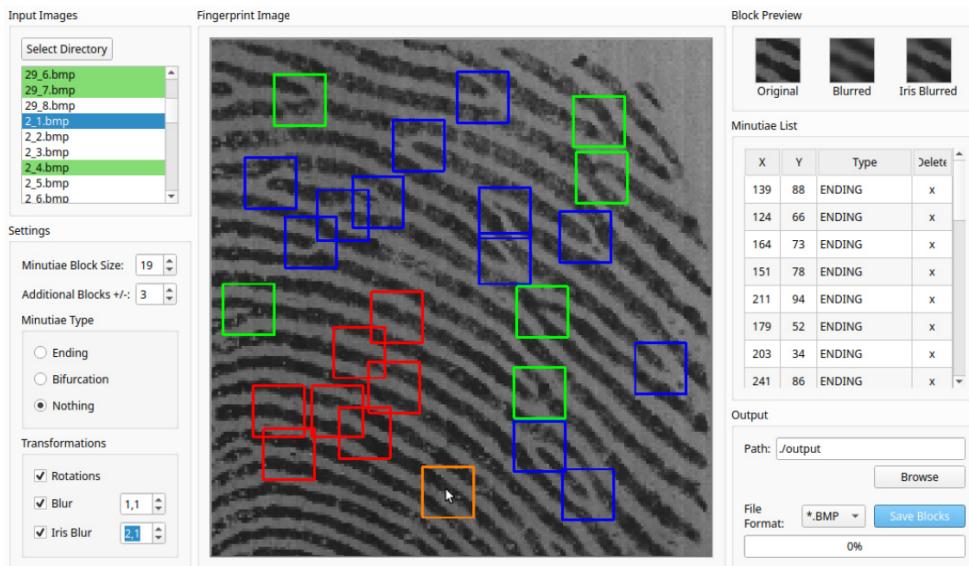
Naprogramovali sme vlastný softvérový nástroj na zber trénovacích vzoriek markantov pre konvolučnú neurónovú sieť. Vývoj začal v rámci riešenia diplomovej práce Lászla Kádeka [31]. Bez tejto aplikácie by nebolo možné vyzbierať 86 280 vzoriek, ktoré sme použili na trénovanie. Aplikácia umožňuje používateľovi zvoliť adresár s obrazmi odtlačkov prstov, z ktorých chceme vyberať trénovacie vzorky markantov.

Aplikácia funguje tak, že používateľ kliknutím myši vyznačuje miesta v odtlačku, kde vidí zvolený typ markantu. Obraz sa dá priblížovať a posúvať. Označené markanty sú reprezentované farebným štvorcom, kde každá farba určuje tvarový typ markantu. Všetky používateľom vybrané trénovacie vzorky sa zobrazujú v zozname v pravej časti aplikácie. Pomocou tohto zoznamu vieme zvýrazňovať doposiaľ vybrané vzorky, prípadne ich vymazávať.

V paneli s nastaveniami na ľavej strane aplikácie, môže používateľ zvoliť veľkosť štvorcového okna, ktoré sa použije pri exporte obrazových blokov. Okrem toho sú uložené aj väčšie a menšie verzie obrazových blokov, ktoré majú spoločný stred, aby sme v budúcnosti nemuseli zbierať markanty odznova, ak sa rozhodneme použiť neurónovú sieť, ktorá má inú dimenziu vstupu. Aby sme mohli vytvoriť, čo najkvalitnejšiu a najrozšiahlejšiu trénovaciu databázu markantov, rozšírili sme zber markantov aj o rôzne obrazové transformácie ako rotovanie a dva typy rozmazenia obrazu. Takýmto

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

spôsobom vieme vytvoriť veľké množstvo reprezentácií markantov, čo posilňuje schopnosť neurónovej siete rozoznať markant aj pri nízkej kvalite obrazu. Nakoniec sú všetky označené miesta markantov exportované vo forme obrazových blokov do používateľom špecifikovaného adresára. Dá sa zvoliť aj typ obrazového formátu.



Obr. 3.35: Používateľské rozhranie systému OF Sample Collector určené na zber trénovacích vzoriek [31]

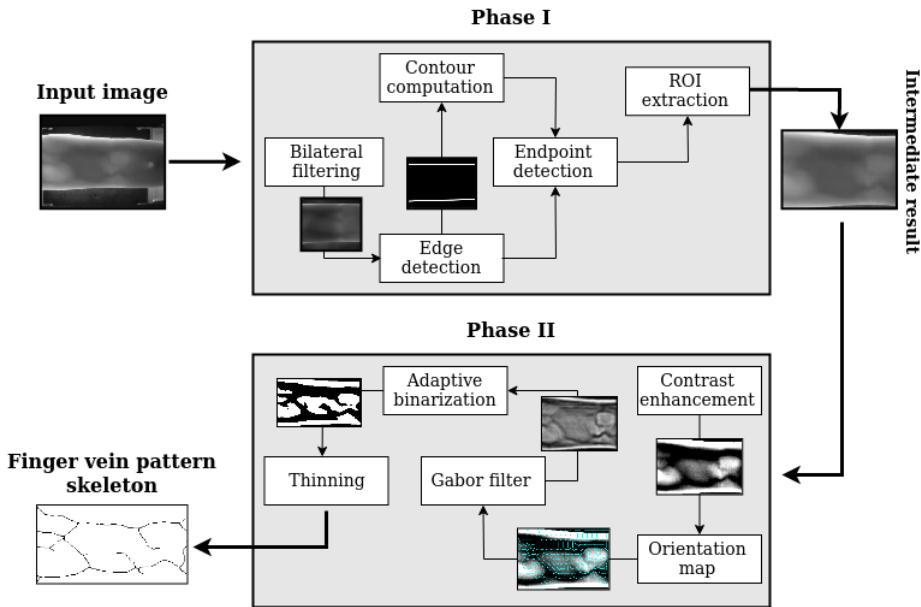
Aplikácia tohto druhu je momentálne v literatúre nedostupná. Mnohé vedecké práce, v ktorých sú publikované podobné riešenia nesprístupňujú svoju trénovaciu vzorku markantov. Naša aplikácia je efektívnym nástrojom ako pohodlne a rýchlo vytvoriť želanú trénovaciu vzorku na ľubovoľnej databáze odtlačkov prstov a vytvoriť tak údaje pre neurónovú sieť prispособenú na riešenie špeciálneho klasifikačného problému.

3.2.7 Rozšírenie systému o rozpoznávanie obrazcov žíl na prste

Inšpirovaní aktuálnymi úspechmi multimodálnych systémov, sme sa rozhodli počas nášho výskumu rozšíriť systém OpenFinger, primárne určený pre odtlačky prstov, o rozpoznávanie identity pomocou vzorov žíl na prste. Rozhodli sme sa tak hlavne z toho dôvodu, že kombinácia odtlačkov prstov a vzorov žíl na prste je medzi multimodálnymi systémami v dostupnej vedeckej literatúre minimálne preskúmaná a na trhu sa objavili prvé senzory (senzor M2-FuseID od spoločnosti M2SYS) schopné v jednom zariadení komfortne zosnímať naraz obidva biometrické znaky. Táto skutočnosť prináša nové scenáre využitia nášho systému OpenFinger fungujúceho v multimodálnom režime. Rozšírenie systému o rozpoznávanie pomocou vzorov žíl na prste bolo zrealizované implementáciou 3 samostatných a vzájomne komunikujúcich knižníc (vid' obrázok 3.3).

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

V nasledujúcich častiach zosumarizujeme podstatné kroky, ktoré vykonáva softvérový modul určený na spracovanie obrazcov žíl a priblížime metódy normalizácie a fúzie skóre, ktoré bolo potrebné zahrnúť do systému OpenFinger, aby mohol fungovať v multimodálnom režime.



Obr. 3.36: Schéma predspracovania vzorov žíl (tento systém vznikol v rámci výskumnej spolupráce s kolegom Ivanom Kováčom [33])

Predspracovanie obrazca žíl

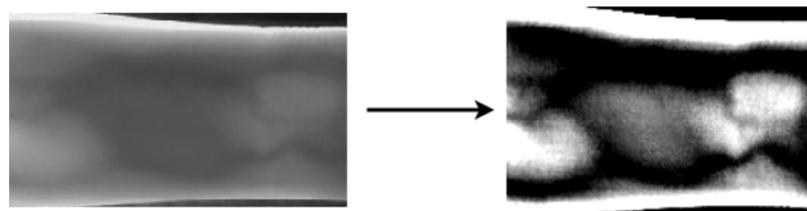
Predspracovanie pozostáva z dvoch fáz. V prvej fáze sa určí oblasť obrazu obsahujúca vzor žíl. V druhej fáze sa táto oblasť prefiltruje Gaborovym filtrom a zvýraznia sa tak charakteristické rysy žíl. Výstupom je kostra obrazca alebo prefiltrovaný obraz, podľa toho, aký druh charakteristických znakov chceme v obraze zachytiť. Kostra je vhodná na odhalovanie geometrických anomalií tvorených sieťou žíl a prefiltrovaný obraz je zase vhodným kandidátom na hľadanie SIFT/SURF kľúčových bodov. Princíp predspracovania vyjadruje obrázok 3.36.

1. *Bilaterálny filter.* Pomocou tohto filtra odstráňme z obrazu šum a zvýšime ostrosť hrán prsta.
2. *Detekcia hrán pomocou Cannyho detektora.* Obraz so zvýraznenými hranami je vstupom do Cannyho detektora, ktorý označí obrazové body prislúchajúce hranám prsta.
3. *Hľadanie kontúr, ich koncových bodov a extrakcia ROI.* Kontúry obrazu sú hľadané v obraze spracovanom Cannyho detektorom. Výstupom sú kontúry, pričom najdlhšie kontúry sú považované za kontúry prislúchajúce obrysom prsta.

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

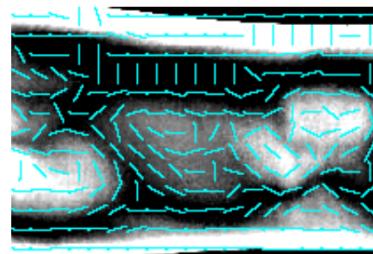
Objavené koncové body kontúr nám slúžia ako záhytné body pri vytvorení ohraničujúceho obdĺžnika, ktorý obsahuje len užitočnú oblasť obrazu.

4. *Vylepšenie kontrastu.* Na zvýšenie rozdielov medzi svetlými a tmavými oblastami používame SUACE metódu [92]. Tento krok je potrebný na správny odhad smerovej mapy.



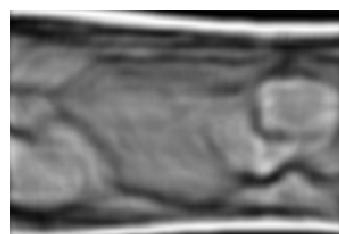
Obr. 3.37: Výsledok SUACE metódy zvyšovania kontrastu (vľavo obrázok po bilaterálnom filtrovaní, vpravo obrázok po zvýšení kontrastu) [33]

5. *Smerová mapa.* Smerová mapa vyjadruje charakteristický smer v malých blokoch obrazu. Je to analytické vyjadrenie obrazu potrebné pri filtrovaní Gaborovym filtrom.



Obr. 3.38: Smerová mapa obrazca žíl [33]

6. *Gaborov filter.* Rovnako ako v prípade odtlačkov prstov, aj v tomto prípade sme využili Gaborov filter na zvýraznenie významných črt obrazu. Ideálne parametre filtrovania boli: veľkosť bloku=11, $\lambda=17$ a $\sigma=5$.

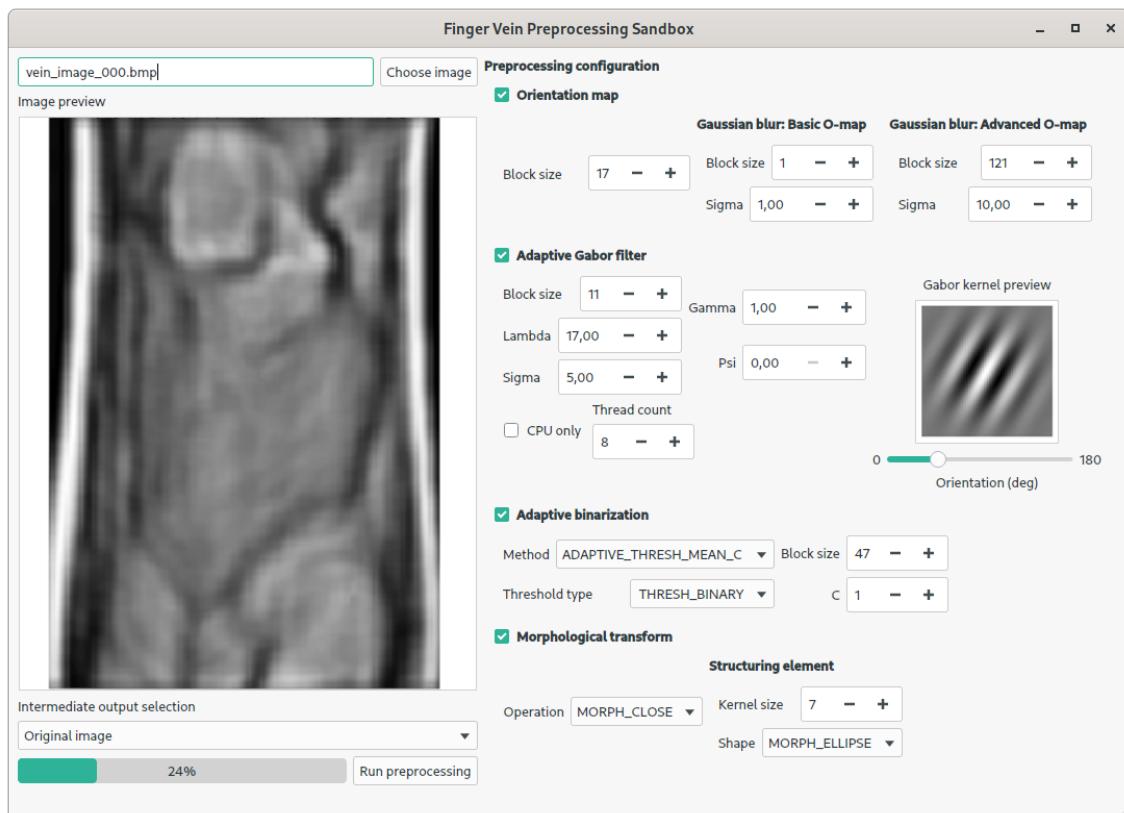


Obr. 3.39: Obrazec žíl po prefiltrovani Gaborovym filtrom [33]

3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER

7. *Adaptívna binarizácia, skeletonizácia a odstraňovanie defektov kostry.* Tieto postupy sú určené na vytvorenie kostry obrazu, v ktorej môžu byť následne vyhľadávané charakteristické detaily. Kostra je reprezentácia obrazu, v ktorej sú hrany zastúpené krivkami s hrúbkou jedného obrazového bodu. Kostra však obsahuje značné množstvo drobných kazov, ktoré je nutné odstrániť. Použili sme morfologické operátory knižnice OpenCV na odstránenie falošných útvarov z kostry.

Na experimentovanie s rôznymi nastaveniami predspracovania sme si vytvorili pomocnú aplikáciu (obrázok 3.40) umožňujúcu ručne zadať parametre do všetkých fáz predspracovania a vidieť všetky medzivýstupy.

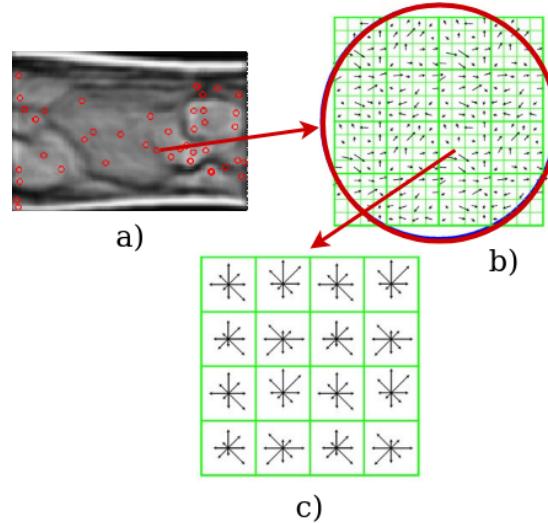


Obr. 3.40: Expertná GUI aplikácia na testovanie predspracovania obrazcov žíl [33]

SIFT/SURF algoritmy detekcie charakteristických znakov

Hlavné metódy extrakcie boli SIFT (Scale-Invariant Feature Transfrom)[93] a SURF (Speeded Up Robust Features)[94]. Tieto metódy odhalujú v obraze body, ktoré sú charakteristické a odolné voči rotácii a zmenám veľkosti.

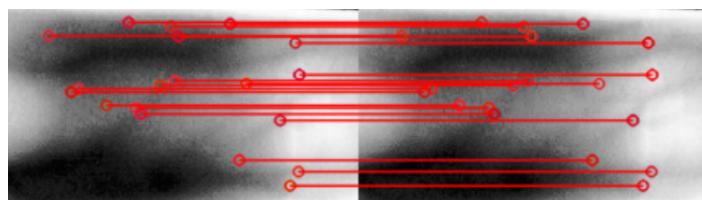
3.2. IMPLEMENTOVANÉ KNIŽNICE A APLIKÁCIE V RÁMCI SYSTÉMU OPENFINGER



Obr. 3.41: Ukážka SIFT kľúčových bodov a deskriptorov (a-lokalizácia kľúčových bodov, b-priradenie smerov, c-tvorba deskriptorov) [33]

Porovnávanie objavených deskriptorov

Na účely porovnania objavených deskriptorov sme použili funkcie knižnice OpenCV. Konkrétnie, algoritmus Brute-force, ktorý ku každému deskriptoru obrazca žil nájde prehľadaním všetkých možností najbližší deskriptor v druhom obrazci žil pomocou zmerania Euklidovskej vzdialenosť. Alternatívnym porovnávacím algoritmom je FLANN, taktiež implementovaný v knižnici OpenCV.



Obr. 3.42: Ukážka porovnávania SIFT/SURF kľúčových bodov pomocou Brute-force porovnávacieho algoritmu [33]

Metódy normalizácie skóre

Systém OpenFinger využíva v multimodálnom režime činnosti fúzii na úrovni porovnávania. Tú je možné vykonať pomocou spojenia skóre podobnosti získaného zvlášť pre odtlačky prstov a obrazce žil. Avšak skóre rôznych porovnávacích algoritmov sa líši v rozsahu prípustných hodnôt, čo zabráňuje priamej fúzii. Preto sme vykonali normalizáciu skóre, ktorá zmenší rozsah prípustných hodnôt skóre do intervalu $\langle 0, 1 \rangle$. Skúmali sme nasledovné normalizačné techniky (s_i je vstupné skóre a s_n označuje normalizované skóre).

$$\text{Double sigmoid, } s_n = \begin{cases} \frac{1}{1+\exp(-2\frac{(s_i-t)}{r_1})} & \text{ak } s_i < t \\ \frac{1}{1+\exp(-2\frac{(s_i-t)}{r_2})} & \text{v opačnom prípade} \end{cases} \quad (3.1)$$

Double sigmoid funkcia vykazuje v intervale $(t - r_1, t + r_2)$ približne lineárnu charakteristiku. Bod t sa zvolí tak, aby predstavoval hodnotu z oblasti, v ktorej sa prekrývajú tzv. genuine (páry totožných vzoriek) a impostor (páry odlišných vzoriek) distribúcie skóre podobnosti. Hodnoty r_1 a r_2 by mali byť zvolené tak, aby pokryli celú oblasť prekryvu vyššie spomínaných distribúcií.

$$\text{Hyperbolický tangens, } s_n = \frac{1}{2} \left\{ \tanh(0.01(\frac{s_i - \mu_{S_G}}{\sigma_{S_G}})) + 1 \right\} \quad (3.2)$$

Parametre μ_{S_G} a σ_{S_G} predstavujú strednú hodnotu a smerodajnú odchýlku vypočítanú zo všetkých genuine skóre (páry totožných vzoriek).

$$\text{Z-score, } s_n = \frac{s_i - \mu_S}{\sigma_S} \quad (3.3)$$

Parametre μ_S a σ_S sú stredná hodnota a smerodajná odchýlka množiny všetkých skóre.

$$\text{Min-Max, } s_n = \frac{s_i - \min(S)}{\max(S) - \min(S)} \quad (3.4)$$

Parametre $\max(S)$ a $\min(S)$ predstavujú maximum a minimum zo všetkých skóre.

Metódy fúzie skóre

Po normalizácii sme mohli prikročiť k spojeniu obidvoch hodnôt skóre pochádzajúcich z oboch biometrických modulov pomocou nasledovných stratégií (S_{final} je konečné skóre po fúzii, S_{fp} je skóre pre odtlačky prstov a S_{fv} je skóre pre obrazce žíl).

$$\text{Min, } S_{final} = \min(S_{fp}, S_{fv}) \quad (3.5)$$

$$\text{Max, } S_{final} = \max(S_{fp}, S_{fv}) \quad (3.6)$$

$$\text{Hyperbolický tangens, } S_{final} = \tanh(S_{fp}) + \tanh(S_{fv}) \quad (3.7)$$

$$\text{Sum, } S_{final} = S_{fp} + S_{fv} \quad (3.8)$$

$$\text{Product, } S_{final} = S_{fp} \times S_{fv} \quad (3.9)$$

$$\text{Mean, } S_{final} = \frac{(a \times S_{fp} + b \times S_{fv})}{2} \quad (3.10)$$

V poslednom prípade predstavujú parametre a a b váhy daného skóre. Pre obidva parametre sme použili hodnotu 0.5.

3.3 Výsledky testovania systému OpenFinger

V tejto časti prezentujeme prehľad softvérových a hardvérových požiadaviek na používanie systému OpenFinger a vykonávanie opisovaných experimentov. Koncentrujeme sa na špecifikáciu použitých testovacích biometrických databáz a komplexne hodnotíme jednotlivé unimodálne režimy (rozpoznávanie s využitím jedného typu biometrického znaku, t.j. odtlačky prstov alebo obrazce žil na prste) a multimodálny režim fungovania z pohľadu dosiahnutej úspešnosti rozpoznávania identity a rýchlosťi spracovania údajov.

3.3.1 Inštalácia a používanie knižnice

Podrobnejší návod ako nainštalovať a používať systém OpenFinger je uvedený vo verejných Github repozitároch jednotlivých knižníc, z ktorých OpenFinger pozostáva (viac v sekcii 4.2). V nasledujúcom prehľade uvádzame softvérové a hardvérové požiadavky, ktoré umožnia náš softvér skompilovať a použiť.

Softvérové požiadavky

- Na cieľovom počítači musí byť nainštalovaný operačný systém Debian (minimálna stabilná verzia 10) alebo Manjaro (minimálna verzia 20.0.1).
- Cieľový počítač musí mať korektne nainštalované nasledujúce knižnice (ideálne nainštalované pomocou natívneho správcu balíkov):
 - Qt 5.14.2
 - QCustomPlot 2.0.1
 - OpenCV 4.3.0
 - Caffe 1.0
 - ArrayFire 3.7.1
 - CUDA 10.2 (a kompatibilný grafický ovládač NVidia GPU)
 - cuDNN 7.6.5
 - OpenSSL 1.1.1.g
 - gcc 7.3.0 (kompilátor)
- Cieľový počítač musí mať k dispozícii SDK k externým USB senzorom odtlačkov prstov, konkrétnie BioMini SDK (pre senzor Suprema BioMini Slim), FxISO SDK Light (pre senzor Biometrika HiScan PRO) a ftrScanAPI SDK (pre senzor Futoronic FS80). Taktiež je potrebné nainštalovať potrebné ovládače pre každý senzor.
- OpenFinger je systém zložený z ekosystému samostatných dynamických knižníc, pričom každá knižnica je distribuovaná ako Qt projekt. Z toho dôvodu je nutné

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER

pred kompliaciou správne nakonfigurovať hlavný projektový súbor (súbor s príponou **.pro**) tak, aby obsahoval správne cesty smerujúce k adresárom, kde sa nachádzajú knižnice a ich hlavičkové súbory nevyhnutné na kompliaciu projektu.

- Stiahnuté biometrické databázy SDUMLA-HMT (odtlačky prstov a obrazce žíl), FVC2002 DB1 až DB4, ktoré umožnia vykonať experimenty opísané v práci.
- V prípade testovania našej klient-server aplikácie (časť 3.3.4) je potrebné mať vygenerované a správne nainštalované príslušné SSL certifikáty.

Hardvérové požiadavky

- Minimálne serverový procesor Intel Xeon Silver 4108 alebo procesor Intel i7-8750H (na týchto procesoroch prebehlo testovanie a garantujú možnosť používať systém OpenFinger).
- Minimálne 32 GB RAM.
- Grafická karta NVidia, ktorá je kompatibilná s knižnicou CUDA 10.2, technológiou Compute Capability minimálne vo verzii 6.1 a je vybavená minimálne pamäťou typu 11 GB GDDR5X (potrebné kvôli trénovaniu konvolučnej neurónovej siete a GPU režimu činnosti všetkých rozpoznávacích modulov)
- Dostatočná kapacita úložiska na uloženie skompilovaného softvéru, natrénovanej neurónovej siete a všetkých biometrických databáz (minimálne 250 GB).
- Biometrické senzory Suprema BioMini Slim, Futronic FS80 a Biometrika HiScan PRO. Navyše, ak chceme využívať algoritmus na porovnávanie odtlačkov prstov zo Suprema BioMini SDK, je nutné, aby bol v čase jeho používania pripojený do USB portu počítača senzor BioMini Slim, napokoľko slúži ako hardvérový kľúč povoľujúci používanie daného SDK.
- V prípade testovania klient-server aplikácie opisovanej v sekcií 3.3.4, je nutné mať aktívne pripojenie do siete WAN a firewallom povolené požadované komunikačné TCP porty a IP adresu servera.

3.3.2 Testovacie biometrické databázy

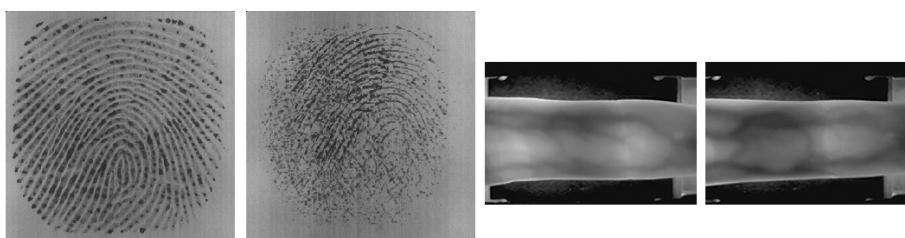
Náš systém sme otestovali na viacerých verejných a dostupných databázach odtlačkov prstov a obrazcov žíl, ktoré sú často využívané inými výskumníkmi v ich publikáciách. Preto je možné ľahko porovnať naše výsledky s inými podobnými softvérovými systémami.

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER

Tabuľka 3.3: Zoznam použitých biometrických databáz na experimenty

Názov databázy	Počet prstov	Počet snímok na 1 prst	Senzor	Rozmer obrazu	Rozlíšenie
FVC2002 DB1	100	8	optický	388 × 374	500
FVC2002 DB2	100	8	optický	296 × 560	569
FVC2002 DB3	100	8	kapacitný	300 × 300	500
FVC2002 DB4	100	8	vytvorené softvérom SFinGe	288 × 384	500
Cross Match DB	51	8	optický	504 × 480	500
SDUMLA-HMT (odtlačky prstov)	636	40	4 rôzne druhy senzorov	256 × 304, 152 × 200, 294 × 356, 400 × 400	500
SDUMLA-HMT (obrazce žíl)	636	6	neuvádz sa	320 × 240	neuvádz sa

Na priebežné testovanie, hľadanie chýb a optimalizovanie našej implementácie biometrického modulu pre odtlačky prstov sme zvolili databázu odtlačkov FVC2002 DB3. Čo sa týka kvality obrazu a variability snímania, je táto databáza v literatúre považovaná za jednu z najnáročnejších publikovaných databáz a výsledky testovania na nej odzrkadľujú skutočnú silu biometrického systému prevereného zložitými situáciami (napr. chýbajúce časti obrazu, nízky kontrast alebo ťažko zreteľné papilárne línie v dôsledku nadmerného prítlaču prsta na senzor).



Obr. 3.43: Ukážky obrázkov z databázy FVC 2002 DB3 (dva vľavo) a SDUMLA-HMT (dva vpravo)

3.3.3 Komplexné zhodnotenie úspešnosti a rýchlosť rozpoznávania

OpenFinger bol počas vývoja podrobnený rôznym druhom testov v odlišných testovacích scenároch, aby sme preskúmali jeho možnosti, limity a predovšetkým silné a slabé stránky. Zamerali sme sa na vyhodnotenie dvoch najdôležitejších oblastí: úspešnosť rozpoznávania a rýchlosť s akou systém pracuje (ako celok alebo jeho vnútorné komponenty). Všetky prezentované výsledky boli namerané na školskom serveri, ktorého softvérová a hardvérová výbava je zhrnutná v tabuľke 3.4.

Tabuľka 3.4: Softvérová a hardvérová konfigurácia školského servera, na ktorom boli vykonané všetky testy

Operačný systém	Debian 10 64-bit
CPU	2x Intel Xeon Silver 4108 (32 vlákien v 16 jadrach), 1.8 GHz
RAM	2 x 16GB DDR4
GPU	Nvidia GeForce GTX 1080 Ti 11GB GDDR5X
Základná doska	SuperMicro X11DPi-NT
Úložisko	WDC WD2500AAJS-6 250 GB

Na komplexné zhodnotenie sme využili náš modul automatizovaného testovania (opísaný v časti 3.1.4), pomocou ktorého sme boli schopní nakonfigurovať rôzne testovacie scenáre a vizualizovať dosiahnuté výsledky formou grafov. V nasledujúcim prehľade uvádzame jednotlivé testovacie scenáre spolu s nadobudnutými výsledkami.

Testovací scenár A: zhodnotenie unimodálneho systému na báze odtlačkov prstov

A.1 Úspešnosť rozpoznávania identity

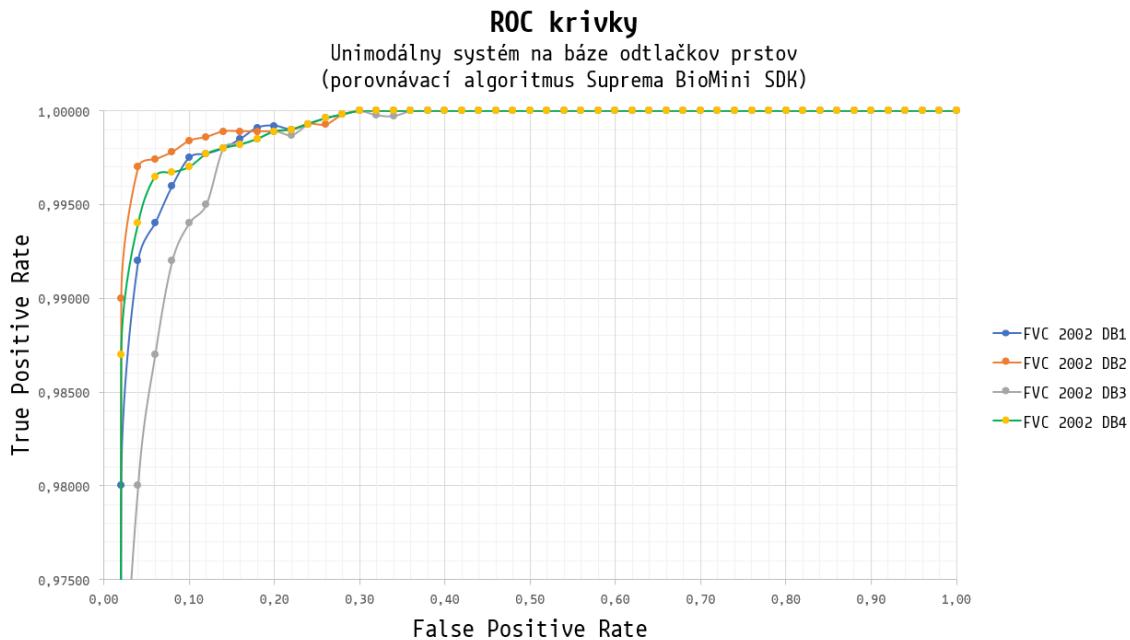
Prvým experimentom vykonaným v tejto oblasti bolo globálne preverenie presnosti rozpoznávania na všetkých 4 FVC 2002 databázach. V tejto databáze sú zahrnuté obrázky z rôznych snímačov, rôznych rozmerov, rôznych osôb a v rôznych kvalitách a preto považujeme tento test za klúčový. Takáto diverzita vstupných údajov objektívne preverí schopnosti predspracovania obrazu, úspešnosť klasifikácie Level-2 znakov neurónovou sieťou, ako aj ich porovnanie obidvoma typmi porovnávacích algoritmov. V tabuľke 3.5 sú zhrnuté hodnoty ukazovateľa EER (Equal Error Rate) pre obidva porovnávacie algoritmy, Suprema BioMini SDK (EER_s) a BOZORTH3 (EER_b). Prahová hodnota pre skóre porovnania zodpovedajúca nameranej hodnote EER je označená ako t_s (pre Suprema BioMini SDK) a t_b (pre BOZORTH3).

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER

Tabuľka 3.5: Unimodálny systém na báze odtlačkov prstov: hodnoty ukazovateľa EER namerané pre všetky FVC 2002 databázy a obidva porovnávacie algoritmy Suprema BioMini SDK a BOZORTH3

Databáza	EER_s (v %)	t_s	EER_b (v %)	t_b
FVC 2002 DB1	0.97	0.12	2.41	61
FVC 2002 DB2	0.51	0.26	1.41	53
FVC 2002 DB3	1.77	0.11	3.02	51
FVC 2002 DB4	0.67	0.11	1.99	50

Priemerná chyba EER (v prípade Suprema BioMini SDK) na všetkých testovaných databázach na úrovni oscilujúcej okolo 1 % je považovaná za veľmi dobrý výsledok. Vyššiu úspešnosť dosiahol porovnávací algoritmus Suprema BioMini SDK. Horšie výsledky algoritmu BOZORTH3 môžeme pravdepodobne pripísť tomu, že na spoľahlivé porovnanie vyžaduje, aby bolo v obidvoch porovnávaných odtlačkoch minimálne 50-60 Level-2 znakov. V prípade databáz FVC nie je garantované, že každý odtlačok obsahuje tento počet Level-2 znakov, hlavne nie v prípadoch snímok nekompletnejších odtlačkov. Na základe výsledkov tohto experimentu sme pri ďalšom testovaní preferovali porovnávací algoritmus Suprema BioMini SDK a stanovili jeho prahovú hodnotu pre porovnávanie na úroveň 0.12.

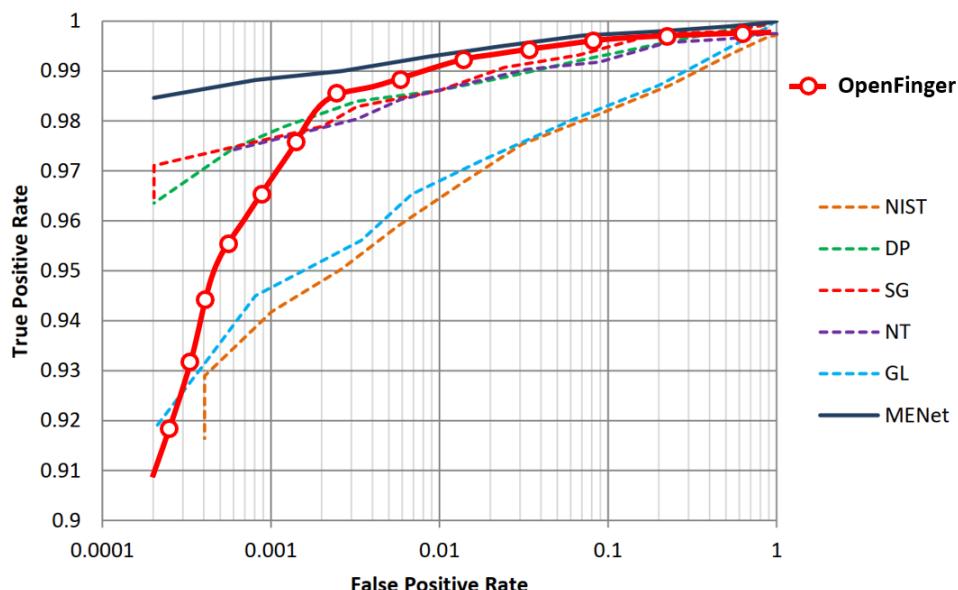


Obr. 3.44: Unimodálny systém na báze odtlačkov prstov: ROC krivky pre všetky FVC databázy

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER

Ďalej sme vykonali experiment, v rámci ktorého sme namerali hodnoty pre ROC krivky, ktoré slúžia ako ústredný indikátor úspešnosti klasifikovania/rozpoznávania v biometrii, aby sme mohli kedykoľvek porovnať nás systém s inými riešeniami. Platí, že, čím väčšia plocha pod ROC krivkou, tým lepší klasifikátor. Opäť sme do testov zahrnuli všetky FVC databázy. Výsledky experimentu sú znázornené na obrázku 3.44.

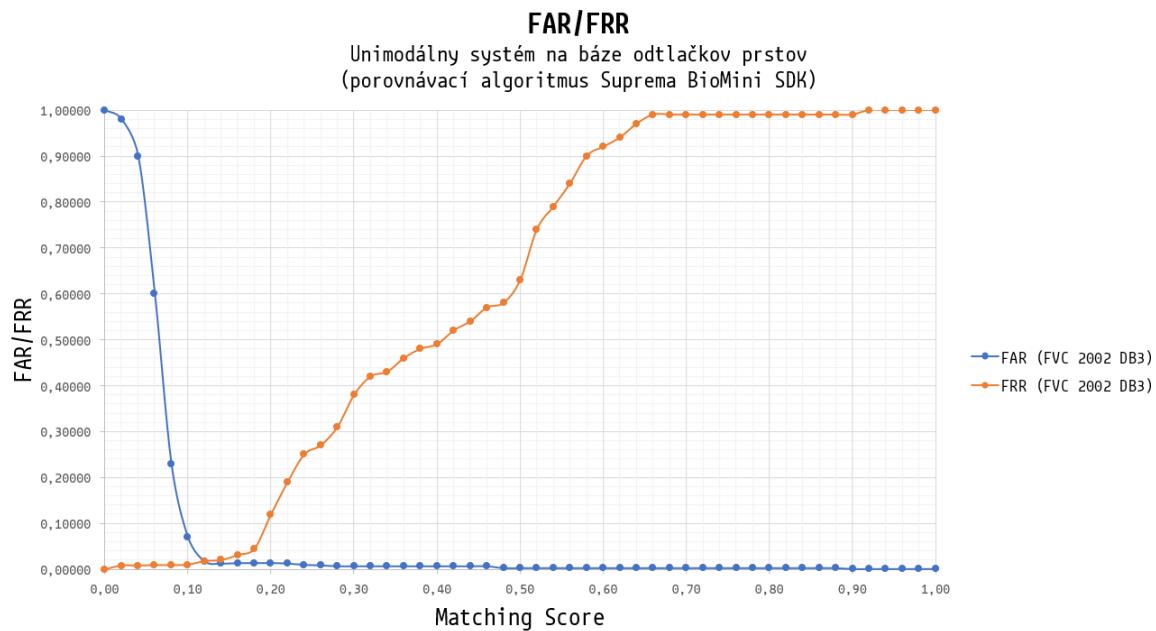
Naše riešenie sme porovnali (obrázok 3.45) s výsledkami publikovanými v práci [83], keďže sa jedná o príbuznú prácu, v ktorej bol navrhnutý dakyloskopický systém postavený na báze hlbokej neurónovej siete MENet. Autori v práci porovnávajú svoje riešenie s najznámejšími otvorenými aj komerčnými algoritmami súčasnosti pomocou ROC kriviek na databáze FVC 2002 DB1. Porovnaním s nimi vieme prehlásiť, že nás systém dosahuje porovnatelné výsledky s aktuálnymi najlepšími riešeniami a môže dosahovať ešte lepšie výsledky pri pridaní ďalších vrstiev do našej konvolučnej siete (tá má momentálne architektúru odvodenú z ResNet-18).



Obr. 3.45: Unimodálny systém na báze odtlačkov prstov: porovnanie nášho systému so systémom MENet [83] a ďalšími známymi algoritmami na databáze FVC 2002 DB1 pomocou ROC kriviek (NIST - algoritmus *MINDTCT*, DP - *CrossMatch Digital Persona*, SG - *SecuGen SDK*, NT - *Neurotechnology SDK*, GL - *Griaule Biometrics SDK*)

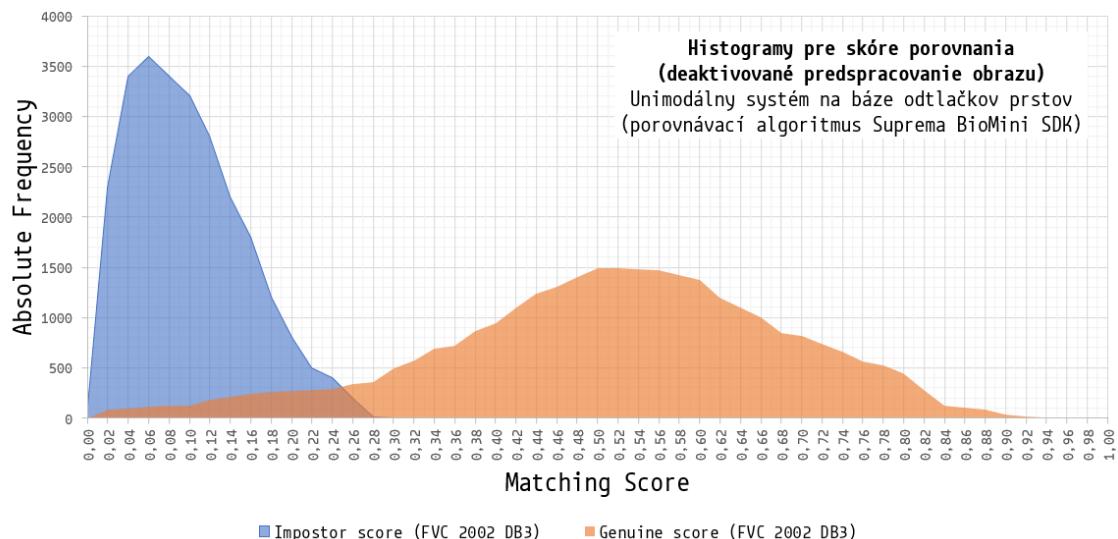
Zo všetkých databáz bola databáza FVC 2002 DB3 najväčšou výzvou vzhľadom na jej nízku kvalitu obrazu a preto sme sa zvlášť zamerali na vyhodnotenie FAR/FRR metriky pre túto databázu. Výsledky vidíme na obrázku 3.46

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER



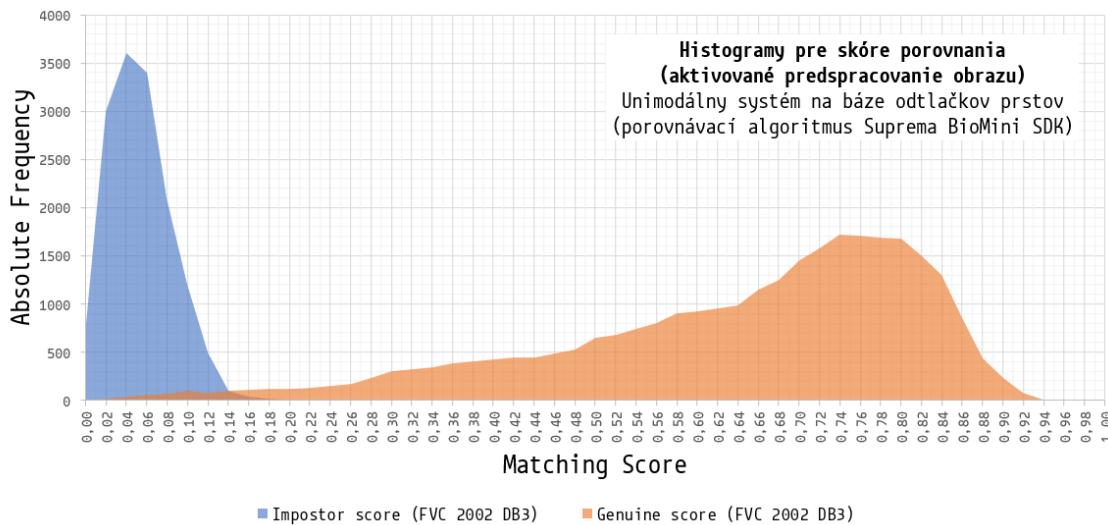
Obr. 3.46: Unimodálny systém na báze odtlačkov prstov: FAR/FRR krivka na databáze FVC 2002 DB3

Okrem iných ukazovateľov nás zaujímalo akú presnosť rozpoznávania dosahujeme na databáze obrazov s veľmi nízkou kvalitou pri použití a bez použitia fázy predspracovania obrazu (chceli sme zistiť akú degradáciu presnosti budeme musieť akceptovať ak chceme zrýchliť systém vynechaním predspracovania). Výsledky obidvoch experimentov znázorňuje obrázok 3.47 a 3.48.



Obr. 3.47: Unimodálny systém na báze odtlačkov prstov: histogramy pre skóre porovnania pri deaktivovanom predspracovaní obrazu

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER



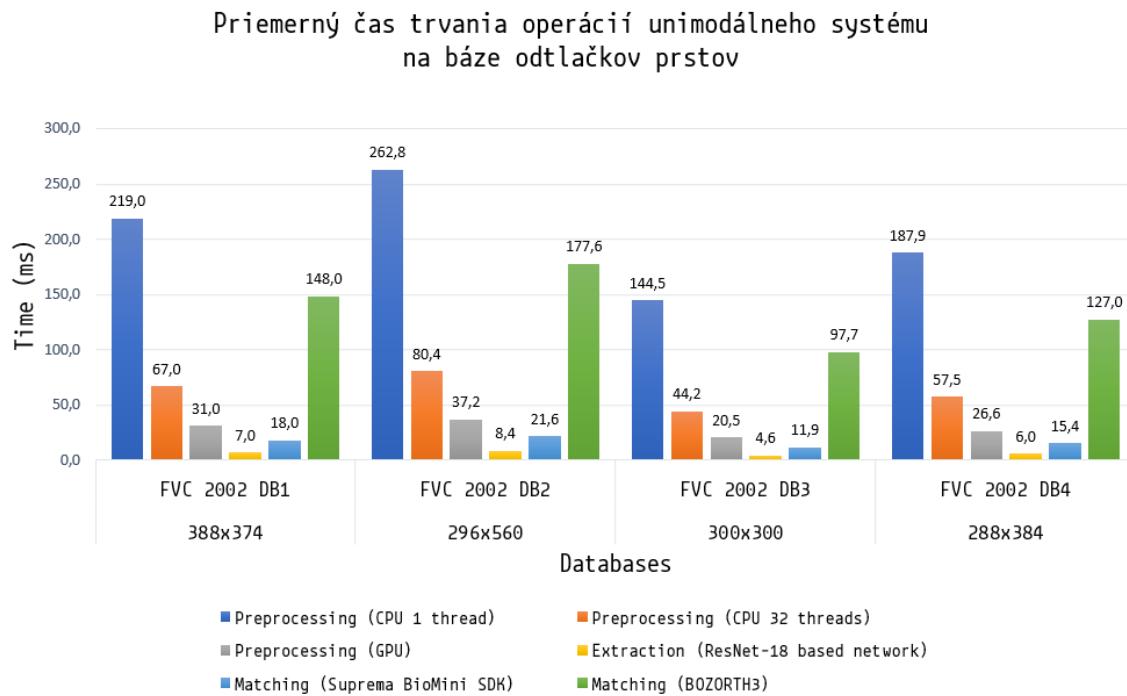
Obr. 3.48: Unimodálny systém na báze odtlačkov prstov: histogramy pre skóre porovnania pri aktivovanom predspracovaní obrazu

Na obrázku sú zachytené zvlášť histogramy pre skóre, ktoré pridelí systém dvom odtlačkom z rovnakého prsta a odtlačkom, ktoré pochádzajú z rôznych prstov. Túto metriku sme využili najmä z toho dôvodu, že jasne vidíme aké najčastejšie hodnoty skóre podobnosti systém počíta pre dvojice odtlačkov, ktoré sa v skutočnosti nezhodujú (z angl. impostor pairs) a tie, ktoré sa zhodujú (z angl. genuine pairs). Presný klasifikátor by mal mať obidva histogramy, čo najviac od seba vzdialenosť a bez prekryvu (t.j. žiadna chyba FAR alebo FRR). Vidíme, že v prípade použitého predspracovania obrazu sme dosiahli stav, v ktorom sú vrcholy histogramov vzdialenejšie a ich prekryv je menší. Z toho dôvodu môžeme povedať, že náš predspracovací algoritmus, na čele ktorého stojí adaptívny Gaborov filter, zlepšuje klasifikačnú presnosť. Na experimenty bola použitá bola databáza FVC 2002 DB3.

A.2 Rýchlosť spracovania údajov

Zmerali sme priemerný čas (v ms) vykonania hlavných fáz spracovania odtlačku na všetkých FVC 2002 databázach. Pri predspracovaní sme porovnali CPU a GPU implementáciu. Pri porovnávaní odtlačkov sme vyhodnotili obidva porovnávacie algoritmy. Obrázok 3.49 jasne signalizuje, že výpočtovo najnáročnejšou operáciou bolo obrazové predspracovanie. Avšak jeho GPU implementácia významne zredukovala jeho trvanie. Porovnávací algoritmus BOZORTH3 bol v tomto teste použitý v jeho 1-vláknovej verzii. Na obrázku sú znázornené aj veľkosti obrazov v jednotlivých databázach. Hlavným záverom tejto analýzy je zistenie, že kombinácia predspracovania vykonaného pomocou GPU a porovnávania algoritmom Suprema BioMini SDK dosahuje najvyššiu rýchlosť.

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER

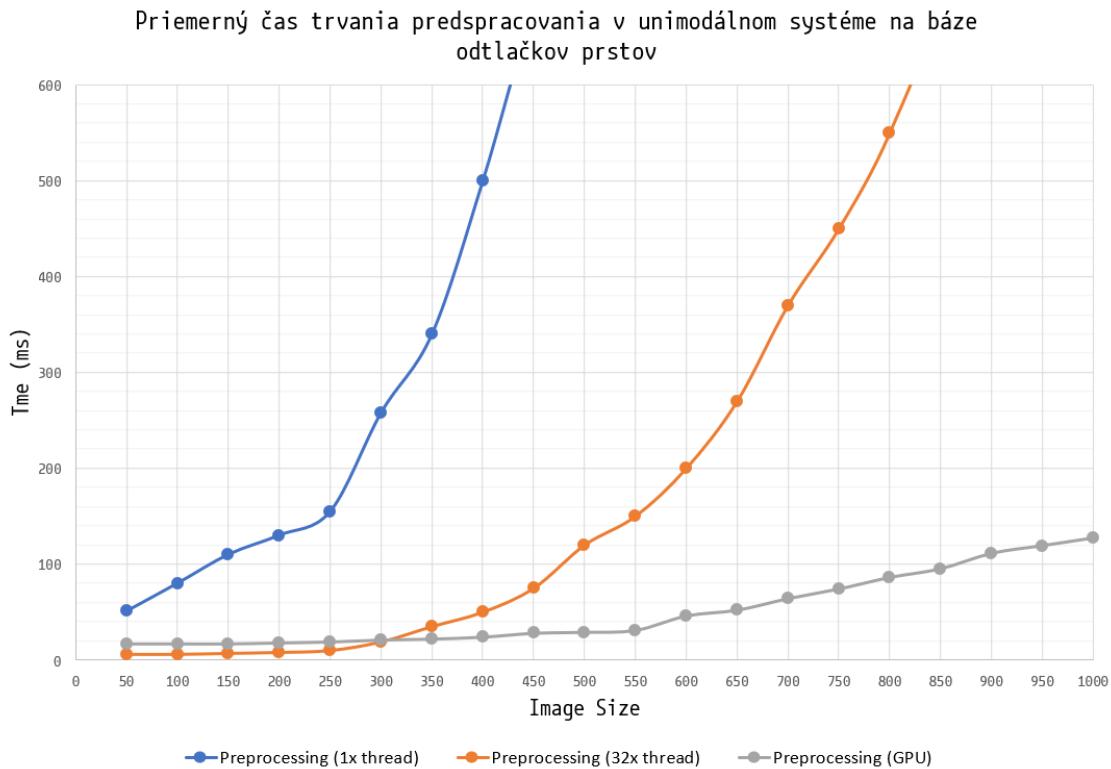


Obr. 3.49: Unimodálny systém na báze odtlačkov prstov: priemerný čas trvania kompletného procesu rozpoznávania na všetkých FVC 2002 databázach (uvedený je priemerný čas spracovania jedného obrazu)

Ked'že v budúcnosti môže byť náš softvér nasadený do oblasti, kde sa bude pracovať s obrazom s rôznymi rozmermi, vykonali sme sériu meraní, ktorej cieľom bolo vypočítať priemerný čas predspracovania (ked'že ostatné operácie nezávisia od rozmeru obrazu) v závislosti od rozmeru obrazu. Predspracovanie sme odmerali na CPU aj GPU.

Výsledky na obrázku 3.50 potvrdzujú, že naša vlastná GPU a viac-vláknová implementácia vybraných operácií niekoľkonásobne zrýchliala celý proces predspracovania. Obrázky mali štvorcový pomer strán a ich rozmer rástol pridávaním 50 obrazových bodov na šírku aj výšku. Z grafu vieme určiť, od akého rozmeru je ideálne použiť na predspracovanie GPU a kedy je, naopak, vhodné viac-vláknové CPU. Približne do rozmeru obrazu 300×300 je rýchlejšia vláknová implementácia (využíva sa 32 vlákien). Väčšie rozmery obrazu je ideálne spracovať pomocou GPU. V prípade obrazu s rozmerom 800×800 je GPU rýchlejšie oproti 32-vláknovému CPU približne 6 krát. V prípade obrazu s rozmerom $1\,000 \times 1\,000$ je GPU rýchlejšie už približne 14 krát.

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER



Obr. 3.50: Unimodálny systém na báze odtlačkov prstov: priemerný čas trvania predspracovania v závislosti od rozmeru vstupného obrazu

Testovací scenár B: zhodnotenie unimodálneho systému na báze obrazcov žíl

B.1 Úspešnosť rozpoznávania identity

Modul rozpoznávania pomocou obrazcov žíl bol testovaný na databáze SDUMLA-HMT v závislosti od typu použitého extraktora (SIFT alebo SURF) a taktiež od typu použitého predspracovania (aktivovaný/deaktivovaný Gaborov filter). Porovnávacím algoritmom bol Brute-force, ktorý už podľa predbežných výsledkov prekonával FLANN algoritmus. Výsledky v tabuľke 3.6 ukazujú namerané chyby EER. Najlepšou konfiguráciou modulu bolo použitie SURF extraktora s aktivovaným Gaborovym filtrom. Označenie EER_{gon} je chyba EER nameraná pre systém s aktivovaným Gaborovým filtrom v rámci predspracovania, naopak EER_{goff} je chyba s deaktivovaným filtrom.

Tabuľka 3.6: Unimodálny systém na báze obrazcov žíl: hodnoty ukazovateľa EER namerané na databáze SDUMLA-HMT pre rôzne druhy predspracovania a extraktorov

Typ extraktora	EER_{gon} (v %)	EER_{goff} (v %)
SIFT	4.43	6.10
SURF	0.06	0.75

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER

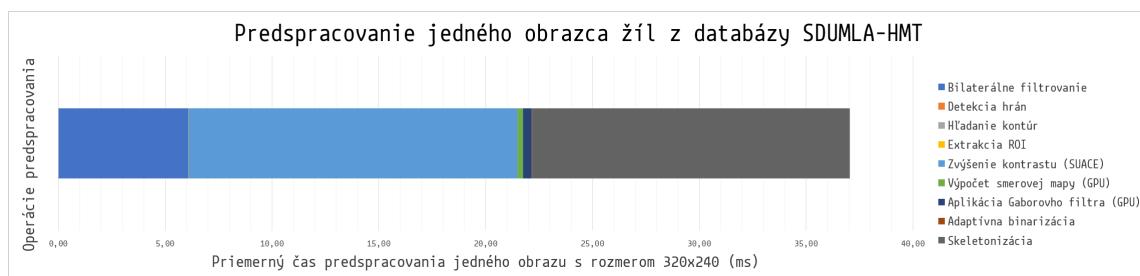
B.2 Rýchlosť spracovania údajov

Pri meraní rýchlosťi sme zistovali aká je celková dĺžka trvania jednotlivých operácií predspracovania obrazca žíl na celej databáze SDUMLA-HMT (3 816 obrazov). Z výsledkov v tabuľke 3.7 vidíme, že výpočtovo najnáročnejšou operáciou je zvýšenie kontrastu a skeletonizácia. Veľkosť jedného obrazu je 320×240 .

Tabuľka 3.7: Unimodálny systém na báze obrazcov žíl: celková dĺžka trvania vnútorných fáz predspracovania na všetkých obrazoch databázy SDUMLA-HMT

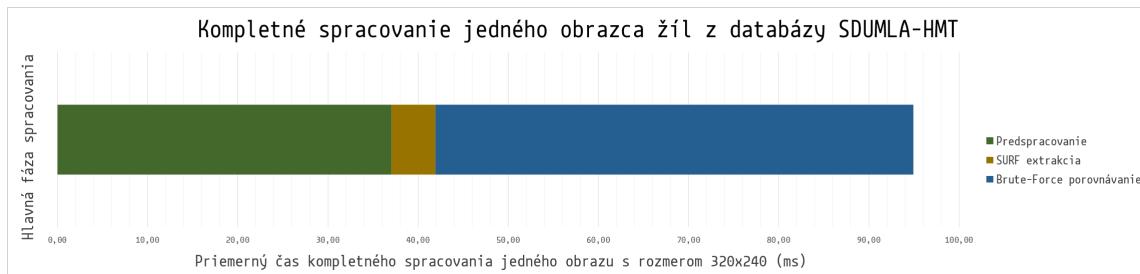
Fáza predspracovania	Celková dĺžka trvania (s)
Bilaterálne filtrovanie	23.20
Detekcia hrán	0.03
Hľadanie kontúr	0.03
Extrakcia ROI	0.06
Zvýšenie kontrastu (SUACE)	58.71
Výpočet smerovej mapy (GPU)	0.98
Aplikácia Gaborovho filtra (GPU)	1.54
Adaptívna binarizácia	0.07
Skeletonizácia	56.72
Spolu	141.34

Navyše, graf na obrázku 3.51 ukazuje podiel vnútorných operácií predspracovania obrazca žíl na celkovom čase predspracovania. Obrázok 3.52 ukazuje podiel jednotlivých hlavných fáz (predspracovanie, extrakcia a porovnávanie) na priemernom čase kompletného spracovania jedného obrazu z databázy SDUMLA-HMT. Predspracovanie jedného obrazu trvalo na školskom serveri približne 37 ms. Celkové spracovanie jedného obrazu trvalo približne 95 ms. Extrakcia SURF deskriptorov sa ukázala ako časovo najmenej náročná operácia.



Obr. 3.51: Unimodálny systém na báze obrazcov žíl: časová náročnosť jednotlivých vnútorných operácií predspracovania jedného obrazca žíl z databázy SDUMLA-HMT

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER



Obr. 3.52: Unimodálny systém na báze obrazcov žíl: časová náročnosť hlavných fáz spracovania jedného obrazca žíl z databázy SDUMLA-HMT

Testovací scenár C: zhodnotenie multimodálneho systému

Spojenie odtlačkov prstov a obrazcov žíl na prste prinieslo svoj efekt v podobe zvýšenej presnosti rozpoznávania. Multimodálny systém využíval na strane modulu odtlačkov prstov porovnávací algoritmus Suprema BioMini SDK a na strane modulu obrazcov žíl bol ako extraktor použitý SIFT aj SURF a porovnávací algoritmus Brute-force. Na to, aby mohol OpenFinger pracovať v multimodálnom pracovnom režime, musíme vykonať najprv normalizáciu a následne fúziu skóre. Spomedzi experimentov sa ako najlepšia stratégia normalizácie skóre ukázala metóda založená na hyperbolickom tangense a preto bola v experimente použitá. Tabuľka 3.8 dokumentuje nameraný ukazovateľ EER pre multimodálny režim činnosti a viaceré stratégie fúzie skóre. Označenie $EER_{multiSIFT}$ je chyba EER pre konfiguráciu systému so SIFT extraktorom a $EER_{multiSURF}$ je chyba EER pre konfiguráciu so SURF extraktorom. Jedna osoba bola v experimente reprezentovaná dvojicou obrazov, t.j. odtlačok prsta (z databázy FVC 2002 DB2) a obrazec žíl (z databázy SDUMLA-HMT).

Tabuľka 3.8: Multimodálny systém: EER ukazovateľ pre rôzne stratégie fúzie skóre

Ukazovateľ EER (%)	Stratégia fúzie					
	Min	Max	Sum	Product	TanH	Mean
$EER_{multiSIFT}$	4.67	4.03	2.11	4.49	2.79	2.12
$EER_{multiSURF}$	4.68	0.32	0.03	3.66	0.22	0.19

Najúspešnejší variant pre konfiguráciu celého multimodálneho systému je spracovanie odtlačkov prstov s aktivovaným predspracovaním a použitím porovnávacieho algoritmu Suprema BioMini SDK a spracovanie obrazcov žíl s aktivovaným predspracovaním a využitím SURF extraktora a porovnávacieho algoritmu Brute-force. Najlepšou metódou normalizácie bol hyperbolický tangens. Najlepšia metóda fúzie bola metóda *Sum*. Záverečná tabuľka 3.9 sumarizuje najlepšie výsledky rozpoznávania (prostredníctvom ukazovateľa EER) dosiahnuté v unimodálnom a multimodálnom režime činnosti.

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER

Tabuľka 3.9: Porovnanie úspešnosti rozpoznávania v unimodálnom a multimodálnom režime (v tabuľke sú uvedené najlepšie zaznamenané výsledky)

Režim systému OpenFinger	Databáza	EER (%)
Unimodálny (odtlačky prstov)	FVC 2002 DB2	0.51
Unimodálny (obrazce žíl)	SDUMLA-HMT	0.06
Multimodálny (odtlačky + obrazce žíl)	FVC 2002 DB2, SDUMLA-HMT	0.03

Multimodálny systém dosiahal vyššiu presnosť ($EER = 0.03$) ako obidva unimodálne systémy a týmto náš výskum preukázal vhodnosť kombinácie odtlačkov prstov s iným typom biometrického znaku na vytvorenie presného autentifikačného systému a potvrdila sa aj správnosť našej softvérovej implementácie multimodálneho režimu činnosti.

3.3.4 Overenie funkcionality systému formou klient-server aplikácie

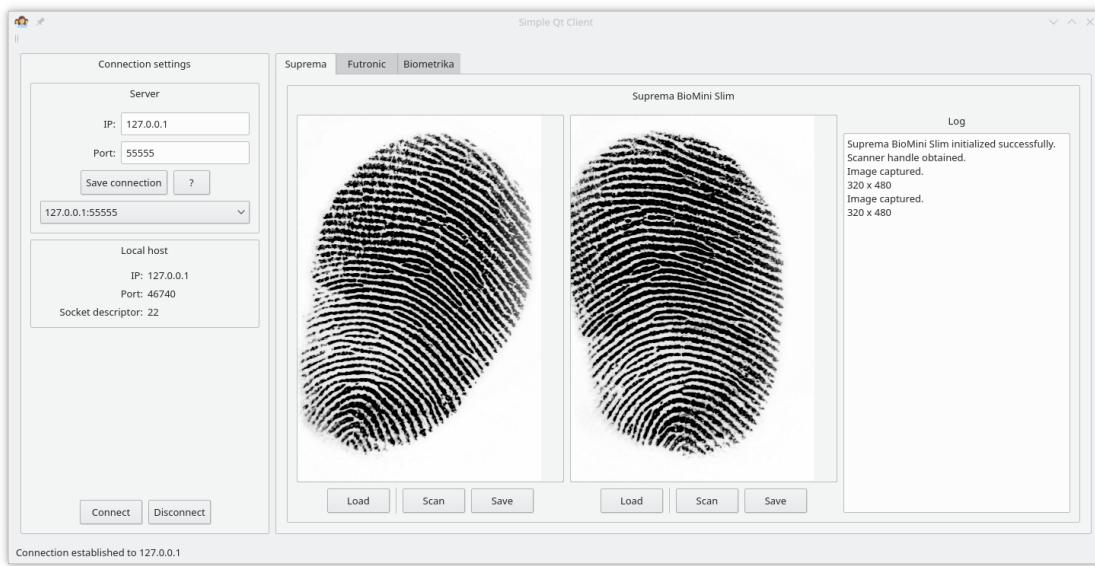
Vyvinuli sme vlastnú klient-server aplikáciu pomocou, ktorej demonštrujeme praktické nasadenie nášho autentifikačného systému v počítačovej sieti. Základnou myšlienkou aplikácie je obsluha pripojených vzdialených klientov pomocou služieb ponúkaných API rozhraním systému OpenFinger, ktorý je umiestnený na školskom serveri. Komunikácia medzi klientami a serverom je kryptograficky chránená protokolom SSL/TLS (v1.3).

Medzi služby, ktoré OpenFinger svojim klientom ponúka, patrí:

- paralelné spracovanie údajov od klientov (každý klient je obslužený v separátnom vlákne servera)
- možnosť autentifikácie (klient sa môže zaregistrovať viacerými prstami do databázy používateľov a potom testovať verifikáciu alebo identifikáciu)
- expertné funkcie (klient môže požiadať server o vrátenie rozšírených výsledkov procesu rozpoznávania, t.j. obrazové medzivýstupy z jednotlivých fáz spracovania ako napr. vyznačené miesta a typy extrahovaných Level-2 znakov)

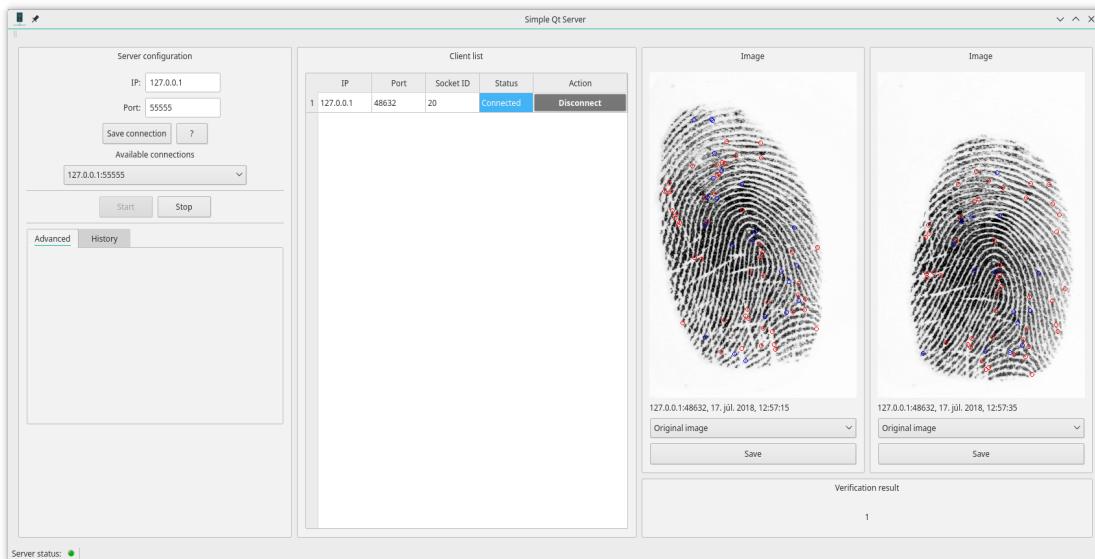
Na obrázku 3.53 vidíme rozhranie klientskej aplikácie, ktorá umožňuje špecifikovať IP adresu a port cieľového servera, na ktorom je nainštalovaný systém OpenFinger. Po nadviazaní spojenia môže klient pripojiť podporovaný USB senzor odtlačkov prstov a zosnímať odtlačok alebo vybrať obrázok odtlačku z úložiska a odoslať ho na server, kde bude následne spracovaný.

3.3. VÝSLEDKY TESTOVANIA SYSTÉMU OPENFINGER



Obr. 3.53: Klient-server aplikácia demonštrujúca praktické využitie systému OpenFinger: strana klienta

Na obrázku 3.54 vidíme rozhranie serverovej aplikácie, ktorá umožňuje nastaviť IP adresu a port, na ktorom bude TCP server počúvať prichádzajúce žiadosti o šifrované spojenia klientov. Ďalej je možné monitorovať a spravovať pripojených klientov. Pre každého klienta je možné zobrazovať všetky výsledky spracovania obrazu a pri požiadavke na autentifikáciu je možné vizuálne skúmať objavené a zhodujúce sa Level-2 znaky porovnávaných odtlačkov prstov.



Obr. 3.54: Klient-server aplikácia demonštrujúca praktické využitie systému OpenFinger: strana servera

Kapitola 4

Sumarizácia dosiahnutých výsledkov a prínos práce

V tejto práci sme zadefinovali hlavný skúmaný problém a ním je potreba spoľahlivého, presného, efektívneho a modulárneho softvérového riešenia daktyloskopickej autentifikácie s otvoreným zdrojovým kódom. V praxi, ale aj v rovine vedeckých publikácií je stále nedostatok dostupných softvérových knižníc na rozpoznávanie odtlačkami prstov s využitím najpokročilejších algoritmov, ponúkajúcich kompletný technologický popis fungovania, používania, inštalácie a s rozsiahlym objektívnym vyhodnotením svojej úspešnosti na verejne dostupných databázach odtlačkov prstov.

Existuje množstvo algoritmov, ktoré riešia čiastkové problémy predspracovania obrazu, avšak len minimum existujúcich riešení ich spája do funkčného celku. Významná technika filtrovania, akou je adaptívny Gaborov filter, je výpočtovo náročná a žiada si efektívne paralelné implementácie a stanovenie optimálnych, avšak veľakrát autormi neurčených hodnôt parametrov. Týmto oblastiam je na poli publikovaných riešení taktiež venovaný minimálny priestor. Taktiež prepojenie medzi spracovaním odtlačkov prstov a stále sa rozvíjajúcimi konvolučnými neurónovými sieťami je momentálne stále vo fáze postupného rozširovania sa a v tejto oblasti chýbajú rozsiahle experimenty, ktoré by mohlo formou softvéru s otvoreným kódom vykonávať množstvo výskumníkov a neustále tak posúvať hranice biometrického rozpoznávania na vyššiu úroveň. Konvolučné neurónové siete majú enormný potenciál pri detekcii a klasifikácii vzorov, ktorých automatizované odhalovanie nemohlo byť klasickými prístupmi dosiahnuté.

Nesmieme zabúdať aj na kvalitné vyhodnotenie navrhnutého biometrického systému. Je častým javom, že súčasným publikáciám z oblasti biometrie chýba aspekt dôkladného preverenia funkcionality. Chýba systematické testovanie úspešnosti a rýchlosť na rôznych databázach obrazov, testovanie pri použití rôznych konfigurácií algoritmov a možnosti prezentovať výsledky zaužívaným a objektívnym spôsobom pomocou rôznorodých metrík akými sú ROC krivky, FAR/FRR, EER a ďalšie iné. Tento spôsob by dovolil ľahko porovnať dva systémy a lepšie tak stanoviť optimálny výskumný smer.

Veľké množstvo riešení je distribuované ako uzavretý softvérový systém, ktorý neumožňuje experimentovanie s hodnotami parametrov jednotlivých algoritmov, ktoré tvoria biometrický systém a preto nie je možné preskúmať limity konkrétnej technológie. Taktiež je citelný nedostatok biometrických riešení, ktoré umožňujú ľahkú integráciu do softvéru tretích strán alebo sú prakticky demonštrované v jednom zo scenárov jeho potenciálneho nasadenia v praxi.

Na všetky tieto nedostatky, otvorené problémy a nepreskúmané možnosti sme sa snažili reagovať koncepciou a výsledkami tejto práce, ktorej hlavným výstupom je komplexný softvérový systém OpenFinger určený primárne na daktyloskopickú autentifikáciu a v neskorších fázach rozšírený o modul rozpoznávania obrazov žíl na prstoch. Je vybavený viacerými novými, doposiaľ nepublikovanými algoritmami vo fázach predspracovania obrazu, extrakcie charakteristických znakov a ich porovnávania a rovnako aj možnosťami fungovania a experimentovania. Najvýznamnejšie z nich sú uvedené v nasledujúcej časti práce.

4.1 Hlavné výsledky práce

Hlavné výsledky práce možno zhrnúť do týchto bodov:

- **Open-source softvér.** OpenFinger bol vyvinutý ako open-source softvér, na kôlko v skúmanej oblasti daktyloskopických systémov chýbajú riešenia tohto typu. Otvorený zdrojový kód znamená umožnenie tretím stranám experimentovať, rozvíjať, nadalej zlepšovať nás systém a predovšetkým vidieť a mať možnosť modifikovať všetky algoritmy a ich parametre.
- **Modulárna architektúra vo forme softvérových knižníc.** OpenFinger bol implementovaný ako ekosystém viacerých knižníc, ktoré medzi sebou vnútorné komunikujú a poskytujú rozhranie pre programátorov. Takáto modulárna architektúra zaručuje jednak flexibilitu (možnosť kedykoľvek použiť len niektorý modul samostatne alebo ho nahradieť iným modulom) a taktiež ľahkú integráciu do iného softvéru, ktorý vyžaduje autentifikáciu odtlačkami prstov.
- **Podpora senzorov odtlačkov prstov.** Nás systém podporuje tri populárne modely senzorov odtlačkov prstov, pričom dva z nich sú FBI certifikované.
- **Adaptívne filtrovanie obrazu.** V knižnici predspracovania sme implementovali účinnú techniku adaptívneho filtrovania obrazu Gaborovym filtrom. V rámci tejto techniky sa nepristupuje k obrazu ako k celku, ale ako k špeciálnemu vzoru, ktorého kvalita musí byť obnovená so zachovaním vlastností papilárnych línii, ktoré sú klíčové pre porovnávanie dvoch odtlačkov prstov.
- **Konvolučná neurónová sieť.** Využili sme konvolučnú neurónovú sieť na klasifikáciu Level-2 znakov, ktorej architektúra bola odvodená od známej siete ResNet-18. Pred samotnou klasifikáciou je analyzovaná kostra odtlačku prsta, v ktorej sú odhalené miesta tvarových anomalií. Obrazové bloky zachytávajúce okolie týchto bodov sú zaslané na klasifikáciu do neurónovej siete, ktorá určí, či sa jedná o Level-2 znak a následne klasifikuje jeho tvarový typ. Na redukcii početnosti falošných Level-2 znakov sme klasifikovali iba tie znaky, ktoré boli podľa mapy kvality vyhovujúce.

4.1. HLAVNÉ VÝSLEDKY PRÁCE

- **Využitie výpočtovej sily GPU a viacvláknového serverového CPU.** Viačerým technikám sme vytvorili aj ich paralelnú implementáciu pomocou GPU a CPU na urýchlenie výpočtov (napríklad Gaborov filter alebo trénovanie a predikcia konvolučnej neurónovej siete). Prínosom je aj vlastná paralelná implementácia známeho algoritmu BOZORTH3, ktorý slúži na porovnávanie Level-2 znakov. V počiatkoch nášho výskumu bol dostupný len ako aplikácia fungujúca v termináli operačného systému. Vytvorili sme z nej multi-vláknovú knižnicu.
- **Expertné sprievodné aplikácie.** Okrem knižníc, ktoré sú určené na výkon biometrických operácií, sme implementovali aj expertnú aplikáciu (s názvom OF Sandbox), ktorá slúži na testovanie predspracovania a dáva používateľovi plnú kontrolu pri nastavovaní dôležitých parametrov a možnosť vizualizovať ľubovoľný krok predspracovania. Ďalšou sprievodnou aplikáciou (s názvom OF Sample Collector) bol interaktívny nástroj na zber a generovanie trénovacích vzoriek Level-2 znakov pre neurónovú sieť, jej trénovanie a testovanie klasifikácie na používateľom zvolených obrazoch a konkrétnych miestach v obraze.
- **Export údajov do formátu ISO/IEC 19794-2.** Neurónovou sieťou odhalené Level-2 znaky sú exportované do standardizovaného formátu ISO/IEC 19794-2, v ktorom sú zaznamenané atribúty ako poloha, tvar a kvalita Level-2 znaku.
- **Modul automatizovaného vyhodnotenia úspešnosti a rýchlosťi.** OpenFinger sme rozšírili o samostatný modul vyhodnotenia úspešnosti rozpoznávania osôb, ktorý má aj svoje grafické používateľské rozhranie. Týmto spôsobom je možné vykonať širokú škálu experimentov zameraných na komplexné vyhodnotenie výsledkov nášho systému na rôznych obrazových databázach, rôznom počte testovaných osôb a pri rôznych nastaveniach algoritmov. Výstupom sú vizualizované ukazovatele ROC, FAR/FRR, EER, histogramy pre skóre porovnania a Precision-Recall. Modul je schopný aj merania rýchlosťi výpočtov.
- **Prínosy v implementácii algoritmov.** Počas výskumu sme implementovali viaceré existujúce algoritmy, ktorých voľnú implementáciu bolo náročné získať alebo neexistovala (hlavne výpočet mapy kvality alebo smerovej mapy). Taktiež sme navrhli a implementovali nové techniky, najmä adaptívny Gaborov filter a vlastný proces detektie a klasifikácie Level-2 znakov založený na konvolučnej neurónovej sieti.
- **Multimodálny režim.** Rozšírením systému OpenFinger o modul rozpoznávania obrazcov žil na prstoch sme obohatili naše riešenie o možnosť fungovať v dvoch separátnych unimodálnych režimoch alebo v multimodálnom režime, ktorý vykonáva fúziju odtlačkov prstov a obrazcov žil na prstoch.
- **Demonštrácia praktického využitia.** Vyvinuli sme vlastnú klient-server aplikáciu, ktorá v prostredí počítačovej siete umožňuje viacerým klientom diaľkové pripojenie sa na autentifikačný server (na ktorom je nainštalovaný OpenFinger) a

4.1. HLAVNÉ VÝSLEDKY PRÁCE

vykonávanie verifikácie alebo identifikácie. Zmyslom bolo poukázať na rôznorodé možnosti praktického využitia nášho systému.

- **Testovacie scenáre.** Systém bol podrobnený sérii experimentov s cieľom určiť jeho presnosť a rýchlosť rozpoznávania identity v unimodálnom/multimodálnom režime fungovania, rôznych databázach obrazov a rôznych konfiguráciách parametrov.

Sumarizácia výsledkov z jednotlivých testov:

- **Unimodálny systém na báze odtlačkov prstov.** Bol testovaný na rozsiahlej vzorke obrazov pochádzajúcich z databáz FVC 2002 (rôzne senzory a rozmery obrazu). Vzhľadom na diverzitu testovacích údajov považujeme tento test za klúčový a najlepšie vypovedá o presnosti nášho softvéru. Najnižšia chyba EER, na úrovni 0.51 %, bola zaznamenaná pri databáze FVC 2002 DB2 a priemerná chyba EER na všetkých databázach bola približne 1 %, čo považujeme za veľmi dobrý výsledok. Aby bolo možné, čo najobjektívnejšie hodnotiť náš softvér, porovnali sme ho aj s inými príbuznými riešeniami z literatúry, konkrétnie riešením MENet [83] a inými najznámejšími systémami. Porovnanie bolo zrealizované pomocou ROC kriviek, kde náš systém dosiahol výsledky na úrovni najlepších známych systémov. Okrem iných ukazovateľov sme sa zamerali aj na zhodnotenie distribúcie skóre porovnávania pri aktivovanom a deaktivovanom predspracovaní obrazu, aby sme tak mohli kvantifikovať dôležitosť tejto fázy spracovania. Pri aktívnom predspracovaní dosiahol náš systém lepsiú rozpoznávaciu schopnosť, čo sa prejavilo aj vo výsledných histogramoch. Suprema Bio-Mini SDK bol najlepším porovnávacím algoritmom. Z pohľadu rýchlosťi spracovania údajov sme vykonali experiment s meraním priemernej dĺžky trvania čiastkových operácií spracovania odtlačku na všetkých FVC 2002 databázach. Preukázala sa efektívnosť našej GPU implementácie predspracovacej fázy, ktorá spôsobila, že priemerný čas celkového spracovania jedného obrazu nameraný na školskom serveri bol na úrovni približne 52 ms. Význam predspracovania s využitím sily GPU bol zdôraznený aj experimentom, v ktorom sme merali dĺžku predspracovania v závislosti od rozmeru vstupného obrazu. Výsledkom bolo zistenie, že od rozmeru približne 300×300 , GPU implementácia prináša až 14-násobné zrýchlenie oproti viac-vláknovej CPU implementácii.
- **Unimodálny systém na báze obrazcov žíl na prstoch.** Pri testovaní sa preukázala ako najlepšia konfigurácia systému súčasné využitie predspracovania pomocou Gaborovho filtra, SURF extraktora a porovnávacieho algoritmu Brute-force. Testy sme vykonali na databáze SDUMLA-HMT a pri takto zvolenej konfigurácii sme namerali chybu EER približne na úrovni 0.06 % (bez využitia Gaborovho filtra sa chyba EER zvýšila na 4.43 %). Taktiež sme vykonali testy na vyhodnotenie rýchlosťi spracovania údajov, kde cel-

4.2. VEREJNÝ GITHUB REPOZITÁR SO ZDROJOVÝMI KÓDMI

kové spracovanie jedného obrazca žil trvalo na školskom serveri približne 95 ms.

- **Multimodálny systém.** Najlepšou konfiguráciou bolo použitie spracovania odtlačkov s aktivovaným procesom predspracovania a porovnávacím algoritmom Suprema BioMini SDK a spracovania obrazcov žil s aktivovaným predspracovaním, SURF extraktorom a porovnávacím algoritmom Brute-Force. Výsledok testu na multimodálnej biometrickej databáze FVC 2002 DB2 + SDUMLA-HMT ukázal, že fúzia odtlačkov prstov a obrazcov žil na prste priniesla zvýšenie rozpoznávacej schopnosti systému, ktorá je vyjadrená chybou EER na úrovni 0.03 %. Najlepšou metódou normalizácie skóre bol hyperbolický tangens a fúzia realizovaná *Sum* metódou.

4.2 Verejný Github repozitár so zdrojovými kódmi

Všetky relevantné zdrojové kódy modulov a knižníc systému OpenFinger spolu s používateľskými a technickými manuálmi sú dostupné v nasledujúcich GitHub repozitároch.

- Knižnica na predspracovanie odtlačkov prstov
<https://github.com/pavolmarak/openfinger-preprocessor>
- Knižnica na extrakciu Level-2 znakov
<https://github.com/pavolmarak/openfinger-extractor>
- Knižnica na porovnávanie odtlačkov
<https://github.com/pavolmarak/openfinger-matcher>
- Sprievodná aplikácia OF Sample Collector
<https://github.com/pavolmarak/openfinger-sample-collector>
- Kompletný modul spracovania obrazcov žil
[https://github.com/pavolmarak/openfinger-vein-module/tree/
Advanced_Preprocessing](https://github.com/pavolmarak/openfinger-vein-module/tree/Advanced_Preprocessing)
- Sprievodná klient-server aplikácia
<https://github.com/pavolmarak/fingerprint-client-gui-qt>
<https://github.com/pavolmarak/fingerprint-server-gui-qt>

Záver

V tejto práci sme predstavili vlastný biometrický systém OpenFinger, ktorý je implementovaný ako kolekcia softvérových knižníc určených na rozpoznávanie identity osoby pomocou jej odtlačkov prstov a obrazcov žíl na prste. OpenFinger má modulárnu architektúru, ktorá umožňuje jeho jednoduchú integráciu do softvéru tretích strán a poskytuje kontrolu nad všetkými klúčovými fázami spracovania biometrických údajov, konkrétnie predspracovaním obrazu, extrakciou charakteristických vlastností odtlačkov a ich porovnávaním. OpenFinger je softvér s otvoreným zdrojovým kódom umožňujúci rozsiahle výskumné experimenty.

Práca obsahuje technický opis viacerých nami implementovaných algoritmov, ktoré boli v čase nášho skúmania len v rovine teórie alebo ich softvérová implementácia bola nedostupná. Navrhli sme aj viacero nových prístupov, predovšetkým vo fáze predspracovania a extrakcie charakteristických znakov odtlačkov. Vytvorili sme účinnú implementáciu adaptívneho Gaborovho filtra a zadefinovali vlastnú strategiu extrakcie Level-2 znakov pomocou kombinácie analýzy kostry odtlačku prsta a klasifikácie vzorov v originálnom obraze pomocou konvolučnej neurónovej siete. Experimentovanie v rámci práce bolo uskutočnené na výkonného školského serveri a keďže boli jednotlivé operácie spracovania výpočtovo náročné, vytvorili sme pre rôzne časti systému ich paralelnú CPU/GPU implementáciu. Navyše, rozpoznávanie osoby je možné realizovať v unimodálnom ako aj multimodálnom režime s málo preskúmaným využitím fúzie odtlačkov prstov a obrazcov žíl, ktoré prinieslo želaný efekt v podobe zvýšenej schopnosti rozpoznať osobu. Naše riešenie môže byť jednoducho využité v reálnom scenári, čo potvrdili aj naše experimenty, v ktorých sme OpenFinger využili ako jadro klient-server aplikácie určenej na vzdialenú autentifikáciu.

Práca sa zaobráší širšími teoretickými aspektami dakyloskopických systémov a priblíží ťa specifika aktuálneho stavu v skúmanej oblasti. Koncentruje sa na všetky dôležité návrhové aspekty systému OpenFinger so zachytením princípov fungovania všetkých modulov a knižníc formou blokových schém. Implementované algoritmy a aplikácie boli zdokumentované z technického aj používateľského pohľadu a sú doplnené početnými vizualizáciami dôležitých fáz spracovania údajov ako aj obrazových výstupov. Celé implementované riešenie bolo komplexne testované v rôznorodých scenároch s cieľom kriticky zhodnotiť všetky slabé a silné stránky na viacerých databázach obrazov, pri premenlivej obrazovej kvalite a celkovej diverzite vzoriek odtlačkov prstov a obrazcov žíl pochádzajúcich z väčšieho počtu osôb.

OpenFinger sa vo svetle nášho dlhodobého vývoja a skúmania preukázal ako fungujúci biometrický systém, ktorý ponúka chýbajúce riešenia v skúmanej oblasti biometrie. Okrem jeho biometrickej funkcionality, ponúka používateľom a výskumníkom silný nástroj na experimentovanie a objavovanie limitov technológie s cieľom prispiť k zvýrazneniu pozície biometrie medzi dostupnými prostriedkami autentifikácie.

Literatúra

- [1] ALLAN, R. 2008. Biometrics Looks To Solve Identity Crisis. Electronic Design, June 19, 2008.
- [2] BARTŮNĚK, J. S. et al. 2006. Adaptive Fingerprint Binarization by Frequency Domain Analysis. In: Circuits, Systems and Computers. 2006, 1977. Conference Record, p. 598 – 602.
- [3] Biometrics Market and Industry Report 2007 – 2012. International Biometric Group.
- [4] Biometrics Overview. NIST Information Technology Laboratory.
- [5] BOROVANSKÝ, L. a kol. 1973. Soustavná anatomie člověka II. 4. Vydání. Praha: Avicenum, 1973, 476 s.
- [6] ASHBAUGH, D. R. 1999. Ridgeology: Modern Evaluative Friction Ridge Identification. Forensic Identification Support Section, Royal Canadian Mounted Police, 53 p.
- [7] CARTER, R. G. 2012. Authentication vs. Authorization. Durham : Duke University.
- [8] CHENG, J. – TIAN, J. 2004. Fingerprint enhancement with dyadic scale-space. In: Pattern Recognition Letters. 2004, Vol. 25, No. 1, p. 1273-1284.
- [9] DESSIMONZ, D. et al. 2005. Multimodal Biometrics for Identity Documents: research report. Lausanne : Université de Lausanne, 2005, 150 p.
- [10] Fingerprint Biometrics. Biometric News Portal.
- [11] FRONTHALER, H. et al. 2008. Fingerprint Image Quality Estimation and its Application to Multi-Algorithm Verification. In: Information Forensics and Security. 2008, Vol. 3, No. 2, p. 331-338.
- [12] FVC-onGoing. On-line evaluation of fingerprint recognition algorithms. University of Bologna : Biometric System Laboratory.
- [13] GREENBERG, S. et al. 2000. Fingerprint Image Enhancement using Filtering Techniques. In: Pattern Recognition. 2000, Vol. 3, p. 227-236.
- [14] GUTIÉRREZ, E. et al. 2007. Biological Variability of the Minutiae in the Fingerprints of a Sample of the Spanish Population. In: Forensic Science International. 2007, Vol. 172, Issues 2-3, p. 98-105.
- [15] HE, Y. et al. 2003. Image enhancement and minutiae matching in fingerprint verification. In: Pattern Recognition Letters. 2003, Vol. 24, No. 10, p. 1349-1360.

- [16] HELFROUSH, M. S. – MOHAMMADPOUR, M. 2009. Fingerprint Segmentation. In: World Applied Sciences Journal. 2009, Vol. 6, No. 3.
- [17] HÖDL, R. et al. 2009. Slap Fingerprint Segmentation. In: Computer Vision Winter Workshop. PRIP: Vienna University of Technology, 2009, 8 p.
- [18] HONG, L. – WAN, Y. – JAIN, A. K. 1998. Fingerprint Image Enhancement: Algorithm and Performance Evaluation. In: IEEE Transactions On Pattern Analysis And Machine Intelligence. 1998, Vol. 20, No. 8, p. 777-789.
- [19] HSIEH, C. – LAI, E. – WANG, Y. 2001. An effective algorithm for fingerprint image enhancement based on wavelet transform. In: Pattern Recognition. 2002, Vol. 36, No. 2, p. 303-312.
- [20] JAIN, A. K. – PANKANTI, S. 2000. Fingerprint Classification and Matching. Academic Press, 2000, 32 p.
- [21] JAIN, A. K. – CHEN, Y. – DEMIRKUS, M. 2007. Pores and Ridges: High-Resolution Fingerprint Matching Using Level 3 Features. In: IEEE Transactions On Pattern Analysis And Machine Intelligence. 2007, Vol. 29, No. 1, p. 15-27.
- [22] KAZI, M. et al. 2011. Comparison of fingerprint enhancement techniques through Mean Square Error and Peak-Signal to Noise Ratio. In: International Journal on Computer Science and Engineering. 2011, Vol. 3, No.1.
- [23] KEKRE, H. B. – BHARADI, V. A. 2010. Fingerprint Core Point Detection Algorithm Using Orientation Field Based Multiple Features. In: International Journal of Computer Applications. 2010, Vol. 1, No. 15, p. 97-103.
- [24] KIM, S. – LEE, D. – KIM, J. 2001. Algorithm for Detection and Elimination of False Minutiae in Fingerprint Images. In: AVBPA Proceedings, Third International Conference. 2001, Vol. 2091, p. 235-240.
- [25] KÜCKEN, M. – NEWELL, A. C. 2005. Fingerprint Formation. In: Journal of Theoretical Biology. 2005, No. 235, p. 71-83.
- [26] LEE, C. et al. 2006. Singular Points and Minutiae Detection in Fingerprint Images Using Principal Gabor Basis Functions. Chinese Culture University : Department of Computer Science, Taipei, Taiwan, 2006, 6 p.
- [27] LIŠKA, P. – ŠMÍD, Z. – ZÍKA, J. 1982. Individuální identifikace v daktyloskopii. In: Československá kriminalistika. 1982, Ročník XV., s. 11 – 23.
- [28] MAIO, D. – MALTONI, D. 1997. Direct gray-scale minutiae detection in fingerprints. In: IEEE Transactions on Pattern Analysis and Machine Intelligence. 1997, Vol. 19, No. 1.

LITERATÚRA

- [29] MALTONI, D. et al. 2009. Handbook of Fingerprint Recognition. Second Edition. London : Springer, 2009. 496 p.
- [30] MARÁK, P. 2010. Rozpoznávanie a spracovanie odtlačkov prstov pomocou informačných technológií : diplomová práca. Bratislava : FEI STU, 2010. 143 s.
- [31] KÁDEK, L. 2018. Daktyloskopický sieťový systém DBOX-server : diplomová práca. Bratislava : FEI STU, 2018. 97 s.
- [32] KOVÁČ, I. 2019. Multimodal biometric system based on fingerprint and finger vein pattern : bakalárská práca. Bratislava : FEI STU, 2019. 122 s.
- [33] KOVÁČ, I. - MARÁK, P. 2020. On Utilization of Adaptive Gabor Filters for Finger Vein Pattern Enhancement. In: ŠVOČ 2020: Zborník vybraných prác študentskej vedeckej a odbornej činnosti, <http://uef.fei.stuba.sk/web/SVOC2020.pdf>. Bratislava : FEI STU, 2020. 6 s.
- [34] METEŇKO, J. et al. 2010. Trendy skúmania daktyloskopických stôp a ich výskum v projekte excellentnosti. In: IV. mezinárodní konference věnovaná kriminalistice a dalším forenzním vědám. Praha: Policejní akademie ČR v Praze, 2010.
- [35] MINKIN, V. 2008. Fingerprints and the Thermodynamics of Human Development. In: Journal of Human Thermodynamics. 2008, Vol. 4, Issue 2, p. 8-12.
- [36] PANKANTI, S. – PRABHAKAR, S. – JAIN, A. K. 2002. On the Individuality of Fingerprints. In: IEEE Transactions On Pattern Analysis And Machine Intelligence. 2002, Vol. 24, No. 8.
- [37] ROSS, A. – SHAH, J. – JAIN, A. K. 2007. From Template To Image: Reconstructing Fingerprints from Minutiae Points. In: IEEE Transactions On Pattern Analysis And Machine Intelligence. 2007, Vol. 29, No. 4, p. 544-560.
- [38] SHAIFAT, F. – KEYSERS, D. – BREUEL, T. M. 2008. Efficient Implementation of Local Adaptive Thresholding Techniques Using Integral Images. Technical University of Kaiserslautern : Department of Computer Science, 2008, 6 p.
- [39] SAGAR, N. 2009. Role of Middleware Companies in the Biometrics Industry. Frost Sullivan, March 3, 2009.
- [40] SHERLOCK, B. G. – MONRO, D. M. – MILLARD, K. 1994. Fingerprint Enhancement by Directional Fourier Filtering. In: IEEE Proceedings: Visual Image Signal Processing. 1994, Vol. 141, No. 2.
- [41] THAI, R. 2003. Fingerprint Image Enhancement and Minutiae Extraction. University of Western Australia, 2003, 71 p.

- [42] ALLAN, R. 2008. Biometrics Looks To Solve Identity Crisis. Electronic Design, June 19, 2008.
- [43] WANG, Y. – HU, J. – HAN, F. 2007. Enhanced gradient-based algorithm for the estimation of fingerprint orientation fields. In: Applied Mathematics and Computation. 2007, Vol. 185, No. 2, p. 823-833.
- [44] YANG, J. – LIU, L. – JIANG, T. 2002. An Improved Method for Extraction of Fingerprint Features. In: Proceedings of SPIE. 2002, Vol. 4875, p. 552-558.
- [45] YANG, J. et al. 2003. A modified Gabor filter design method for fingerprint image enhancement. In: Pattern Recognition Letters. 2003, Vol. 24, Issue 12, p. 1805-1817.
- [46] ZHANG, Y. – WANG, P. 1996. A Parallel Thinning Algorithm with Two-Subiteration that generates One-Pixel-Wide Skeletons. In: Pattern Recognition. 1996, Vol. 4, p. 457-461.
- [47] ZHAO, F. – TANG, X. 2005. Preprocessing and postprocessing for skeleton-based fingerprint minutiae extraction. In: Pattern Recognition. 2007, Vol. 40, No. 3, p. 1270-1281.
- [48] ZHU, E. et al. 2006. Asystematic method for fingerprint ridge orientation estimation and image segmentation. In: Pattern Recognition. 2006, Vol. 39, No. 9, p. 1452-1472.
- [49] PERUMAL, V. - RAMASWAMY, J. 2009. An Innovative Scheme For Effectual Fingerprint Data Compression Using Bezier Curve Representations. In: International Journal of Computer Science and Information Security. 2009. Vol. 6, No. 1, p. 149 - 157.
- [50] TABASSI, E. - GROTHÉR, P. - SALAMON, W. - WATSON, C. 2009. Minutiae Interoperability. In: BIOSIG 2009 - Proceedings of the Special Interest Group on Biometrics and Electronic Signatures. 2009. 17. -18. september 2009, Darmstadt, Germany.
- [51] BOLLE, R. - PANKANTI, S. - JAIN, A. 1998. Biometrics, Personal Identification in Networked Society: Personal Identification in Networked Society. Kluwer Academic Publishers Norwell, MA, USA. ISBN:0792383451.
- [52] HASTINGS, R. 2010. Investigation of some statistical properties of fingerprint patterns. Thesis (Ph.D.)–University of Western Australia.
- [53] LEO, W. 2014. What are the Effects of the Daubert Decision on Fingerprint Identification.
- [54] HART-DAVIS, A. 2012. Veda. IKAR: Bratislava. 512 s. EAN: 9788055126289.

LITERATÚRA

- [55] U.S. Department of Justice. 2008. The Fingerprint Sourcebook.
- [56] CHAMPOD, C. et al. 2004. Fingerprints and Other Ridge Skin Impressions. CRC Press, 304 p.
- [57] BAZEN, A. 2002. Fingerprint Identification - Feature Extraction, Matching, and Database Search. PhD. Thesis.
- [58] PAINDAVOINE, M. - SUDIRO, A. - KUSUMA, M. 2007. Simple Fingerprint Minutiae Extraction Algorithm Using Crossing Number On Valley Structure. In: Automatic Identification Advanced Technologies. p. 41 - 44.
- [59] GOVINDARIJU, V. - SHI, Z. 2006. A chaincode based scheme for fingerprint feature extraction. In: Pattern Recognition Letters. Vol. 27. p. 462 - 468.
- [60] BARTŮNĚK, J. S. 2016. Fingerprint Image Enhancemet, Segmentation and Minutiae Detection [PhD. thesis]. Department of Applied Signal Processing, Blekinge Institute of Technology, Sweden. 44 p.
- [61] TURRONI, F. 2012. Fingerprint Recognition: Enhancement, Feature Extraction and Automatic Evaluation of Algorithms [PhD. thesis]. Department of Computer Science, University of Bologna, Italy. 158 p.
- [62] POH, N. et al. 2012. Description of Metrics For the Evaluation of Biometric Performance. BEAT: Biometrics Evaluation and Testing. 22 p.
- [63] MSIZA, I. S. et al. 2011. Fingerprint Segmentation: An Investigation of Various Techniques and a Parameter Study of a Variance-based Method. In: International Journal of Innovative Computing, Information and Control, Volume 7, Number 9, September 2011, pp. 5313–5326.
- [64] NGUYEN, D. et al. 2018. Automatic Latent Fingerprint Segmentation. In: IEEE 9th International Conference on Biometrics Theory, Applications and Systems (BTAS).
- [65] ZHU, E. et al. 2005. Quality Estimation of Fingerprint Image Based on Neural Network. In: Advances in Natural Computation: First International Conference, ICNC 2005, Changsha, China, August 27-29, 2005. pp. 65-70.
- [66] BARTŮNĚK, J. S. et al. 2013. Adaptive Fingerprint Image Enhancement with Emphasis on Pre-processing of Data. In: IEEE Transactions on Image Processing 22(2). 15 p.
- [67] PRASAD, V. S. N. - DOMKE, J. 2005. Gabor Filter Visualization. 9 p.
- [68] GOTTSCHLICH, C. 2012. Curved Gabor Filters for Fingerprint Image Enhancement. In: IEEE Transactions on Image Processing, vol. 21, no. 4, pp. 2220-2227, Apr. 2012.

- [69] WATSON, C. I. et al. 2004. User's Guide to Export Controlled Distribution of NIST Biometric Image Software. National Institute of Standards and Technology. 35 p.
- [70] VALDES-RAMIREZ, D. et al. 2019. A Review of Fingerprint Feature Representations and Their Applications for Latent Fingerprint Identification: Trends and Evaluation. In: IEEE Access (Volume:7). pp. 48484 - 48499.
- [71] HWANG, H. et al. 2002. Run Representation Based Minutiae Extraction in Fingerprint Image. In: IAPR Workshop on Machine Vision Applications, Dec. 11-13, 2002, Nara-ken New Public Hall. Nara, Japan. 5 p.
- [72] BANSAL, R. et al. 2010. Effective Morphological Extraction of True Fingerprint Minutiae based on the Hit or Miss Transform. In: International Journal of Biometrics and Bioinformatics(IJBB), Volume (4), Issue (2), 16 p.
- [73] FENG, J. F. et al. 2014. High-resolution palmprint minutiae extraction based on Gabor feature. In: Science China Information Sciences, 2014, Vol. 57: 112106(15), 16 p.
- [74] VAŽAN, R. 2020. SourceAFIS fingerprint matcher. Dostupné na <https://sourceafis.machinezoo.com/>.
- [75] PATRICIU, V. et al. 2015. Fingerprint Orientation Image Estimation in the Frequency Domain. In: Genetic Algorithms-Fuzzy Based Trade-Off Adjustment Between Software Complexity and Deliverability, Springer International Publishing, pp.439-443.
- [76] HOU, Z. et al. 2011. A review on fingerprint orientation estimation. In: Security and Communication Networks, Volume 4, Issue 5, pp. 591-599.
- [77] ZHU, E. et al. 2006. Fingerprint Ridge Orientation Estimation Based on Neural Network. In: Proceedings of the 5th WSEAS Int. Conf. on Signal Processing, Robotics and Automation, Madrid, Spain, February 15-17, 2006, pp. 158-164.
- [78] WANG, W. et al. 2008. Design and implementation of Log-Gabor filter in fingerprint image enhancement. In: Pattern Recognition Letters 29 (2008), pp. 301–308.
- [79] YANG, J. et al. 2003. A modified Gabor filter design method for fingerprint image enhancement. In: Pattern Recognition Letters 24 (2003), pp. 1805–1817.
- [80] ZHANG, L. et al. 2009. Fingerprint ridge distance estimation based on ridge search. In: International Joint Conference on Bioinformatics, Systems Biology and Intelligent Computing, pp. 604-607.
- [81] LEHTIHET, R. et al. 2014. Ridge Frequency Estimation for Low-Quality Fingerprint Image Enhancement Using Delaunay Triangulation. In: International Journal of Pattern Recognition and Artificial Intelligence, Vol. 28, No. 1 (2014), 1456002, 15 p.

- [82] ENGELSMA, J. J. et al. 2019. Fingerprints: Fixed Length Representation via Deep Networks and Domain Knowledge. In: arXiv:1904.01099, 10 p.
- [83] DARLOW, L. N. - ROSMAN, B. 2017. Fingerprint minutiae extraction using deep learning. In: IEEE International Joint Conference on Biometrics (IJCB), Denver, CO, pp. 22-30.
- [84] NGUYEN, D. et al. 2018. Robust Minutiae Extractor: Integrating Deep Networks and Fingerprint Domain Knowledge. In: International Conference on Biometrics (ICB), Gold Coast, QLD, pp. 9-16.
- [85] TANG, Y. 2017. FingerNet: An unified deep network for fingerprint minutiae extraction. In: IEEE International Joint Conference on Biometrics (IJCB), Denver, CO, pp. 108-116.
- [86] WATSON, C. I. et al. 2007. User's Guide to NIST Biometric Image Software (NBIS). Dostupné na <https://nvlpubs.nist.gov/nistpubs/Legacy/IR/nistir7392.pdf>.
- [87] CHEN, J. - GUO, Z. 2016. Palmprint Matching by Minutiae and Ridge Distance. In: Cloud Computing and Security, ICCCS 2016, Lecture Notes in Computer Science, vol 10040, pp. 371-382.
- [88] ALSAADE, F. 2008. Score-Level Fusion for Multimodal Biometrics. In: University of Hertfordshire Research Archive, PhD. Thesis, 136 p.
- [89] YANG, W. et al. 2018. A Fingerprint and Finger-vein Based Cancellable Multi-biometric System. In: Pattern Recognition 78, 35 p.
- [90] ELMIR, Y. - KHELIFI, N. 2019. Secured Biometric Identification: Hybrid Fusion of Fingerprint and Finger Veins. In: International Journal of Information Technology and Computer Science 11, pp. 30-39.
- [91] CHERRAT, E. M. et al. 2020. Convolutional neural networks approach for multimodal biometric identification system using the fusion of fingerprint, finger-vein and face images. In: PeerJ Computer Science 6:e248, 15 p.
- [92] BANDARA, A. M. R. R. et al. 2017. Super-efficient spatially adaptive contrast enhancement algorithm for superficial vein imaging. In: IEEE International Conference on Industrial and Information Systems (ICIIS), pp. 1-6.
- [93] LOWE, D. G. 2004. Distinctive Image Features from Scale-Invariant Keypoints. In: International Journal of Computer Vision, vol. 40, pp. 91-110.
- [94] BAY, H. et al. 2008. Speeded-Up Robust Features (SURF). In: Computer Vision and Image Understanding, vol. 110 (no. 3), pp. 346-359.