



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV INTELIGENTNÍCH SYSTÉMŮ

DEPARTMENT OF INTELLIGENT SYSTEMS

DETEKCE ŽIVOSTI RUKY

LIVENESS DETECTION OF A HAND

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

VEDOUCÍ PRÁCE

SUPERVISOR

JOZEF VANICKÝ

Ing. MARTIN SAKIN

BRNO 2020

Zadání bakalářské práce



Student: **Vanický Jozef**
Program: Informační technologie
Název: **Detekce živosti ruky**
Liveness Detection of a Hand

Kategorie: Umělá inteligence

Zadání:

1. Prostudujte chování lidské kůže na ruce osvětlené různými vlnovými délkami.
2. Navrhňte algoritmus pro segmentaci ruky z fotky, tzn. eliminování pozadí.
3. Navrhňte algoritmus pro odlišení živé ruky od falzifikátu ze snímku ruky.
4. Navržené řešení implementujte.
5. Zhodnoťte dosažené výsledky a diskutujte další možné pokračování této práce.

Literatura:

- New Optical Methods for Liveness Detection on Fingers:
<http://downloads.hindawi.com/journals/bmri/2013/197925.pdf>
- Fingerprint Sensors: Liveness Detection Issue and Hardware based Solutions: http://www.sensorsportal.com/HTML/DIGEST/P_907.htm
- Liveness Detection in Biometrics: <https://www.intechopen.com/books/advanced-biometric-technologies/liveness-detection-in-biometrics>

Pro udělení zápočtu za první semestr je požadováno:

- Splnění bodů 1 až 3.

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

Vedoucí práce: **Sakin Martin, Ing.**

Vedoucí ústavu: Hanáček Petr, doc. Dr. Ing.

Datum zadání: 1. listopadu 2019

Datum odevzdání: 28. května 2020

Datum schválení: 31. října 2019

Abstrakt

Táto práca rieši problém bezpečnosti biometrických systémov využívajúcich biometrický údaj ruky. Zameriava sa na absenciu detekcie živosti pri verifikácii vzorku biometrickým systémom. Riešenie práce ponúka rozšírenie bezkontaktných biometrických systémov o systém detekcie živosti, ktorý využíva špecifických vlastností ľudskej kože a jej reakcií na určité vlnové dĺžky viditeľného spektra elektromagnetického žiarenia. V práci sa analyzujú reakcie kože na špecifické vlnové dĺžky viditeľného spektra, pričom sú porovnávané s reakciami anorganických materiálov, ktoré napodobujú ruku. Výsledkom práce je návrh a implementácia algoritmu detekcie živosti, ktorý dokáže na základe analýzy sady fotografií ľudskej dlane, ktorá bola vystavená štyrom vlnovým dĺžkam viditeľnej časti elektromagnetického spektra, úspešne rozpoznať ruku od falzifikátu s priemernou mierou presnosti 82,20%.

Abstract

This thesis solves the security problem of biometric systems which uses biometric data of a hand. It focuses on the absence of liveness detection during verification of a sample by the biometric system. In result this thesis offers to extend the contactless biometric systems by a system of liveness detection, which utilizes specific properties of human skin and its reactions to certain wavelengths of the visible spectrum of electromagnetic radiation. Reactions of the skin on the specific wavelengths of visible spectrum are analyzed and compared with the reactions of inorganic materials which imitates the hand. Outcome of this thesis is a design and implementation of a liveness detection algorithm, which can, based on the analysis of a set of photographs of the human palm, which was exposed to four wavelengths of a visible part of the electromagnetic spectrum, successfully recognize a hand from a counterfeit with an average accuracy rate of 82.20%.

Kľúčové slová

detekcia živosti, ruka, vlnová dĺžka, koža, žiarenie, viditeľné svetlo, viditeľné spektrum, biometria, bezkontaktná detekcia

Keywords

liveness detection, hand, wavelength, skin, radiation, visible light, visible spectrum, biometry, contactless detection

Citácia

VANICKÝ, Jozef. *Detekce živosti ruky*. Brno, 2020. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Martin Sakin

Detekce živosti ruky

Prehlásenie

Prehlasujem, že som túto bakalársku prácu vypracoval samostatne pod vedením Ing. Martina Sakina. Ďalšie informácie mi poskytol Ing. Lukáš Semerád, Bc. Miroslav Kažimír a Bc. Ivo Juráček. Uviedol som všetky literárne pramene, publikácie a ďalšie zdroje, z ktorých som čerpal.

.....
Jozef Vanický
3. júna 2020

PodĎakovanie

Rád by som podakoval Ing. Martinovi Sakinovi za jeho vedenie a usmerňovanie pri tvorbe tejto práce. Moje podakovanie patrí aj Ing. Radkovi Tománkovi za jeho rady pri návrhu snímacieho zariadenia určeného k tvorbe datasetu a všetkým, ktorí svojím pričinením v období pandémie vírusu SARS-CoV-2 akokoľvek dopomohli k vytvoreniu datasetu potrebného k natrénovaniu klasifikátora, ktorý je hlavným prvkom tejto práce.

Obsah

1	Úvod	3
2	Biometria a jej metódy	4
2.1	Základy biometrických systémov	4
2.2	Identifikácia podľa ruky	5
2.2.1	Geometria ruky	5
2.2.2	Odtlačky prsta	6
2.2.3	Žily prstov	6
2.2.4	Rozpoznávanie podľa nechtu	7
2.2.5	Dynamika stláčania kláves	8
2.2.6	Dynamika podpisu	8
2.3	Hodnotenie kvality biometrických systémov	9
3	Detekcia živosti	10
3.1	Koža	10
3.2	Vplyv elektromagnetického žiarenia na kožu	11
3.2.1	Infračervené žiarenie (IR)	12
3.2.2	Viditeľné svetlo	13
3.2.3	Ultrafialové žiarenie	13
3.3	Metódy detekcie živosti	14
3.3.1	Teplota	14
3.3.2	Teplý a studený podnet	14
3.3.3	Oxidácia krvi	15
3.3.4	Pulz	15
3.3.5	Prítlak	15
3.3.6	Multi-spektrálna analýza	16
3.3.7	Detekcia potu	16
3.3.8	Elektrické vlastnosti kože	17
4	Návrh	18
4.1	Voľba vlnových dĺžok	18
4.2	Segmentácia ruky	19
4.2.1	Úprava parametrov kamery	20
4.2.2	Semienkové vyplňovanie s využitím Haarovho klasifikátora	20
4.2.3	Segmentácia maskou ruky a kontúrami	21
4.2.4	Segmentácia ruky maskou predtrénovanej neurónovej siete	22
4.2.5	Segmentácia rozdielom dvoch snímkov	22
4.3	Detekcia živosti	22

4.3.1	Klasifikácia konvolučnou neurónovou sieťou	23
4.3.2	Klasifikácia použitím Support Vector Machine (SVM)	23
5	Implementácia	25
5.1	Zariadenie na tvorbu datasetu	25
5.2	Algoritmus a parametre snímania	27
5.3	Dataset	30
5.4	Eliminácia pozadia	31
5.5	Detekcia živosti na základe modelov štyroch vlnových dĺžok	34
6	Experimenty a vyhodnotenie	38
6.1	Rozdelenie datasetu na tréningovú a testovaciu množinu	38
6.2	Aplikovanie PCA	38
6.3	Voľba počtu komponentov PCA	39
6.4	Zhodnotenie samotných modelov	40
6.5	Zhodnotenie implementácie	43
7	Záver	44
	Literatúra	45
A	Schéma zapojenia	47
B	Obsah priloženého pamäťového média	48

Kapitola 1

Úvod

Bezpečnosť je téma, ktorej sa posledné roky dostáva čoraz väčšia pozornosť, či už ide o zabezpečenie osobných zariadení, rozsiahlejších počítačových systémov, alebo kritických objektov, akými môžu byť niektoré priestory letiska, či laboratória v ktorých sa skúmajú nebezpečné vírusy. V takýchto prípadoch je potreba dôkladne zabezpečiť, že do systému majú prístup iba konkrétne oprávnené osoby.

Zabezpečenie systémov je v tejto dobe na vysokej úrovni, avšak stále sa objavujú spôsoby ako tento súhrn opatrení prelomiť. Samostatné použitie hesiel, jednorazových kódov, či RFID kariet sa už v mnohých prípadoch nepovažujú za dostatočne bezpečné. K zabezpečeniu kritických objektov a počítačových systémov sa začali pridávať systémy identifikácie autorizovaných osôb na základe biometrických údajov.

Biometrický údaj je údaj o fyzickej osobe, ktorým je možné osobu nezameniteľne identifikovať. Ide o biologické vlastnosti, anatomicke-fyzikálne rysy, alebo opakované činnosti, ktoré sú pre daného človeka špecifické, nezameniteľné a merateľné. Biologickým údajom môže byť napríklad odlačok prsta, odlačok dlane, geometria ruky, snímok sietnice oka, alebo dúhovky oka.

Základné biometrické zabezpečenia, ako napríklad optické kontaktné snímače odlačku prsta môžu byť útočníkom ľahko prekonateľné. Stačí mať na malú chvíľu prístup k predmetu, ktorého sa daná osoba dotkla. Môže ísť napríklad o sklo, papier, mobil, alebo kľučku dverí. Získaný odlačok sa dá ešte vylepšiť a následne spracovať. Takýmto spôsobom je možné získať ešte lepšie výsledky a relatívne bezproblémovo v systéme prevziať identitu obeť. Z toho dôvodu sa tieto zabezpečenia modifikujú, inovujú a pridáva sa do nich systém detekcie živosti.

Systémy detekcie živosti analyzujú, predložené biometrické vzorky v snahe určiť, či sa jedná skutočne o legitímnu osobu, alebo sa snaží do systému niekto preniknúť podvrhnutím falzifikátu s legitímnym biometrickým údajom. Tieto systémy môžu analyzovať rôzne vlastnosti charakteristické pre živé organické tkanivo a to napríklad oxidáciu krvi v krvnom riečisku, pulz, reakciu na tepelný a studený podnet, elektrické, alebo spektrálne vlastnosti kože. Táto práca sa zaoberá detekciou živosti ruky na základe charakteristického chovania kože osvietenej rôznymi vlnovými dĺžkami svetla.

Detekciu živosti je potrebné implementovať ako súčasť celého biometrického systému. Ak by bol proces detekcie živosti vykonávaný separátne od autentifikácie osoby, systém by mohol byť relatívne ľahko napadnuteľný, pretože útočník by mohol v procese detekcie živosti využiť svoje vlastné charakteristiky, zatiaľ čo by počas autentifikácie využil ukradnuté biometrické údaje oprávnenej osoby.

Kapitola 2

Biometria a jej metódy

Detekcia živosti spadá do oboru biometrie, ktorý sa zaoberá automatizovaným postupom rozpoznávania vzorov, anatomicko-fyzikálnych rysov, či charakteristického chovania, na základe ktorého je možné rozpoznať osobu. Hlavným prvkom biometrie je jedinečnosť skúmaných vlastností, vďaka ktorým je možné osobu identifikovať alebo verifikovať.


Jej hlavnými výhodami je vysoká presnosť, s ňou spojené zvyšovanie bezpečnosti a eliminovanie pokusov o falzifikáciu totožnosti. V porovnaní s heslami nie je možné biometrické črty autorizovanej osoby jednoducho dať niekomu inému, alebo ich zabudnúť. Ďalšou výhodou je stálosť údajov vďaka zachovaniu vlastností počas celého života užívateľa. Ďalej ide o jedinečnosť, ktorou sa každý jedinec líši od iného, či univerzálnosť, pretože prvok biometrie sa vzťahuje na všetkých užívateľov. V prípade hesiel má biometria výhodu v jednoduchosti využitia v praxi, kedy sa hľadajú jednoduchšie riešenia.

Jednou z nevýhod biometrie je nejednoznačné skóre porovnania výstupu. Výsledok zhody porovnávaného objektu so vzorkou registrovanou v databáze totiž nikdy nie je úplne totožný a preto je potrebné pracovať s drobnými odchýlkami. Ďalšou nevýhodou je napatiteľnosť biometrického systému a potreba systému detekcie živosti [8].

2.1 Základy biometrických systémov


Úlohou biometrického systému môže byť verifikácia, alebo identifikácia osoby, kedy systémy biometrie overujú vlastnosti osoby.

Pri identifikácii sa zisťuje identita osoby. Biometrická vlastnosť osoby sa porovnáva s množinou vzoriek, ktoré sú uložené v databáze, pričom osoba neoznamuje systému svoju identitu. Jedná sa o porovnanie 1:N, ktorej výsledkom je jednoznačná identifikácia osoby, alebo negatívny výstup, viz obrázok 2.1.



Obr. 2.1: Schéma identifikácie v biometrickom systéme.

Pri verifikácii sa postupuje odlišne. Užívateľ systému poskytne okrem svojej biometrickej vlastnosti aj svoju identitu. Následne sa v databáze vyhľadá biometrická vzorka danej osoby, ktorá sa porovná so vstupom na snímači, viz obrázok 2.1. Ide o porovnanie 1:1, teda o autentizáciu ako v klasických prípadoch s užívateľským menom a heslom. Následným výstupom porovnania je autorizácia, alebo zamietnutie osoby [20].



Obr. 2.2: Schéma verifikácie v biometrickom systéme.


2.2 Identifikácia podľa ruky

Z dôvodu zamerania sa tejto práce na detekciu živosti ruky, budú v tejto kapitole popísané existujúce metódy biometrických systémov využívajúce práve unikátnych vlastností ruky.

2.2.1 Geometria ruky

Podstatou tejto technológie je meranie geometrických vlastností ruky, keďže každý jedinec má tieto vlastnosti jedinečné.

Pri tejto technológii sa meria výška, dĺžka, šírka prstov, zakrivenia a anomálie ruky. K presnejším výpočtom môžu slúžiť aj distančné kolíky, viz obrázok 2.3. Meranie geometrie ruky je pomerne jednoduché. Kamera vytvorí fotografiu ruky tak, aby ruku bolo vidno zhora, alebo zdola. V súčasnosti už prebehlo meranie podľa 3D geometrie ruky, pri ktorom sa využíva celý jej povrch. Meranie geometrie ruky vyžaduje menšie rozlíšenie, ako pri vytváraní fotografií odtlačkov prstov.



Obr. 2.3: Osi merania ruky vrátane distančných kolíkov [13].

Výhodou merania je vysoká akceptovateľnosť, rysy ruky sa ľahko získajú, takisto cena zariadenia je pomerne nízka [8][20].

Nevýhodou merania je fakt, že rysy ruky sa behom života ľudí menia, preto sa zvyšuje pravdepodobnosť chyby systému a znižuje sa počet ľudí, ktorí sa týmto systémom dajú rozpoznať.

2.2.2 Odtlačky prsta

Každý človek na planéte má od ostatných ľudí iné odtlačky. Tieto odtlačky sú počas celého života relatívne nemenné, zároveň sú obnovované dorastajúcou kožou. Odtlačky obsahujú biometrický markant, viz obrázok 2.4, ktorý sa využíva pri porovnávaní jednotlivých odtlačkov.



Obr. 2.4: Váľaný odtlačok prsta [8].


Najrozšírenejším typom snímaču odtlačkov prstov je optický skener, založený na jednoduchom princípe snímania. Fotografia je vytvorená pri položení prstu na sklenenú plochu snímača. Snímanie môže byť vykonané napríklad aj ultrazvukovým, či kapacitným snímačom. Odtlačky prstov sú veľmi využívanou technológiou, keďže veľkosť a cena snímačov je pomerne malá [8].

2.2.3 Žily prstov

Pri tejto metóde využitia biometrie sa používajú senzory typu CMOS. Pri vystavení prstu zdroju IR žiarenia dochádza k jeho čiastočnej absorpcii vo vetvách žil. Toto vetvenie je pre každého jedinca unikátne a preto je ťažké oklamať biometrický systém založený na tejto metóde [8]. Metódy umožňujúce túto detekciu vychádzajú z viacerých možností snímania cievneho riečiska prsta:

- **Transmisivná:**


Pri tejto metóde je potrebné snímaný objekt vložiť do poľa IR žiarenia, medzi zdroj a senzor [4]. Obraz prenikne prstom a prostredníctvom tejto metódy je dosiahnutý vysoký kontrast snímku, viz obrázok 2.5. Nevýhodou je, že prístroj je priestorovo rozmernejší.



Obr. 2.5: Snímok žil použitím transmisívnej metódy [8].

- **Reflexívna:**

Prst je umiestnený na strane oproti obrazovému senzoru a IR žiareniu. Žiarenie neprenikne hlbšie do tkaniva, ale je odrazené a kontrast snímku je nízky, čo je nevýhodou tejto metódy, viz obrázok 2.6. Výhodou sú menšie rozmery zariadenia než pri transmisívnej metóde.




Obr. 2.6: Žily pri použití reflexívnej metódy [8].

- **Metóda s bočným svetlom:**

V tejto metóde ide o umiestnenie IR žiarenia z oboch strán prstu, pričom snímač je umiestnený zo spodnej strany prstu. Žiarenie je počas nasvietenia prstu vo vnútri tkaniva rozptýlené a zachytené na snímači. Obraz, ktorý vzniká je kontrastný a kompaktnosť snímača je zachovaná [8].

2.2.4 Rozpoznávanie podľa nechtu

Metóda využíva k rozpoznávaniu človeka akýsi čiarový kód zložený z nerovností povrchovej štruktúry nechtu, ktorá kopíruje štruktúru jeho ložiska, viz obrázok 2.8. Tieto nerovnosti sú unikátne pre každý prst osoby a pri správnom nasvietení polarizovaným svetlom je možné ich osnímať. Prírodný polymér zvaný keratín sa tvorí medzi ložiskom nechtu a samotným nechtom a mení orientáciu lúča dopadajúceho svetla. Nechet je však potrebné týmto svetlom nasvietiť pod určitým uhlom, čím je umožnené analyzovať fázové zmeny lúča po jeho odraze. Týmto spôsobom sa získa unikátna jednorozmerná štruktúra ložiska nechtu [8].



Obr. 2.7: Štruktúra nechtu ako biometrický kód [5].

2.2.5 Dynamika stláčania kláves


Tento spôsob identifikácie sa využíval už v období druhej svetovej vojny. Ide o metódu využívajúcu neurofyziologických faktorov človeka, udávajúcich rytmus písania na klávesnici. Nezabýva sa teda obsahom textu, ale spôsobom písania. Ide o jedinečnú dynamickú vlastnosť každého jedinca. Medzi popisované rysy patrí tlak aplikovaný na klávesu, celková rýchlosť písania, dĺžka trvania každého stisku a časové úseky medzi stlačeniami jednotlivých kláves.

Medzi výhody tejto metódy patrí absencia prídavného hardvéru, akceptovateľnosť užívateľmi a možnosť priebežného monitorovania. Medzi nevýhody patrí vysoká miera pravdepodobnosti chybného odmietnutia, zahrnutie preklepov a iných problémov a úzka oblasť aplikovateľnosti [5].

2.2.6 Dynamika podpisu

Systémy pri podpise človeka zisťujú tvar, tlak, smer písania a rýchlosť napísania častí podpisu. Dvaja ľudia sa nikdy nepodpíšu podpisom toho druhého. Pri takomto rozpoznávaní sa využívajú elektronické podložky, ktoré zaznamenávajú zmenu tlaku, ktorým pero pôsobí na podložku.

Výhodou je komfort pri autentizácii, ktorú je možné vykonávať na diaľku. Nevýhodou môže byť falšovanie podpisu v prípade, ak jedinec používa príliš jednoduchý podpis [5].



Obr. 2.8: Znázornenie statických charakteristík písma: a) Hustota a vektor línie. b) Vertikálna hustota línie. c) Uzavretá oblasť horná. d) Uzavreté oblasti spodná.[20].

2.3 Hodnotenie kvality biometrických systémov

Biometrické systémy pracujú tak, že porovnávajú snímané vlastnosti s vlastnosťami, ktoré boli do systému uložené skôr. Pre systém je určený prah citlivosti. Ak je výsledok porovnávania vyšší ako prah citlivosti, užívateľ je prijatý do systému. V opačnom prípade systém užívateľa zamietne [20].

Pri hodnotení kvality biometrických systémov uplatňujeme nasledujúce vlastnosti:

- **Pravdepodobnosť chybného prijatia** - False Acceptance Rate (FAR)
Označuje sa ako chyba 2. typu. Nastáva v čase, ak užívateľ, ktorý nemá prístup do systému, je systémom prijatý. Vypočítava sa ako podiel nesprávne prijatých vzoriek a sumy všetkých rozdielnych vzoriek.
- **Pravdepodobnosť chybného odmietnutia** - False Rejection Rate (FRR)
Označuje sa ako chyba 1. typu. Nastáva v čase, ak užívateľ, ktorý má prístup do systému, je systémom zamietnutý. Určuje ju podiel nesprávnych odmietnutí k sume všetkých prevedených pokusov tej istej osoby [19].
- **Miera chybných zhody** - False Match Rate (FMR)
Jedná sa o hodnotu podielu, ktorou systém chybné akceptoval užívateľov. Výpočet FMR je podobný ako výpočet FAR, ale celkový počet vzorov nezahrňuje chybné zapísané dáta.
- **Miera chybných nezhody** - False Non Match Rate (FNMR)
Vyjadruje hodnotu podielu, ktorou systém chybné neakceptoval oprávnených užívateľov. Výpočet tejto miery sa od výpočtu FRR líši tak, že celkový počet vzorov nezahrňuje chybné zapísané dáta [8].
- **Krivka vyjadrujúca robustnosť systému** - Receiver Operating Characteristics (ROC)
Krivka, ktorá určuje bezpečnostnú silu systému. Je možné ju vykresliť ako závislosť hodnôt FRR a FAR, prípadne FNMR a FMR. Tieto však naraz protichodne ovplyvňuje hodnota prahu. Kvalitné systémy s vysokou bezpečnosťou majú veľmi nízku hodnotu FAR a zároveň nízke hodnoty FRR [8].

Kapitola 3

Detekcia živosti

V tejto kapitole sú predstavené základné informácie o koži a elektromagnetickom spektre. Predstavené sú jednotlivé časti kože, ich stavba a poškodenia kože. V kapitole sa ďalej pojednáva o elektromagnetickom žiarení, viditeľnom spektre tohto žiarenia, ktorému sa neskôr v dokumente venuje pozornosť a o vplyve tohto žiarenia na kožu. Ako ďalšie sú spomenuté existujúce metódy detekcie živosti zamerané na ruku.

3.1 Koža

Koža je orgán, ktorý pokrýva celé telo a v telesných otvoroch prechádza v sliznicu, pričom od povrchu do hĺbky je rozdelená na tri časti:

- **pokožka** (lat. epidermis),
- **škára/zamša** (lat. dermis),
- **podkožie** (lat. subcutis/hypodermis).

Pokožka

Pokožka (epidermis) je vrstva kože nachádzajúca sa na povrchu, viz obrázok 3.1. Jej hlavnou funkciou je ochrana voči vonkajším fyzikálnym, chemickým a biologickým škodlivinám. Ide o epitelové tkanivo, skladajúce sa z niekoľkých vrstiev buniek. Tieto bunky sa množia v hlbších častiach pokožky, zatiaľ čo na povrchu odumierajú - keratinizujú. Ďalšími bunkami sú melainocyty, ktoré tvoria melanin - pigment. Pokožku môžeme ešte mikroskopicky rozdeliť na päť vrstiev. Ide o vrstvu bazálnu, ostnatú, zrnitú, lesklú a rohovú. Spodná vrstva pokožky je zvlhčená, pričom zabieha do škáry kužeľovitými výbežkami [12].


Škára

Škára (dermis) je stredná časť kože, prevažne obsahujúca väzivo, potné žľazy, mazové žľazy a cievy, viz obrázok 3.1. Obsahuje aj vlasové folikuly. V tejto časti kože sú uložené nervové zakončenia, ktorými vnímame napríklad bolesť, chlad a teplo [9].

Na dlaniach a na bruškách prstov sú najviac viditeľné takzvané kožné lišty, ktoré sú potiahnuté kožnými valmi. Tieto kožné valy sú tvorené výbežkami škáry voči pokožke [21].

Podkožie

Ide o najhlbšie tkanivo pokožky, ktoré tvorí väzivo spolu s kolagénovými a elastickými vláknami, v ktorých sú roztrúsené tukové bunky vytvárajúce podkožný tuk. Toto tkanivo má rôznu hrúbku. Zásobuje tuk, vodu a má významnú tepelnú ochrannú funkciu, pričom zaisťuje pružný pohyb kože [12].



Obr. 3.1: Zloženie kože [23].

Kožná adnexa, sfarbenie a poškodenia kože

Kožnou adnexou sa rozumie prídavné kožné orgány umiestnené v zamši. Ide napríklad o ochlpenie a nechty.

Melanin určuje sfarbenie kože, vlasov, chlпов a jeho množstvo sa zvyšuje vplyvom slnečného žiarenia, ktoré sa skladá z viacerých častí spektra elektromagnetického žiarenia. Podľa melanínu sa určuje fototyp osoby. Fototyp sa prejavuje slabou, až silnou citlivosťou na slnečné žiarenie a možnosťou podráždenia pokožky. Neschopnosť tvoriť pigment sa prejavuje u albínov. Sfarbenie kože udáva aj jej hrúbka a prekrvenie, u ktorého berieme do úvahy aj anémiu, ktorá spôsobuje bledosť u chudokrvnosti [21].

Systémy detekcie živosti môžu byť značne ovplyvnené kožnými poškodeniami a ochoreniami. Ide hlavne o nasledujúce ochorenia: ekzémy, psoriáza, bradavice, systémová sklerodermia, tinea dlane, bakteriálna infekcia Pyodermia, Raynaudov fenomén, multiformný erytém, genetická choroba Epidermolysis bullosa, Dermatitis artefacta prejavujúca sa zmenami kože z dôvodu manipulácie zo strany napríklad drogového závislého pacienta. Zároveň by mali byť brané do úvahy aj nežiadúce kožné reakcie na lieky a aplikácie rôznych krémov, alebo masť [7].

Táto práca sa zaoberá detekciou živosti vnútornej strany ruky od končekov prstov k zápästiu. Do úvahy sú brané zdravé ruky bez dermatologických ochorení a prsteňov.

3.2 Vplyv elektromagnetického žiarenia na kožu


Vplyv elektromagnetického žiarenia na organizmus je závislý na energiách tohto žiarenia. Účinky jednotlivých druhov žiarení sú vzhľadom na rozdielnom energetickom rozsahu rôzne. Na základe týchto poznatkov vznikla vedeckou medicínou uznávaná metóda liečby zvaná fototerapia, ktorá je založená na interakcii optického žiarenia s tkanivom.

Človek môže priamo vnímať iba veľmi malý obor spektra elektromagnetického žiarenia. Ide o viditeľné, infračervené a ultrafialové spektrum žiarenia [3].

Elektromagnetické spektrum sa na základe vlnových dĺžok delí do niekoľkých kategórií:

- Kozmické gama žiarenie
- RTG žiarenie
- UV žiarenie: 10 nm - 390 nm
- Viditeľné spektrum farieb: 390 nm - 790 nm
- Infračervené žiarenie: 790 nm - 0.1 mm
- Mikrovlny
- Rádiové vlny [2]

Rozsahy vlnových dĺžok sú približné a v mnohých publikáciách sa môžu líšiť.



Obr. Elektromagnetické spektrum

Obr. 3.2: Elektromagnetické spektrum [16].

3.2.1 Infračervené žiarenie (IR)

Vlnová dĺžka elektromagnetického žiarenia (energia) udáva účinky tohto žiarenia a jeho priechodnosť látkami. Je dôsledkom vibračných a rotačných pohybov atómov a molekúl. Prirodzeným zdrojom IR žiarenia je Slnko.

Aj napriek tomu, že sa infračervené žiarenie využíva v liečbe a za určitých okolností je zdraviu prospešné, môže zdraviu aj ublížiť. Infračervené svetlo môžeme vnímať v podobe tepla, ktoré vyžaruje zo zdroja žiarenia. Je prevažne absorbované pokožkou a do podkožia preniká iba jeho blízke pásmo. V prípade, ak je tkanivo vystavené zdroju žiarenia, dochádza k rozšíreniu ciev, začervneniu kože a pri intenzívnejšom vystavení zdroju IR žiarenia väčšiemu než 3 μm môže dôjsť aj k popáleniu. Toto žiarenie môže poškodiť aj zrak, pretože časť žiarenia je v oku absorbovaná.

IR žiarenie rozdeľujeme podľa vlnových dĺžok do troch pásiem: blízke pásmo (IR-A), stredné pásmo (IR-B) a vzdialené pásmo (IR-C).

Blízke pásmo

Blízke pásmo s vlnovou dĺžkou 0,76 μm - 1,4 μm preniká najhlbšie do tkaniva a to z dôvodu najväčšej energie z pásiem IR žiarenia. Toto pásmo je absorbované vodou pomerne slabo.

Stredné pásmo


Žiarenie stredného pásma o vlnových dĺžkach 1,4 μm - 3,0 μm je oproti pásmu blízkeho silno pohlcované vodou, to však neplatí o skle. Zatiaľčo zdrojom blízkeho pásma je slnečné žiarenie, zdrojom pásma stredného sú rôzne typy žiaroviek.

Vzdialené pásmo

Vzhľadom k vlnovému rozsahu vzdialeného pásma, ktoré je väčšie než 3 μm , je toto žiarenie intenzívne pohlcované vodou aj sklom [3].

3.2.2 Viditeľné svetlo

Viditeľné spektrum reprezentuje spektrum farieb, ktoré môžeme vnímať zrakom. Približne na vlnových dĺžkach 390 nm hraničí fialová farba s UV žiarením. Tieto vlny spadajú do kategórie krátkej vlnovej dĺžky. Na druhej strane intervalu hraničí viditeľné spektrum v podobe červenej farby s IR žiarením na vlnových dĺžkach približne 790 nm, viz obrázok 3.2. Viditeľné spektrum preniká celou pokožkou a škárou až k podkožiu, viz obrázok 3.3.



Obr. 3.3: Prenikanie vlnových dĺžok elektromagnetického spektra do kože [1].

Jeho energia je približne 3 eV, pričom vyvoláva fotochemické účinky na koži. Množstvo svetla, ktoré prejde kožou a následne bude rozptýlené v súbore buniek závisí, na vlnovej dĺžke svetla a jeho intenzite [3].

3.2.3 Ultrafialové žiarenie

Ultrafialové žiarenie rozdeľujeme rovnako ako infračervené do troch pásiem: blízke pásmo (UV-A), stredné pásmo (UV-B) a vzdialené pásmo (UV-C). Jeho prirodzeným zdrojom je Slnko a medzi umelé zdroje sa radia oblúčkové lampy a výbojky. Na koži pôsobí pigmentáciou

a tvorbou melanínu, čo následne bráni preniknutiu blízkeho UV-A do hlbších vrstiev kože. Pri použití ochranných krémov dochádza k absorpcii UV-B žiarenia účinnou látkou, čím nedochádza k ovplyvneniu kože žiarením. UV žiarenie môže mať na kožu negatívne účinky ako zápal pokožky, prípadne jej popáleniny pri vysokých dávkach žiarenia. UV žiarenie môže poškodiť aj spojovky a rohovky očí. Medzi neskoršie následky vystavenia nadmernému UV žiareniu patria degeneratívne zmeny na koži, ktoré môžu vyústiť až v karcinom [3].

3.3 Metódy detekcie živosti

Biometrický systém sám o sebe nie je zárukou bezpečnosti. Mnoho biometrických systémov sníma iba jeden biometrický rys. Za takýto rys môžeme považovať špecifické usporiadanie papilárných línií v podobe odtlačkov dlane, či prsta. U týchto systémov chýba detekcia živosti a preto môžu byť jednoducho oklamané falzifikátom biometrického rysu. Pokusy o oklamanie biometrického systému sú najčastejším a v prípade zlého zabezpečenia aj najlahším spôsobom útoku na systém. Z toho dôvodu je potreba biometrické systémy rozšíriť o systém detekcie živosti, ktorý odlíši živé tkanivo od iného materiálu, či dokonca od odumretého tkaniva [6][8].

Dôležitým faktorom tohto systému je v prvom prípade rýchle, efektívne a bezbolestné použitie adspekciou bez invazívnych lekárskeho metód. Medzi ďalšie parametre patrí aj cena a veľkosť systému [20].

Detekcia živosti môže byť v reálnych systémoch tvorená rôznymi metódami. Môžeme ich rozdeliť na metódy zamerané na hardvér a softvér. Metódy, pri ktorých sú použité aditívne hardvérové jednotky kontrolujú vlastnosti samotného vzorku, pričom sú tieto jednotky pripojené k senzoru. Tieto metódy sa vyznačujú vysokou presnosťou a od toho sa odvíja aj ich vysoká cena [10]. Oproti tomu sú softvérové metódy založené na spracovaní obrazu vzorku cenovo prívetivejšie. Tieto metódy využívajú k rozhodovaniu špecifické charakteristiky ľudskej kože a tkaniva. Detekciu živosti môžeme ďalej rozdeliť na kontaktnú a bezkontaktnú. Pri kontaktnej dôjde k dotyku ruky s povrchom, ktorý je súčasťou snímanej plochy. Pri bezkontaktnej detekcii živosti môže byť objekt analyzovaný napríklad zo snímku určitej oblasti v priestore. Takáto forma bezkontaktnej detekcie môže využívať klasifikátor natrénovaný na dataseť pravých vzoriek a falzifikátov.

3.3.1 Teplota

K detekcii živosti je možné použiť aj meranie teploty. Táto metóda však nie je úplne vhodná, pretože teplota ľudského prstu kolísava v závislosti na okolitých podmienkach, ročnom období a zároveň aj na základe fyzického stavu snímanej osoby. Teplota kolísava medzi 25 °C až 37 °C a to aj behom samotného snímania, preto v dôsledku tejto vnútrotriednej variability nie je vhodné k detekcii živosti túto metódu použiť [8].

3.3.2 Teplý a studený podnet

Metóda založená na schopnosti jedinca rozpoznať tepelné zmeny. Senzor má na úrovni spodného článku prstu umiestnenú plôšku s rozdielnou teplotou než má okolitý materiál. Užívateľ musí stlačiť určité tlačidlo na základe tepelného podnetu vyvolaného teplotou tejto plôšky, či zacítiť pocit chladu, alebo tepla. Nevýhodou je 50 % šanca uhádnutia tepelného stavu plôšky útočníkom. Nevýhodou je aj doba zahrievania plôšky, ktorá môže mať vplyv na

rozhodovanie užívateľa pri voľbe tlačidla. Nejedná sa teda o najvhodnejšiu metódu detekcie živosti [8].


3.3.3 Oxidácia krvi

Červené a infračervené svetlo o vlnových dĺžkach 660 nm a 940 nm umožňuje detekciu živosti na základe merania oxidácie krvi. Ide o schopnosť krvi absorbovať tieto vlnové dĺžky svetla. V prípade živého prstu, v ktorom koluje krv, je možné detegovať zmenu absorpcie svetla v prúdiacej krvi.

U neživého prstu nenastáva zmena prietoku okysličenej a neokysličenej krvi, z toho dôvodu nie je možné detegovať zmenu absorpcie konkrétnych vlnových dĺžok svetla. U falzifikátu nie je možné simulovať prietok okysličenej krvi [6]. Z toho dôvodu je metóda veľmi presná a úspešná.

3.3.4 Pulz

Ďalšou metódou je meranie pulzu, viz obrázok 3.4. Táto kontaktná metóda vychádza zo znalostí, že srdcom pumpovaná krv má za následok opakované objemové zmeny v cievach - pulzovanie. Drobné pohyby pulzovania sú okom nepozorovateľné, avšak prístrojom merateľné. Metóda sa využíva hlavne pri detekcii zameranej na prst. Laserový senzor v tomto prípade meria vzdialenosť pulzujúceho prstu. Ide o veľmi presnú metódu merania, až v radoch mikrometrov, avšak vzhľadom na spôsob merania je potreba na detekciu väčší časový úsek [20].




Obr. 3.4: Princíp merania pulzovania prstu [8].

3.3.5 Prítlak

Pôsobením tlaku na prst pozorujeme využitím snímačej kamery zmeny na koži, viz obrázok 3.5. Ide o zmeny vlastností kože a papilárnych línií. Tieto zmeny sú odlišné v prípade, kedy snímame živé, umelé, alebo mrtvé prsty. Metódu je možné implementovať jak hardvérovo, tak softvérovo.

Hardvérová metóda vyhodnocuje snímok prsta osvieteného špecifickými vlnovými dĺžkami svetla po vyvinutí tlaku prsta na snímanú plochu.


Softvérová metóda spracováva rozloženie papilárnych línií pred a po vyvinutí tlaku prstom na snímanú plochu. Následne sa vyhodnocuje rozdiel vzdialenosti papilárnych línií pred a po vyvinutí tlaku [6].



Obr. 3.5: Rozdiel v prítlaču prsta na senzor [6].

3.3.6 Multi-spektrálna analýza

Táto metóda vychádza zo spektrálnych vlastností kože, ktoré udáva jej chemické zloženie. K detekcii živosti sa tu využíva vystavenie ruky rôznym vlnovým dĺžkam elektromagnetického spektra. Chemické zloženie kože totiž ovplyvňuje svetelnú absorpciu a rozptyl svetla. Rôzne vlnové dĺžky svetla tak prenikajú a odraňajú sa vo vzorku v rôznej hĺbke materiálu. Využívajú sa napríklad LED diódy s vlnovými dĺžkami viditeľného spektra a spektra infračerveného žiarenia. Odrazené svetlo je snímané pomocou CCD/CMOS kamery. Na základe spektrálnej analýzy je tak možné vyhodnotiť rozdielne výsledky falzifikátu a skutočnej ruky, viz obrázok 3.6. Táto metóda môže byť využitá pri bezkontaktnéj aj kontaktnéj detekcii živosti [6].



Obr. 3.6: Spektrálne rozdiely živého prsta a falzifikátu [6].

3.3.7 Detekcia potu

Využitím potných pórov, ktoré pokrývajú celé telo vrátane prstov, je možné detegovať živosť predloženého vzorku. Pri detekcii živosti sa postupuje vyvinutím tlaku prsta na senzor a to približne po časovú dobu piatich sekúnd. Z potných pórov papilárnych línií sú vytláčané kvapky potu, ktoré spôsobia ich následné stmavnutie [8].


3.3.8 Elektrické vlastnosti kože

Princíp metódy je založený na vodivosti kože. Možnosťou je merať jej odpor, či vodivosť. Elektrická vodivosť kože je variabilná, v rozmedzí $20\text{ k}\Omega$ až $3\text{ M}\Omega$. Je závislá na teplote okolia, ročnom období a fyzickom stave snímanej osoby. Platia teda rovnaké podmienky ako pri meraní teploty, v dôsledku čoho táto metóda nie je vhodná k detekcii živosti [8].

Kapitola 4

Návrh

Po získaní teoretických znalostí z oblastí, ktoré sa viažu na problém detekcie živosti je patričné preskúmať existujúce metódy a postupy, ktoré sa ponúkajú ako vhodné na použitie. K riešeniu problému detekcie živosti pomocou viditeľného spektra elektromagnetického žiarenia je možné využiť umelú inteligenciu zameranú na klasifikáciu obrazových dát. Ponúka sa napríklad konvolučná neurónová sieť. Tú je nutné natrénovať na rozsiahlom datasete rúk a falzifikátov, ktoré je ešte pred trénovaním potrebné segmentovať zo snímkov. Tie by mali obsahovať iba relevantné vlastnosti. Stojí za zmienku spomenúť, že dataset dodaný k práci nebol dostatočne kvalitný. Tento dataset obsahoval množstvo snímkov nedostatočnej kvality, na ktorých neboli nasnímané detaily dlane, či už kvôli zlej polohe ruky v zornom poli kamery, alebo nevhodným umiestnením zdroja osvetlenia, viz obrázok 4.1. Tvorba nového datasetu môže byť nepríjemnosťou z časového hľadiska, avšak zároveň značne rozširuje možnosti návrhu systému detekcie živosti.



Obr. 4.1: Nevhodné umiestnenie zdroja osvetlenia dodaného datasetu.

4.1 Voľba vlnových dĺžok

Jedným z dôležitých bodov systému detekcie živosti je napríklad použitie vhodných vlnových dĺžok. Tvorba nového datasetu teda ponúka možnosť analýzy chovania rôznych úsekov

viditeľného svetla na kožu a následnú voľbu vlnových dĺžok na základe vykonanej analýzy.

LED dióda	Farba	Vlnová dĺžka[nm]	U[V]	I[mA]	P[mW]
OSV3XME3E1E	UV	380 - 390	3.4 - 4.5	700	600
OSB4XDE5E1E	Modrá	455 - 465	3.3 - 4.5	1400	5000
OSG5XME3E1E	Zelená	525	3.5 - 4.5	700	3000
OSY5XAE3E1E	Žltá	590	2.5 - 3.5	700	3000
OSR5XAE3E1E	Červená	625	2.5 - 3.5	700	3000
PM2B-3LEE-SD	Cherry red	730 - 740	2.3 - 3.0	700	520

Tabuľka 4.1: Zoznam testovaných LED diód, ich vlnové dĺžky a ďalšie parametre.

Na základe informácií popísaných v kapitole 3.2 je vhodné použiť z tabuľky 4.1 vlnové dĺžky LED diód také, aby bolo možné analyzovať snímky, na ktorých preniká svetlo do kože rôzne hlboko. Teda cieľom je analyzovať snímky, v ktorých svetlo zasahuje jednotlivo epidermis, dermis a hypodermis. Podľa obrázka 3.3 z kapitoly 3.2.2 je účelné použitie vlnovej dĺžky 380 - 390 nm prenikajúcej do vrstvy epidermis a 730 - 740 nm, ktorá preniká najhlbšie do vrstvy hypodermis. Voľba ďalších vlnových dĺžok prenikajúcich do vrstvy dermis závisela na experimentoch, v ktorých sa ukázalo, že na snímkoch rúk, ktoré boli osvietené ďalšími vlnovými dĺžkami zo zoznamu, boli pri použití LED diód vyžarujúcich svetlo o vlnových dĺžkach 525 nm a 590 nm zachytené najlepšie detaily ruky. Použitie ďalších vlnových dĺžok bolo vylúčené.

Výsledný zoznam zvolených LED diód obsahuje vlnové dĺžky:

- UV: 380 - 390 nm
- Zelená: 525 nm
- Žltá: 590 nm
- Cherry red¹: 730 - 740 nm

4.2 Segmentácia ruky

Predtým, než sa predloží klasifikátoru, ktorý bude v tejto práci predstavovať základ systému detekcie živosti dataset snímok, alebo snímok, ktorý má byť klasifikovaný, je potrebné odstrániť z neho všetky prebytočné vlastnosti, ktoré by mohli negatívne ovplyvniť tréning a klasifikáciu. Tým by sa mohla znížiť kvalita systému detekcie živosti. Vlastnosťami sa rozumie všetky objekty a povrchy, ktoré nie sú určené ku klasifikácii. Cieľom je teda zanechať na snímku iba ruku. Snímky, ktoré budú algoritmu predkladané sú v základnom farebnom modeli RGB, ktorý odpovedá aditívnemu skladaniu farieb. Tento spôsob skladania farieb je charakteristický práve pre prácu so svetlom [15].

Potreba tvorby nového datasetu ponúka nové možnosti, nie len v podobe voľby vlnových dĺžok na základe ktorých bude detekovaná živosť. V prípade skúmania metód segmentácie obrazu sa napríklad naskytá možnosť úpravy parametrov snímacej kamery.

¹Farba Cherry red je ďalej v práci pomenovaná ako červená.

4.2.1 Úprava parametrov kamery

Správnym nastavením niektorých parametrov kamery v spojení s dobrým osvetlením je možné značne potlačiť výskyt pozadia na výslednom snímku. Medzi hlavné parametre patri veľkosť clony a rýchlosť uzávierky.

Zúženie clony


Clona určuje koľko svetla prejde objektívom pri danej rýchlosti uzávierky fotoaparátu. Zúženie, či rozšírenie clony sa pri fotografovaní používa hlavne pri nepriaznivých svetelných podmienkach. Modifikácia clony a rýchlosti uzávierky spolu priamo súvisia. V prípade zúženia clony by bolo potrebné nechať uzávierku fotoaparátu otvorenú dlhšie pre zachovanie pomeru svetla, ktoré sa má dostať na senzor. Tu však nie je cieľom tento pomer úplne zachovať. Zúžením clony kamery pri zachovaní rýchlosti uzávierky je možné získať tmavší snímok. V spojení s nastavením ďalších parametrov je týmto spôsobom možné úspešne potlačiť pozadie snímaného objektu [11].

Zmena rýchlosti uzávierky

Modifikácia osvetlenia je možná taktiež samostatnou zmenou rýchlosti uzávierky. Avšak v tomto prípade dochádza aj k rozmazaniu akéhokoľvek pohybu. Miera takého rozmazania však závisí na dĺžke trvania otvorenej uzávierky. Kamera z tabuľky 5.1, ktorá je k dispozícii pre túto prácu, neponúka možnosť modifikácie rýchlosti uzávierky, preto bude potrebné modifikáciu osvetlenia simulovať algoritmom vytvárajúcim sériu snímok, avšak zachycujúc iba poslednú z nich. Tým sa zároveň aj čiastočne docieli lepšia kvalita detailu snímku, než by tomu bolo pri klasickej úprave rýchlosti uzávierky. Krátkym osvetlením snímaného objektu pri zúženej clone a simulovanej zmene rýchlosti uzávierky je možné doceliť snímku, na ktorom je osvetlený objekt v popredí, zatiaľ čo jas pozadia je značne potlačený. To však nezaručuje úplne tmavé pozadie a výsledný efekt sa zároveň líši pri práci s diódami rôznych vlnových dĺžok viditeľného spektra, ako je možné vidieť na obrázkoch 4.2 a 4.3.



Obr. 4.2: Viditeľné pozadie pri ≈ 735 nm




Obr. 4.3: Tmavé pozadie pri 590 nm

Výsledkom tohto jednoduchého postupu síce nie je segmentácia ruky z pozadia, je však možné použiť ho v spojení s niektorou z ďalších metód pre docielenie požadovaného výsledku.

4.2.2 Semienkové vyplňovanie s využitím Haarovho klasifikátora

Jednou z možností eliminácie pozadia je použitie metódy semienkového vyplňovania. K tomu je potrebné stanoviť súradnice, na ktorých algoritmus začne. Súradnice však nesmú ležať

mimo ruky, pretože prípadné objekty v pozadí by mohli v prípade niektorých vlnových dĺžok, viz obrázok 4.2, vykonať chybnú segmentáciu. Nutnosťou je teda detegovať ruku. Ponúka sa použitie Haarovho kaskádového klasifikátora, ktorý využíva ku klasifikácii takzvané Haarove príznaky. Tie sú založené na rozdieli jasnosti medzi obdĺžnikovými oblasťami. Medzi základné príznaky patria príznaky hrany, čiary a štvorhranné príznaky. Haarov klasifikátor sa využíva napríklad pri detekcii tváre, alebo rúk [14][18]. V tomto prípade je cieľom využiť dostupných online XML súborov Haarovho klasifikátora z dôvodu eliminácie nutnosti tréningovania, ktoré by vyžadovalo vytvorenie tisícov pozitívnych a negatívnych vzoriek. Úlohou detekcie je vytvoriť ohraničujúci rámec okolo ruky, následne získať súradnice jeho stredu a spustiť algoritmus semienkového vyplňovania. Implementáciou tohto postupu sa výsledky detekcie ukázali ako nevyhovujúce. Algoritmus vytváral niekoľko rôznych ohraničujúcich rámcov na rôznych súradniciach fotografie, viz obrázok 4.4, alebo vytvoril ohraničujúci rámec rovný veľkosti celej snímky.



Obr. 4.4: Príklad neúspešnej detekcie ruky Haarovým klasifikátorom.

Takýto výsledok však neplatil pre snímky, na ktorých sa vyskytovalo iba prirodzené pasívne osvetlenie. Klasifikátor vykazoval tieto výsledky pri použití viacerých dostupných XML súborov². Spomenuté výsledky sú následkom použitia špecifických farieb spektra. V prípade tejto práce sú snímky zamerané na konkrétne vlnové dĺžky, zatiaľčo v prípade tvorby klasifikátora sa pravdepodobne pracovalo klasicky s celým viditeľným spektrom.

Existujú ďalšie možnosti, ako detegovať ruku a získať tak počiatkové súradnice pre použitie metódy semienkového vyplňovania. Táto metóda je však neefektívna a v prípade niektorých snímok datasetu, by ju nebolo možné použiť. Príkladom môže byť obrázok 4.2.

4.2.3 Segmentácia maskou ruky a kontúrami

Skúmaná bola takisto možnosť eliminácie pozadia na základe masky ruky a kontúr. Maska však bola v mnohých prípadoch neúplná. V prípade kontúr zas body reprezentujúce hrany nebolo možné spojiť do výslednej kontúry a to ani po použití rôznych metód, prípadne bolo vytvorených viacero menších kontúr jednotlivých častí ruky. Ak bolo získanie celej kontúry úspešné, algoritmus detegoval v pozadí aj ďalšie kontúry, ktorými sa znehodnotil výsledok. Keďže sa vytvárajú štyri snímky ruky pre viaceré vlnové dĺžky, uvažovalo sa nad použitím masky, alebo kontúry jednej ruky pre zadanú štvoricu. Ruka, alebo jej falzifikát však môže byť na niektorých snímkoch mierne posunutý z toho dôvodu sa od tejto možnosti upustilo.

²<https://github.com/Aravindlivewire/Opencv/tree/master/haarcascade>

4.2.4 Segmentácia ruky maskou predtrénovanej neurónovej siete

Ďalšou z možností je použitie predtrénovanej neurónovej siete k vytvoreniu masky objektu, ktorou by bolo následne možné extrahovať ruku z pozadia. S touto metódou sa taktiež experimentovalo použitím modelu DeepLabV3-RESNET101³, avšak aj v prípade lepších snímok nemala výsledná maska žiadúci tvar ako je možné vidieť na obrázkoch 4.5 a 4.6.



Obr. 4.5: Snímok ruky predložený neurónovej sieti.



Obr. 4.6: Maska ruky vytvorená neurónovou sieťou.

4.2.5 Segmentácia rozdielom dvoch snímok

Postupným skúmaním problematiky a elimináciou nevyhovujúcich metód sa ako najvhodnejšia na extrakciu objektu ukázala byť metóda prakticky primitívna. Jedná sa o vykonanie rozdielu dvoch snímok, teda snímku pozadia a ruky. Túto možnosť by nebolo možné použiť, ak by mal byť k detekcií použitý dodaný dataset. Nutnosť tvorby nového datasetu tak znova rozšírila možnosti práce. Táto inak jednoduchá a časovo nenáročná metóda má však aj svoje nevýhody. Pri snímaní ruky a pozadia je potrebné zachovať rovnaké parametre kamery pre obe snímky, nijak nemeniť okolité osvetlenie, ani nemanipulovať so snímacím zariadením. Akákoľvek malá zmena môže znehodnotiť výsledok. Ďalšou nevýhodou, s ktorou bude potrebné počítať je fakt, že dataset určený k trénovaniu klasifikátora bude mať kvôli nutnosti tvorby snímok pozadia pred použitím algoritmu eliminácie pozadia dvojnásobnú veľkosť.

4.3 Detekcia živosti

Detekciu živosti si je možné predstaviť ako binárnu klasifikáciu. Ide o rozhodnutie, či patri skúmaný objekt do jednej, alebo druhej triedy - ruka, alebo falzifikát. Správne nastavenie parametrov kamery môže značne uľahčiť prácu nie len v prípade segmentácie obrazu, ale aj pri algoritme detekcie živosti. Objekty na snímku, v tomto prípade ruka, alebo jej falzifikát, by totiž nemali byť príliš tmavé, avšak ani prepálené nadmerným osvetlením. Parametre je preto vhodné upraviť manuálne opakovaným testovaním do doby, než sa dosiahne požadovaného efektu na ktorom je zachytený detail ruky. Ďalšie informácie k nastaveniu parametrov sú poskytnuté pri popise implementácie v kapitole 5.2.


³https://pytorch.org/hub/pytorch_vision_deeplabv3_resnet101/

4.3.1 Klasifikácia konvolučnou neurónovou sieťou

Klasifikácia neurónovou sieťou je jednou z najpoužívanejších metód. V prípade tejto možnosti bolo úmyslom použiť API Keras⁴, ktorá využíva open source platformu TensorFlow⁵. Tvorba modelu je pomerne jednoduchá, avšak tréning je náročnejšie. Natréning modelu by mohlo vyžadovať vytvorenie datasetu väčšieho než je počet pixelov jedného snímku datasetu. V tejto práci obsahuje nespracovaný dataset jednotné rozlíšenie snímok 720×1280 , čo je viac než 900-tisíc pixelov. Tento problém sa typicky rieši využitím takzvaných pravidiel palca (Rules of thumb), ktoré určujú napríklad vhodný počet vrstiev siete, predspracovanie dát, či aktivačnú funkciu. Spojenie viacerých takýchto pravidiel má za následok zníženie požiadavkov na veľkosť datasetu. Pri tvorbe tejto práce sa bohužiaľ vyskytlo obmedzenie v podobe karanténnych opatrení, obmedzení pohybu a združovania osôb z dôvodu vyhlásenia svetovej pandémie vírusu SARS-CoV-2, čím sa značne obmedzili možnosti vytvárania datasetu. Avšak aj napriek množstvu prekážok sa podarilo rozšíriť dataset na výslednú veľkosť 500 snímok. Tento počet snímok nemusí dostačovať na natréning konvolučnej neurónovej siete bez rizika pretrénovania. Od použitia konvolučnej neurónovej siete sa upustilo s cieľom zamerania sa na Support Vector Machines. Možnosť rizika pretrénovania sa ani v tomto prípade nevyklučuje, môže byť však nižšia.

4.3.2 Klasifikácia použitím Support Vector Machine (SVM)

SVM je algoritmus, ktorý sa používa ku klasifikačným a regresným úlohám. Jeho výhodou je, že dokáže transformovať nelineárnu klasifikačnú úlohu, ktorú nie je možné realizovať v zadanom priestore, do iného priestoru vyššej dimenzie. Myšlienkou je nájdenie optimálnej deliace roviny medzi dvoma triedami, pričom sa snaží maximalizovať vzdialenosť tejto roviny a najbližších vzoriek. To má za následok zlepšenie výslednej klasifikácie, viz obrázok 4.7.



Obr. 4.7: Reprezentácia modelu SVM. Rozdelenie dvoch tried deliacou rovinou [22].

V tomto prípade bolo zvažované použitie nástrojov strojového učenia scikit-learn⁶, ktoré pomerne uľahčujú tvorbu modelu množstvom vstavaných funkcií. Obtiažnejším krokom bolo zistiť, v akom tvare predložiť dataset tréningovému modelu, viz implementácia v kapitole 5.5.

⁴<https://keras.io>

⁵<https://www.tensorflow.org>

⁶<https://scikit-learn.org/>

Klasifikácia zastúpením farieb v histograme

Pri analýze problému detekcie živosti sa uvažovalo, aký spôsob detekcie živosti použiť pri tak malom množstve dát. Medzi variantami bola možnosť analýzy zastúpenia farieb v histograme, čo však nie je najlepšou možnosťou. Pri rôznych vlnových dĺžkach sa totiž niektoré materiály falzifikátu správajú veľmi podobne ako živá ruka. Príkladom môže byť vlnová dĺžka 730 - 740 nm, pre červenú farbu.

Klasifikácia snímku a histogramu orientovaných gradientov

Skúmaním existujúcich metód sa dospelo k postupu analýzy RGB snímku a jeho histogramu orientovaných gradientov, ktorý je zjednodušenou reprezentáciou obrázka. Využíva sa práve ku extrakcii určitých vlastností z obrázka, pričom sa zameriava na smerové vektory obrázka. K získaniu lepších výsledkov tréningu sa využije metóda analýzy hlavných komponentov (PCA), ktorá ma za úlohu znížiť dimenzionalitu ortogonálnych transformácií pôvodných n -dimenzionálnych dátových objektov do menšieho k -dimenzionálneho priestoru, ktorý je definovaný hlavnými lineárne nezávislými komponentami [24].

Kapitola 5


Implementácia

Táto kapitola pojednáva o zvolených metódach implementácie skúmaných v kapitole 4. Pojednáva o zariadení určeného k tvorbe datasetu snímok, o jeho komponentoch, algoritme a parametroch snímania. Ďalej pojednáva o samotnom datasete, algoritme predspracovania snímok datasetu, o algoritme predspracovania samotných snímok a o klasifikátore slúžiacom k detekcii živosti samotnej ruky. Všetky spomenuté skripty sú implementované pre prácu s príkazovým riadkom - neobsahujú grafické užívateľské rozhranie.

5.1 Zariadenie na tvorbu datasetu

Snímacie zariadenie je navrhnuté s dôrazom na vhodné umiestnenie kamery a LED diód. K snímaniu sú použité dodané výkonové SMD LED diódy umiestnené na dvoch doskách plošných spojov. Pretože tieto výkonové diódy oproti klasickým LED diódam odoberajú veľký prúd a pri dlhšom zapnutí sa rýchlo zahrievajú, je medzi dosku a každú z diód umiestnená teplovodivá pasta odvádzajúca teplo. Na každej z dosiek plošných spojov je striedavo umiestnených šesť výkonových LED diód, pričom sa jedná o dva oddelené obvody troch diód zapojených v sérii. Tri diódy jednej farby a tri diódy ďalšej farby. Na oboch použitých doskách plošných spojov je dokopy umiestnených dvanásť LED diód štyroch vlnových dĺžok. Medzi doskami je umiestnená kamera. Svetlo vyžarujúce z diód teda nebude priamo zasahovať do zorného poľa kamery. Snímaný objekt však bude priamo osvetlený a nebude sa tak jednať o bočné osvetlenie, ako tomu bolo v prípade dodaného datasetu na obrázku 4.1. Komponenty sú osadené na konštrukcii zostrojenej z častí stavebnice MERKUR¹, viz obrázok 5.1.

¹<http://www.merkurtoys.cz>

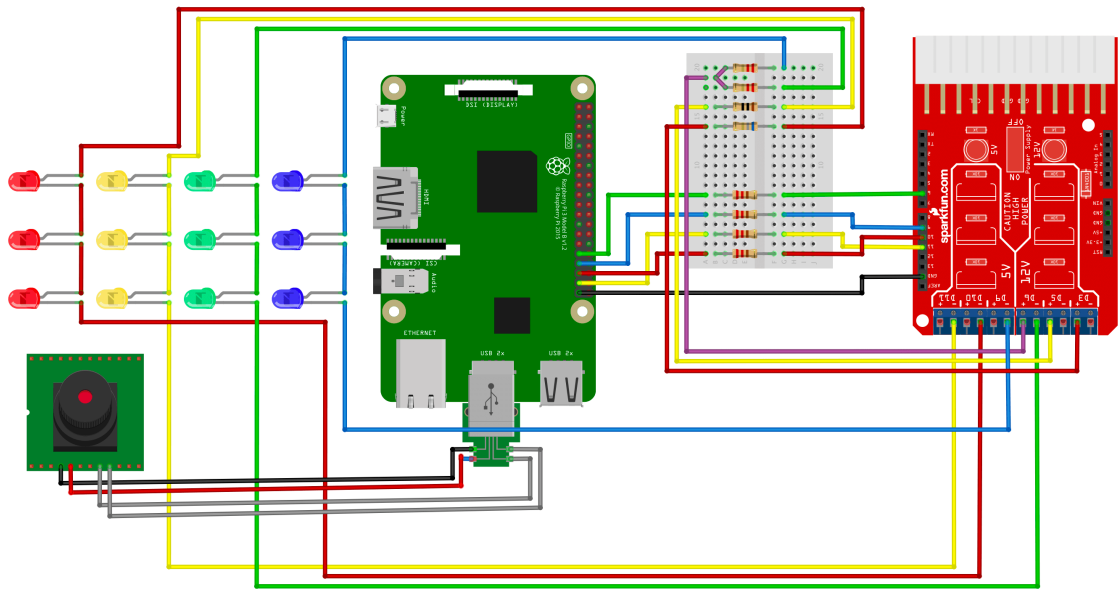


Obr. 5.1: Osadenie kamery a LED diód na konštrukcii snímacieho zariadenia.

Pretože účelom zariadenia je tvorba datasetu, bol kladený dôraz na jeho funkčnosť oproti užívateľskej prívetivosti. LED diódy sú ovládané pomocou mikropočítača Raspberry Pi, ktoré je napájané napätím 5 V. K napájaniu diód je použitý externý zdroj s výstupným napätím 12 V a prúdom 6 A. LED diódy majú rôzne pracovné napätie avšak rovnaký prúd, pričom sú citlivé na prepätie. Kvôli citlivosti je pred každú zo sérií predradený odpor. Pri pracovnom prúde $I = 700 \text{ mA}$ je pri každej zo série LED diód rôzny úbytok napätia, na základe ktorého je vypočítaný požadovaný predradený odpor. Hodnota predradeného odporu je vypočítaná vzorcom $R = (U - U_{LED})/I_{LED}$. Pre sériu LED diód OSG5XME3E1E z tabuľky 5.1 je takto vypočítaný odpor $R = 1.7 \Omega$, pričom najbližšia dostupná hodnota odporu je 2.2Ω . Ako výkonový člen obvodu, k riadeniu výkonových LED diód je použitá výkonová doska od spoločnosti Sparkfun². Doska je osadená šiestimi mosfetami. Tri sú použité na 5 V logiku a ďalšie tri na 12 V logiku. Jedná sa o N-kanálové mosfety RFP30N06LE s prechodovým odporom 0.047Ω , ktoré spínajú na mínuse. Sú výhodné pre výkonové spínanie oproti klasickým bipolárnym tranzistorom. Diódy sú pripojené anodou cez predradený odpor na plusový port 12 V logiky. Katódy sú pripojené separátne na porty jak 5 V logiky tak 12 V logiky. Pri riadení LED diód sa nevyužíva pulzne šírková modulácia. Zmyslom algoritmu bude rýchle rozsvietenie a zhasnutie diód, na ktoré postačuje použitie spínacej logiky 0/1. Riadenie LED diód prebieha použitím univerzálnych vstupno - výstupných portov 6, 13, 19 a 26 na Raspberry Pi a portov 6, 9, 10 a 11 na vysokonapäťovom spínači.

Navrhnuté schéma zapojenia je priložené v prílohe A. Schéma zariadenia neobsahuje kameru propojenú k USB portu zariadenia. Na základe vytvorenej schémy zariadenia bolo zostrojené zapojenie, viz obrázok 5.2.

²<https://www.sparkfun.com>



Obr. 5.2: Znáznornenie zapojenia.

Typ komponentu	Názov	Množstvo
Mini počítač	Raspberry Pi model 3B+	1
Vysokonapäťový spínač	SparkFun Power Driver Shield Kit	1
Kamera	Logitech C920 HD PRO WEBCAM	1
Zdroj napájania LED	Napájací zdroj s výstupom 200 W, 12 V, 6 A	1
Zdroj napájania Raspberry Pi	5 W USB power adapter	1
Výkonová LED dióda	OSV3XME3E1E	3
Výkonová LED dióda	OSG5XME3E1E	3
Výkonová LED dióda	OSY5XAE3E1E	3
Výkonová LED dióda	PM2B-3LEE-SD	3
Odpor	2.2 Ω	2
Odpor	6.8 Ω	1
Odpor	10 Ω	1
Odpor	220 Ω	4


Tabuľka 5.1: Zoznam komponentov snímacieho zariadenia.

5.2 Algoritmus a parametre snímania

Účelom skriptu s názvom `paparazzi.py` je tvorba datasetu. Tento skript bude zároveň použitý k vytvoreniu množiny snímok určenej k demonštrácii samotnej klasifikácie - detekcie živosti. Implementácia a testovanie prebiehalo na minipočítači Raspberry Pi s operačným systémom Raspbian GNU/Linux 10 (buster)³. Algoritmus pracuje s priechomom database

³<https://www.raspberrypi.org/downloads/raspbian/>

v koreňovom adresári skriptu. Očakáva sa existencia tohto priečinka a jeho podpriečinkov `hands` a `fakes`. Zároveň sa očakávajú plné povolenia na prácu so súbormi (čítanie a zápis) v tejto ceste. Skript obsahuje jak globálne, tak samostatné nastavenie parametrov kamery pre použité vlnové dĺžky. Tieto parametre boli opakovane nastavované na základe manuálnych testovaní, než bolo dosiahnuté použitie aktuálnych hodnôt. Kalibrácia parametrov bola vykonávaná za stálych svetelných podmienok izbového osvetlenia bez priameho slnečného svetla. Výsledné nastavenie parametrov záležalo na požiadavku na snímajú detail ruky pri danej vlnovej dĺžke spolu s elimináciou osvetlenia pozadia. V prípade požiadavky na snímajú detail je v tejto práci cieľom zamerať sa na odrazové vlastnosti materiálu v rôznych hĺbkach prenikajúceho osvetlenia, viz obrázok 5.3.



Obr. 5.3: Zachytené detaily ruky po dokončení kalibrácie parametrov kamery.

Skript nie je plne automatizovaný a k jeho použitiu sú okrem komponentov navrhnutého zariadenia z tabuľky 5.1 potrebné nasledovné periférie: klávesnica, displej. Alternatívnou je použitie vzdialeného prístupu napríklad protokolom SSH⁴.

Popis skriptu `parazzi.py`

Spustením skriptu sú vykonané základné inicializačné postupy. Kontroluje sa výskyt priečinku datasetu s názvom `database`, jeho podpriečinkov a inicializuje sa kamera. Prebieha verifikácia pripojenia kamery, jej inicializácia a funkčnosť LED diód. Rozlíšenie kamery sa nastaví na 720×1280 pixelov funkciou `make_720p(camera)`. Nasledne sa pomocou funkcie `set_webcam_params_global(camera)` nastaví ďalšie globálne parametre kamery zhodné pre snímajú pri všetkých štyroch použitých vlnových dĺžkach. Týmito parametrami sú `backlight_compensation`, `brightness`, `white_balance_temperature_auto`, `gain`, `sharpness` a `exposure_auto`. Po následnej interakcii užívateľa a jeho voľby snímajú ruky, alebo falzifikátu, je volaná funkcia `process_photo_parameters(camera, database_type)`,

⁴<https://www.ssh.com/ssh/protocol/>

v ktorej program vykoná zmenu pracovnej cesty do určitého podpriechniku `hands`, alebo `fakes` na základe hodnoty v premennej `database_type` a funkciou `generate_photo_name()` sa vygeneruje reťazec použitý pri nasledovnom vytvorení priečinka pre zadanú sériu snímok prebiehajúcej relácie snímania. Tento reťazec je uložený v premennej `photo_name`. Po vytvorení priečinka sa nasleduje k vykonávaniu snímania. Snímanie prebieha v dvoch vnorených cykloch. Vonkajším cyklom je riadená fáza snímania pozadia a následne snímania ruky. Vnútorým cyklom spočívajúcim v štyroch opakovaníach reprezentujúcich štyri použité farby LED diód definovaných v poli `LEDS` je riadené samotné snímanie. Vo vnútornom cykle sa teda nastaví parametre kamery pre aktuálne použitú vlnovú dĺžku - farbu LED diód, viz. výpis 5.1 a následne je volaná funkcia `capture_photo(camera, led)`. Nastavenie parametrov kamery sa vykonáva použitím nástroja `v4l2-ctl`⁵.

```
def set_webcam_params_yellow(camera):
    subprocess.check_call(
        "v4l2-ctl -d /dev/video0 -c contrast=175",
        shell=True)
    subprocess.check_call(
        "v4l2-ctl -d /dev/video0 -c saturation=170",
        shell=True)
    subprocess.check_call(
        "v4l2-ctl -d /dev/video0 -c white_balance_temperature=1000",
        shell=True)
    subprocess.check_call(
        "v4l2-ctl -d /dev/video0 -c exposure_absolute=80",
        shell=True)
```

Výpis 5.1: Nastavenie parametrov kamery použitých pre snímanie pri vlnovej dĺžke 590 nm.

Vo funkcii `capture_photo(camera, led)` sa volaním ďalšej funkcie `turn_led_on(led)` rozsvietia LED diódy. Ovládanie LED diód je riadené cez univerzálne vstupno - výstupné piny minipočítača Raspberry Pi. Následne je cyklom vytvorená séria jedenástich snímok. Snímky sú vytvorené volaním funkcie `get_raw_image(camera)`, ktorá navracia vytvorený snímok. Prvých desať snímok je zahodených a algoritmus ďalej pracuje iba s posledným. LED diódy sa vypnú funkciou `turn_led_off(led)` a funkcia `capture_photo(camera, led)` vracia vytvorený snímok. Cyklus na vytvorenie dočasných snímok bol vytvorený z dôvodu, aby kamera v tak krátkom momente kvalitne zaostrila na osvetlený detail ruky. Zmenou počtu týchto snímok úpravou hodnoty premennej `dropOutFrames` sa zmení celková kvalita výsledného snímku, nie len v prípade ostrosti. Mierne sa upraví aj osvetlenie snímaného objektu. Spracovávanie pokračuje späť vo vnútornom cykle prebiehajúcej funkcie `process_photo_parameters(camera, database_type)`, kde sa na základe snímania pre aktuálnu LED diódu uloží snímok do priečinka, ktorého názov zodpovedá reťazcu v premennej `photo_name`. Základ názvu snímku zodpovedá zreťazeniu hodnoty premennej `photo_name`, názvu LED diód, ktoré boli použité pri vytvorení snímku a ďalšieho reťazca. Tento reťazec zodpovedá tomu, či ide o prvé, alebo druhé opakovanie vonkajšieho cyklu, teda či bolo vykonané snímanie pozadia, alebo ruky.

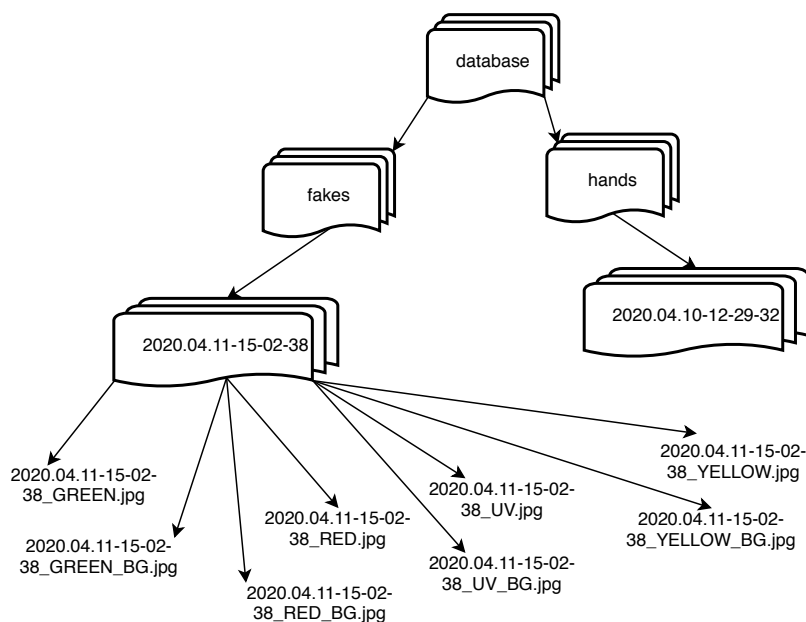
⁵<https://www.mankier.com/1/v4l2-ctl>

V prípade prvého opakovania je poslednou časťou názvu snímku reťazec `_BG.jpg`, v prípade druhého opakovania je to reťazec `.jpg`. Časť za bodkou značí formát uloženého snímku. Názov snímku má teda napríklad takýto formát: `2020.04.10-19-34-49_UV_BG.jpg`.

Program teda vytvoril osem snímok pre štyri farby použitých LED diód, pričom pre každú farbu boli vytvorené 2 snímky - snímka samotného pozadia a snímka ruky. Snímky boli uložené v podpriechniku zodpovedajúcom dátumu a času snímania, ktorý bol vytvorený v priechniku zodpovedajúcom hodnote premennej `database_type`, pričom táto premenná je nastavená voľbou užívateľa po spustení programu, kedy je užívateľ dotazaný na snímanie ruky, alebo falzifikátu.

5.3 Dataset

Táto podkapitola popisuje celkovú štruktúru a parametre vytvoreného datasetu. Dataset je uložený v hlavnom koreňovom priečniku celej práce a jeho štruktúra pozostáva z dvoch podpriechnikov `hands` a `fakes`. V prvom z nich sú uložené sety snímok rúk, v ďalšom zas sety snímok falzifikátov. Set označuje sériu snímok štyroch snímaných farieb a skladá sa z ôsmich snímok. Jedná sa o štyri snímky rúk a štyri snímky samotného pozadia, ktoré identifikuje reťazec `_BG`. Každý set je uložený vo vlastnom priečniku, ktorého názov interpretuje presný čas vykonania snímania, viz 5.4. Reťazec interpretuje postupne rok, mesiac, deň, hodinu, minútu a sekundu, kedy sa vykonalo snímanie.



Obr. 5.4: Stromová štruktúra datasetu.

Dataset obsahuje 500 setov snímok. Ide o 250 setov rúk a 250 setov falzifikátov. Na snímkoch sú opakujúce sa rovnaké ruky a falzifikáty, avšak v rôznych polohách. Dataset bol takto vytvorený s reálne menším počtom osôb a falzifikátov z dôvodu mnohých obmedzení pohybu a združovania osôb, ktoré boli v platnosti počas tvorby tejto práce. Tieto obmedzenia značne ovplyvňovali aj tvorbu falzifikátov, preto boli na dostupných modeloch rúk vytvorené rôzne povrchové úpravy, ktorých účelom bolo zmeniť odrazivosť materiálu a simulovať tak ďalší falzifikát. Falzifikáty sú tvorené z bielej sadry, gumy, silikónu, želé,

plastu, plastelíny, modrého nitrilu, syntetickej kože, papiera, vody, ľadu a farby. Príkladom môže byť obrázok 5.5. Povrchové úpravy boli tvorené olejom, krémom bez UV faktora, luminescenčným atramentom, vodou, vazelínou, kuchynským čistiacim prípravkom, želé a alkoholom.



Obr. 5.5: Použité falzifikáty: vľavo guma s plyšovou výplňou, vpravo silikón.

5.4 Eliminácia pozadia

Segmentácia ruky rozdielom snímku ruky a snímku samotného pozadia je v práci implementovaná v dvoch skriptoch. Algoritmus skriptu `database_extractor.py` je určený k automatizovanému spracovaniu datasetu - eliminácii pozadia snímok celého datasetu z priečinka `database` a následným uložením spracovaných snímok v novom priečinku `database_extracted`. Skript s názvom `extractor.py` spracúva jeden set snímok uložený v priečinku `photos`. Výsledkom tohto skriptu je nový priečinok `photos_extracted` obsahujúci snímky objektu po segmentácii. Slovo `set` označuje skupinu snímok viacerých farieb jedného snímania. Zatiaľčo skript `database_extractor.py` je určený k použitiu v prípade hromadnej predprípravy snímok na tréningovanie klasifikátora detekcie živosti, skript `extractor.py` slúži ako primárny na predprípravu snímok, teda elimináciu pozadia, pred samotnou klasifikáciou konkrétneho setu - vzorku. Skripty používajú k eliminácii pozadia v zásade rovnakú logiku, avšak v prípade prvého z nich je pri generovaní výsledných vzoriek použitá rovnaká štruktúra a názvy podpriečinkov, aké má spracovávaný dataset. Zároveň sa generuje súbor `labels.csv` identifikujúci jednotlivé sety, ich cesty a označenia, či sa jedná o ruku alebo falzifikát. Požiadavkou na tento skript je iba existencia priečinka datasetu tak, ako bol vytvorený skriptom `paparazzi.py`. V prípade skriptu `extractor.py` je očakávaná neupravená množina ôsmich snímok v priečinku `photos` s názvami, ktoré mu boli vygenerované skriptom `paparazzi.py`. V oboch prípadoch sa predpokladajú rovnaké povolenia na prácu so súbormi, aké sú spomenuté v podkapitole 5.2 pri popise skriptu `paparazzi.py`.

Popis skriptu `extractor.py`

Po spustení skriptu je funkciou `check_output_database_dir_exist()` vykonaná kontrola existencie priečinka `photos_extracted` v koreňovej ceste tohto skriptu. V prípade ak už existuje, bude zmazaný použitím `shutil.rmtree(EXTRACTED_PHOTOS_ROOT_DIR)`. Následne je vytvorený nový priečinok s rovnakým názvom. V tomto algoritme je takisto použitý vonkajší a vnútorný cyklus. Program pokračuje vonkajším cyklom, ktorý vykonáva nasledujúce akcie pre každú z farieb LED diód `color` definovaných v poli `COLORS`. Premenné `hand_file` a `background_file` sú inicializované na `None` a program ďalej pokračuje vnútorným cyklom, ktorý na základe reťazcov `".jpg"` a `"_BG.jpg"` a hodnoty premennej `color` identifikuje v priečinku dvojicu snímok ruky a pozadia rovnakej farby a priradí ich cestu do premenných `hand_file` a `background_file`. Pokračuje sa volaním funkcie `load_specific_photo_pair(hand, background, color)`, ktorá načíta súbory zo zadaných ciest a následne ich navracia do hlavného programu. Ďalej sa na obe snímky aplikuje Gaussov filter s cieľom odstránenia prípadného šumu. Ako jadro filtru je použitá matica veľkosti 7×7 . Volaním funkcie `subtraction(hand, background)` je vytvorený rozdiel matice pixelov snímku ruky a matice pixelov snímku pozadia. Táto funkcia už navracia snímok extrahovaného pozadia, viz obrázky 5.6 a 5.7.



Obr. 5.6: Načítaný snímok ruky pred spracovaním.



Obr. 5.7: Snímok po vykonaní rozdielu fotografií.

Hodnoty pixelov sú následne normalizované v rozsahu 0 až 255, čím sa zvýši saturácia snímku, ktorá má pozitívny vplyv na výsledok detekcie kontúr. Snímok na obrázku 5.7 obsahuje mimo ruky stále zbytočne veľa informácií v podobe prebytočného pozadia - veľkého počtu tmavých pixelov, ktoré však v prípade niektorých ďalších snímok nemusia byť čierne a na snímku sa tak môžu stále vyskytovať časti pozadia, ktoré je potrebné eliminovať funkciou `detect_hand(image)`. V tejto funkcii sa snímok prevedie do farieb šedi a prahovaním sa vytvorí dvojúrovňový obrázok - maska, viz obrázky 5.8 a 5.9. Pri prahovaní bol na základe testovaní použitý prah binárny a OTSU s hodnotou prahovania 125.



Obr. 5.8: Spracovávaný snímok prevedený do farieb šedi.



Obr. 5.9: Maska snímku po aplikácii binárneho a OTSU prahovania.

Na masku je ďalej použitá funkcia `cv2.findContours(thresh_gray, cv2.RETR_LIST, cv2.CHAIN_APPROX_SIMPLE)`. Táto funkcia navracia z masky kontúry, ktoré sa používajú napríklad pri analýze tvarov, alebo pri detekcii objektov. K nájdeniu kontúr využíva algoritmus Suzuki85. Cyklom sa prehliadajú nájdené kontúry od najmenej s cieľom získania súradníc ohraničujúceho rámca najväčšej kontúry. Následne je funkciou navrátený obrázok s rozsahom súradníc najväčšieho rámca a pokračuje sa v cykle tela hlavnej funkcie. Obrázok je uložený do priečinka `photos_extracted` a to s rovnakým názvom snímku, aký mal pôvodný snímok ruky. Vo výsledku je zo snímku eliminované pozadie a takisto je odstránené prebytočné okolie, viz obrázok 5.10, ktoré by pre budúci klasifikátor znamenalo prebytočné informácie, ktoré by mohli negatívne ovplyvniť tréning algoritmu detekcie živosti. Následne sa cyklom pokračuje pre spracovanie ďalších farieb definovaných v poli `COLORS`



Obr. 5.10: Zachytené detaily ruky po dokončení kalibrácie parametrov kamery.

Popis skriptu `database_extractor.py`

Spustením skriptu je vykonaná kontrola existencie súboru `labels.csv`. Ak existuje, je odstránený a vytvára sa nový súbor s rovnakým názvom. Na prvý riadok súboru je zapísaná hlavička identifikujúca parametre. Hlavička pozostáva z troch parametrov: `img_set_idx` identifikujúci číslo setu snímok, `type` určujúci typ snímku, či ide o ruku, alebo falzifikát. Ruky budú identifikované hodnotou 1.0 a falzifikáty hodnotou 0.0. Posledným parametrom je `path`, ktorý reprezentuje absolútnu cestu k danému snímku. Následne je vyko-

naná kontrola existencie priečinka `database_extracted`, do ktorého budú ukladané výstupné súbory tohto skriptu. Vytvorí sa v ňom nový podpriečinko `hands`. Volaním funkcie `sets_dir_iterator(path_to_sets, path_to_extracted_sets, cnt)` sa začne spracovanie podpriečinka `hands` z datasetu. Cyklom prebieha postupné spracovanie všetkých setov v priečinku `hands`. Do pomocných premenných `path_to_specific_photo_set` a `path_to_extracted_photo_set` sa uloží cesta k aktuálne spracovávanému setu a takisto nová cesta tohto setu v `database_extracted` po subtrakcii pozadia. Vytvorí sa nový priečinko extrahovaného setu v priečinku `database_extracted` a následným volaním funkcie `export_photo(photo_set_path, extracted_photos_path, sets_counter)` sa pokračuje rovnakým spôsobom, ako tomu bolo v prípade skriptu `extractor.py`, viz 5.4. Funkcia je spracovávaná cyklom, ktorý zaisťuje vykonanie činností podľa hodnoty premennej `color` pre všetky farby z poľa `COLORS`. V priečinku spracovávaného setu sa identifikuje dvojica ruky a pozadia konkrétnej farby podľa premennej `color`. Na obe snímky sa aplikuje Gaussov filter, ktorý odstráni šum v snímkoch. Jadrom filtru je matica 7×7 . Následne sa volaním funkcie `cv2.subtract(hand, background)` vykoná rozdiel oboch snímok, ako je tomu v prípade skriptu `extractor.py` vo funkcii `subtraction(hand, background)`. Funkcia vracia snímok extrahovaného pozadia. Snímok je následne normalizovaný pre zvýšenie saturácie, ktorá dopomôže k lepšej detekcii kontúr a funkciou `detect_hand(image)` sa vykoná orezanie snímku na základe najväčšej kontúry - kontúry ruky. Aj táto funkcia pracuje rovnako, ako v prípade implementácie skriptu `extractor.py`. Orezaný snímok sa uloží s rovnakým názvom, aký mal pôvodný snímok ruky. Uložený bude do priečinka z cesty v premennej `extracted_photos_path`, teda do priečinka aktuálne spracovávaného setu, avšak už v `database_extracted`. Na základe cesty tohto snímku je identifikovaný typ snímku, teda ruka, alebo falzifikát a informácie o extrahovanom snímku sa uložia do súboru `labels.csv`. Takto sú cyklom spracované farby snímok aktuálneho setu postupným iterovaním poľom `COLORS`. Premenná `sets_counter` značí poradové číslo aktuálne spracovaného setu snímok a v súbore `labels.csv` tak značí spoločné snímky hodnotou v stĺpci `img_set_idx`. Po skončení cyklu a teda aj funkcie `export_photo(photo_set_path, extracted_photos_path, sets_counter)` sa pokračuje späť v cykle funkcie `sets_dir_iterator(path_to_sets, path_to_extracted_sets, cnt)` a spracuje sa ďalší set snímok v priečinku `hands`. Po spracovaní všetkých snímok v `hands` sa končí vykonávanie tejto funkcie. Kontroluje sa existencia priečinka `fakes` a znova sa volá funkcia `sets_dir_iterator(path_to_sets, path_to_extracted_sets, cnt)`, avšak teraz už s cestou k priečinku `fakes` datasetu a cestou k rovnakému priečinku v extrahovanom datasete. Tentokrát sa teda vykonáva spracovanie falzifikátov.

5.5 Detekcia živosti na základe modelov štyroch vlnových dĺžok

K detekcii živosti je použitý skript s názvom `classifier.py`. Pri implementácii klasifikátora sa pristúpilo k použitiu algoritmu Support Vector Machines a to z dôvodu malej veľkosti datasetu, ktorý by nemusel dostačovať pri použití konvolučnej neurónovej siete. V prípade tréningu klasifikátora očakáva skript existujúci priečinko `dataset_extracted` vytvorený skriptom `database_extractor.py`. V prípade klasifikácie samotného setu je požadovaný priečinko `photos_extracted` vygenerovaný skriptom `extractor.py`, v ktorom je priamo uložená štvorica snímok štyroch vlnových dĺžok, ktoré sú použité k detekcii živosti v tejto práci, viz kapitola 4.1. Základná logika skriptu detekcie živosti je prevzatá z publikácie

Image Classification Using SVM [17]. Aj v prípade tohto skriptu sú očakávané povolenia práce so súborami, ako je to spomenuté v podkapitole 5.2 pri popise skriptu `paparazzi.py`. Pri návrhu algoritmu sa rozhodlo klasifikovať snímky každej vlnovej dĺžky zvlášť. Pôjde teda o štyri samostatné klasifikátory zdieľajúce rovnakú implementáciu.

Popis skriptu `classifier.py`

Spustením skriptu je nutná interakcia s užívateľom, kedy sa očakáva voľba tréningu modelu, alebo klasifikácie setu. V prípade tréningu sa vytvorí konfiguračný priečinok v kořenovom priečinku tohto skriptu a následne sa cyklom, ktorého opakovaním reprezentujú jednotlivé farby - vlnové dĺžky, predprípravia snímky aktuálne spracovanej farby, na základe ktorých je následne natrénovaný a testovaný model. Po štvrtom opakovaní cyklu sú všetky modely natrénované, otestované a program je ukončený. V cykle je najprv volaná funkcia `t_prepare_training(color)`. Hodnota premennej `color` reprezentuje podreťazec aktuálne spracovávaných snímkov datasetu a vlnovú dĺžku, pre ktorú bude tréningový model. V tejto funkcii sa volá ďalšia funkcia s názvom `t_dataset_load_and_preprocess(color)`. Na základe súboru `labels.csv` sa do premenných `first_idx` a `last_idx` uloží index prvého a posledného spracovávaného setu. Do premennej `specific_color_set` sa z `labels.csv` vyfiltrujú iba informácie o snímkoch práve spracovanej farby. Inicializujú sa dve prázdne pole `features` a `labels`, cyklom sa na základe indexu začínajú spracovávať data z premennej `specific_color_set`. Získa sa cesta k snímku na zadanom indexe, jeho typ - či ide o ruku, alebo falzifikát. Následne sa snímok z cesty načíta a zmení sa jeho veľkosť na 250×250 pixelov, pretože všetky vzorky predložené klasifikátoru by mali mať rovnakú veľkosť. Zo snímku sa ďalej funkciou `create_features(img)` extrahujú vlastnosti, viz výpis 5.2.

```
def create_features(img):
    # flatten three channel color image
    color_features = img.flatten()
    # convert image to greyscale
    grey_image = rgb2gray(img)
    # get HOG features from greyscale image
    hog_features = hog(grey_image,
                      block_norm='L2-Hys',
                      pixels_per_cell=(16, 16))
    # combine color and hog features into a single array
    flat_features = np.hstack((color_features, hog_features))
    return flat_features
```

Výpis 5.2: Extrahovanie vlastností snímku. Prevzaté z publikácie [17], upravené.

Typ snímku sa vloží do poľa `labels` a vlastnosti získané z predošlej funkcie sa vložia do poľa `features`. Takto sa prechádzajú všetky indexy z premennej `specific_color_set`, než sú všetky snímky a ich typy postupne zretazené v spomenutých premenných. Jednodimenzionálne pole `features` sa transformuje na 2D pole. Následne sa funkcia s názvom `t_dataset_load_and_preprocess()` ukončí, pričom navracia premenné `features` a `labels`. Obe sa transformujú na vhodný datový typ, funkcia `t_prepare_training(color)` takisto končí, pričom vracia tieto premenné. Ďalej sa pokračuje volaním funkcie s názvom `t_train_model(features, labels, color)`. Jedná sa už teda o tréning modelu. Obe premenné obsahujúce typy snímkov datasetu a ich skúmané vlastnosti, sú rovnako rozdelené

do trénovacej množiny datasetu a testovacej množiny v pomere 75 % ku 25 %. Trénovacia množina dát sa normalizuje funkciou `t_scale_features(features_train, color)` a následne je aplikovaná funkcia `t_compute_pca`, ktorá má za úlohu znížiť dimenzionalitu ortogonálnych transformácií pôvodných n -dimenzionálnych dát do menšieho k -dimenzionálneho priestoru, ktorý je definovaný hlavnými lineárne nezávislými komponentami. Objekty vytvorené v oboch funkciách sa uložia do priečinka `config`, viz výpis 5.3.

```
# Projects input into a space with lower dimensions.
def t_compute_pca(scaled, color):
    print("Getting principal component analysis of scaled matrix..."
          )
    pca = PCA(n_components=374)
    fit = pca.fit(scaled)
    scaled = pca.transform(scaled)
    t_save_pca_cfg(fit, color)
    return scaled
```

Výpis 5.3: Použitie PCA k dosiahnutiu lepších výsledkov trénovania modelu SVM. Prevzaté z publikácie [17], upravené.

Počet komponentov vo funkcii `t_compute_pca()` bol zvolený ako maximálny počet snímok trénovacieho datasetu (374). Tato hodnota ovplyvňuje veľkosť uloženého objektu `pca`. Zvolený počet komponentov je vysvetlený v kapitole 6.3. Pri testovacej množine sú následne použité obe objekty, pričom sa na základe týchto objektov vytvorených na trénovacích dátach aplikuje normalizácia a redukcia dimenzionality dát. Následne sa inicializuje model SVM s lineárnym jadrom a model sa použitím trénovacích dát trénuje. Po ukončení trénovania modelu nasleduje testovanie. Až sa testovanie ukončí, sú vypísané percentuálne výsledky testovania ako presnosť klasifikácie modelu a miery správnej a nesprávnej klasifikácie, viz tabuľka 5.2.

Model of YELLOW wavelength was trained.	
Model accuracy:	87.2000 %
True positive rate:	86.8852 %
True negative rate:	87.5000 %
False positive rate:	12.5000 %
False negative rate:	13.1148 %

Tabuľka 5.2: Príklad výpisu, po natrénovaní modelu pre vlnovú dĺžku 590 nm.

Následne sa model uloží do koreňovej zložky skriptu. Funkcia `t_train_model` sa ukončí a pokračuje sa v cykle k spracovaniu dát a trénovaniu modelu pre ďalšiu vlnovú dĺžku.

Akonáhle boli modely natrénované, je možné spustiť skript za účelom samotnej klasifikácie. Aj tu sa využíva cyklus pre postupnú prácu so snímkom konkrétnej farby. V tomto prípade sa do premenných `ss` a `pca` načítajú objekty pre konkrétne klasifikovanú vlnovú dĺžku z priečinka `config` a načíta konkrétny model. Následne sa spracujú snímky z priečinka `photos_extracted` podobne ako tomu bolo v prípade trénovania. Nepracuje sa však so súborom `labels.csv`. Nie je totiž potreba udržiavať informáciu o type snímku. Cesta k snímku sa pre aktuálnu farbu získa funkciou `c_find_photo(color)`. Ďalej je snímok na-

čítaný a upravený funkciou `get_image_and_resize(photo_path)` na rovnakú veľkosť, ako tomu bolo v prípade tréovania. Jedná sa o tu samú funkciu, ktorá bola použitá v prípade tréovania. Získajú sa vlastnosti snímku pomocou `create_features(image)`, viz výpis 5.2, ktoré sa následne normalizujú využitím metódy `transform()` objektu `ss` a redukuje sa počet dimenzií využitím totožnej metódy objektu `pca`. Následne sa už prechádza k samotnej klasifikácii. Takýmto spôsobom sa cyklus opakuje, než sa klasifikujú snímky pre všetky štyri vlnové dĺžky. Výsledný výpis klasifikácie vyzerá nasledovne, viz tabuľka 5.3.

Classification of green image	
Hand probability:	88.0925 %
Fake probability:	11.9075 %
Classification of uv image	
Hand probability:	98.6693 %
Fake probability:	1.3307 %
Classification of red image	
Hand probability:	91.2974 %
Fake probability:	8.7026 %
Classification of yellow image	
Hand probability:	94.6108 %
Fake probability:	5.3892 %
Overall hand probability:	93.1675 %
Overall fake probability:	6.8325 %

Tabuľka 5.3: Výpis klasifikácie ruky použitím štyroch vlnových dĺžok svetla.

Kapitola 6

Experimenty a vyhodnotenie

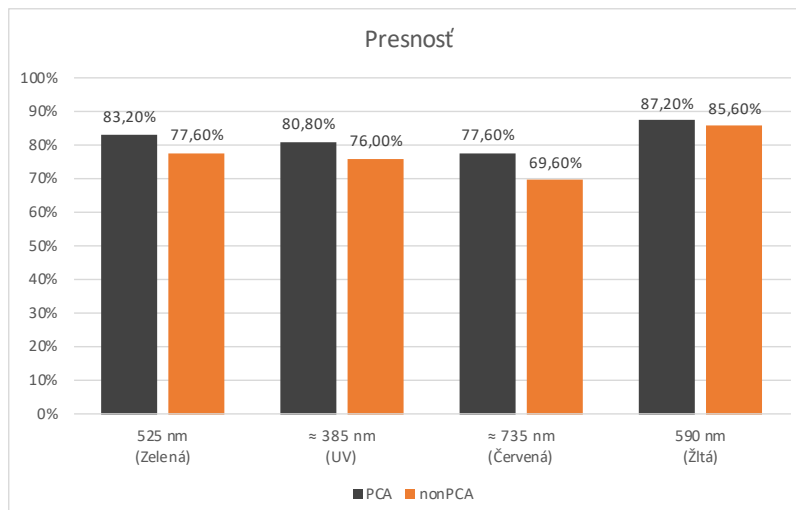
Kapitola pojednáva o zvolených parametroch tréovania modelov SVM, o výsledkoch tréovania a o zhodnotení týchto výsledkov. Ďalej pojednáva o získaných poznatkoch implementovaných algoritmov, problémoch, chybách a prípadných možnostiach, ako tieto chyby eliminovať.

6.1 Rozdelenie datasetu na tréovaciu a testovaciu množinu

Rozdelenie tréovacej a testovacej množiny percentuálne na 75 % a 25 % celkovej veľkosti datasetu bolo zhodnotené ako vhodná voľba. V prípade, ak by boli rozdelené rovnomerne na 50 % snímok, štatistické výsledky vyhodnotenia modelov na základe testovacej množiny by boli presnejšie, avšak zníženie veľkosti tréovacej množiny by malo za následok horšiu klasifikáciu - model by nebol dostatočne natréovaný. Cieľom teda bolo zabezpečiť čo najväčšiu tréovaciu množinu. Ak by však tréovacia množina obsahovala 90 % vzoriek datasetu, model by dosahoval lepšej klasifikácie, avšak štatistické výsledky vytvorené na základe malej testovacej množiny by boli skreslené.

6.2 Aplikovanie PCA

Počas implementácie klasifikátora bol algoritmus rozšírený o analýzu hlavných komponentov, takzvané PCA. Jeho použitím sa na dáta aplikuje redukcia počtu dimenzií, čo má pozitívny vplyv na tréovanie modelu, ako je možné vidieť z grafu [6.1](#).



Obr. 6.1: Presnosť jednotlivých modelov pri trénovaní s použitím PCA a bez nej.

6.3 Voľba počtu komponentov PCA


Voľba hodnoty parametru `n_components` môže mať vplyv na výsledok trénovania klasifikátora. Táto hodnota určuje maximálny počet dimenzií s najväčšou variabilitou. Data sú totiž väčšinou variabilné vo všetkých dimenziách, avšak v niektorých sú variabilné veľmi a v iných môže ísť iba o Gaussovský šum. Zvolenie väčšej hodnoty by teda malo vo výsledku znamenať vytvorenie väčšieho počtu dimenzií a teda lepšej deliacej roviny vlastností pri trénovaní modelu SVM, čo by malo pozitívne ovplyvniť výsledky trénovania. Najväčšia použiteľná hodnota je hodnota veľkosti trénovej množiny. Bolo otestovaných viacero hodnôt tohto parametru, pričom sa ukázalo, že v prípade zvolenia veľkej hodnoty boli výsledky trénovania lepšie, než v prípade menšej. Príkladom sú výsledky dvoch hodnôt v tabuľke 6.1. Dôležitým parametrom je napríklad `False positive rate`, ktorý určuje percentuálne zastúpenie vyhodnotenia falzifikátu ako ruky. V prípade tohto parametra sa teda cieľ k dosiahnutiu nízkeho percenta.

Model:	GREEN		UV	
Počet komponentov PCA:	374	94	374	93
Model accuracy:	83.20 %	74.40 %	80.80 %	77.60 %
True positive rate:	81.96 %	73.77 %	83.60 %	77.04 %
True negative rate:	84.37 %	75.00 %	78.12 %	78.12 %
False positive rate:	15.62 %	25.00 %	21.87 %	21.87 %
False negative rate:	18.03 %	26.22 %	16.39 %	22.95 %
Model:	RED		YELLOW	
Počet komponentov PCA:	374	94	374	94
Model accuracy:	77.60 %	74.40 %	87.20 %	81.60 %
True positive rate:	77.04 %	75.40 %	86.88 %	80.32 %
True negative rate:	78.12 %	73.43 %	87.50 %	82.81 %
False positive rate:	21.87 %	26.56 %	12.50 %	17.18 %
False negative rate:	22.95 %	24.59 %	13.11 %	19.67 %

Tabuľka 6.1: Porovnanie úspešnosti tréningu modelov pri malom a veľkom počte komponentov PCA.


6.4 Zhodnotenie samotných modelov

Aj napriek zaujímavým vlastnostiam, ktoré sa získali snímaním rúk a falzifikátov pri vlnovej dĺžke 730 - 740 nm zasahujúcej do najhlbšej časti kože sa ukázal natrénovaný model ako najslabší s presnosťou 77.60 % a chybnou klasifikáciou falzifikátu ako ruky s percentuálnou hodnotou 21.87 %. Možným dôvodom nízkej presnosti je citlivosť snímania pri tejto vlnovej dĺžke, kde hraje rolu jak náklon ruky, tak jemná zmena okolitého osvetlenia, či vzdialenosť ruky od snímača. Ak je ruka príliš blízko k snímaču, alebo príliš ďaleko od neho, je veľká šanca, že sa nenasníma skúmaný detail charakteristický práve pre ruku, avšak nie pre falzifikát. Ďalším možným dôvodom je použitie nie veľmi kvalitného algoritmu extrakcie ruky z pozadia, kde nie je zaistená úplná segmentácia. Zároveň sa použitím tohto algoritmu stráca množstvo pôvodných detailov ruky. Použitý algoritmus eliminácie pozadia však vykazoval na vytvorenom datasete najlepšie výsledky spomedzi skúmaných algoritmov, z toho dôvodu sa pristúpilo práve k jeho použitiu. Spracované snímky niektorých vlnových dĺžok obsahujú farebné rozdiely spôsobené algoritmom odstraňovania snímku ruky a snímku pozadia, viz obrázok 6.2.




Obr. 6.2: Spracované snímky ruky (vľavo) a falzifikátu (vpravo) pri vlnovej dĺžke ≈ 735 nm predkladané modelu.

Ďalším modelom vykazujúcim horšie percento presnosti s hodnotou 80.80 % a chybnou klasifikáciou falzifikátu s percentuálnou hodnotou 21.87 % je model UV. V tomto prípade vlnová dĺžka preniká iba tesne pod povrch kože do vrstvy epidermis. Príkladom analyzovaných snímok je obrázok ruky a falzifikátu 6.3.




Obr. 6.3: Spracované snímky ruky (vľavo) a falzifikátu (vpravo) pri vlnovej dĺžke ≈ 385 nm predkladané modelu.

Naopak druhým najkvalitnejším modelom je na základe výsledkov tréningu model, pri ktorom sa analyzujú ruky a falzifikáty osvietené vlnovou dĺžkou viditeľného spektra s hodnotou 525 nm. Príkladom analyzovaných snímok týmto modelom je obrázok ruky a falzifikátu 6.4. Presnosť tohto modelu na testovacej množine snímok dosiahla 83.20 %. Tento model detegoval falzifikáty ako reálne ruky s mierou 15.62 %.



Obr. 6.4: Spracované snímky ruky (vľavo) a falzifikátu (vpravo) pri vlnovej dĺžke 525 nm predkladané modelu.

Ako najkvalitnejší, s presnosťou 87.20 %, sa ukázal byť model, ktorý klasifikuje snímky vlnovej dĺžky 590 nm, viz obrázok 6.5. Chybná klasifikácia falzifikátov v tomto prípade predstavovala mieru 12.50 % zo 125 snímok testovacej množiny.



Obr. 6.5: Spracované snímky ruky (vľavo) a falzifikátu (vpravo) pri vlnovej dĺžke 590 nm predkladané modelu.

Vo výsledku je možné označiť vlnové dĺžky 525 nm a 590 nm zasahujúce približne 0.5 nm pod povrch kože, ako najlepšiu voľbu v prípade tvorby systému detekcie živosti. Samozrejme rôzne typy falzifikátov rôznych materiálov môžu na každú vlnovú dĺžku viditeľného svetla reagovať inak, preto môže byť vhodné využiť ku klasifikácii vlnové dĺžky také, ktoré zasahujú jednotlivito do rôznych vrstiev kože, čím sa potláčajú možnosti prekonania systému detekcie živosti. Prípadnou snahou o eliminovanie chybnej klasifikácie niektorými z viacerých modelov môže byť napríklad vypočítanie priemernej hodnoty výstupu klasifikácie všetkých použitých modelov a následné určenie rozhodovacej hranice výsledku klasifikácie. Samozrejme toto nie je úplným riešením, avšak môže to byť jednou z lepších možností

potlačenia nesprávnej klasifikácie než napríklad výpis tvrdiaci, že dva zo štyroch modelov identifikovali falzifikát.

6.5 Zhodnotenie implementácie

Voľba LED diód určitých vlnových dĺžok bola vykonaná na základe teoretických informácií o prenikaní svetla do rôznej hĺbky kože a manuálnych testovaní, pričom je možné ich považovať za vhodnú voľbu. Jedným z možných vylepšení snímacieho zariadenia na tvorbu datasetu, môže byť prídavný snímač aktuálneho osvetlenia miestnosti dynamicky meniaci parametre kamery. Pri tvorbe datasetu muselo byť totiž udržiavané stále izbové osvetlenie. Ďalšou z možností vylepšenia tohto zariadenia za účelom lepšej kvality snímok je vymedzenie vzdialenosti snímaného objektu, úpravou konštrukcie snímacieho zariadenia. V ostatných smeroch je možné považovať skonštruované zariadenie za spoľahlivé a vhodné k ďalšiemu využitiu. Voľba algoritmu na extrakciu ruky z pozadia bola vykonaná na základe testovania viacerých navrhnutých algoritmov. Výsledný algoritmus nie je najideálnejší, napriek tomu však vykazoval pri extrakcii ruky najlepšie výsledky spomedzi skúmaných algoritmov. Algoritmus splňoval svoj účel, avšak možným zlepšením je v tomto prípade vytvorenie algoritmu, pri ktorom nebude potrebné vytvárať snímky pozadia. Výsledný algoritmus detekcie živosti dokázal úspešne klasifikovať snímky s priemernou presnosťou 82.20 %. Najnižšia dosiahnutá presnosť klasifikácie dosahuje u jedného z modelov 77.60 %, zatiaľčo ďalší z modelov dosahuje presnosť až 87.2 %. Svoj podiel na výsledkoch klasifikácie môže mať rozsah a kvalita vytvoreného datasetu. Tvorba datasetu podliehala viacerým obmedzeniam, preto bolo nutné pri jeho tvorbe pracovať s menším počtom vzoriek. V prípade datasetu sa ako možnosť k zlepšeniu sa ponúka vytvorenie nového rozsiahlejšieho datasetu.

Kapitola 7

Záver

Detekcia živosti je rozšírením, ktoré mnohým biometrickým systémom stále chýba. Cieľom tejto práce bolo navrhnutie a implementovanie algoritmu detekcie živosti ruky osvietenej rôznymi vlnovými dĺžkami.

K dosiahnutiu tohto cieľa bolo potrebné naštudovať chovanie ľudskej kože vystavenej rôznym vlnovým dĺžkam zo škály elektromagnetického spektra. Naštudované bolo chovanie ľudskej kože pri vlnových dĺžkach UV žiarenia, infračerveného žiarenia a viditeľného svetla. Na základe získaných znalostí bolo zistené, že vlnová dĺžka svetla, ktorému bola koža vystavená, ovplyvňuje jej spektrálne vlastnosti.

Tieto informácie boli ďalej využité s cieľom vytvorenia algoritmu, ktorý dokáže detegovať živosť ruky na základe snímku ruky, alebo jej falzifikátu vystaveného konkrétnym vlnovým dĺžkam svetla. Využité boli štyri vlnové dĺžky zasahujúce jednotlivo všetky vrstvy kože. K vytvoreniu algoritmu detekcie živosti boli využité metódy strojového učenia s učiteľom v podobe Support Vector Machines za účelom vytvorenia binárneho klasifikátora. K trénovaniu klasifikátora bol vytvorený dataset snímok obsahujúci 500 snímok, z ktorých polovica tvorila ruky a druhá polovica zas falzifikáty napodobujúce spektrálne vlastnosti rúk. Tento dataset bol vytvorený pomocou navrhnutého a skonštruovaného snímacieho zariadenia, osadeného LED diódami zvolených vlnových dĺžok svetla.

Jedným z cieľov práce bolo navrhnutie a implementovanie algoritmu na elimináciu pozadia v snímkoch rúk. Implementovaný algoritmus dosahoval zo škály navrhnutých algoritmov najlepšie výsledky, pričom spočíval v úprave parametrov kamery, následnom vytvorení rozdielu snímku ruky a pozadia, detekcie ruky a odstránenia prebytočného okolia ruky v snímku.

Navrhnutý klasifikátor spočíval v štyroch modeloch klasifikujúcich jednotlivo snímky rúk štyroch vlnových dĺžok. Po následnej implementácii a natrénovaní dokázal úspešne rozpoznať ruku od falzifikátu s priemernou presnosťou 82.20 %. Tejto presnosti sa dosiahlo na základe experimentov v ktorých sa zistilo, že s využitím analýzy hlavných komponentov je možné zlepšiť výsledok klasifikácie.

V práci boli splnené všetky vytýčené ciele, nad rámec práce bolo vytvorené zariadenie na snímanie, jeho algoritmus a dataset. Možným pokračovaním tejto práce môže byť rozšírenie datasetu, zvýšenie presnosti klasifikácie a následné vytvorenie biometrického systému so vstavaným systémom detekcie živosti využívajúcim algoritmov tejto práce.

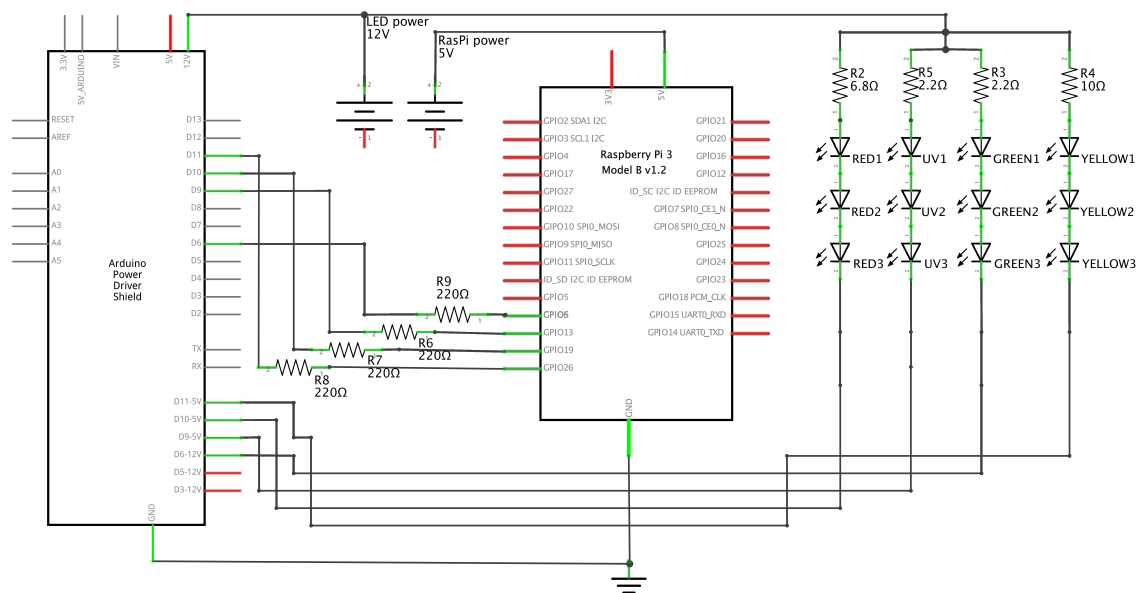
Literatúra

- [1] ALEXANDROVÁ, P., EFREMOVA, Y., HERCOGOVÁ, J., KOLÁŘOVÁ, H., LONGO, L. et al. *Nové pohledy na neinvazivní laser*. Grada Publishing a.s., 2015. ISBN 978-80-247-1651-0.
- [2] ARMY. *Elektromagnetické spektrum* [online]. [cit. 2019-12-27]. Dostupné z: http://www.army.cz/images/id_8001_9000/8753/radar/k21.htm.
- [3] BENEŠ, J., JIRÁK, D. a VÍTEK, F. *Základy lékařské fyziky*. Univerzita Karlova v Praze, 2015. ISBN 978-80-246-2645-1.
- [4] BENZIANE, S. a BENYETTOU, A. *Biometric Technology Based on Hand Vein*. *ORIENTAL JOURNAL OF COMPUTER SCIENCE & TECHNOLOGY*. December 2013, roč. 6, s. 401–4012.
- [5] DRAHANSKÝ, M. *Biometrické systémy Studijní opora* [online]. 01.2006. Vysoké učení technické v Brně, Fakulta Informačních technologií [cit. 2020-05-05]. Dostupné z: https://www.fit.vutbr.cz/study/courses/BIO/private/BIO_Studijni_opora.pdf.
- [6] DRAHANSKÝ, M. *Liveness Detection in Biometrics*. In: CHETTY, G. a YANG, J., ed. *Advanced Biometric Technologies*. IntechOpen, 2011, kap. 9 [cit. 2019-12-15]. Dostupné z: <https://doi.org/10.5772/17205>.
- [7] DRAHANSKÝ, M., DOLEZEL, M., VANA, J., BREZINOVA, E., YIM, J. et al. *New Optical Methods for Liveness Detection on Fingers* [online]. Hindawi Publishing Corporation, BioMed Research International, 2013 [cit. 2019-12-15]. Dostupné z: <http://downloads.hindawi.com/journals/bmri/2013/197925.pdf>.
- [8] DRAHANSKÝ, M. a ORSÁG, F. *Biometrie*. 2011. ISBN 978-80-254-8979-6.
- [9] EUCERIN. *Struktura a funkce kůže* [online]. [cit. 2019-12-20]. Dostupné z: <https://www.eucerin.cz/o-kuzi/zakladni-informace/struktura-a-funkce-kuze>.
- [10] GALBALLY, J., ALONSO FERNANDEZ, F., FIERREZ, J. a ORTEGA GARCIA, J. *A high performance fingerprint liveness detection method based on quality related features*. *Future Generation Computer Systems*. Elsevier. 2012, roč. 28, č. 1, s. 311–321.
- [11] GOLOWCZYNSKI, M. *Cheat sheet: Wide vs narrow aperture* [online]. [cit. 2020-05-01]. Dostupné z: <https://www.digitalcameraworld.com/tutorials/cheat-sheet-wide-vs-narrow-aperture>.
- [12] HERRERA, P., CHLEBNÍČKOVÁ, M. a VOKURKA, M. *Manikúra a pedikúra*. MAXDORF, 2000. ISBN 80-85800-26-8.

- [13] JAIN, A., ROSS, A. a PANKANTI, S. *A Prototype Hand Geometry-based Verification System*. Október 2002.
- [14] KRÁLÍK, M. *Detekce objektů v obraze s pomocí rozšířené sady Haarových příznaků a histogramu*. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií.
- [15] KRŠEK, P. *Základy počítačové grafiky Studijní opora* [online]. 0.9.1. Vysoké učení technické v Brně, Fakulta Informačních technologií [cit. 2020-05-05]. Dostupné z: https://wis.fit.vutbr.cz/FIT/st/cfs.php.cs?file=%2Fcourse%2FIZG-IT%2Ftexts%2Fizg_opora.pdf&cid=12213.
- [16] LABGUIDE. *Elektromagnetické spektrum* [online]. [cit. 2019-12-27]. Dostupné z: <https://labguide.cz/wp-content/uploads/2015/01/ELEKTROMAGNETICKÉ-SPEKTRUM.jpg>.
- [17] MORRIS, S. *Image Classification Using SVM*. RPub. RStudio. 2012, [cit. 2020-04-15]. Dostupné z: https://rpubs.com/Sharon_1684/454441.
- [18] OPEN SOURCE COMPUTER VISION. *Cascade Classifier* [online]. [cit. 2020-05-05]. Dostupné z: https://docs.opencv.org/3.4/db/d28/tutorial_cascade_classifier.html.
- [19] PAVLÍK, T. a DUŠEK, L. *Biostatistika*. Masaryk University, 2012. ISBN 978-80-7204-782-6.
- [20] RAK, R., MATYÁŠ, V., ŘÍHA, Z., PORADA, V., BITTO, O. et al. *Biometrie a identita člověka - ve forenzních a komerčních aplikacích*. Grada Publishing, a.s., 2008. ISBN 978-80-247-2365-5.
- [21] RICHARD ROKYTA ET AL.. *Fyziologie*. Galén, 2016. ISBN 978-80-7492-238-1.
- [22] TAO, D., TANG, X., LI, X. a WU, X. *Asymmetric Bagging and Random Subspace for Support Vector Machines-Based Relevance Feedback in Image Retrieval*. *IEEE transactions on pattern analysis and machine intelligence*. August 2006, roč. 28, s. 1088–99.
- [23] TÓTH, L. *Koža a jej zloženie* [online]. [cit. 2019-12-20]. Dostupné z: <https://zdravoteka.sk/priznaky/mokvanie-koze/>.
- [24] ZENDULKA, J. *Ukládání a příprava dat: Proces získávání znalostí z dat, předzpracování dat v procesu získávání znalostí - charakteristiky dat, exploratorní analýza*. 2019. Přednášeno na Vysokém učení technickém v Brně, Fakulta Informačních technologií.

Príloha A

Schéma zapojenia



Obr. A.1: Schéma zariadenia.

Príloha B

Obsah priloženého pamäťového média

Obsahom priloženého pamäťového média je:

- text bakalárskej práce,
- zdrojové súbory v \LaTeX pre vysádzanie textu bakalárskej práce,
- zdrojové súbory použité pri vytváraní datasetu,
- zdrojové súbory eliminácie pozadia snímok,
- zdrojové súbory klasifikátora,
- modely klasifikátora,
- pomocné súbory klasifikátora,
- súbor *readme.md* so stručným popisom skriptov pamäťového média,
- demo snímky.