

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

ÚSTAV INFORMAČNÍCH SYSTÉMŮ

FACULTY OF INFORMATION TECHNOLOGY

DEPARTMENT OF INFORMATION SYSTEMS

DETEKCE ŽIVOSTI PRSTU POMOCÍ OSVĚTLENÍ RŮZNÉ VLNOVÉ DÉLKY

DIPLOMOVÁ PRÁCE


MASTER'S THESIS

AUTOR PRÁCE


AUTHOR

BC.TOMÁŠ MALÝ

BRNO 2013



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV INFORMAČNÍCH SYSTÉMŮ
FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF INFORMATION SYSTEMS

DETEKCE ŽIVOSTI PRSTU POMOCÍ OSVĚTLENÍ RŮZNÉ VLNOVÉ DÉLKY

LIVENESS FINGER DETECTION BY LEDS WITH DIFFERENT WAVELENGTHS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

BC. TOMÁŠ MALÝ

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. JAN VÁŇA

BRNO 2013

Abstrakt

Cílem práce bylo nastudovat oblast biometrie a zaměřit se na způsoby detekce živosti. Následně navrhnout detekci živosti pro existující optický senzor využívající LED diod s různou vlnovou délkou.

Abstract

The goal of this thesis was to study biometrics and focus on liveness detection. Design liveness detection for existing sensor with LEDs using different wavelength.

Klíčová slova

biometrie, detekce živosti, bezpečnost, LED, vlnová délka, spektrální analýza, optický senzor.

Keywords

biometrics, liveness detection, security, LEDs, wavelength, spectral analysis, optical sensor

Citace

Tomáš Malý: Detekce živosti prstu pomocí osvětlení různé vlnové délky. Brno, 2013, diplomová práce, FIT VUT v Brně

Detekce živosti prstu pomocí osvětlení různé vlnové délky

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením pana Ing. Jana Váni. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....
Tomáš Malý
20.5.2013

Poděkování

Děkuji vedoucímu diplomové práce Ing. Janu Váňovi za metodické vedení, pedagogickou a odbornou pomoc při zpracování mé diplomové práce. Dále bych chtěl poděkovat všem dobrovolníkům, kteří mi pomohli s testováním.

© Tomáš Malý, 2013.

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

Obsah

1	Úvod.....	4
2	Biometrie.....	5
2.1	Historie biometrie	5
2.2	Identita, identifikace a verifikace.....	6
2.2.1	Identita	6
2.2.2	Identifikace	6
2.2.3	Verifikace	6
2.3	Biometrický systém	7
2.3.1	Snímací modul	7
2.3.2	Hodnocení kvality a extrakce charakteristických rysů	7
2.3.3	Porovnávací modul	8
2.3.4	Databázový modul	8
2.3.5	Slabá místa biometrického systému.....	8
2.4	Biometrické vlastnosti	9
2.4.1	Obličej.....	9
2.4.2	Otisk prstu.....	9
2.4.3	Geometrie ruky	10
2.4.4	Dlaně.....	10
2.4.5	Duhovka.....	10
2.4.6	DNA.....	11
2.4.7	Další biometrické vlastnosti.....	11
2.5	Měření výkonnosti	12
2.5.1	Míra chybného přijetí – FAR.....	12
2.5.2	Míra chybného odmítnutí – FRR.....	12
2.5.3	Míra vyrovnání chyb – ERR.....	12
2.5.4	Vztah mezi FAR a FRR.....	13
3	Testování živosti otisku prstu	14
3.1	Barva.....	14
3.2	Spektrální vlastnosti.....	14
3.3	Pocení	14
3.4	Ultrazvuk	15
3.5	Pružnost a tlak.....	15
3.6	Elektrické vlastnosti.....	15
3.7	Teplota	15
3.8	Teplý a studený podnět.....	16

3.9	Okysličení krve	16
3.10	Tep	16
4	Navržení způsobu detekce živosti	17
4.1	Způsob detekce živosti	17
4.2	Způsoby porovnávání	18
4.3	Snímky	18
4.4	Zvolený způsob detekce	20
5	Testování živosti	22
5.1	Snímání	22
5.1.1	Databáze	24
5.2	Zjišťování hodnot	24
5.2.1	Směrodatná odchylka	25
5.2.2	Medián	25
5.2.3	Histogram	25
5.2.4	Průměr histogramu	26
5.2.5	Odchylka v histogramu	26
5.2.6	Medián v histogramu	26
5.3	Barevné modely	27
5.3.1	Barevný model XYZ (1931 CIE)	27
5.3.2	Barevný model Luv (CIELUV, CIE 1976)	29
5.3.3	Barevný model Lab (CIE 1976)	29
5.3.4	Barevný model YCbCr	31
5.4	Strojové učení	31
5.4.1	Základní algoritmy strojového učení	32
5.5	Metody strojového učení	32
5.5.1	Random forest	32
5.5.2	Neuronové sítě	33
5.5.3	Boosting	33
5.5.4	Bayesian network	34
6	Implementace	35
6.1	OpenCV	35
6.2	Databáze	35
6.3	Struktura programu	36
6.4	Histogram pro černobílý snímek	36
6.5	Histogram pro barevný snímek	37
6.6	Strojové učení	37
6.6.1	Neuronové sítě	38

6.6.2	Boosting.....	38
6.6.3	Random forest.....	39
7	Testování.....	40
7.1	Výběr barevného modelu.....	40
7.1.1	Barevný model XYZ.....	40
7.1.2	Barevný model Luv	40
7.1.3	Barevný model Lab.....	41
7.1.4	Barevný model YCbCr	41
7.1.5	Výsledek	41
7.2	Výběr metody strojového učení.....	42
7.2.1	Random forest.....	42
7.2.2	Boosting.....	42
7.2.3	Bayes Classifier	43
7.2.4	Neuronové sítě	43
7.3	Přidávání atributů.....	44
7.3.1	Přidání druhého barevného modelu	44
7.3.2	Přidání mediánu k histogramu	45
7.3.3	Přidání mediánů k pixelům	46
7.3.4	Přidání mediánu k pixelům i histogramům	46
7.4	Nejlepší výsledky.....	47
8	Závěr	48
	Literatura	49
	Seznam příloh	51
	Příloha A. Obsah CD	52
	Příloha B. Výsledky testování barevných modelů pro neuronové sítě	53
	B.1 Pro barevný model XYZ.....	53
	B.2 Pro barevný model Luv	54
	B.3 Pro barevný model Lab.....	54
	B.4 Pro barevný model YCbCr	55

1 Úvod

Biometrie je obor zabývající se rozpoznáním identity člověka na základě jeho fyziologických nebo behaviorálních charakteristik (např. otisk prstu, obličej, chůze, podpis ...). Díky tomu jsme schopni určit, zda daná osoba má přístup do určité sekce budovy, zda má oprávnění pro konkrétní činnost, zda je opravdu tím, za koho se vydává atd. Oproti ověřování totožnosti na základě vlastnictví (přístupová karta) nebo znalosti (heslo) se nemůže stát, že subjekt zapomene heslo či ztratí kartu, jelikož se prokazuje vlastní biometrikou.

Se zavedením biometrické identifikace a verifikace začali útočníci pátrat po možnostech jak tyto senzory obelstít. U otisku prstu například použitím umělého prstu či jeho snímkem. V biometrických systémech je tedy nutná detekce živosti, kdy je mimo ověření identity nutné zjišťovat, zda přiložený prst je živý nebo umělý. Lze se zaměřit například na teplotu lidského prstu, na tep v lidském prstu, na stopy potu atd. Jak metody detekce, tak pokusy o podvedení jsou stále zdokonalovány a experimentuje se s novými.

Cílem této práce bude navrhnout a následně otestovat detekci živosti pro již existující optický senzor za využití LED s různou vlnovou délkou. Jedná se o senzor, který dosahuje vysoké spolehlivosti při rozpoznávání prstů, ale nemá vlastní detekci živosti. Je tedy nutné, aby navržená detekce neměla negativní vliv na použitelnost senzoru, například na dobu výpočtu a uživatelskou přívětivost.

Práce je rozdělena do 7 kapitol, z nichž první tři jsou teoretické, další dvě se zabývají návrhem a samotnou detekcí živosti, poslední dvojice kapitol pokrývá implementaci a testování mnou navržené detekce živosti.

Úvodní kapitola pokrývá historii biometrie a několik základních pojmů, jako je identita, identifikace, verifikace, biometrický systém a jeho moduly. Dále popisuje několik základních biometrických vlastností a pro ně vhodnou detekci živosti. Třetí kapitola je zaměřena přímo na způsoby testování živosti lidského prstu, který je v praxi nejpoužívanější biometrickou vlastností.

Čtvrtá kapitola popisuje vlastnosti senzoru, pro nějž má být detekce živosti navržena. Zhodnotí několik možných způsobů detekce živosti a zvolí nejvhodnější. Pátá, stěžejní, kapitola potom dále popisuje navržený způsob detekce živosti a její jednotlivé části, především extrakci atributů a strojové učení. Jsou zde tedy popsány možné atributy snímků, které se jeví jako vhodné pro detekci živosti.

Šestá kapitola popisuje implementaci navržené detekce živosti v jazyce C++ s využitím knihovny OpenCV. Jsou zde především popsány klíčové funkce aplikace a jejich parametry. V sedmé kapitole jsou testovány jednotlivé atributy snímku a jak jejich kombinace ovlivní celkovou úspěšnost aplikace. Také jsou tu otestovány možné metody strojového učení a do výsledné verze je vybrána ta, se kterou je dosahováno nejlepších výsledků.

2 Biometrie

V této kapitole si stručně popíšeme historii biometrie a uvedeme několik základních pojmů a principů týkajících se biometrie a detekce živosti.

2.1 Historie biometrie

Těžko odhadnout kdy poprvé se začaly používat biometrické vlastnosti pro rozpoznávání. Jelikož toto rozpoznávání používáme dennodenně, kdy osoby kolem nás rozlišujeme podle obličeje, chůze, atd. V těchto datech se liší i nejrůznější prameny. V knize [2] se uvádí, že za použití nepřímých důkazů můžeme datovat první použití v Číně ve 14. století, kde se dochovaly kresby na skalních stěnách připomínající strukturu otisku prstu, dále na keramice byly nalezeny otisky prstu, které mohly sloužit jako doklad o autorství.

Naproti tomu [3] udává první použití otisku prstů v 9. století v Číně, kdy obchodníci použili svůj otisk prstu jako stvrzení dokumentů týkajících se půjček a dluhů. Dále ve 14. století v Persii se uvádí, že vládní představitelé používali otisk prstu místo podpisu.

Další pramen [4] uvádí, že již ve faraonské dynastii Egypta byly používány biometrické identifikační metody. V údolí Nilu byly zaznamenávány údaje u pěstitelů obilí, aby nedošlo k tomu, že během výkupu do centrálního skladu a následného placení provize nebude jeden pěstitel vyplacen 2x. Dále je zmíněn Khaseke, což byl úředník za vlády faraona Khafre. Ten měl na starost vyplacení mzdy velkému množství dělníků při stavbě pyramid. O těchto dělnících byly uchovávané informace jako jméno, rodiče, profese, věk ale i detailní popis těla a obličeje. Také byla zaznamenána délka loktu, rozpětí mezi palcem a ukazováčkem a všechna zranění projevující se navenek.

O dalším používání biometrie se již tyto prameny shodují. V 19. století se začaly používat otisky prstů v kriminalistice. Z dochovaných materiálů se udává několik klíčových letopočtů [1, 3].

- 1684 – *Neheiah Crew* publikoval první práci na téma hřebeny pokožky prstu a dlaně.
- 1788 – *Johann C. A. Mayer* rozpoznal, že otisky prstu jsou unikátní pro každého člověka.
- 1823 – *Jan E. Purkyně* publikoval svoji tezi, diskutující devět vzorů v otiscích prstu (oblouk, klenutý oblouk, vír, smyčky,...).
- 1858 – *Sir William J. Herschel* koloniální úředník používal v Indii u dělníků otisk prstu jako stvrzení identity a potvrzení převzetí peněz.
- 1865 – *Sir Francis Galton* publikoval studii („Hereditary talent and character“) zabývající se dědičností. Zaměřující se na skutečnost, že děti dědí od svých rodičů některé jejich vlastnosti, ovlivňující jejich fyzické atributy a chování.
- 1869 – *Sir Francis Galton* spoluzakladatelem eugeniky (věda zabývající se dědičnými chorobami).
- 1880 – *Sir Francis Galton* přichází s oborem antropometrie (používání a zaznamenání lidských rozměrů a následné použití při identifikaci nebo verifikaci).
- 1892 – *Sir Francis Galton* vydává knihu „Finger Prints“ kde detailně popisuje statický model analýzy otisku prstů a identifikaci. Na základě této knihy vzniká později daktyloskopie (což je nauka zaměřena na papilární linie na prstech, chodidlech a dlaních).

- 1892 – *Juan Vucetich* Argentinský policista, který studoval Galtonovi práce přes rok, provedl první kriminalistickou identifikaci založenou na otisku prstu. Usvědčil vraha díky krvavému otisku na místě činu.
- 1896 – Daktyloskopie zavedena v Argentině jako identifikační systém.
- 1900 – *Sir Francis Galton* prosazuje daktyloskopii. Prokazuje neměnnost a jedinečnost reliéfů na prstu díky čemuž je daktyloskopie zavedena do policejní praxe.
- 1924 – Založení oddělení na identifikaci otisků prstů u FBI.
- 1965 – První použití systému na automatickou identifikaci otisku (AFIS) s více jak 810 tisíci otisků prstů.
- 1971 – Publikován první článek k rozpoznávání obličeje.
- 2000 – AFIS u FBI obsahuje celkem 47 milionů desetic otisků prstů. V průměru dojde k 50 tisícům prohledávání denně.

2.2 Identita, identifikace a verifikace

S ohledem na aplikaci a na její požadavky může biometrický systém pracovat buď v režimu identifikace, nebo verifikace. V následujících kapitolách definujeme rozdíl mezi těmito pojmy a v čem se liší principy jednotlivých režimů.

2.2.1 Identita

Před identifikací a verifikací je potřeba stanovit co je to identita a jaké druhy identit známe. Identita je jednoznačná charakteristika každého z nás. Rozlišujeme mezi *fyzickou identitou* a *elektronickou identitou*. Fyzická identita definuje, kdo jsem. Popisuje náš vzhled, naše fyzické vlastnosti, naše chování. Máme pouze jednu fyzickou identitu a nikdo ji nemá stejnou (ani vaječné dvojče nemá stejnou DNA). Elektronická identita je něco, pod čím vystupujeme v elektronickém světě (přezdívka, e-mail, uživatelský účet). Elektronických identit můžeme mít více [2].


2.2.2 Identifikace

Při identifikaci hledáme identitu osoby. Ta se nám neprokáže žádným dodatečným dokladem, pouze systém nasnímá nebo obdrží biometrickou vlastnost, pro kterou bude v databázi hledána shoda. V databázi jsou k jednotlivým biometrickým záznamům přiřazeny identity a naším cílem je nalézt záznam s identitou ověřované osoby. Tento proces může být časově velice náročný, pokud se jedná o rozsáhlou databázi. Výsledkem je buď nalezená identita, nebo výsledek není nalezen. Identifikaci se říká porovnání 1:N nebo 1:MANY jelikož musím projít celou databázi. Příkladem identifikace může být například kontrola, zda v systému již není tento uživatel zaregistrován. Identifikace je vidět na obrázku 2.1a porovnávám jednoho motýla s konkrétní databází [2].

2.2.3 Verifikace

Zde dochází k ověření identity. Uživatel se prokáže elektronickou identitou a na jejím základě je ověřována fyzická identita. Nemusíme tedy prohledávat celou databázi, ale díky předložené elektronické identitě vyhledáme jeden konkrétní záznam, což není tak časově náročné jako identifikace. Pokud nenalezne v databázi záznam odpovídající elektronické identitě uživatele, je přístup uživateli zamítnut (verifikace končí neshodou). Pokud najdeme příslušný záznam a

biometrická vlastnost odpovídá vzorku v záznamu, je ověření označeno za úspěšné (verifikace končí shodou) a uživatel získá například přístup do budovy, e-mailu atd. Verifikaci se říká porovnání 1:1, protože kontroluje vstup a konkrétní záznam v databázi. Verifikace je znázorněna na obrázku 2.1b kdy porovnávám dva konkrétní psy. Verifikace nalevo končí neshodou, verifikace napravo končí shodou [2].



Obrázek 2.1: Ukázka a) identifikace (nahore) b) verifikace (dole) [1].

2.3 Biometrický systém

Biometrický systém je systém, který rozpoznává biometrické vzory (biometrické vlastnosti). Tyto údaje extrahuje jako sadu vlastností, které porovná s údaji v databázi a na základě výsledku provede určité akce. Obecný biometrický systém můžeme rozdělit na čtyři moduly [5]: snímací modul; hodnocení kvality a extrakce charakteristických rysů; porovnávací modul; databázový modul. Tyto moduly budou popsány dále.

2.3.1 Snímací modul

Je zapotřebí biometrická čtečka či snímač pro získání biometrických dat. Například pro získání otisku prstu by se mohlo jednat o optický senzor, který zaznamená povrch prstu. Mluvíme tedy o rozhraní mezi člověkem a přístrojem, které je rozhodující pro účinnost celého systému. Pokud jsou špatně nasnímana biometrická data, všechny další moduly budou s těmito chybnými nebo nepřesnými daty dále pracovat. To může například vyústit až v zamítnutí přístupu oprávněným osobám nebo naopak přijetí osob, které by měli být zamítnuty. Jelikož většina biometrických rozlišení potřebuje snímek, je důležitá tedy i kvalita snímání a tedy jakou snímací techniku použijeme, abychom pro konkrétní systém dosáhli co nejkvalitnějších výsledků [5, 6].

2.3.2 Hodnocení kvality a extrakce charakteristických rysů

Před samotnou extrakcí je potřeba ověřit kvalitu nasnímaných dat ze snímacího modulu (zda jsou vhodná pro další zpracování). Většinou jsou získaná data podrobena algoritmu zesílení signálu tak, aby se zlepšila jejich kvalita. Může se ale stát, že data jsou v nevhodné kvalitě a osoba je vyzvána k opakování snímání. Až data projdou hodnocením kvality jsou zpracována a provede se extrakce

charakteristických rysů. Například pozice a orientace markantů, což jsou právě charakteristické rysy jako lokální hřebeny a údolní anomálie u otisku prstu. Během zápisu jsou tyto rysy uloženy do databáze a dále jsou označovány jako *šablona* [5].

2.3.3 Porovnávací modul

Extrahované rysy jsou porovnány s uloženými šablonami. V biometrických systémech založených na otiscích prstů se spočte počet shodných markantů mezi vstupem a šablonou a díky tomu se vypočítá skóre shody. Toto skóre určuje, na kolik vstup odpovídá porovnávané šabloně a může být upraveno vzhledem ke kvalitě vstupních biometrických dat. Porovnávací modul také obsahuje rozhodovací modul, který podle stanoveného skóre buď potvrdí ověřovanou identitu, nebo poskytne možné identity zkoumaného vstupu seřazené podle skóre [5].

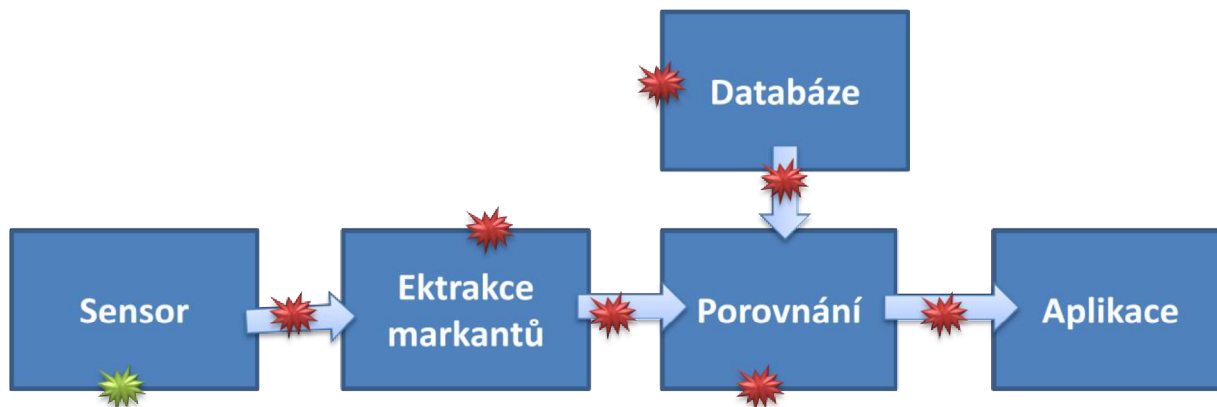
2.3.4 Databázový modul

Databáze se jeví jako úložiště biometrických informací (šablon). Během procesu zápisu jsou uloženy charakteristické rysy biometrické vlastnosti, obvykle společně s dalšími informacemi charakterizujícími uživatele jako jméno, identifikační číslo a podobně. Sběr dat během procesu zápisu může být pod dozorem, zde záleží na typu aplikace a dalších okolnostech. Systém může pro jednoho uživatele uložit i více šablon do databáze. Biometrické systémy zaměřené na rozpoznávání obličeje, například pro jednoho uživatele, uloží více šablon každou s jiným snímkem obličeje [5].

2.3.5 Slabá místa biometrického systému

V každém biometrickém systému nalezneme několik slabých míst, kde útočník může provést útok a pokusit se obelstít nebo obejít náš systém. Tato slabá místa [1] jsou zobrazena na obrázku 2.3. Útočník může použít podvrh, například umělý prst, při samotném snímání biometrické vlastnosti. Při komunikaci mezi moduly může dojít k replikaci a zaslání starých dat. Může dojít k modifikaci procesu extrakce charakteristických rysů (markantů). Opět může dojít k vložení dat při komunikaci mezi modulem pro extrakci a hodnocení rysů. Útočník může napadnout i proces porovnání nebo přímo databázi, kde změní samotnou šablonu. Poslední z možných útoků je potom změna samotného výsledku porovnání [1].

Tato práce se zaměřuje na eliminaci podvrhu biometrické vlastnosti (viz obrázek 2.3 zelený útok), kde se uplatňuje právě detekce živosti. Detekce živosti prstu je více popsána v kapitole 3.



Obrázek 2.3: Slabá místa biometrického systému [1].

2.4 Biometrické vlastnosti

Již několikrát byly zmíněny biometrické vlastnosti, v následující kapitole si uvedeme několik biometrických vlastností.

2.4.1 Obličej

Rozpoznávání podle obličeje používá každý z nás intuitivně několikrát denně, aniž bychom si uvědomovali, že se jedná o biometrické rozpoznávání. Přestože každý z nás má jiný obličej právě obličej vykazuje velkou vnitrotřídní variabilitu (změny při gestikulaci) a často i vyšší mezitřídní variabilitu (např. dvojčata a dvojníci), příklad těchto variabilit je na obrázku 2.4. Škála aplikací využívajících rozpoznávání obličeje je široká, od kontrolovaných statických vyhodnocení až po automatické dynamické rozpoznání s rušivým pozadím. Samotné snímání ale často vyžaduje určitá omezení jako jednoduché pozadí s kontrolovaným osvětlením. Tyto systémy totiž mají problém s porovnáním snímků obličeje pořízených v jiném úhlu, za jiných podmínek (jako je zmiňované pozadí a osvětlení) [2, 5].

Nejsnazší a nejlevnější je obelstít tyto systémy s fotografií, je tedy nutné použít testování živosti. Další možností je využití multimodálních systémů a spojit rozpoznávání obličeje s hlasovým rozpoznáváním a sledují se ústa ověřované osoby. U těchto způsobů detekce živosti se dá za nevýhodu považovat doba snímání. Pro zachycení grimas či mrknutí osoby potřebujeme více snímků nebo video sekvenci. Je nutná i určitá forma spolupráce s ověřovanou osobou. Pokud bychom se chtěli vyhnout těmto nevýhodám, můžeme použít dodatečný hardware a živost kontrolovat například za využití termokamery [14].



Obrázek 2.4: a) mezitřídní variabilita (nahore) b) vnitrotřídní variabilita (dole) [1].

2.4.2 Otisk prstu

Otisky prstů jsou nejrozšířenější biometrická vlastnost. Každý má unikátní otisk prstu i u dvojčat má každé unikátní otisky prstů. Otisk se skládá z hřebenů a údolí a je formován již během embryonálního vývoje. Průběhy papilárních linií jsou neměnné s časem, pokud tedy nedojde k poranění, které by je

mohlo poškodit. Malá část populace se nehodí na automatickou identifikaci za využití otisku prstů, kvůli nejruznějším onemocněním kůže či poruchám na povrchu bříška prstu [2, 5].

Možné způsoby detekce živosti lidského prstu jsou popsány v kapitole 3.

2.4.3 Geometrie ruky

Při rozlišování používající geometrii ruky se vychází z délky prstů, šířky prstů, výšky prstů, zakřivení a lokální anomálie. Tato technika je relativně jednoduchá a levná. Navíc faktory jako vlhké počasí, suchá pokožka a podobně neovlivní měření tak jak by mohli ovlivnit například snímání otisku prstu. Za nevýhodu se dá považovat to, že systém není vhodný pro situace, kde potřebujeme určit identitu jedince z velké skupiny lidí, jelikož geometrie ruky není natolik rozlišovací. Dalším problémem při získávání informací o geometrii ruky mohou být předměty jako prstýnky, případně omezení v obratnosti (artritida). Fyzická velikost takovýchto systému je větší než například u otisku prstů, pokud bychom ho chtěli využít u notebooku a podobně, musí dojít k jistému omezení. Zde se potom místo celé ruky zkoumá jen její část, zpravidla pár prstů (obvykle ukazováček a prostředníček) [2, 5].

Způsob detekce živosti bude obdobný jako při používání otisku prstů, tedy například tepelné vlastnosti, spektrální vlastnosti atd.

2.4.4 Dlaně


Principy postavené na využívání vlastností lidské dlaně jsou velice podobné těm u otisku prstu. Dlaň stejně jako otisk prstu obsahuje hřebeny a údolí, navíc je dlaň daleko větší. Tudíž máme více plochy a údajů na porovnávání, tedy rozlišovací schopnost by měla být vyšší. Na druhou stranu musíme snímat větší plochu, tedy senzory jsou větší a dražší než u otisku prstů. Lidská dlaň obsahuje další charakteristiky, které můžeme využít při rozlišování, jedná se o hlavní linie, vrásky atd. Pokud využijeme i tyto vlastnosti měli bychom být schopni dosáhnout velice přesného biometrického systému [5].

Stejně jako u geometrie ruky i zde bude při detekci živosti použito podobných principů jako při otiscích prstů popsaných v kapitole 3.

2.4.5 Duhovka

Je kruhová oblast lidského oka ohraničena bělmem a zornicí viz obrázek 2.5. Vývoj duhovky započne během vývoje plodu a ukončí se během prvních dvou let život, ačkoliv určité změny pigmentace probíhají i později. Duhovka nese velké množství informací, které můžeme využít při rozlišování. Tyto informace jsou opět unikátní, ani dvojčata nemají stejné duhovky. Systémy využívající duhovku jsou navíc velice rychlé a přesné, také se hodí pro použití při velkém množství vzorků a to nejen pro svoji rychlost ale také proto, že jsou velice přesné a mají velkou rozlišovací schopnost. U těchto systémů nebývá problém detekovat kontaktní čočky s vytisknutou duhovkou. Ze začátku byly tyto systémy drahé a vyžadovaly značnou spolupráci od snímané osoby, nyní jsou již levnější a daleko přijatelnější pro uživatele [5, 6].

Pro detekci živosti u duhovky můžeme například využít spektrálních vlastností, kde se liší reakce umělých materiálů a lidské duhovky na světla o různé vlnové délce. Další možností je využít odraz světla od sítnice tzv. efekt červených očí. Světlo se odrazí od sítnice zpět ke zdroji světla a pokud je kamera blízko zdroji světla, bude snímat červenou kvůli krevním cévám za sítnicí. Je možné zkoumat i odraz od rohovky a čočky, kdy se zaměřujeme na pozici zdroje světla a jeho odraz [15].



Obrázek 2.5: Příklad lidského oka [7].


2.4.6 DNA

Deoxyribonukleová kyselina je považována za nejlepší způsob identifikace osob. Dokáže určit totožnost každého jedince, krom dvojčat kde se uvádí [6], že mají stejnou DNA. V praxi se používá spíše ve forenzní medicíně než u verifikačního systému. Důvodů je několik, hlavně pro ověření je potřeba vzorek z nás, což není nejvhodnější. Dále by mohlo dojít k tomu, že útočník získá vzorek naší DNA a použil by ho při prokazování totožnosti [2, 6].

2.4.7 Další biometrické vlastnosti

Dále je možné zkoumat například, jak člověk píše na klávesnici, předpokládá se, že každý má jiný rytmus psaní. Tato biometrická vlastnost se spíše než pro identifikaci bude hodit pro verifikaci. Dá se u ní očekávat vysoká vnitrotřídní variabilita (ukázána na obrázku *obrázek 2.4*) skrze emotivní stav pozorované osoby, pozice vzhledem ke klávesnici, typu klávesnice atd. [5].

Mezi další vlastnosti se dá zařadit například podpis, hlas, chůze. Tyto biometrické vlastnosti nejsou tolik rozšířené především kvůli vnitrotřídní variabilitě stejně jako u psaní. Museli bychom mít volnější kritéria, což ulehčí práci útočníkovi [2, 5].



obrázek 2.6: Zastoupení biometrických vlastností na trhu [8].

2.5 Měření výkonnosti

V biometrii se nestává, že při ověřování dojdeme k 100% shodě, kterou například požadujeme při kontrole heslem. To je zapříčiněno mnoha faktory jako změna okolních podmínek (úroveň osvětlení nebo teplota v místnosti), zdravotní stav uživatele (pokud je nachlazen při rozpoznávání hlasem se to může projevit), chybou senzoru (snímaný otisk je rozmazaný), špatnou manipulací se senzorem (částečný otisk). Již v kapitole 2.3.3 bylo zmíněno, že se *vypočítá skóre shody*. Jelikož nedochází k 100% shodě (pokud by došlo, pravděpodobně se jedná o nějaký tip útoku) musíme zjistit, nakolik se testovaný vzorek shoduje se šablonami z databáze. Tím získáme **skóre porovnání** (skóre shody). Celkový výsledek a tedy potvrzení nebo odmítnutí pak záleží na nastavení prahu biometrického systému [5].

Při porovnání skóre a prahu je tedy biometrickým systémem rozhodnuto. Existuje několik možných rozhodnutí při verifikaci (identifikaci) [2]:

- Osoba A je přijata jako A => správné přijetí (True Accept)
- Osoba B je odmítnuta jako B => správné odmítnutí (True Reject)
- Osoba A je přijata jako B => chybné přijetí (False Accept)
- Osoba A je odmítnuta jako A => chybné odmítnutí (False Reject)

2.5.1 Míra chybného přijetí – FAR

FAR (False Accept Rate) je pravděpodobnost, že biometrický systém udělá chybu a vyhodnotí dva odlišné vzorky jako shodné (jeden vzorek na vstupu a druhý je kontrolovaná šablona z databáze). Tím selhal a přijal útočníka, který měl být zamítnut [1].

Míra chybného přijetí je definována takto [8]:

$$FAR = \frac{\text{Počet shodných porovnání rozdílných vzorků}}{\text{Celkový počet porovnání rozdílných vzorků}} \quad (2.1)$$

2.5.2 Míra chybného odmítnutí – FRR

FRR (False Rejection Rate) je pravděpodobnost, že dva shodné vzorky (dva vzorky od stejné osoby) budou vyhodnoceny jako odlišné. Tedy zamítneme například oprávněný přístup do budovy, uživatel potom musí ověřování opakovat nebo využít jinou formu identifikace. V praxi není tato chyba tak závažná jako předcházející, přesto při častém vyzívání uživatele k opakovanému snímání mohou ztratit důvěru v biometrickou verifikaci [1].

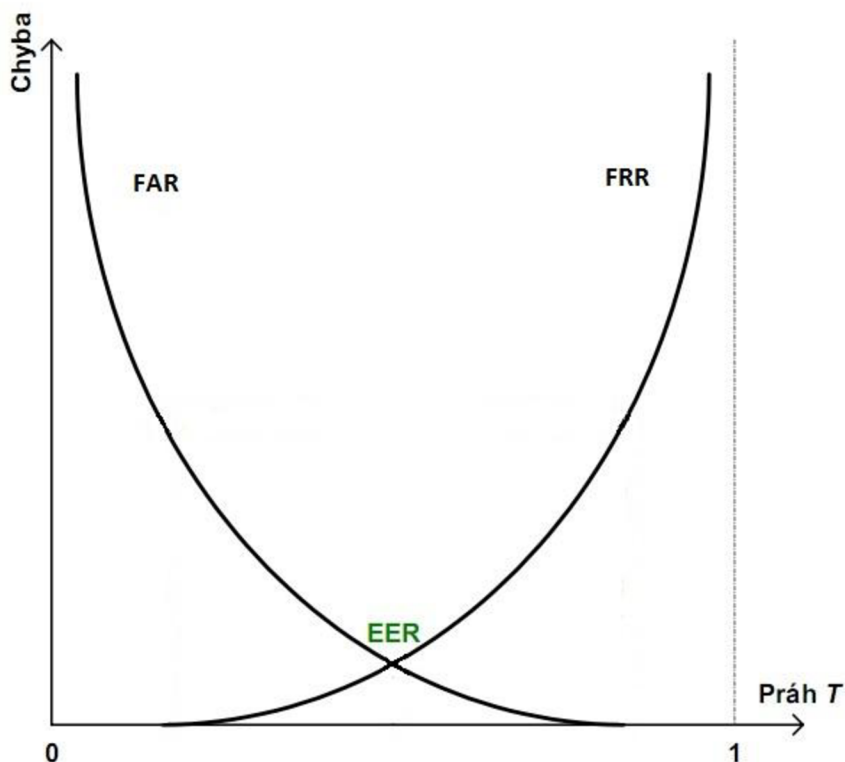
Míra chybného odmítnutí je definována takto:

$$FRR = \frac{\text{Počet porovnání vzorků osoby A vedoucí k neshodě}}{\text{Celkový počet porovnání vzorků osoby A}} \quad (2.2)$$

2.5.3 Míra vyrovnání chyb – ERR

ERR (Equal Error Rate) je stav kdy FAR = FRR. Tedy při nastavení prahu na hodnotu ERR bude počet špatně přijatých vzorků odpovídat počtu špatně odmítnutých vzorků. Příklad tohoto bodu je na

obrázku 2.7. V praxi není možné tento bod určit, protože FAR a FRR jsou diskrétní křivky (na obrázku 2.7 jsou pro zjednodušení lineární) [2].



Obrázek 2.7: Závislost míry chybného přijetí (FAR) a míry chybného odmítnutí (FRR)[1].

2.5.4 Vztah mezi FAR a FRR

Ideálně chceme držet jak chybné přijetí, tak i chybné odmítnutí co nejmenší. V praxi to bohužel nejde tak snadno dosáhnout, protože průběhy FAR a FRR jdou proti sobě (znázorněno na obrázku 2.7). Na ose x máme možné nastavení prahu systému, pokud budeme chtít práh zmenšit (posun doleva), dosáhneme tím zmenšení FRR (míry chybného odmítnutí) tedy je menší šance, že dva stejné vzorky budou vyhodnoceny jako odlišné. Na druhou stranu jsme tím dosáhli i toho, že vzroste FAR tedy počet případů kdy dva odlišné vzorky budou vyhodnoceny jako shodné. V policejné-soudních aplikacích budeme pravděpodobně vyžadovat co nejmenší hodnotu FAR. Chceme zabránit situaci, že na základě důkazů odsoudíme nevinnou osobu. V komerčních aplikacích nám půjde převážně o pohodlí uživatele a nechceme, aby oprávněnému zaměstnanci byl odmítnut přístup do zařízení, tedy udržujeme FRR nejmenší.

Výše zmiňovaný bod ERR může sloužit jako kompromis, ovšem je potřeba si uvědomit, že průběh FAR a FRR je na obrázku 2.7 pro představu značně zjednodušen [1].

3 Testování živosti otisku prstu

Jak již bylo zmíněno, biometrické systémy se stávající čím dál více rozšířenější pro identifikaci (verifikaci) uživatele s jejich rozšířením roste i počet potencionálních útočnicků. Je tedy nutné dbát na zabezpečení těchto systémů. Detekce živosti zásadním způsobem zvyšuje bezpečnost biometrického systému na úrovni věrohodnosti vstupních dat. Útočnick se může například pokoušet obelstít snímání prstu použitím umělého prstu odpovídající osobě, která má do systému přístup. Díky testování živosti bychom měli být schopni detekovat tento umělý prst a přístup zamítnout. Testování živosti ale nemusí být tak jednoduché, jak se na první pohled zdá. Pokud útočnick zjistí, jak je provedena detekce živosti může se na toto testování se svým padělkem připravit.

Navíc je potřeba dodržovat několik základních pravidel při testování živosti. Za nejdůležitější pravidlo se dá považovat **nutnost testování živosti na stejné části těla, která je použita pro identifikaci/verifikaci**. Toto je jasné, pokud budeme při snímání otisku prstu kontrolovat oči útočnicka, bezpečnosti biometrického systému to nepomůže. Další pravidlem je, že **ověřování živosti by mělo probíhat nejlépe současně s testováním biometrické vlastnosti**. Chceme zabránit tomu, aby útočnick mohl například na snímání použít padělek a na následnou kontrolu živosti použít svůj vlastní prst [4].

Nyní se podíváme na několik nejrozšířenějších způsobů testování živosti zaměřených na kontrolu lidského prstu.

3.1 Barva

Vyrobít umělý prst, který by barevně odpovídal živému, není takový problém. Wei-Yun však dokázal [9], že pokud je prst přitisknut na plochu tak v místě tlaku se mění průtok krve, což má za příčinu změnu barvy prstu z červené na bílou. Toho se u umělého či amputovaného prstu nedosáhne. Metoda se jeví jako velice úspěšná při rozpoznání želatinového prstu, který se jinak velice těžko detekuje [10].

3.2 Spektrální vlastnosti

Tato metoda je založena na multispektrálních vlastnostech kůže. Pokožka je ozařována pomocí LED se světlem o různých vlnových délkách a dochází k částečnému pohlcení a odražení světla. Výhodou je zde výskyt optických senzorů u většiny snímání otisku prstů, tedy nepotřebujeme na tuto detekci živosti žádný doplňující hardware [2, 11].

3.3 Pocení

Lidské tělo je pokryto potními póry, tedy i lidský prst. Profesor Shuckers [9] přišel s využitím potu pro detekci živosti. Prst se přiloží na snímanou plochu, kde je několik sekund snímán a čeká se, až se kapičky potu objeví v papilárních liniích. Ty se stávají tmavší a lépe viditelné viz obrázek 3.1.

Tato metoda také využije stávající senzor a je celá softwarová což je výhoda. Nevýhodou je, že potřebuje delší dobu snímání, aby se pot rozšířil [2, 9].



Obrázek 3.1: Šíření potu [9].

3.4 Ultrazvuk

Metoda je založena na principu pronikání ultrazvukové vlny pod povrch prstu. Díky odraženým vlnám jsme pak schopni detekovat například nalepený padělek prstu, který má jiné charakteristiky než lidský prst [2].

3.5 Pružnost a tlak

Jak již bylo zmíněno při tlaku lidského prstu na destičku se mění barva z červené na bílou. Další vlastností může být pružnost lidské kůže při tlaku. Tedy pokud prst přitlačíme k destičce, dojde k deformaci kůže a změně tloušťky papilárních linií viz obrázek 3.2 [9].



Obrázek 3.2: Série snímků znázorňující pružnost lidského prstu [9].

3.6 Elektrické vlastnosti

Lidská kůže je vodivá a dá se tedy využít na měření odporu nebo vodivosti. Tato vlastnost je ale závislá na faktorech jako je vlhkost, která se může u testovaných jedinců výrazně lišit například i vlivem onemocnění nebo vnějších podmínek. Díky tomu je nutné nastavit hraniční parametry volněji, což značně ulehčí práci útočníkovi. Při útoku mu pak stačí například vhodná koncentrace solného roztoku nebo například naslinění prstu, aby měl stejnou odezvu jako živý [2, 9].

3.7 Teplota

Podobně jako u elektrických vlastností i zde teplotu jedince může ovlivnit mnoho faktorů a rozsah teplot naměřených na lidském prstu je velice široký. Tato teplota se pohybuje od 25°C až do 37°C [2]. Parametry biometrického systému s tím musí počítat, aby neoznačily jako neživý například prst

člověka, který trpí problémy s cirkulací krve. Tím opět pomáháme útočnickovi, kterému se pak takový systém daleko snáze oklame a stačí mu například jen zahrát umělý prst [2].

3.8 Teplý a studený podnět

Můžeme využít plošku umístěnou v nižší části dotyku prstu, kterou buď zahřejeme, nebo ochladíme. Na uživateli poté bude, například pomocí stisku tlačítka určit, ke kterému jevu došlo. Nevýhodou zde může být, že útočník má 50% šanci na uhádnutí [2].

3.9 Okysličení krve

Další princip využívá okysličení krve, která se měří podobným způsobem jako v nemocnici využívající oximetr. V těle koluje okysličená a neokysličená krev, ta lze detekovat pomocí infračerveného záření s lišící se vlnovou délkou (660nm a 940nm). Živý prst musí poté reagovat na oba typy osvětlení, což nenastane, pokud je prst umělý nebo amputovaný. Nevýhodou této metody je opět časová náročnost, kdy je potřeba, aby došlo ke změně poměru okysličené a neokysličené krve [2, 12].


První oximetry tu byli již v roce 1940, ale až v roce 1972 se začalo využívat infračerveného světla. Velké rozšíření oximetrů přišlo až v 90 letech. Nyní se používají v lékařství hlavně kvůli schopnosti měření saturace krve bez nutnosti odběru krevního vzorku [2, 12].

3.10 Tep

Pro měření tepu se může použít také oximetr, jehož princip je popsán v bodu 3.9. Nebo lze využít faktu, že při pumpování krve do žil dochází k objemovým změnám v tepnách a žilách. Díky těmto změnám se mění i samotný povrch kůže, což je pro pouhé lidské oko nepostřehnutelné, ale existuje několik na toto zaměřených měření.

Ing. Lodrová navrhla dva přístupy pro ověřování tepu [9], kde měří malé objemové změny. První přístup využívá CCD kameru s makro objektivem na získání sekvence snímků (viz obrázek 3.3 vpravo). Dále jsou určeny referenční body a v závislosti na lidském tepu se mění vzdálenost mezi papilárními liniemi a to periodicky v průměru s rozdílem 4,5 μ m.

Druhý přístup (viz obrázek 3.3 vlevo) využívá laseru na měření vzdálenosti [9].



Obrázek 3.3: Měření pulzace prstu: laser (vlevo) a CCD kamera (vpravo) [9].

4 Navržení způsobu detekce živosti

Cílem práce bylo vyvinout detekci živosti pro existující senzor. Jako vhodný se ukázal senzor *TBS 3D-Enroll* (na obrázku 4.1) od švýcarské společnosti TBS (Touchless Biometric Systems), který neobsahuje detekci živosti. Senzor obsahuje diody s různou vlnovou délkou, konkrétně červenou o vlnové délce 700 nm, zelenou o vlnové délce 550 nm, modrou o vlnové délce 470nm a infračervenou s vlnovou délkou 800nm. Dále senzor obsahuje 3 kamery, díky kterým je schopen vytvořit 3 snímky zachycující co největší část bříška snímaného prstu. Při snímání je pak prst ozářen zeleným světlem a mění se osvětlení jednotlivých diod, aby se dosáhlo konstantního osvětlení a na snímku nebyli žádné stíny. Díky této technologii je senzor jedním z nejlepších na trhu a svým principem je vhodný pro zavedení detekce živosti bez náročných hardwarových úprav. Snímky prstů jsou v rozlišení 1280x1024 pixelů [13].



Obrázek 4.1: TBS 3D-Enroll [13].

4.1 Způsob detekce živosti

Pro detekci živosti na výše popsaném senzoru byly uvažovány metody popsané v následujících odstavcích.

První variantou byla možnost založit detekci živosti na tepelných a elektrických vlastnostech prstu (viz kapitoly 3.6 a 3.7). Při tepelných vlastnostech je nutné provést měření teploty na povrchu prstu na několika místech současně. Bylo by nutné do senzoru integrovat zařízení podobné termokameře, což je z praktického hlediska nerealizovatelné. Stejný problém by nastal i u elektrických vlastností. Pokud by se tyto metody použily, bylo by nutné provést dodatečné snímání mimo senzor, což by bylo z hlediska specifikovaných podmínek nepřijatelné.

Jelikož senzor snímá prst, bylo by možné měřit papilární linie a jejich změny v závislosti na lidském tepu (viz kapitola 3.10). Ověřování živosti by vyžadovalo sekvenci snímku, delší dobu snímání, stabilizaci nebo fixaci prstu a pravděpodobně by vyžadovalo i vyšší rozlišení snímku proto jsme nad tímto způsobem dále neuvažovali.

Spektrální vlastnosti kromě zkoumání reakce na světlo o různé vlnové délce mohou využít i změny v lidském prstu při přitisknutí na plochu, to je nazýváno jako Blanching effect, díky kterému se mění barva prstu (viz kapitola 3.1). Když je prst vystaven lehkému tlaku, krev proudí bez překážek. Pokud dojde k silnějšímu tlaku, prst „zbledne“ vlivem vytlačování krve ze středu k okrajům.

Při zkoumání reakcí na světla o různé vlnové délce se tyto změny projeví u lidského prstu ale na umělé materiály to nebude mít žádný vliv. Poskytnutý senzor, ale provádí bezdotykové snímání, takže tuto vlastnost nemůžeme využít. Ze stejného důvodu nemůžeme použít ani detekci založenou na změně barvy při tlaku a pružnost lidského prstu [10].

Jako nejvhodnější se tedy jeví spektrální vlastnosti, kde nemůžeme využít Blanching effectu ale pořád můžeme zkoumat reakce na světlo o různé vlnové délce.

4.2 Způsoby porovnávání

Uvádí se dva principy postavené na spektrálních vlastnostech. První z nich je **přenosové měření**, kdy nás zajímá pouze přenášené světlo a světlo rozptýlené povrchem prstu. Při této metodě je nižší intenzita světla [11].

Druhý způsob je **metoda odrazu** zaměřující se pouze na světlo odražené od povrchu a horních vrstev prstu.


Přenosové měření je užitečné především u kvantitativních analýz, zatímco metoda odrazu je preferována u kvalitativního ověřování a právě v biometrických senzorech. V našem případě se dá také mluvit o metodě odrazu, jelikož budeme zkoumat snímek osvětleného prstu diodou a zaměříme se na to, kolik světla bylo pohlceno a kolik odraženo.

4.3 Snímky


Po provedení sady snímání živých a umělých prstů jsme vytvořili předběžnou databázi pro prvotní analýzu možného způsobu detekce živosti. Z naměřených dat plyne, že každý materiál osvětlený různými vlnovými délkami má charakteristickou odezvu a to konkrétně v tom kolik světla se odrazí nebo pohltí (snímek je pak světlejší nebo tmavší). Snímky živých prstů (obrázek 4.3) jsme porovnali se snímky několika umělých prstů (obrázek 4.2), snímky těchto prstů jsou na obrázcích 4.4 a 4.5. Od pohledu se snímky živých a umělých prstů liší zejména pod červenou LED. Živé prsty jsou na snímcích o poznání světlejší, tudíž, se více světla odrazilo a méně absorbovalo.




Obrázek 4.2: Obrázek několika umělých prstů z různých materiálů (latex, durocast, vosk) různého zabarvení. Po radě očíslované zleva jako vzorek 1 - 4.



Obrázek 4.3: Snímek živého prstu ozářeného červenou, zelenou, modrou a infračervenou LED.




Obrázek 4.4: Snímek umělého vzorku 2 ozářeného červenou, zelenou, modrou a infračervenou LED.

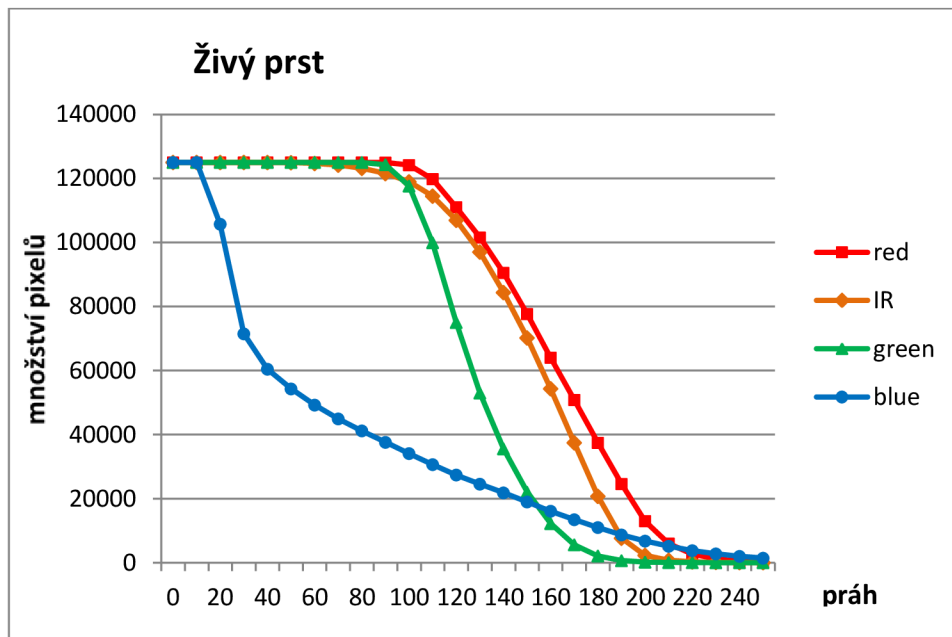


Obrázek 4.5: Snímek umělého vzorku 3 (voskového) ozářeného červenou, zelenou, modrou a infračervenou LED.

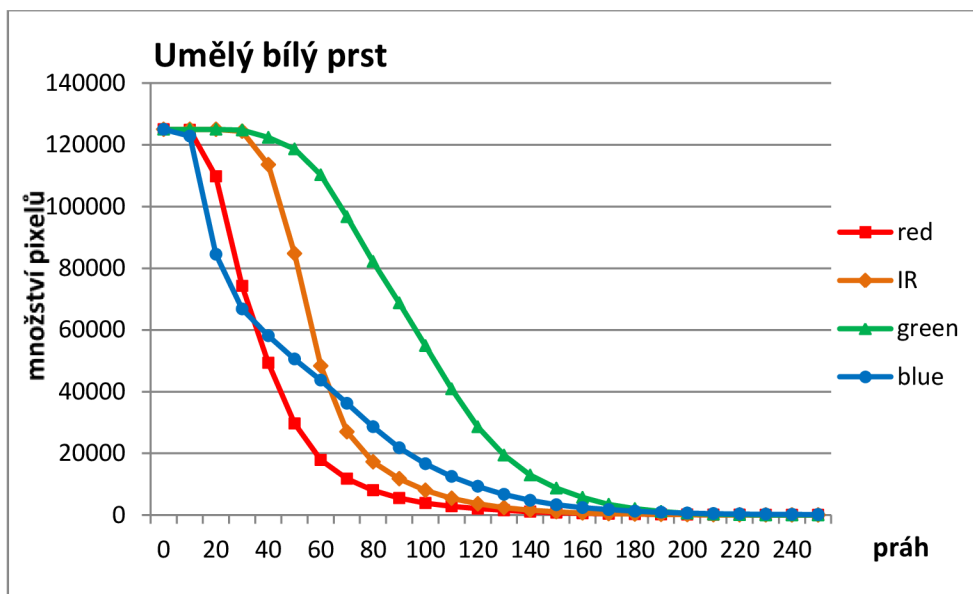
Pro potvrzení vizuálních rozdílů jsme vytvořili krátký program využívající OpenCV, který zpracoval tyto snímky. Ze snímku byly vyříznuty úseky, kterými jsme se zabývali (viz obrázek 4.6). Snímky jsou černobílé, hodnoty pixelů tedy odpovídají stupňům šedi od 0 až do 255 (0 bílá a 255 černá). Rozhodli jsme se postupně snímek prahovat (od nuly do 250) a sledovat počet pixelů, který zůstane v obrázku. Takto získané hodnoty jsou znázorněny v grafu, graf 5.1 zobrazuje počet pixelů v živém prstu a graf 5.2 v umělém bílém prstu.



Obrázek 4.6: Úsek prstu pro programové porovnávání.



Graf 4.1: Prahování snímků živého prstu.



Graf 4.2: Prahování snímků bílého umělého prstu.

4.4 Zvolený způsob detekce

Z výše uvedených grafů a snímků je vidět, jak živé a umělé prsy reagují odlišně na různé LED a tedy na různou vlnovou délku světla. Na těchto odlišnostech bude stát mnou navrhovaná detekce živosti, budeme prahovat část prstu a sledovat úbytek pixelů s rostoucím prahem. Jelikož živý prst absorbuje méně světla, je proto světlejší, což by se v detekci živosti mohlo projevit při kontrolování průměrné hodnoty pixelu snímků. Z obrázků 4.3 až 4.5 je dále vidět, že u živého prstu je barva téměř neměnná (až na modrou LED, což je zapříčiněno tím, že se nachází v přední části senzoru a zadní část prstu

není tolik osvětlená), za to u umělých prstů se odstín mění více. Tedy směrodatná odchylka a průměr naměřených hodnot by také měl pomoci rozlišit živý prst od umělého.

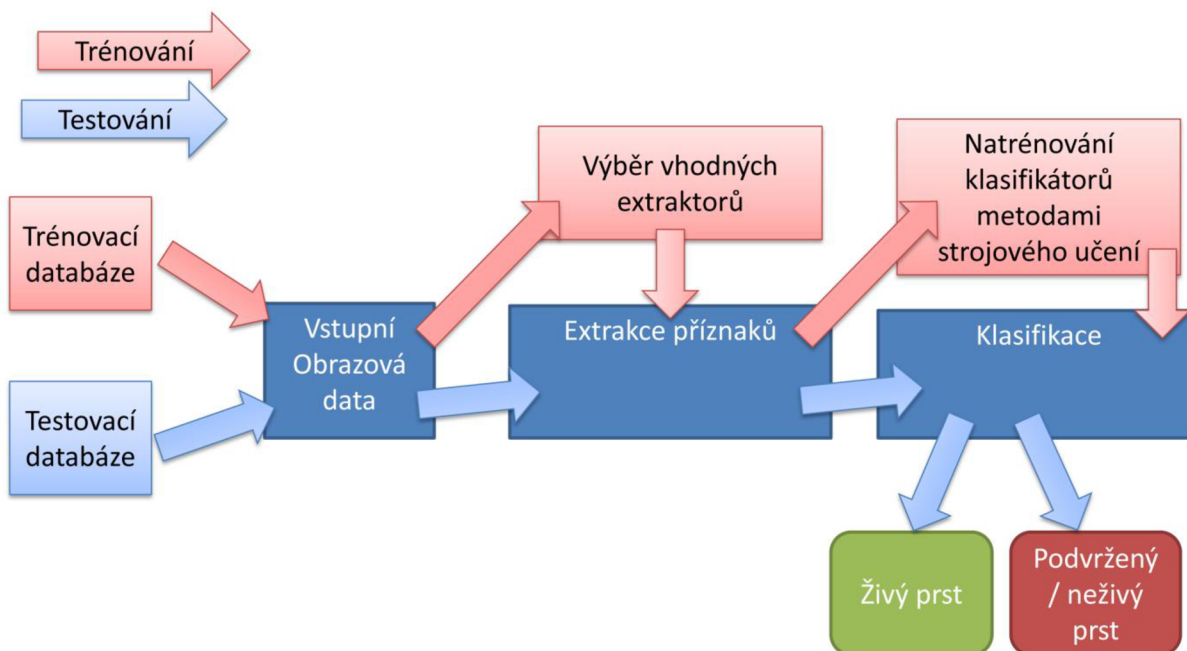
Pokud by se tato metoda neprokázala, jako dostatečně vhodná, budou zkoumány další metody využívající zejména rozdílné reakce lidského prstu a umělých materiálů na světla o různé vlnové délce.

5 Testování živosti

Testování živosti jsme si rozdělili do několika bloků, které jsou zobrazeny na obrázku 5.1. Jedná se tedy v první řadě o *testovací a trénovací databáze*, na kterých budeme ověřovat testování živosti a její jednotlivé části. Stěžejní tedy bude nasnímání snímků, které je popsáno v kapitole 5.1.

Další blok se zabývá *výběrem vhodných extraktorů* pro detekci živosti. Možné atributy snímku jsou popsány v kapitolách 5.2 a 5.3. V kapitole 7 jsou jednotlivé atributy a jejich kombinace otestovány, přičemž nás zajímá jejich vliv na úspěšnost testování živosti. Na základě těchto testování určíme, které kombinace atributů pro nás budou nejvhodnější.

Blok *natrénování klasifikátorů* úzce souvisí s blokem *klasifikace*, protože metody strojového učení použijeme při klasifikaci jednotlivých snímků. V kapitole 5.5 je popsáno několik možných metod strojového učení, které budou v kapitole 7.2 otestovány s cílem určit nejvhodnější metodu do naší detekce živosti.



Obrázek 5.1: Blokové schéma testování živosti.

5.1 Snímání

Abychom mohli ověřovat, jak vybrané vlastnosti ze snímků prstu pomáhají v rozlišování živých a neživých prstů, bylo potřeba nasnímat prsty dobrovolníků, neživé modely a nejrůznější materiály. Živé prsty byly nasnímány 23 dobrovolníkům z řad obou pohlaví. Každému jsme nasnímali čtyři prsty, kdy jak již bylo popsáno a ukázáno v kapitole 4.2 (na obrázku 4.3) pro každý prst byly vytvořeny 4 snímky (osvětlený červenou, zelenou, modrou a infračervenou diodou).

Kromě umělých prstů (16 prstů) viz obrázek 4.2, jsme dále snímali rukojeti nožů (obrázek 5.2), dřevěné materiály (obrázek 5.3), vytisknuté snímky prstů na papíře, kusy kartonu, barevnou

plastelínu, rukavice z latexu a mikrotenu, krabí tyčinku, mrkev a kuřecí maso (obrázek 5.4). Celkem bylo vytvořeno 54 snímků.



Obrázek 5.2: Rukojeti nožů pro snímání.



Obrázek 5.3: Dřevené materiály pro snímání.



Obrázek 5.4: Kuřecí maso pro snímání.


Snímání neprobíhalo v jednom dni, ani na jednom místě, ale podmínky byly vždy podobné a to místnost s pokojovou teplotou. Podmínky se tedy mohly lišit jen minimálně, což by odpovídalo i praktickému nasazení aplikace a senzoru.

5.1.1 Databáze

Snímky byly několikrát rozděleny na dvě poloviny, které byly stejně velké a obsahovaly stejný počet snímků živých i neživých prstů. Toto rozdělení bylo provedeno, abychom získali variaci trénovacích a testovacích databází. Každá databáze se liší od ostatních, abychom při testování dosáhli nejrozumnějších kombinací snímků. Při testování jsme dále měnili i role databází, tedy prvně jsme použili jednu část databáze jako trénovací a druhou část otestovali, poté provedli test znovu s trénováním z druhé databáze a první sloužila pro testování.


5.2 Zjišťování hodnot

Při navrhování způsobu detekce živosti v kapitole 4.2 jsme pracovali s úsekem prstů (obrázek 4.6), který se ale ukázal pro finální použití nevhodný, protože u některých snímků zasahoval mimo prst. Rozhodli jsme se tedy celý výsek udělat delší a užší, abychom zamezili případům, kdy se bude nacházet mimo prst. Přesto v něm bude stále zachycen střed prstu. Novou oblast jsme vizuálně vyzkoušeli na několika snímcích u kterých se jednalo, buď o velice krátký prst, nebo nebyl v senzoru přímo uprostřed viz obrázek 5.5, kde je vidět že kontrolovaná oblast se vždy nachází na prstu.



Obrázek 5.5: Kontrola zda vybraný úsek nepřesahuje mimo prst.

Všechny hodnoty používané při detekci živosti budou z této části snímku. Pro získání hodnot pixelů ve vybrané oblasti jsme vytvořili tři úsečky, na kterých bude rovnoměrně rozmístěno 11 bodů, z nichž získáme hodnotu bodů, a tedy konkrétní stupeň šedi viz obrázek 5.6. Z takto získaných hodnot spočítáme průměrnou hodnotu a odchylku. Celou vybranou oblast využijeme také při analýze histogramu, kde budeme pracovat se všemi pixely z oblasti. Z histogramu zjišťujeme průměr a odchylku, poté snímek převedeme do jiného barevného modelu a histogram znovu analyzujeme.



Obrázek 5.6: Body pro získávání hodnot.

5.2.1 Směrodatná odchylka

Ze získaných hodnot jsme spočítali aritmetický průměr, tím byla zjištěna průměrná barva pixelů v kontrolované oblasti. Pro zpřesnění analýzy a zohlednění větších barevných změn spočítáme i směrodatnou odchylku, určující jak jsou hodnoty rozptýleny vzhledem k aritmetickému průměru. S většími rozdíly hodnot od průměru bude směrodatná odchylka větší od 0, naopak pokud budou hodnoty blízké průměru směrodatná odchylka se bude blížit 0. Směrodatná odchylka je vždy kladné číslo ve stejných jednotkách jako hodnoty, z kterých byla vypočítána [16].

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (5.1)$$


5.2.2 Medián

Medián dělí řadu na dvě stejné poloviny, pokud bychom čísla seřadili do neklesající posloupnosti, tak prostřední číslo, bude medián. Pokud má posloupnost sudý počet prvků, za medián označujeme aritmetický průměr hodnot na místech $n/2$ a $n/2+1$ [16].

Rozhodli jsme se vypočítat pro hodnoty bodů i medián, který byl dodatečně otestován, zda vylepší klasifikaci prstů, více v kapitole 7.3. Ukázalo se, že medián zvedne procentuální úspěšnost aplikace.

5.2.3 Histogram

Jak bylo již zmíněno v kapitole 5.2, vytvořili jsme pro vybranou oblast snímků histogram a dále jej analyzovali. Histogram ve statistice slouží k zobrazení distribuce dat a dá se chápat jako sloupcový graf. Na vodorovné ose máme diskrétní intervaly (tzv. koše nebo třídy) a na svislé četnost, nebo-li počet výskytů v konkrétním intervalu. Ukázka histogramu viz obrázek 5.7 [17].



Obrázek 5.7: Ukázka histogramu[18].

Ve zpracování obrazu se histogram používá pro grafické znázornění stínu a jasu v obrazu. Na vodorovné ose budou hodnoty 256 odstínů s černou (0) nalevo a bílou (255) napravo. Na svislé ose poté výskyty jednotlivých odstínů, s vyšším výskytem je tento odstín na snímku více zastoupen [17].

5.2.4 Průměr histogramu

Při analýze histogramu jsme počítali jeho průměr, tedy bod na ose x (třída), který bude mít průměrnou četnost. V rovnici 5.2 jsme použili názvy z obrázku 5.7, kdy sčítám násobky tříd a jejich četností a podělíme sumou všech četností [20].

$$\mu = \frac{\sum_{i=1}^N \text{třída}_i \cdot \text{četnost}_i}{\sum_{i=1}^N \text{četnost}_i} \quad (5.2)$$

5.2.5 Odchylka v histogramu

Odchylka v histogramu se příliš neliší od klasické směrodatné odchylky, také nám říká, jak jsou hodnoty rozptýleny od aritmetického průměru. V histogramu jak daleko jsou třídy od průměru. V rovnici 5.3 jsme použili názvosloví z obrázku 5.7, počítáme vzdálenost konkrétní třídy od průměru, tu dále umocníme, abychom pracovali s kladnými čísly. Dále vynásobíme četností v této třídě tuto sumu, poté podělíme sumou všech četností a odmocníme, kvůli předcházejícímu umocnění [20].

$$\sigma = \sqrt{\frac{\sum_{i=1}^N \text{četnost}_i \cdot (\text{třída}_i - \text{průměr})^2}{\sum_{i=1}^N \text{četnost}_i}} \quad (5.3)$$


5.2.6 Medián v histogramu

Medián dělí histogram na dvě stejné části. Pokud bychom si vypsali seřazené třídy s příslušnou četností, tak třída vyskytující se v polovině této posloupnosti bude medián. Další možností by bylo spočítat polovinu celkové četnosti, což je hodnota které chceme dosáhnout. Postupně přičítat třídy a jejich četnosti, než se dostaneme na požadovanou hodnotu a získáme medián [20].

Medián v histogramu byl také dodatečně testován a zjistili jsme, že vylepší rozlišovací schopnost aplikace. Více o tomto testování v kapitole 7.3.

5.3 Barevné modely


Ze senzoru máme 4 černobílé snímky, každý osvětlený jinou LED. Pro další analýzy jsme se rozhodli černobílé snímky sloučit a vytvořit tak barevný snímek, tedy ze tří jednobarevných snímků vytvoříme jeden tříkanálový (použijí snímky osvětlené červenou, zelenou a modrou LED). Při spojování snímků použijeme hodnotu pixelu osvětleného jednou z barevných diod a uložíme tuto hodnotu do barevného obrazu pod příslušnou barevnou složku téhož pixelu. Výsledný obrázek neodpovídá skutečnému barevnému snímku, ale pro naše analýzy je dostačující. Výsledek sloučení je na obrázku 5.8. Nový barevný snímek poté převedeme do dalších barevných modelů popsaných níže.



Obrázek 5.8: Výsledek sloučení černobílých snímků do barevného snímku.

5.3.1 Barevný model XYZ (1931 CIE)

Je jeden z prvních matematicky definovaných barevných prostorů. Lidské oko je citlivější na změny jasů než na změny barvy a model XYZ to zohledňuje. Nové barevné prostory se objevovaly, protože všechny viditelné barvy nešlo získat jen kombinací červené, zelené a modré složky. Prostor byl navržen tak, že parametr Y vyjadřuje jas, X představuje červenou/zelenou část barvy a Z odpovídá modré/žluté. X nabývá hodnot 0 až 95.047, Y 0 až 100 a Z 0 až 108.833. Barvený prostor je znázorněn chromatickým diagramem na obrázku 5.8 [21, 22].




Obrázek 5.9: Barevný prostor XYZ znázorněn chromatickým diagramem [21].

Na převod z RGB do XYZ se používá násobení maticí, v našem případě bychom použili matici 5.4, kdy jednotlivé složky XYZ spočítáme podle rovnic 5.5. Na obrázku 5.10 je znázorněn snímek prstu převedený z RGB do XYZ [22].

$$\begin{matrix} 0.4124564 & 0.3575761 & 0.1804375 \\ 0.2126729 & 0.7151522 & 0.0721750 \\ 0.0193339 & 0.1191920 & 0.9503041 \end{matrix} \quad (5.4)$$

$$\begin{aligned} X &= (R \cdot 0.4124564) + (G \cdot 0.2126729) + (B \cdot 0.0193339) \\ Y &= (R \cdot 0.3575761) + (G \cdot 0.7151522) + (B \cdot 0.1191920) \\ Z &= (R \cdot 0.1804375) + (G \cdot 0.0721750) + (B \cdot 0.9503041) \end{aligned} \quad (5.5)$$




Obrázek 5.10: Snímek prstu převedený z RGB modelu do XYZ.

5.3.2 Barevný model Luv (CIELUV, CIE 1976)

Vznikl jako transformace modelu XYZ pokoušející se udržet vnímavostní jednotnost. To se hodí v oblastech jako je počítačová grafika, kde se zabývají například barevnými světly. Barevný model Luv používá bílý translační bod, který může přinášet užitečné výsledky při práci s jedním zdrojem světla. Pro převod do barevného modelu Luv z XYZ se dají použít rovnice 5.5 [19, 23].

Snímek prstu v barevném modelu Luv je vidět na obrázku 5.11.

$$\begin{aligned} L &\leftarrow \begin{cases} 116Y^{\frac{1}{3}} & \text{pro } Y > 0.008856 \\ 903.3Y & \text{pro } Y \leq 0.008856 \end{cases} \\ u' &\leftarrow \frac{4X}{X + 15 \cdot Y + 3Z} \\ v' &\leftarrow \frac{9Y}{X + 15 \cdot Y + 3Z} \\ u &\leftarrow 13 \cdot L \cdot (u' - u_n) \text{ kde } u_n = 0.19793943 \\ v &\leftarrow 13 \cdot L \cdot (v' - v_n) \text{ kde } v_n = 0.46831096 \end{aligned} \tag{5.5}$$




Obrázek 5.11: Snímek prstu převeden do barevného modelu Luv.

5.3.3 Barevný model Lab (CIE 1976)

Lab byl definován tak, aby pokryl kompletní rozsah barev, které vidí lidské oko a které například pomocí RGB nejdou vyjádřit. Navíc je také nezávislý na zařízení a proto se často používá jako referenční. Lab se zaměřuje spíše na popis, jak barva vypadá, než na to kolik jaké barevné složky je potřeba, aby zařízení tuto barvu vytvořilo. Na obrázku 5.12 je znázorněn barevný model Labu v porovnání s několika dalšími modely [25].

Lab se jako ostatní skládá ze složek, konkrétně L je luminance s hodnotami 0 až 100 (0 černá, 100 bílá) určující jas bodu. Složky a, b určují, jak barva vypadá. Složka a ve směru červeno/zeleném a složka b modro/zeleném. Užití tohoto modelu je například v programu photoshop při zaostřování fotografií, kde je snímek převeden do modelu Lab a pracuje se pouze s L složkou, což zabraňuje vzniku barevných artefaktů na hranách [25].

Převod do barevného modelu Lab se provede rovnicemi 5.6. Na obrázku 5.13 je zobrazen snímek prstu převedený do tohoto barevného modelu [19].



Obrázek 5.12: Barevný prostor Labu v porovnání s několika dalšími barevnými prostory[25].

$$X \leftarrow \frac{X}{X_n} \text{ kde } X_n = 0.950456$$

$$Z \leftarrow \frac{Z}{Z_n} \text{ kde } Z_n = 1.088754$$

$$L \leftarrow \begin{cases} 116Y^{\frac{1}{3}} - 16 & \text{pro } Y > 0.008856 \\ 903.3Y & \text{pro } Y \leq 0.008856 \end{cases}$$


$$a \leftarrow 500(f(X) - f(Y)) + \text{delta}$$

$$b \leftarrow 200(f(X) - f(Z)) + \text{delta}$$

(5.6)

$$f(t) \leftarrow \begin{cases} t^{1/3} & \text{pro } t > 0.008856 \\ 7.787t + \frac{16}{116} & \text{pro } t \leq 0.008856 \end{cases}$$

$$\text{delta} = \begin{cases} 128 & \text{pro 8-bitové obrázky} \\ 0 & \text{pro obrázky s plovoucí desetinnou čárkou} \end{cases}$$




Obrázek 5.13: Snímek převedený do barevného modelu Lab.

5.3.4 Barevný model YCbCr

Barevný model YCbCr zohledňuje citlivost lidského oka na změny jasu. Y složka vyjadřuje intenzitu světla (jas). Cb a Cr složky vyjadřují intenzitu modré a červené složky ve vztahu k zelené složce. Pokud bychom chtěli minimalizovat množství informací s ohledem na vyšší citlivost lidského oka na změnu jasu než na změnu barvy, zachováme Y složku s vyšší přesností než složky Cb a Cr. Tento model se používá u videa nebo digitálních fotografií a ve formátu JPEG, kde díky jeho vlastnostem můžeme zanedbat nedůležité informace [27].

Pro převod z RGB do YCbCr se použijí rovnice 5.7. Na obrázku 5.14 je zobrazen převod snímku prstu do tohoto barevného modelu.


$$\begin{aligned} Y &\leftarrow 0.299 \cdot R + 0.587 \cdot G + 0.114 \cdot B \\ Cr &\leftarrow (R - Y) \cdot 0.713 + \text{delta} \\ Cb &\leftarrow (B - Y) \cdot 0.564 + \text{delta} \end{aligned} \tag{5.7}$$
$$\text{delta} = \begin{cases} 128 & \text{pro 8-bit obrázek} \\ 32768 & \text{pro 16-bit obrázek} \\ 0.5 & \text{pro obrázek s plovoucí desetinnou čárkou} \end{cases}$$



Obrázek 5.14: Snímek prstu převeden do barevného modelu YCbCr.

5.4 Strojové učení

Strojové učení je oblast umělé inteligence, zabývající se možnostmi učení počítačového systému na základě dat. Příkladem strojového učení může být systém, který bude rozlišovat mezi e-maily a spamy nebo jako v našem případě v oblasti biometrie rozhodovací modul pro určení živosti. Dá se říci, že strojové učení se uplatní především tam, kde pracujeme se statistickými údaji, které jsme schopni ohodnotit. U těchto systémů bývá obvykle časově oddělená fáze učení od fáze používání znalostí, jako je znázorněno na obrázku 5.15. Během učení se vytvoří obecná reprezentace typu chování (v našem případě rozdíly mezi živými a neživými prsty). Po naučení se systému předloží nové záznamy a on sám rozhodne například, do které kategorie patří [28, 29, 30].



Obrázek 5.15: Obecné schéma učícího se systému [28].

5.4.1 Základní algoritmy strojového učení

V této kapitole si uvedeme několik základních algoritmů strojového učení lišících se zejména ve způsobu učení.

Učení s učitelem, kde při učení používáme dvojice dat a to vstupní data (např. vektor příznaků) a požadovaný výstup tedy šítek k příslušnému vstupu, který systému musí zadat uživatel. Tento styl učení může být časově náročnější a je tu navíc riziko, že učitel přiřadí výstup špatně a systém se tedy neučí korektně. Tento způsob učení jsme použili při implementaci rozhodování v této práci [28,29,30].

Učení bez učitele, zde nejsou ke vstupním datům přiřazena data výstupní. Systém musí v parametrickém prostoru nalézt třídy objektů, například vyhledáváním shluků [29].

Kombinace učení s učitelem a bez učitele. Systém dostane část vstupních dat s příslušným výstupem, ale další (typicky větší část) je bez výstupu [28, 29, 30].

Zpětnovazebné učení, kdy se učí jednat s ohledem na pozorování světa. Každá akce má určitý dopad na prostředí, což poskytuje zpětnou vazbu ve formě odměny [28, 29, 30].

5.5 Metody strojového učení

Tato kapitola se zaměří na několik konkrétních metod strojového učení především na ty, které jsme testovali v rámci této práce. Testování těchto metod je popsáno v kapitole 7.2

5.5.1 Random forest

Random forest je jedna z metod strojového učení, jejímž jádrem je sestavení rozhodovacích stromů v době učení a výstupem poté bude nejčastější výsledek jednotlivých stromů v době rozhodování. Každý strom je vytvořen na základě náhodné části trénovacích dat. Sestavování rozhodovacích stromů v tomto modelu se ale liší od sestavování obecných rozhodovacích stromů. V našem případě je v každém kroku vybrána náhodná část atributů a pouze otázky týkající se těchto atributů, budou kandidáty na další otázky. U obecných rozhodovacích stromů je jakákoliv otázka kandidátem v libovolném kroku. Model random forest po sestavení odhadne význam jednotlivých atributů, založený na tom o kolik by se odhad zhoršil, pokud by nebyl použit [31].


Random forest má několik výhod. Jako jednu z podstatnějších můžeme považovat, že je velice jednoduché rozšíření pro více možných tříd výsledku, kdy obvykle pracujeme jen se dvěma. Metoda

potřebuje od uživatele zadat dva parametry a to počet atributů vybraných v každém kroku a počet stromů. Algoritmus není na tyto parametry obzvláště citlivý, což pomáhá zmírnit výpočetní zátěž [31].

5.5.2 Neuronové sítě

Lineární metody pracující s lineární kombinací fixních základních funkcí mají užitečné výpočetní a analytické vlastnosti, ale jejich praktická použitelnost je omezena dimenzionalitou. Aby bylo možné používat tyto modely, je nutné adaptovat základní funkci do dat. Neuronové sítě tento problém řeší opravením základních funkcí předem, ale umožní jim být adaptivní. Konkrétně parametrickou formou základních funkcí, kde se hodnoty parametrů přizpůsobují během tréninku [32].

Je mnoho typů neuronových sítí. Zde bude popsána nejpoužívanější vícevrstvá dopředná neuronová síť zpětného šíření (feed-forward back-propagation). Výpočetní schéma vícevrstvé neuronové sítě je znázorněné na obrázku 5.16. Neuronové sítě propojují určité neurony (každý neuron nebo uzel se dá představit jako kontejner s konkrétním numerickým stavem v daném okamžiku). Neurony v jedné vrstvě jsou propojeny s dalšími, tyto spojení plní úlohy přenosu informace z jedné vrstvy do druhé. V první vrstvě zvané Input layer (na obrázku 5.16 jen Input) jsou uchovány informace. Ty jsou poté zpracovány aktivační funkcí, která určí stav neuronů v další vrstvě. Během fáze učení výstupní vrstvy (na obrázku 5.16 Output) obdrží jak predikci od předcházející vrstvy tak hodnotu od učitele. Skryté vrstvy mezi vstupní a výstupní vrstvou, stejně jako aktivační funkce mezi vrstvami poskytují nelinearitu funkci převodu vstupních hodnot z první vrstvy do výsledků predikce na vrstvě výstupní. Spojení mezi vrstvami je reprezentováno maticí, pro transformaci výstupu vrstvy na vstup pro vrstvu následující násobíme touto maticí. Cílem optimalizace neuronových sítí je určit vhodné hodnoty pro tuto matici [31].

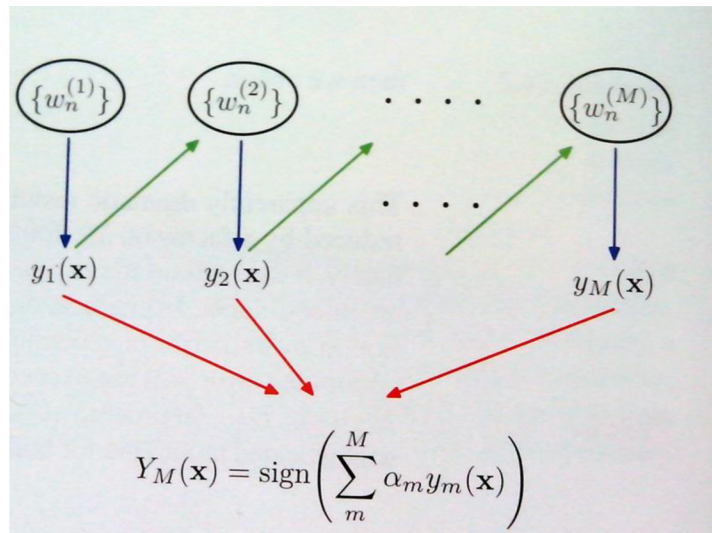


Obrázek 5.16: Výpočetní schéma vícevrstvé neuronové sítě [26].

5.5.3 Boosting

Boosting, nebo-li podporování, je technika kombinující několik základních klasifikátorů do společné formy, která bude účinnější než kterýkoliv ze základních klasifikátorů. Rozhodovací strom je nejoblíbenější základní klasifikátor používaný pro boosting. Často stačí nejjednodušší strom skládající se z jednoho uzlu (tzv. pahýl) [32].

Princip této metody spočívá v postupném trénování základních klasifikátorů, kde každý klasifikátor je trénován ohodnocenými daty, toto ohodnocení závisí na výsledcích předchozího klasifikátoru. Princip je naznačen na obrázku 5.17, $y_m(x)$ značí jednotlivé klasifikátory, $\omega_n^{(m)}$ značí váhy, modré šipky znázorňují proces trénování, zelené upravují z výsledku klasifikátoru váhy, po natrénování všech klasifikátorů jsou zkombinovány a společně poskytnou finální rozhodnutí [32].



Obrázek 5.17: Schéma principu boosting učení [32].

5.5.4 Bayesian network

Bayesian network je pravděpodobnostní grafická model představující sadu náhodných veličin a jejich podmíněných závislostí přes acyklický orientovaný graf. Jako příklad si můžeme představit pravděpodobnostní vztahy mezi příznaky a onemocněními. Díky příznakům a tomuto modelu můžeme vypočítat pravděpodobnost různých onemocnění [32].

V tomto modelu existují dva typy informací a to podmíněné hrany a podmíněné pravděpodobnostní tabulky přiřazené všem uzlům. Pokud v grafu existuje přímá hrana z Y do X, nazýváme Y rodičem X a obráceně X je potomkem Y. Podmíněná pravděpodobnostní tabulka popisuje pravděpodobnost dědění hodnoty od rodiče [31].

6 Implementace

Pro samotnou implementaci detekce živosti jsme použili programovací jazyk C++ a knihovnu OpenCV, která mi značně usnadnila implementační část.

6.1 OpenCV

OpenCV je volná knihovna pro počítačové vidění, zpracování obrazu a strojové učení. Původně byla vyvíjena společností Intel, nyní je spravována Willow Garage a Itseez. Napsaná v C/C++, ale obsahuje rozhraní pro C/C++, Java, Python. Je multiplatformní a poskytuje všestranný a spolehlivý nástroj používaný mnoha uživateli. Pro výpočty v reálném čase používá IPP (Integrated Performance Primitives) a implementaci vybraných algoritmů na grafickém jádře. IPP je více vláknová knihovna funkcí pro multimédia a aplikace pro zpracování dat od společnosti Intel. Uvádí se [26], že OpenCV obsahuje přes 2500 optimalizovaných algoritmů a má přes 2.5 milionů stáhnutí po celém světě [24, 26].

OpenCV jsme využili pro zpracování snímků, kde jsme například jednotlivými příkazy byli schopni snímek načíst, oříznout nebo převést do jiného barevného modelu. Dále jsme knihovnu použili při implementaci strojového učení. Konkrétní příkazy a části programu budou popsány v následujících kapitolách.

6.2 Databáze

Program pro svoji funkčnost potřebuje trénovací databázi, kterou bude učit příslušnou metodou strojového učení. Pro testování bude sloužit buď testovací databáze zadaná do parametru, nebo konkrétní jeden snímek. Je potřeba dodržovat určitý formát zápisu snímků, především pak v trénovací databázi. Jednotlivé snímky jednoho prstu (osvícené každý jinou diodou) musí mít koncovku `_image_3.pgm` pro červenou LED, `_image_4.pgm` pro zelenou LED, `_image_5.pgm` pro modrou a `_image_6.pgm` pro infračervenou LED. Dále je nutné, aby intenzita diod odpovídala intenzitě, se kterou jsme pracovali. Názvy živých snímků musí v trénovací databázi obsahovat slovo `zivy`, aby byl program schopný rozpoznat živé vzorky a mohl příslušnou metodu strojového učení správně učit. Při předávání názvu snímku programu předáme jen samotný název bez koncovek pro jednotlivé LED snímky, například pokud chceme, aby program při učení použil snímek živého prstu, zadám jen `zivy_1.1`, aplikace sama připojí jednotlivé koncovky a bude pracovat jak se snímkem `zivy_1.1_image_3.pgm` tak `zivy_1.1_image_6.pgm`. Je nutné, aby všechny snímky byly dostupné. Při dodávání textového souboru s výčtem prvků, jak pro testovací tak trénovací databázi, je na konci souboru nutný jeden volný řádek.

Velikosti databází jsou staticky definované na začátku programu makrem, to konkrétně udává, kolik prvků ze souboru se načte a dále se používá při strojovém učení. Odlišuje se makro pro trénovací a testovací databázi `#define NUMBER_OF_TRAINING_SAMPLES 73` a `#define NUMBER_OF_TESTING_SAMPLES 73`. Společně s těmito makry se i definuje počet atributů, který bude pro každý snímek získán a předán modelu strojového učení buď pro naučení, nebo pro rozpoznání prstu.

6.3 Struktura programu

Program je rozdělen do dvou částí, každá část obsahuje jeden cyklus `for`. První část pracuje s trénovací databází, kde musí vytvořit matici s atributy živých a neživých snímků, která bude použita pro strojové učení. Druhá část vytvoří matici pro testovací databázi nebo otestuje jen jeden konkrétní snímek. Obě části jsou tedy ve formě cyklu, který načítá názvy snímků živých a neživých prstů, v dalším vnořeném cyklu pro jeden prst pracuje s jednotlivými snímky a získává o nich informace.

Mezi výše zmiňovanými částmi nalezneme učení konkrétní metody strojového učení. Zde bylo otestování více metod, kdy jejich výsledky budou popsány v kapitole 7.2.

6.4 Histogram pro černobílý snímek

Po oříznutí snímků osvětlených jednotlivými diodami budeme pro každý snímek jednoho prstu vytvářet histogram a ten analyzovat. Definujeme si počet košů/tříd (tento pojem je vyobrazen na obrázku 5.6) `int bins = 256;` rozsah hodnot, kterých pixely mohou nabývat `float xranges[] = {0, 256};`. U více kanálových (barevných snímků) by bylo nutné rozložit obrázek do jednotlivých rovin nebo-li rozdělit vícekanálové pole do několika jednonábových. Vytvoříme histogram [19]

```
hist = cvCreateHist(1, hsize, CV_HIST_ARRAY, ranges, 1);
```

- První parametr udává počet rozměrů.
- Velikost pole ne-boli počet košů histogramu.
- Formát reprezentace dat v histogramu `CV_HIST_ARRAY` zastupuje vícerozměrné pole.
- Rozsah pro koše/třídy histogramu, je potřeba k určení jaké hodnoty spadají do jakého koše. V našem případě do každého koše spadá jedna příslušná hodnota, je ale možné nastavit méně širších košů.
- Udává, zda se bude jednat o rovnoměrné rozmístění košů.

Po vytvoření histogramu jej vypočítáme [19]

```
cvCalcHist(planes, hist, 0, NULL);
```

- První parametr udává zdrojové pole s hodnotami pixelů.
- Výstupní histogram.
- Příznak akumulace, pokud je 1 tak histogram není vymazán a můžeme do jednoho histogramu zanést údaje z více obrázku/polí.
- Poslední parametr je volitelná maska.

Pro analýzu histogramu je nutné určit maximální a minimální hodnotu (četnost) košů, což je údaj potřebný pro normalizaci výsledků histogramu.

6.5 Histogram pro barevný snímek

Před tvorbou samotného histogramu pro barevný model je nejprve nutné sloučit snímky ve stupních šedi (jednokanálové) do barevného (tří-kanálového), na to použijeme funkci [19]

```
cvMerge(c, b, a, NULL, d);
```

- Zde první čtyři parametry slouží k zadání vstupních snímků respektive matic, v našem případě použijeme jen tři snímky a čtvrtý necháme NULL.
- Poslední parametr je výsledný snímek, který musí být předpřipraven jako vícekanálový.

Po sloučení získáme snímek v barevném modelu RGB, který můžeme následující funkcí převést do libovolného barevného modelu [19]

```
cvCvtColor(d, d, CV_BGR2YCrCb);
```

- První parametr udává zdrojový obrázek.
- Druhý parametr udává cílový obrázek.
- Třetí parametr je kód pro převod v uvedeném příkladu z RGB (který je v OpenCV uchovávan v pořadí BGR) do YCrCb.

Samotná tvorba histogramu se od jednokanálového snímku drobně liší. Je například potřeba rozdělit snímek na jednotlivé kanály, to provede příkaz `split`. Způsob vytvoření samotného histogramu je jiný, protože jsme nyní histogram nepředpřipravovali, ale rovnou použili funkci [19]

```
calcHist(&xyz_planes[0], 1, 0, Mat(), x_hist, 1, &histSize, &histRange, uniform, accumulate);
```

- První parametr udává zdrojové pole, jeden z výsledků operace `split`.
- Druhý parametr je počet zdrojových obrázků.
- Seznam kanálů, kdy první je číslován od 0.
- Volitelná maska.
- Výstup, kam má být histogram vytvořen.
- Počet rozměrů histogramu.
- Počet košů histogramu.
- Rozsah pro koše/třídy histogramu, je potřeba k určení jaké hodnoty spadají do jakého koše.
- Udává, zda se bude jednat o rovnoměrné rozmístění košů.
- Příznak akumulace, pokud je 1 tak histogram není vymazán a můžeme do jednoho histogramu zanesť údaje z více obrázku/polí.

6.6 Strojové učení

Pro strojové učení jsou vytvořeny 3 matice: trénovací, testovací a třetí obsahující štítky k trénovací, ty při učení určí, zda se jedná o živý či neživý prst. Do matic jsou postupně ukládány hodnoty ze snímků konkrétních prstů. V následujících podkapitolách se zaměříme na způsoby implementace testovaných

metod učení, především na zadávané parametry, jelikož samotná predikce probíhá příkazem, kde metodě předáme například příslušný řádek v trénovací matici.

6.6.1 Neuronové sítě

V první řadě musíme definovat vrstvy [26]

```
int layers_d[] = { ATTRIBUTES_PER_SAMPLE, 10, 2};  
Mat layers = Mat(1, 3, CV_32SC1);
```

Na prvním řádku definujeme tři vrstvy 36->10->2. Jeden vstupní uzel bude odpovídat atributu vzorku, 10 skrytých uzlů a pro každou výstupní třídu jeden výstupní uzel. Druhý řádek vytvoří matici jeden řádek tři sloupce, do kterých nahrajeme vrstvy, poslední parametr udává, že půjde o signed integer 32bitů [19].

Vytvoření neuronové sítě provede následující úsek kódu [26]

```
CvANN_MLP* nnetwork = new CvANN_MLP;  
nnetwork->create(layers, CvANN_MLP::SIGMOID_SYM, 0.6, 1);
```

- První parametr odkazuje na matici, kam byly nahrány jednotlivé vrstvy.
- Druhý parametr určuje aktivační funkci pro každý neuron.
- Následují dva parametry aktivační funkce.

Před samotným naučením, kde předáme jen trénovací matici a její ohodnocení je nutné nastavit parametry (ty budou také použity při trénování) [26]

```
CvANN_MLP_TrainParams params2 = CvANN_MLP_TrainParams(  
    cvTermCriteria(CV_TERMCRIT_ITER+CV_TERMCRIT_EPS, 1000, 0.000001),  
    0.1, 0.1);
```

- První parametr udává, že učení skočí po 1000 iteracích nebo až bude mezi iteracemi rozdíl ve váhách 0.000001.
- Další parametry jsou koeficienty pro zpětné šíření.

6.6.2 Boosting

Samotná implementace ostatních metod strojového učení je obdobná, nastavíme parametry, vytvoříme objekt, který následně díky trénovací matici a jejího ohodnocení naučíme. Nastavení parametrů u boostingu se provede následujícím příkazem [19]

```
CvBoostParams params = CvBoostParams(CvBoost::REAL, 100, 0.95, 25,  
false, priors);
```

- První parametr udává typ posilovacího algoritmu.
- Druhý udává počet slabých klasifikátorů.
- Je trim rate, což je hodnota (rozsah 0-1) pro odstranění vzorků s vahou $< 1 - \text{trim rate}$.

- Maximální hloubka stromu.
- Zda se má provádět výpočet náhradního rozdělení.
- Váhy výstupů.

Protože `CvBoostParams` dědí z `CvDTreeParams`, nastavili jsme i další parametry jako minimální počet vzorků a další méně podstatné údaje [19].

6.6.3 Random forest

Po vytvoření matic a nastavení shodných priorit pro oba výstupy nastavíme parametry [19]

```
CvRTParams params = CvRTParams(25,6, 0, false, 15, priors, false, 4,
100, 0.01f, CV_TERMCRIT_ITER | CV_TERMCRIT_EPS);
```

- První parametr udává maximální hloubku.
- Minimální počet vzorků.
- Přesnost regrese.
- Čtvrtý parametr je pro případné umožnění výpočtu náhradního rozdělení.
- Maximální počet kategorií při provádění rozdělení uzlu stromu.
- Váhy/priority výstupů.
- Pokud je `true`, bude vypočten význam jednotlivých proměnných.
- Počet proměnných vybraných v uzlu při hledání nejlepšího rozdělení.
- 100 udává maximální počet stromů v lese.
- Následuje parametr určující přesnost lesu.
- Poslední parametr jsou ukončující kritéria, v našem případě naučením maximálního počtu stromů v lese a překročením přesnosti lesa.

7 Testování

V následující kapitole bude kromě popsání testování samotné aplikace i popsáno testování a výběr některých jeho částí jako metody strojového učení nebo barevné modely. Při výběru možných řešení jsme se zaměřovali, aby úspěšnost aplikace byla co nejvyšší u rozpoznání živých prstů, přičemž správné určení neživých bylo až na druhém místě.

7.1 Výběr barevného modelu

Pro výběr barevného modelu a jeho konkrétní složky jsme použili několik trénovacích a testovacích databází. V aplikaci jsme vyzkoušeli metody strojového učení pospané v kapitole 5.5, přičemž nejlepších výsledků bylo dosaženo s metodami strojového učení random forest a neuronové sítě, detailnější testování všech metod strojového učení z kapitoly 5.5 je popsáno v kapitole 7.2. Při tomto testování jsme se především zaměřovali na testování s neuronovými sítěmi. Neuronové sítě se jeví jako nejvhodnější model strojového učení. Ze snímků jsme získávali pouze hodnoty týkající se analýzy histogramu barevných modelů, tedy pro každou složku průměr a směrodatnou odchylku. Postupně jsme testovali nejrůznější barevné modely, a jak kombinace jejich složek upraví výsledky testování. Vyzkoušeli jsme 4 barevné modely popsané v kapitole 5.3. Tabulky s výsledky pro jednotlivé trénovací a testovací databáze na neuronových sítích jako metodě strojového učení jsou uvedeny v příloze B.

7.1.1 Barevný model XYZ

Výsledky testování tohoto barevného modelu jsou pro neuronové sítě popsány v tabulce 7.1. V tabulce je vidět, že při použití pouze jedné složky dosahovala nejlepších výsledků Y složka, která v tomto barevném modelu zastupuje jas. Přesto při vytvoření dvojic složek se lépe jeví kombinace bez Y složky a to konkrétně XZ, jak bylo uvedeno v kapitole 5.3.1 X představuje zastoupení červené/zelené barvy a Z odpovídá modré/žluté. Při použití všech tří složek dosahujeme podobných výsledků jako u použití pouze XZ.

Při testování s random forest dosahovalo nejlepších výsledků použití XYZ 95%, YZ 93% a XZ 91% správně určených živých prstů.

Tabulka 7.1: Výsledky barevného modelu XYZ pro neuronové sítě.

složka	x	y	z	xyz	xy	xz	yz
úspěšné živých	83%	91%	88%	95%	92%	95%	92%
úspěšně neživých	59%	73%	69%	71%	70%	75%	80%

7.1.2 Barevný model Luv

Barevný model Luv se jeví jako nejúspěšnější a bude použit v aplikaci pro získání hodnot, výsledky pro neuronové sítě jsou v tabulce 7.2. Už při použití jednotlivých barevných složek dosahujeme lepších výsledků než u barevného modelu XYZ. Při použití dvou barevných složek úspěšnost roste na 95% pro živé a 77% pro neživé. Všechny tři složky dohromady úspěšnost živých ještě zvedli a to na

97%, pokles nastal u neživých, který nám nevadí, protože jak bylo zmíněno na začátku, důraz bude kladen především na správné určení živých prstů.

S modelem random forest jsme dosáhli průměrně úspěšnosti rozpoznání živých prstů 91% až na použití složek XYZ, kde jsme dosáhli 100% u živých prstů avšak 53% u neživých.

Tabulka 7.2: Výsledky barevného modelu Luv pro neuronové síť.

složka	x	y	z	xyz	xy	xz	yz
úspěšně živých	89%	91%	93%	97%	93%	93%	95%
úspěšně neživých	72%	67%	73%	73%	71%	72%	77%

7.1.3 Barevný model Lab

V tabulce 7.3 nalezneme výsledky testování barevného modelu Lab. Tento model také poskytuje poměrně dobré výsledky pohybující se u živých prstů od 90% až k 95% při použití všech tří složek. Přesto model Luv dosahuje lepších výsledků.

Barevný model Lab dosahoval lepších výsledků u metody strojového učení random forest, zde složky XZ a YZ dosahovali 96% a XYZ dosáhl až 100% správně určených živých prstů. Pro neživé prsty měli XZ a YZ 73%, za to XYZ totožně jako u Luv 53% správně určených neživých prstů.

Tabulka 7.3: Výsledky barevného modelu Lab pro neuronové síť.

složka	x	y	z	xyz	xy	xz	yz
úspěšně živých	89%	92%	91%	95%	91%	94%	92%
úspěšně neživých	72%	64%	69%	72%	76%	72%	80%

7.1.4 Barevný model YCbCr

Výsledky posledního barevného modelu a to YCbCr jsou v tabulce 7.4. Nejlépe se zde jeví výsledky kombinace složek XY úspěšnost 94% pro živé prsty a 75% pro neživé. Ještě lepší výsledky byly dosaženy za použití XYZ úspěšnost 95% živých prstů bylo rozpoznáno správně a 73% neživých.

Tento barevný model si vedl dobře i s metodou strojového učení random forest, kde s využitím složek Z, XY, YZ, XZ, XYZ jsme dosáhli 96%, přičemž nejvyšší úspěšnosti u neživých se dosáhlo s YZ a to 80% (u ostatních jsme se pohybovali u 70%).

Tabulka 7.4: Výsledky barevného modelu YCbCr pro neuronové síť.

složka	x	y	z	xyz	xy	xz	yz
úspěšně živých	88%	91%	90%	95%	94%	92%	93%
úspěšně neživých	74%	71%	68%	73%	75%	72%	75%

7.1.5 Výsledek

Barevný model, který použijeme v aplikaci na analýzy histogramu, jsme zvolili **Luv** konkrétně jeho složky xyz. Dále při testování vyzkoušíme k analýze přidat druhý barevný model, a jak ten ovlivní

výsledky. Otestujeme **XYZ** (složky **xz**), **Lab** (**xyz**) a **YCbCr** (**xyz**) což jsou modely, které s konkrétními složkami dosáhli druhých nejlepších výsledků a to 95% u určování živých prstů.

7.2 Výběr metody strojového učení

Pro výběr metody strojového učení jsem použil stejné testovací a trénovací databáze jako u barevného modelu. V aplikaci jsme zkoušeli metody strojového učení popsané v kapitole 5.5 a ze snímků získávali průměrnou hodnotu pixelů, jejich směrodatnou odchylku pro každou LED a analyzovali histogramy těchto snímků (průměr a směrodatná odchylka). Také jsme analyzovali histogram výše zvoleného modelu, tedy Luv a jeho xyz složek. Výsledkem bude zvolená metoda strojového učení, u které budeme později testovat přidávání dalších atributů ze snímků a jejich vliv na změnu přesnosti u rozpoznávání živých a neživých prstů.

7.2.1 Random forest

Výsledky testování metody strojového učení Random forest jsou v tabulce 7.5, průměrná úspěšnost u živých prstů je poměrně vysoká (95%), přičemž minimální úspěšnost byla 91% a maximální 97%. Dosáhli jsme i poměrně vysoké přesnosti u neživých prstů a to 87%. Metoda strojového učení random forest se tedy jeví jako potenciální kandidát do finální aplikace.

Tabulka 7.5: Výsledky random forestu jako modelu strojového učení.

databáze		Úspěšnost	
trénovací	testovací	živých správně	neživých správně
5a	5b	91%	74%
5b	5a	95%	92%
6a	6b	97%	88%
6b	6a	97%	96%
7a	7b	95%	96%
7b	7a	97%	85%
8a	8b	91%	81%
8b	8a	95%	85%
průměr		95%	87%

7.2.2 Boosting

Boosting se jako metoda strojového učení nejeví tak dobře jako předcházející random forest, jeho výsledky jsou v tabulce 7.6. Průměrná úspěšnost u živých prstů je nižší a to 90% a pokles nastal i u neživých prstů, kde jsme klesly na 76%. Posilování se nejeví jako vhodný model pro naše potřeby.

Tabulka 7.6: Výsledky boostingu jako modelu strojového učení.

databáze		Úspěšnost	
trénovací	testovací	živých správně	neživých správně
5a	5b	93%	62%
5b	5a	93%	81%
6a	6b	86%	81%
6b	6a	86%	85%
7a	7b	95%	77%
7b	7a	86%	77%
8a	8b	93%	81%
8b	8a	84%	66%
průměr		90%	76%

7.2.3 Bayes Classifier

Bayes Classifier má své výsledky zobrazeny v tabulce 7.7, na první pohled si všimneme vysoké úspěšnosti u neživých prstů, až na jednu sadu databází se držíme vždy nad 90% a celkový průměr je tedy 93%. Vysoká je i úspěšnost živých prstů, kde máme 94% správně určených. Celková úspěšnost je tedy vyšší než u metody random forest ,ale jak bylo již zmíněno stěžejní je pro nás úspěšnost u živých prstů, která je v případě random forest vyšší.

Tabulka 7.7: Výsledky Bayes Classifier jako modelu strojového učení.

databáze		úspěšnost	
trénovací	testovací	živých správně	neživých správně
5a	5b	95%	100%
5b	5a	93%	96%
6a	6b	95%	96%
6b	6a	100%	70%
7a	7b	100%	92%
7b	7a	91%	96%
8a	8b	91%	96%
8b	8a	86%	100%
průměr		94%	93%

7.2.4 Neuronové sítě

Výsledky poslední metody strojového učení jsou v tabulce 7.8. Úspěšnost u živých prstů je velice vysoká, kdy v průměru dosahujeme 98%. Neživé prsty dosahují, až na jeden případ, úspěšnosti 85% a více, kde díky jednomu horšímu výsledku je průměr 88%. Tento model má nejvyšší úspěšnost u živých prstů a proto jej ve finální aplikaci použijeme a budeme jej dále testovat a pokusíme se jeho účinnost zvednout přidáním dalších atributů ze snímku.

Tabulka 7.8: Výsledky neuronových sítí jako modelu strojového učení.

databáze		úspěšnost	
trénovací	testovací	živých správně	neživých správně
5a	5b	97%	70%
5b	5a	97%	92%
6a	6b	97%	85%
6b	6a	97%	88%
7a	7b	97%	92%
7b	7a	100%	92%
8a	8b	97%	85%
8b	8a	100%	96%
průměr		98%	88%

7.3 Přidávání atributů

Po zvolení neuronových sítí jako metody strojového učení a zvolení optimálního barevného modelu jsme přidávali další atributy tedy vlastnosti snímků a sledovali, jak ovlivní úspěšnost aplikace. Rozhodli jsme se přidat medián ze získaných pixelů, medián při analýze histogramu a analyzovat další barevné modely. Přidané atributy jsme zkoušeli i kombinovat, výsledky nalezneme v následujících podkapitolách.

7.3.1 Přidání druhého barevného modelu

Rozhodli jsme se začít přidáním druhého barevného modelu, zvolil jsem modely, které se při testování jevíly nejúspěšněji a to **XYZ** (složky **xz**), **Lab** (**xyz**) a **YCbCr** (**xyz**), více v kapitole 7.1. Tento atribut jsme přidal jako první, protože jsem z něj chtěli vycházet a k jednotlivým barevným modelům přidávat další atributy.

V tabulce 7.9 jsou vidět výsledky po přidání barevného modelu **XYZ**. Oproti původním výsledkům, které nalezneme v tabulce 7.8, nedošlo u správně určených živých prstů ke změně. Byl zaznamenán pokles úspěšnosti u určování neživých prstů, přesto jak bylo výše zmíněno, rozhodli jsme se i pro zatím ne tak dobře se jevící barevný model testovat dále přidáváním dalších atributů.

Tabulka 7.9: Přidání barevného modelu XYZ a jeho složek xz do aplikace.

databáze		úspěšnost	
Trénovací	testovací	živých správně	neživých správně
5a	5b	97%	70%
5b	5a	95%	92%
6a	6b	100%	88%
6b	6a	97%	74%
7a	7b	97%	74%
7b	7a	100%	70%
8a	8b	97%	85%
8b	8a	100%	96%
průměr		98%	81%

Další přidáný model byl **Lab**, kde se přidali všechny jeho složky tedy xyz. Výsledky aplikace jsou v tabulce 7.10. Samotný model Lab celkové úspěšnosti také nepřidal, nastal mírný pokles úspěšnosti, jak u rozlišování živých tak neživých prstů.

Tabulka 7.10: Přidání barevného modelu Lab do aplikace.

databáze		úspěšnost	
trénovací	testovací	živých správně	neživých správně
5a	5b	95%	66%
5b	5a	95%	92%
6a	6b	95%	92%
6b	6a	97%	85%
7a	7b	97%	96%
7b	7a	100%	74%
8a	8b	97%	85%
8b	8a	100%	92%
průměr		97%	85%

Poslední přidáný model byl **YCbCr** a konkrétně jeho složky xyz. S přidáním tohoto modelu došlo k nejmenším, ale opět k záporným změnám úspěšnosti rozlišování prstů, více v tabulce 7.11. Úspěšnost u živých prstů se tedy nezměnila, zato u neživých se zhoršila z 88% na 85%.

Tabulka 7.11: Přidání barevného modelu YCbCr do aplikace.

databáze		úspěšnost	
trénovací	testovací	živých správně	neživých správně
5a	5b	97%	62%
5b	5a	97%	81%
6a	6b	97%	88%
6b	6a	97%	77%
7a	7b	97%	96%
7b	7a	100%	92%
8a	8b	97%	88%
8b	8a	100%	96%
průměr		98%	85%

7.3.2 Přidání mediánu k histogramu

Další atributy jsme přidávali k přidáním barevným modelům zmíněných v kapitole 7.3.1, měli jsem tedy 4 selekce, které jsem se snažil vylepšit. Vždy se skládala z údajů o bodech samotných a analýze histogramu těchto bodů a liší se barevnými modely, kde jako základ je Luv(xyz) a buď není přidán žádný další, nebo je přidán **XYZ** (složky **xz**), **Lab** (xyz) či **YCbCr** (xyz).

V tabulce 7.12 jsou uvedeny úspěšnosti pro konkrétní barevné modely. Oproti původním hodnotám 98% úspěšnost u živých a 88% u neživých (bez přidávání dalších atributů) vidíme, že u všech modelů došlo naopak k lehkému zhoršení než k očekávanému zlepšení.

Tabulka 7.12: Úspěšnosti po přidání mediánu k histogramům.

barevné modely	úspěšnost	
	živých správně	neživých správně
jen Luv	98%	80%
přidán YCbCr	98%	87%
přidán XYZ	98%	81%
přidán Lab	97%	88%

7.3.3 Přidání mediánů k pixelům

Po přidání mediánu k pixelům můžeme v tabulce 7.13 vidět, že úspěšnost určování živých prstů zůstala beze změny. Úspěšnost u neživých prstů se dokonce u barevného modelu YCbCr zlepšila z 88% na 90%.

Tabulka 7.13: Úspěšnosti po přidání mediánu k pixelům.

barevné modely	úspěšnost	
	živých správně	neživých správně
jen Luv	98%	82%
přidán YCbCr	98%	90%
přidán XYZ	98%	82%
přidán Lab	98%	83%

7.3.4 Přidání mediánu k pixelům i histogramům

Poslední experiment se týkal přidání mediánu jak k pixelům, tak i k histogramům, kde bylo dosaženo zlepšení jak na straně úspěšné detekce živých tak i neživých prstů, výsledky jsou zobrazeny v tabulce 7.14. Samotný model Luv a model Luv s přidáním YCbCr dosahují oba účinnosti 99% při určování živých prstů, u neživých prstů dosahuje lepších výsledků přidání modelu YCbCr, kde oproti původní úspěšnosti 88% jsme dosáhli 90%.

Tabulka 7.14: Úspěšnosti po přidání mediánu jak k pixelům, tak i k histogramům.

barevné modely	úspěšnost	
	živých správně	neživých správně
jen Luv	99%	82%
přidán YCbCr	99%	90%
přidán XYZ	98%	84%
přidán Lab	98%	91%

7.4 Nejlepší výsledky

Nejlepších výsledků při výběru barevného modelu bylo dosaženo s modelem Luv a konkrétně jeho složek xyz. Jako nejúspěšnější metoda strojového učení se ukázaly neuronové sítě.

Při testování přidávání atributů bylo nejlepších výsledků dosaženo u pixelů při použití směrodatné odchylky, průměru a mediánu pro osvětlení jednotlivými LED. U histogramu pro jednotlivé LED bylo použito průměru, směrodatné odchylky a medián. Po převedení do barevných modelů a analýzy jejich histogramů (průměr a směrodatná odchylka) se ukázali jako nejlepší barevné modely Luv a YCbCr.

8 Závěr

Problematika biometrie a detekce živosti je popsána v kapitolách 2 a 3. Z oblasti biometrie je lehce nahlédnuto do historie, jsou osvětleny některé základní pojmy, principy a několik biometrických vlastností. V kapitole 3 je popsáno několik základních principů testování živosti prstu, jelikož se jedná o nejrozšířenější biometrickou vlastnost a i samotná diplomová práce se zabývá živostí prstu.

V kapitole 4 je na základě několika snímků navrhnout způsob detekce živosti k optickému senzoru. Navrhnuté principy budou dále testovány jak na živých tak neživých prstech, kde se projeví, zda jsou vhodné pro testování živosti. Mezi konkrétně navrhované principy tedy patří analýzy histogramů, výpočet směrodatné odchylky a průměru.

Ukázalo se, že navrhované vlastnosti prstu se pro detekci živosti hodí, ale po testování v kapitole 7 bylo zjištěno, že pro zlepšení úspěšnosti budou doplněny dalšími vlastnostmi. Nejlepších výsledků bylo dosaženo při použití průměru, směrodatné odchylky a mediánu z hodnot bodů při osvětlení jednodílnými LED. Pro snímky od jednotlivých LED byly také analyzovány histogramy, kde jsem počítal průměr, směrodatnou odchylku a medián. Ze snímků červené, modré a zelené diody byl vytvořen barevný snímek, který byl převeden do barevných modelů Luv a YCbCr, kde byl také vytvořen histogram a určen průměr a směrodatná odchylka. Dohromady se jednalo o 36 atributů.

Testování probíhalo vždy na dvou databázích, které vznikly rovnoměrným rozdělením všech snímků živých a neživých prstů. Jednalo se o 92 snímků živých prstů od 23 osob, 54 snímků umělých prstů a nejrůznějších materiálů. Při osmi kombinacích těchto databází bylo dosaženo úspěšnosti 99% u rozpoznávání živých prstů a 90% u neživých prstů. Jako nejčastěji špatně vyhodnocené neživé snímky byly kromě jednoho umělého prstu, například bílá plastová rukojeť nože nebo žlutá plastelína. Ukázalo se tedy, že využívání osvětlení o různé vlnové délce se jeví jako vhodný způsob detekce živosti.

Jako možné rozšíření aplikace by mohlo být zakomponování detekce živosti přímo do aplikace provádějící snímání prstu a okamžité rozpoznání. Mezi další rozšíření by mohlo patřit například přidání sekundární detekce živosti využívající též kamery senzoru a měřící změnu šířky papilárních linií v závislosti na tepu lidského srdce, kde by pravděpodobně bylo ale nutné zajistit fixaci prstu.

Literatura

- [1] DRAHANSKÝ, Martin. *Biometrické systémy: studijní opora* [online]. 2006 [cit. 2012-11-24]
- [2] DRAHANSKÝ, Martin a Filip ORSÁG. *Biometrie*. 1. vyd. [Brno: M. Drahanský], 2011, 294 s. ISBN 978-80-254-8979-6.
- [3] DRAHANSKÝ, Martin. *Fingerprint recognition technology: related topics : skin disease, image quality and liveness detection*. Saarbrücken: LAP Lambert Academic Publishing, c2011, 172 s. ISBN 978-3-844-33007-6.
- [4] RAK, Roman. *Biometrie a identita člověka ve forenzních a komerčních aplikacích*. 1. vyd. Praha: Grada, 2008, 631 s., 32 s. barev. obr. příl. ISBN 978-80-247-2365-5.
- [5] *Handbook of biometrics*. Editor Anil K Jain, Patrick J Flynn, Arun A Ross. New York: Springer Science Business Media, 2008, x, 556 s. ISBN 978-0-387-71040-2.
- [6] *Handbook of fingerprint recognition*. New York: Springer Science, 2003, 348 s. ISBN 03-879-5431-7.
- [7] *Přístroj zvaný oko* [online]. [cit. 2012-11-26]. Dostupné z: <http://veronika.sovova.sweb.cz/interest/oko.htm>
- [8] DRAHANSKÝ, Martin. Přehled biometrických systému a testování jejich spolehlivosti. *Kongres Bezpečnosti sítí* [online]. 2007, s. 37 [cit. 2012-12-27]. Dostupné z: http://data.security-portal.cz/clanky/113/odborne_prednasky/Prezentace.pdf
- [9] LODROVA, Dana. *Spoofing and anti-spoofing ,methods for fingerprint sensor* [online]. 2009 [cit. 2012-12-28].
- [10] YAU, Wei-Yun. *Fake finger detection by finger color change analysis*. Heidelberg, 2007. ISBN 3-540-74548-3 978-3-540-74548-8.
- [11] HENGFOSS, Clarissa et al. *Dynamic liveness and forgeries detection of the finger surface on the basis of spectroscopy in the 400–1650 nm region* [online]. 2011 [cit. 2012-12-28].
- [12] SEVERINGHAUS. History of Blood Gas Analysis: VII. Pulse Oximetry. *Masimo* [online]. s. 4 [cit. 2012-12-28]. Dostupné z: http://www.masimo.com/Nellcorfiction/PDF_FF/History%20of%20Pulse%20Oximetry.pdf
- [13] Product Sheet 3D-Enroll. *TBS BIOMETRICS* [online]. [cit. 2012-12-28].
- [14] PAN, Gang. Liveness Detection for Face Recognition. *Recent Advances in Face Recognition* [online]. 2008, s. 109-124 [cit. 2012-12-28].
- [15] TOTH, Bori. Liveness Detection for Iris Recognition. *Biometrics and E-Auth entication over Open Networks* [online]. 2005, s. 27 [cit. 2013-05-14].
- [16] GIBILISCO, Stan. *Statistika bez předchozích znalostí*. Vyd. 1. Brno: Computer Press, 2009, 272 s. ISBN 978-80-251-2465-9.
- [17] SZELISKI, Richard. *Computer Vision: Algorithms and Applications*. London: Springer, 2010, 812 s. Texts in computer science. ISBN 978-1-84882-934-3.
- [18] Jak používat histogram během fotografování. MODR, Vlastimil. *Fotografie a grafika* [online]. 2011 [cit. 2013-04-15]. Dostupné z: <http://www.photo-modr.estranky.cz/clanky/zaklady-fotografovani/jak-pouzivat-histogram-behem-fotografovani.html>
- [19] OPENCV. *OpenCV 2.4.5.0 documentation* [online]. 2011 [cit. 2013-04-17]. Dostupné z: <http://docs.opencv.org/>
- [20] LEAVINGCERTMATHS. Histogram - mean and median. *YouTube* [online]. [cit. 2013-04-15]. Dostupné z: <http://www.youtube.com/watch?v=vMrc6dP8pCo>

- [21] Introduction to Colour Science. *Techmind.org* [online]. 2001. vyd. [cit. 2013-04-16]. Dostupné z: <http://www.techmind.org/colour/>
- [22] XYZ. TROST, Stefan. *Software and Individual Solutions by Stefan Trost Media* [online]. 2007. vyd. [cit. 2013-04-16]. Dostupné z: <http://www.sttmedia.com/colormodel-xyz>
- [23] CIE Luv Color. WARD, Gregory. *Anywhere Software* [online]. [cit. 2013-04-17]. Dostupné z: <http://www.anywhere.com/gward/pixformat/cieluvf1.html>
- [24] 2012-GZN-témata ke zkoušce [online]. 2012 [cit. 2013-04-20]. Dostupné z: http://merlin.fit.vutbr.cz/wiki/index.php/2012-GZN-t%C3%A9mata_ke_zkou%C5%A1ce
- [25] Barevný model L*a*b. PIHAN, Roman. *FotoRoman* [online]. 2003 [cit. 2013-04-17]. Dostupné z: http://www.fotoroman.cz/glossary2/3_lab.htm
- [26] OPENCV. *OpenCVWiki* [online]. [cit. 2013-04-20]. Dostupné z: <http://opencv.willowgarage.com/wiki/>
- [27] Color space. *RealWorld Graphics: web and application graphic resources* [online]. 2005 [cit. 2013-04-17]. Dostupné z: <http://www.rw-designer.com/color-space>
- [28] *Strojové učení*. [online]. [cit. 2013-04-17]. Dostupné z: http://sorry.vse.cz/~berka/docs/izi456/kap_4.pdf
- [29] Metody strojového učení. *FJFI ČVUT* [online]. s. 4 [cit. 2013-04-18]. Dostupné z: <http://fyztyd.fjfi.cvut.cz/2003/cd/prispevky/sbpdf/strojuc.pdf>
- [30] Machine Learning and Neural Networks. *Fakulta informačních technologií VUT v Brně* [online]. [cit. 2013-04-18]. Dostupné z: <https://www.fit.vutbr.cz/study/courses/SIN/private/lectures/SIN-NN.pdf>
- [31] ZHANG, Yan-Qing. *Machine learning in bioinformatics*. Hoboken, N.J.: Wiley, c2008, xviii, 456 s. ISBN 978-0-470-11662-3.
- [32] BISHOP, Christopher M. *Pattern recognition and machine learning*. New York: Springer Science Business Media, 2006, xx, 738 s. ISBN 03-873-1073-8.

Seznam příloh

A. Obsah CD

B. Výsledky testování barevných modelů pro neuronové sítě

Příloha A. Obsah CD

- Zdrojové kódy
- Manuál k programu
- Spustitelný soubor
- Databáze snímků
- Diplomová práce ve formátu PDF a .docx

Příloha B. Výsledky testování barevných modelů pro neuronové sítě

B.1 Pro barevný model XYZ

databáze			barevné složky						
trénovací	testovací		x	y	z	yxz	xy	xz	yz
5a	5b	živý	71%	93%	80%	95%	95%	97%	95%
		neživý	62%	59%	74%	62%	55%	88%	74%
5b	5a	živý	82%	86%	89%	95%	93%	95%	93%
		neživý	70%	96%	62%	70%	85%	77%	85%
6a	6b	živý	89%	91%	93%	93%	91%	93%	93%
		neživý	51%	74%	66%	70%	70%	77%	81%
6b	6a	živý	80%	95%	91%	93%	89%	97%	86%
		neživý	66%	81%	62%	74%	81%	70%	92%
7a	7b	živý	84%	93%	91%	97%	91%	95%	89%
		neživý	74%	81%	77%	70%	70%	81%	92%
7b	7a	živý	86%	93%	91%	95%	93%	97%	97%
		neživý	55%	74%	70%	81%	77%	74%	77%
8a	8b	živý	82%	82%	84%	97%	93%	91%	91%
		neživý	70%	70%	66%	70%	81%	66%	70%
8b	8a	živý	89%	91%	82%	93%	93%	97%	93%
		neživý	25%	51%	74%	74%	37%	66%	70%

B.2 Pro barevný model Luv

databáze			barevné složky						
trénovací	testovací		x	y	z	yxz	xy	xz	yz
5a	5b	živý	93%	95%	95%	100%	84%	95%	100%
		neživý	51%	62%	62%	66%	66%	62%	70%
5b	5a	živý	86%	97%	93%	91%	91%	95%	95%
		neživý	85%	62%	74%	77%	59%	81%	81%
6a	6b	živý	91%	89%	93%	95%	91%	95%	93%
		neživý	81%	62%	77%	70%	77%	85%	77%
6b	6a	živý	84%	89%	86%	97%	100%	89%	93%
		neživý	66%	70%	77%	70%	59%	70%	81%
7a	7b	živý	93%	95%	91%	100%	97%	95%	95%
		neživý	81%	55%	81%	62%	74%	66%	70%
7b	7a	živý	86%	86%	95%	100%	93%	95%	91%
		neživý	81%	77%	66%	77%	85%	81%	81%
8a	8b	živý	89%	89%	93%	97%	93%	84%	97%
		neživý	74%	74%	62%	70%	66%	77%	77%
8b	8a	živý	89%	89%	97%	95%	91%	93%	97%
		neživý	59%	74%	85%	92%	85%	55%	81%

B.3 Pro barevný model Lab

databáze			barevné složky						
trénovací	testovací		x	y	z	yxz	xy	xz	yz
5a	5b	živý	93%	91%	97%	100%	91%	95%	100%
		neživý	51%	77%	62%	62%	55%	70%	74%
5b	5a	živý	86%	86%	93%	86%	86%	89%	93%
		neživý	85%	51%	70%	74%	70%	70%	77%
6a	6b	živý	91%	93%	84%	97%	91%	93%	93%
		neživý	81%	74%	66%	66%	62%	81%	77%
6b	6a	živý	84%	93%	84%	95%	84%	89%	86%
		neživý	66%	55%	74%	70%	81%	77%	77%
7a	7b	živý	93%	100%	93%	95%	91%	95%	91%
		neživý	81%	55%	77%	81%	81%	77%	74%
7b	7a	živý	86%	95%	91%	97%	95%	95%	93%
		neživý	81%	66%	74%	81%	88%	74%	92%
8a	8b	živý	89%	95%	93%	97%	91%	97%	93%
		neživý	74%	55%	59%	66%	81%	74%	81%
8b	8a	živý	89%	84%	95%	93%	95%	95%	89%
		neživý	59%	77%	70%	74%	88%	51%	88%

B.4 Pro barevný model YCbCr

databáze			barevné složky						
trénovací	testovací		x	y	z	yxz	xy	xz	yz
5a	5b	živý	89%	86%	93%	100%	91%	95%	100%
		neživý	74%	74%	66%	66%	62%	66%	77%
5b	5a	živý	86%	95%	93%	86%	91%	89%	95%
		neživý	74%	70%	70%	74%	77%	77%	77%
6a	6b	živý	91%	93%	89%	95%	93%	91%	89%
		neživý	81%	62%	66%	70%	85%	66%	77%
6b	6a	živý	84%	93%	86%	95%	97%	93%	89%
		neživý	77%	77%	77%	70%	70%	77%	62%
7a	7b	živý	91%	93%	95%	100%	95%	89%	93%
		neživý	77%	74%	66%	74%	66%	77%	62%
7b	7a	živý	95%	91%	76%	95%	95%	97%	86%
		neživý	66%	74%	62%	74%	81%	77%	85%
8a	8b	živý	80%	84%	91%	97%	93%	93%	93%
		neživý	88%	66%	66%	74%	74%	66%	77%
8b	8a	živý	91%	91%	95%	89%	93%	91%	95%
		neživý	55%	70%	70%	85%	88%	66%	81%