

UNIVERZITA PARDUBICE
FAKULTA EKONOMICKO-SPRÁVNÍ
ÚSTAV SYSTÉMOVÉHO INŽENÝRSTVÍ A INFORMATIKY

DISERTAČNÍ PRÁCE

2022

Ing. Kateřina Příhodová

Univerzita Pardubice
Fakulta ekonomicko-správní
Ústav systémového inženýrství a informatiky

Biometrické rozpoznávání osob využívající termálních charakteristik ruky

Disertační práce

Autor: Ing. Kateřina Příhodová
Školitel: doc. Ing. Miloslav Hub, Ph.D.

Pardubice
2022

University of Pardubice
Faculty of Economics and Administration
Institute of System Engineering and Informatics

Biometric recognition of persons using the hand thermal characteristics

Dissertation thesis

Author: Ing. Kateřina Příhodová
Supervisor: doc. Ing. Miloslav Hub, Ph.D.

Pardubice
2022

ABSTRAKT

Biometrické rozpoznávání je jedním ze způsobů identifikace osob, nebo ověření identity osob. V našem životě se dnes již zcela běžně setkáváme s využíváním biometrického rozpoznávání. Například lidé mohou odemknout své chytré telefony nebo notebooky pomocí své tváře nebo otisků prstů, využití těchto biometrických charakteristik je pro uživatele velmi pohodlné. Žádné biometrické rozpoznávání však ještě není ani zdaleka dokonalé. S větším využíváním biometrického rozpoznávání dokonce vznikají i nové výzvy v této oblasti. Cílem disertační práce je tedy navržení a ověření nového způsobu biometrického rozpoznávání osob s využitím termálních charakteristik ruky v kombinaci s běžně používanými charakteristikami ruky.

V první části předložené disertační práci je uvedení do problematiky rozpoznávání osob a vysvětleny jsou základní pojmy z oblasti biometrického rozpoznávání. Dále je v disertační práci uveden rozsáhlý přehled současného stavu v oblasti biometrického rozpoznávání na bázi ruky. Ze současného stavu řešené problematiky vyplývají určité výzvy v této oblasti. Jde například o vysokou intrapersonální variaci, ne vždy dostatečnou kvalitu vstupních dat a útoky na biometrické systémy. Po specifikaci výzev je práce zaměřena na metody vhodné pro dosažení cíle disertační práce. Těmito metodami jsou metody strojového učení a hlubokého učení. Jde o především o tradiční statistické metody, rozhodovací stromy, podpůrné vektorové stroje, neuronové sítě a kombinaci těchto metod. Pomocí těchto metod je pak realizováno biometrické rozpoznávání osob na bázi ruky (využití termálních charakteristik ruky v kombinaci s běžně používanými charakteristikami ruky). Vzájemné porovnání kvality jednotlivých modelů biometrického rozpoznávání osob je poté provedeno pomocí vybraných ukazatelů výkonnosti.

KLÍČOVÁ SLOVA

biometrické rozpoznávání, termální charakteristiky, snímky ruky, fúze na úrovni senzoru, hluboké učení, strojové učení, konvoluční neuronové sítě

ABSTRACT

Biometric recognition is one way of identifying people or verifying identity. In our lives today, we already quite commonly encounter the use of biometric recognition. For example, people can unlock their smartphones or laptops with their face or fingerprints; the use of these biometric characteristics is very convenient for users. However, no biometric recognition is far from perfect. With the increasing use of these biometric recognition, new challenges are even emerging in this field. The aim of the dissertation is to design and verify a new method of biometric recognition people using the thermal characteristics of the hand in combination with commonly used characteristics of the hand.

In the presented dissertation thesis, the introduction to the issue of person recognition is first introduced, and the basic concepts in the field of biometric recognition are explained. There is also an extensive overview of the current state-of-the-art in hand-based biometric recognition. The current state of the problem raises certain challenges in this area. For example, there is high intrapersonal variation, not always sufficient quality of input data, and attacks on biometric systems. After the specification of the calls, the work is focused on methods suitable for achieving the goal of the dissertation. These methods are machine learning and deep learning methods. These are mainly traditional statistical methods, decision trees, supporting vector machines and neural networks, and a combination of these methods. Using these methods, biometric hand-based (using the thermal characteristics of the hand in combination with commonly used characteristics of the hand) person recognition is then realized. Then, mutual comparison of the quality of individual models of biometric recognition of people is performed using selected performance indicators.

KEYWORDS

biometric recognition, thermal characteristic, hand images, sensor level fusion, deep learning, machine learning, convolutional neural networks

Prohlašuji:

Tuto práci jsem vypracovala samostatně. Veškeré literární prameny a informace, které jsem v práci využila, jsou uvedeny v seznamu použité literatury.

Byla jsem seznámena s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 30. 3. 2022

Ing. Kateřina Příhodová

PODĚKOVÁNÍ

Ráda bych poděkovala panu doc. Ing. Miloslavu Hubovi, Ph.D. za vedení a připomínky při vypracovávání disertační práce. Můj dík patří také ostatním vědeckým pracovníkům Ústavu systémového inženýrství a informatiky Fakulty ekonomicko-správní Univerzity Pardubice. Dále chci poděkovat své rodině za podporu po celou dobu studia.

OBSAH

SEZNAM OBRÁZKŮ	11
SEZNAM TABULEK.....	13
SEZNAM ZKRATEK	14
SEZNAM SYMBOLŮ	16
ÚVOD.....	17
1 SOUČASNÝ STAV V OBLASTI TÉMATU DISERTAČNÍ PRÁCE.....	18
1.1 Biometrické rozpoznávání	18
1.2 Biometrické systémy na bázi ruky	19
1.3 Historický vývoj biometrických systémů na bázi ruky	23
1.3.1 <i>Biometrické systémy na bázi ruky do roku 1900.....</i>	<i>23</i>
1.3.2 <i>První novodobé biometrické systémy na bázi ruky.....</i>	<i>23</i>
1.3.3 <i>Biometrických systémů na bázi ruky na přelomu tisíciletí.....</i>	<i>24</i>
1.4 Klasické metody v biometrických systémech na bázi ruky	25
1.4.1 <i>Senzor.....</i>	<i>25</i>
1.4.2 <i>Zpracování obrazu.....</i>	<i>26</i>
1.4.3 <i>Extrakce biometrických rysů.....</i>	<i>28</i>
1.4.4 <i>Porovnání s biometrickou šablonou</i>	<i>30</i>
1.4.5 <i>Rozhodnutí</i>	<i>32</i>
1.5 Moderní metody v biometrických systémech na bázi ruky	33
1.6 Metody v biometrických systémech využívající infračervené záření.....	34
1.6.1 <i>Infračervené záření</i>	<i>34</i>
1.6.2 <i>Infračervené záření v biometrických systémech</i>	<i>35</i>
1.7 Porovnání vybraných studií	36
1.8 Dosud nevyřešené výzvy biometrických systémů na bázi ruky	38
2 CÍL DISERTAČNÍ PRÁCE A POSTUP JEHO DOSAŽENÍ	40
2.1 Cíle disertační práce.....	40
2.2 Obecný postup dosažení cíle disertační práce	40
3 MĚŘENÍ VÝKONNOSTI BIOMETRICKÝCH SYSTÉMŮ.....	41
3.1 Přesnost klasifikace.....	41

3.2	Míra chybného odmítnutí.....	42
3.3	Míra chybného přijetí.....	42
3.4	Operační křivka ROC a plocha pod křivkou AUC	43
3.5	Výpočetní čas.....	43
4	MULTI-BIOMETRIE	44
4.1	Multi-biometrické systémy	44
4.2	Fúze na různých úrovních biometrického systému.....	47
4.2.1	<i>Před-klasifikační fúze</i>	<i>48</i>
4.2.2	<i>Po-klasifikační fúze.....</i>	<i>48</i>
5	POSTUP VÝZKUMU.....	50
6	METODY VHODNÉ PRO DOSAŽENÍ CÍLE DISERTAČNÍ PRÁCE.....	52
6.1	Metody vhodné pro zpracování obrazu a extrakci rysů	52
6.2	Metody vhodné pro klasifikaci	58
6.2.1	<i>Individuální metody klasifikace</i>	<i>59</i>
6.2.2	<i>Ensemble metody</i>	<i>66</i>
7	DATOVÁ SADA SNÍMKŮ RUKY	70
7.1	Biometrický skener ruky	70
7.2	Termální kamera a její nastavení	72
7.3	Vytváření datové sady	73
7.4	Popisná statistika datové sady.....	74
8	SPECIFIKACE VYUŽITÉHO HARDWARU A SOFTWARE	78
9	NAVRHOVANÝ MULTI-BIOMETRICKÝ SYSTÉM	79
9.1	Fúze na úrovni senzoru	79
9.2	Zpracování obrazu	80
9.3	Konvoluční neuronová síť jako extraktor rysů	80
9.4	Ladění konvolučních neuronových sítí pro klasifikaci.....	81
10	VÝSLEDKY VÝZKUMU	82
10.1	Výkon biometrické identifikace z hlediska přesnosti	82
10.2	Výkon biometrické identifikace z hlediska výpočetní složitosti	86
10.3	Srovnání navrhovaného multi-biometrického a uni-biometrického systému	88

10.4	Srovnání s předchozími studii.....	89
10.5	Analýza chyb	90
11	DALŠÍ SMĚRY VÝZKUMU.....	92
11.1	Rozpoznání pohlaví na základě MSX snímků ruky.....	92
11.2	Současný stav řešené problematiky – rozpoznání pohlaví	93
11.3	Metody a výsledky rozpoznávání pohlaví	93
12	PŘÍNOSY DISERTAČNÍ PRÁCE.....	96
12.1	Vědecké přínosy	96
12.2	Aplikační a ekonomické přínosy	97
	ZÁVĚR	98
	PUBLIKACE DISERTANTKY VZTAHUJÍCÍ SE K ŘEŠENÉMU TÉMATU.....	126
	ŽIVOTOPIS	128
	PŘÍLOHY	129

SEZNAM OBRÁZKŮ

Obrázek 1: Obecný model biometrického systému	19
Obrázek 2: Biometrické charakteristiky na dlani ruky	20
Obrázek 3: Vývoj biometrických systémů na bázi ruky	25
Obrázek 4: Geometrické rysy ruky	29
Obrázek 5: Tvar ruky	30
Obrázek 6: Jednotlivé části elektromagnetického spektra	34
Obrázek 7: ROC křivky	43
Obrázek 8: Kategorie multi-biometrického systému	45
Obrázek 9: Fúze na různých úrovních biometrického systému	47
Obrázek 10: Postup výzkumu	51
Obrázek 11: Klasický postup rozpoznávání vzorů	52
Obrázek 12: Využití CNN pro rozpoznávání vzorů	52
Obrázek 13: Architektura konvoluční neuronové sítě	54
Obrázek 14: Porovnání velikosti modelu, rychlosti a přesnosti pro předtrénované sítě.....	55
Obrázek 15: Architektura konvoluční neuronové sítě AlexNet.....	56
Obrázek 16: Architektura konvoluční neuronové sítě GoogLeNet	57
Obrázek 17: Architektura konvoluční neuronové sítě VGG-16	58
Obrázek 18: Diskriminační analýza.....	60
Obrázek 19: Naivní Bayesův klasifikátor	61
Obrázek 20: Rozhodovací stromy.....	62
Obrázek 21: Algoritmus k-NN, pro k=6.....	63
Obrázek 22: Podpůrné vektorové stroje.....	64
Obrázek 23: Neuronová síť	65
Obrázek 24: McCulloch-Pittsův model neuronu	65
Obrázek 25: Snímky z datové sady – hřbet a dlaň ruky termální a viditelný snímek	70
Obrázek 26: Biometrický skener pohled zepředu.....	71
Obrázek 27: Biometrický skener pohled z perspektivy	71
Obrázek 28: Tepelná stopa ruky na „Kapa“ desce	72
Obrázek 29: Porovnání snímků ruky po tělesné aktivitě	74
Obrázek 30: Počty osob v jednotlivých věkových skupinách	76
Obrázek 31: Základní statistiky datové sady	76
Obrázek 32: Navrhovaný multi-biometrický systém – první přístup	79

Obrázek 33: Navrhovaný multi-biometrický systém – druhý přístup	79
Obrázek 34: Příklad termálního, viditelného a MSX snímku.....	80
Obrázek 35: Vizualizace aktivací první konvoluční vrstvy trénované sítě AlexNet.....	83
Obrázek 36: Chybné klasifikace	91

SEZNAM TABULEK

Tabulka 1: Porovnání vybraných biometrických charakteristik ruky	22
Tabulka 2: Přehled vybraných studií – biometrické systémy na bázi ruky	37
Tabulka 3: Matice záměn.....	41
Tabulka 4: Přehled použitých metod pro extrakci rysů a extrakci rysů s klasifikací	53
Tabulka 5: Porovnání konvolučních neuronových sítí	55
Tabulka 6: Přehled použitých metod pro klasifikaci a společnou extrakci rysů s klasifikací ..	59
Tabulka 7: Srovnání vytvořené datové sady s již dostupnými datovými sadami	77
Tabulka 8: Výkon biometrické identifikace z hlediska přesnosti – individuální klasifikátory	84
Tabulka 9: Výkon biometrické identifikace z hlediska přesnosti – ensemble metody	85
Tabulka 10: Výkon biometrické identifikace z hlediska přesnosti – CNN	85
Tabulka 11: Výkon biometrické identifikace z hlediska časové složitosti – individuální klasifikátory	87
Tabulka 12: Výkon biometrické identifikace z hlediska časové složitosti – ensemble metody	88
Tabulka 13: Výkon biometrické identifikace z hlediska časové složitosti – CNN	88
Tabulka 14: Srovnání uni-biometrického a multi-biometrického systému.....	89
Tabulka 15: Srovnání se souvisejícími výzkumy	90
Tabulka 16: Přesnost klasifikace vybraných metod	95

SEZNAM ZKRATEK

3D	Trojrozměrný (angl. Three-Dimensional)
AAM	Model aktivního vzhledu (angl. Active Appearance Model)
Acc	Přesnost (angl. Accuracy)
AMS	Aktivní model tvarů (angl. Active Model Shapes)
ART	Úhlová radiální transformace (angl. Angular Radial Transform)
AUC	Plocha pod křivkou ROC (angl. Area Under Curve)
BDM	Neexistuje český ekvivalent (angl. Biometric Dispersion Matcher)
CART	Klasifikační a regresní strom (angl. Classification and Regression Tree)
CCD	Zařízení s vázanými náboji (angl. Charge-Coupled Device)
CNN	Konvoluční neuronové sítě (angl. Convolutional Neural Network)
CPU	Centrální procesorová jednotka (angl. Central Processing Unit)
DA	Diskriminační analýza (angl. Discriminant Analysis)
DNA	Deoxyribonukleová kyselina (angl. Deoxyribonucleic Acid)
EER	Stejná míra chybovosti (angl. Equal Error Rate)
FAR	Míra chybného přijetí (angl. False Acceptance Rate)
FRR	Míra chybného odmítnutí (angl. False Rejection Rate)
GMM	Gaussovské mixovací modely (angl. Gaussian Mixture Model)
GPU	Grafický procesor (angl. Graphics Processing Unit)
GRNN	Zobecněné regresní neuronové sítě (angl. General Regression Neural Network)
HMM	Skryté Markovovy modely (angl. Hidden Markov Models)
CHAID	Chí-kvadrát automatický detektor interakce (angl. Chi-square Automatic Interaction Detector)
ICA	Analýza nezávislých komponent (angl. Independent Component Analysis)
ID3D	Identifikace s trojrozměrným snímkem (Identification – Three-Dimensional)
ILSVRC	Rozsáhlá výzva pro vizuální rozpoznávání ImageNet (angl. ImageNet Large Scale Visual Recognition Challenge)
INSPASS	Systém zrychleného odbavení cestujících (angl. Immigration and Naturalization Service Passenger Accelerated Service System)
IR	Infračervené záření (angl. Infrared Radiation)
k-NN	Algoritmus k-nejbližších sousedů (angl. k-Nearest Neighbours)
LBP	Lokální binární vzor (angl. Local Binary Pattern)
LDA	Lineární diskriminační analýza (angl. Linear Discriminant Analysis)

LSTM	Dlouhodobá krátkodobá paměť (angl. Long Short-Term Memory)
MATLAB	Neexistuje český ekvivalent (angl. Matrix Laboratory)
MLP	Vícevrstvá neuronová síť (angl. Multi-Layer Perceptron)
MSX	Multi-spektrální dynamický snímek (angl. Multi-Spectral Dynamic Imaging)
PCA	Analýza hlavních komponent (angl. Principal Component Analysis)
PIN	Osobní identifikační číslo (angl. Personal Identification Number)
QUEST	Neexistuje český ekvivalent (angl. Quaternion Estimator)
RBM	Omezený Boltzmannův stroj (angl. Restricted Boltzmann Machine)
ROC	Operační křivky (angl. Receiver Operating Characteristic)
ROI	Výběr oblasti zájmu (angl. Region of Interest)
RSM	Náhodný podprostor (angl. Random Subspace Method)
RTG	Rentgenové záření (angl. Roentgen Radiation)
SGD	Stochastický sestupný gradient (angl. Stochastic Gradient Descendent)
SIFT	V měřítku neměnná transformace rysů (angl. Scale Invariant Feature Transform)
SVM	Podpůrné vektorové stroje (angl. Support Vector Machine)
UAV	Bezpilotní letoun (angl. Unmanned Aerial Vehicle)
UV	Ultrafialové záření (angl. Ultraviolet Radiation)
VGG	Neexistuje český ekvivalent (angl. Visual Geometry Group)

SEZNAM SYMBOLŮ

c_i	váha i -tého Gaussovského modelu
FA	chybné odmítnutí
FR	chybné přijetí
L	dimenze vektoru biometrických rysů
M	počet modelů
N_{FA}	počet chybných přijetí
N_{FR}	počet chybných odmítnutí
N_{NN}	počet pokusů neoprávněnými narušiteli o identifikaci
N_{OU}	počet pokusů oprávněnými uživateli o identifikaci
NN	identifikace neoprávněným narušitelem
OU	identifikace oprávněným uživatelem
$P(A)$	apriorní pravděpodobnost jevu A
$P(A B)$	aposteriorní (podmíněná) pravděpodobnost jevu A za předpokladu, že nastal jev B
$P(B)$	pravděpodobnost jevu B
$P(B A)$	aposteriorní (podmínečná) pravděpodobnost jevu B za předpokladu, že nastal jev A
S	počet biometrických šablon
TA	správné přijetí
TR	správné odmítnutí
u	identita osoby, ke které je obraz ruky přiřazen s pravděpodobností p
\mathbf{x}	vektor biometrických rysů
\mathbf{x}_i^B	i -tá biometrická šablona
x_1, \dots, x_k	nezávislé proměnné
Z	diskriminační skóre
β_0	konstanta
β_1, \dots, β_k	koeficienty
$\boldsymbol{\mu}_i$	průměrný vektor i -tého modelu
Σ_i	kovarianční matice i -tého modelu

ÚVOD

V dnešní moderní společnosti se klade stále větší důraz na práci s informacemi. Informace jsou jedny z nejcennějších aktiv, které můžeme vlastnit, je tedy potřeba je chránit. Mezi základní požadavky na jejich zabezpečení je jejich důvěrnost, integrita a dostupnost [78]. Požadavek na důvěrnost informací vyžaduje, aby přístup k informacím měly pouze subjekty, které mají oprávnění k nim přistupovat. Jednou z možností, jak zajistit důvěrnost informací, je za pomoci autentizace, během níž dojde k ověření identity subjektu, kterému jsou následně přidělena příslušná práva.

Autentizaci lze definovat jako: „*Způsob ověření identity uživatele v systému za účelem řízení přístupu k systému či zdrojům*“ [44]. Autentizaci lze provést pomocí znalosti (heslo, PIN), autentizačního předmětu (tokenu, mobilního telefonu), nebo pomocí toho, čím fyzicky a duševně jsme (biometrické charakteristiky). Poslední možnost využívají biometrické rozpoznávací systémy, které se dostaly zejména v posledních letech do popředí díky vědecko-technickému pokroku.

Biometrické systémy jsou aplikace biometrických technologií, které umožňují automatickou identifikaci nebo verifikaci určité fyzické osoby využívající k tomu fyziologické (tvář, otisk prstu, ...) nebo behaviorální (hlas, chůze, ...) charakteristiky. Biometrické charakteristiky musí být univerzální (u všech osob musí existovat daná charakteristika), musí mít vysokou vnější variabilitu (u různých osob vysoká různorodost) a nízkou vnitřní variabilitu (u jedné osoby nízká různorodost) [24].

Rychlý vývoj v oblasti informačních technologií a zvýšení bezpečnostních rizik vede ke snaze zlepšit spolehlivost biometrických systémů. Jednou z možností, jak zlepšit tuto spolehlivost, je využití infračerveného záření. Infračervené záření lze zachytit pomocí termální kamery, přičemž detektor v termální kameře zjišťuje intenzitu infračerveného záření. Jelikož intenzita infračerveného záření přímo závisí na povrchové teplotě tělesa, dokáže termální kamera teplotu vypočítat a zobrazit. Povrchová teplota tělesa je zobrazena na termálním snímku (termogram). Již je prokázáno, že termální snímky některých částí těla (například obličej) zachycují unikátní charakteristiky osoby a lze je díky tomu využít pro biometrické rozpoznávání.

Proto je v disertační práci upřena pozornost na využití termálních charakteristik ruky v biometrice a je navržen a ověřen nový způsob biometrického rozpoznávání osob s využitím termálních charakteristik ruky v kombinaci s běžně používanými charakteristikami ruky.

1 SOUČASNÝ STAV V OBLASTI TÉMATU DISERTAČNÍ PRÁCE

1.1 Biometrické rozpoznávání

V dnešním moderním světě je často důležité spolehlivě automaticky rozpoznat osoby, a to zejména z důvodů zvýšených bezpečnostních rizik. Využit lze biometrické rozpoznávání, které je v [191] definováno jako: „*Automatická identifikace nebo automatické ověření identity osoby založené na fyziologických a behaviorálních charakteristikách*“.

Identifikace je v této práci chápána jako proces porovnání biometrických rysů získaných z nasnímaného biometrického vzorku se všemi referenčními šablonami uloženými v datové sadě. Existuje-li v datové sadě referenční šablona, která dostatečně odpovídá sadě biometrických rysů, biometrický systém osobu identifikuje identitou spojenou s touto referenční šablonou, v opačném případě k identifikaci nedojde. [88]

Verifikace neboli ověření identity je v této práci chápána jako proces, kdy se ověřuje, zda prověřovaná osoba je tou, za kterou se vydává. Biometrické rysy získané z nasnímaného vzorku se porovnávají s jednou vlastní biometrickou šablonou, která je uložena v datové sadě. Pokud biometrické rysy dostatečně odpovídají této referenční šabloně, je identita ověřena, v opačném případě ověřena není. [88]

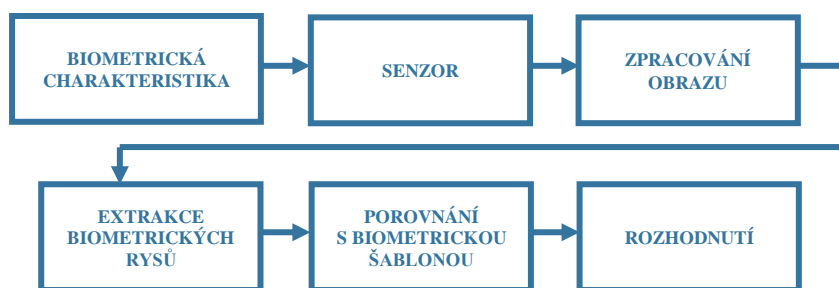
Biometrické rozpoznání osob je založeno na jejich biometrických charakteristikách (angl. biometric characteristics), jde o jejich jedinečné fyziologické a behaviorální charakteristiky. Fyziologické charakteristiky jsou takové charakteristiky lidského těla, se kterými jsme se narodili a patří mezi ně například struktura oční duhovky [98], [130], struktura oční sítnice [105], tvář [187], tvar vnějšího ucha [49], daktyloskopické otisky prstů [87], dlaní [128] a chodidel [11], otisk kloubu prstu [176], geometrie prstů [211] a ruky [5], topografie (rozmístění a tvar) žil hřbetu ruky [190], DNA [62]. Mezi behaviorální charakteristiky neboli charakteristiky lidského chování patří například hlas [185], písmo [152], podpis [73] a chůze [110].

Analogová nebo digitální reprezentace biometrických charakteristik se nazývá biometrický vzorek (angl. biometric sample). Z biometrického vzorku se extrahují rozlišující opakovatelné biometrické rysy (angl. biometric features). Biometrické rysy jsou hodnoty vybraných biometrických vlastností (biometric property), jež jsou použity pro následné porovnání. [39]

1.2 Biometrické systémy na bázi ruky

Biometrický systém je v [39] definován jako: *systém, jehož účelem je biometrické rozpoznávání jedinců založené na jejich behaviorálních a fyziologických charakteristikách.*

Biometrický rozpoznávací systém se skládá z několika modulů: senzor zachytí biometrickou charakteristiku, následuje zpracování obrazu, extrakce identifikačních rysů, porovnávání s biometrickou šablonou a rozhodnutí. Jednotlivé moduly biometrického systému jsou znázorněny v jeho obecném modelu na obrázku 1.



Obrázek 1: Obecný model biometrického systému

Zdroj: autor


Ne všechny fyziologické a behaviorální charakteristiky jsou vhodné pro biometrické rozpoznávání. Nejvíce jedinečných fyziologických charakteristik najdeme na hlavě a na ruce. Na hlavě lze nalézt následující biometrické charakteristiky:

- tvář,
- oční duhovka,
- oční sítnice,
- tvar vnějšího ucha.

Na ruce lze nalézt biometrické charakteristiky na dlani ruky, ty jsou zobrazeny na obrázku 2. Existují však i biometrické charakteristiky na hřbetu ruky, další biometrickou charakteristikou na ruce je její tvar (obrys) nebo její geometrie (vybraná geometrická měření). Biometrické charakteristiky, které jsou běžně využívány biometrickými systémy na bázi ruky, jsou následující [174]:

- geometrie ruky
- tvar ruky,
- otisk dlaně,
- otisk prstu,

- otisk kloubu prstu,
- topografie krevního řečiště ruky (hřbet i dlaň),
- topografie krevního řečiště prstu.



Obrázek 2: Biometrické charakteristiky na dlani ruky

Zdroj: [74]

Jako první se v biometrických systémech na bázi ruky se využíval otisk prstu [87] a geometrie ruky, u geometrie ruky byly biometrickými rysy například šířky, délky, úhly [5], [60], [151], později se jako další biometrická charakteristika přidal i tvar ruky [42], [131], [199].

Velmi často se také využívají biometrické charakteristiky otisk dlaně [13], otisk kloubu prstu [176] a topografie krevního řečiště na hřbetu ruky [190]. Nově se dále objevují biometrické systémy, které využívají jako charakteristiku také tep zachycený na prstu ruky [81], póry na rukou [96], nebo gesta rukou [132].

V současné době existují i multi-biometrické systémy, které využívají kombinaci více biometrických charakteristik. V kombinaci s geometrií ruky nebo tvarem ruky se používá otisk dlaně [13], [57], [97], [132], [189] nebo topografie krevního řečiště [70], [108], [136]. Topografie krevního řečiště se v případě skenování celé ruky měří buď na dlani, nebo na hřbetu ruky. Vytvořeny byly i systémy, které kombinují více než dvě charakteristiky, například

geometrii ruky, otisk dlaně a otisk prstu [55], [198]. Multi-biometrické systémy dosahují vyšší přesnosti než biometrické systémy využívající pouze jednu biometrickou charakteristiku [148].

Biometrické charakteristiky, které se nacházejí na ruce jsou vhodné k biometrickému rozpoznávání, protože splňují následující požadavky [153]:

- Jedinečnost – biometrická charakteristika nesmí být pro jakékoliv dvě osoby shodná,
 - vysoká vnější variabilita (u různých osob vysoká různorodost),
 - nízká vnitřní variabilita (u jedné osoby nízká různorodost).
- Univerzálnost – biometrická charakteristika musí existovat (být měřitelná) u všech osob, v praxi jde o obtížně dosažitelný požadavek, proto se povoluje určitá tolerance (biometrické charakteristiky musí být měřitelné u co největší množiny lidí).
- Stálost – biometrická charakteristika musí být dostatečně neměnná v čase. Změny mohou být způsobeny stárnutím, nemocí, zraněním, vykonávanou prací.
- Měřitelnost – biometrická charakteristika musí být opakovaně měřitelná a jednoduše předložitelná snímacímu zařízení.

Jedním z požadavků na biometrickou charakteristiku je její jedinečnost. Výhodou biometrických charakteristik lidské ruky je, že otisky nebo krevní řečiště jsou jedinečné i pro jednovaječná dvojčata. U těchto charakteristik totiž nezáleží pouze na DNA, ale i na vývoji. U jednovaječných dvojčat je největší problém právě s požadavkem na jedinečnost biometrické charakteristiky, protože tato dvojčata mají stejnou DNA a rozeznat je podle obličeje, bývá nemožné. [74]

Požadavek na univerzálnost biometrické vlastnosti, nemusí být naplněn u biometrických charakteristik na ruce, pokud dojde ke zranění ruky, dále může nastat problém s rozpoznáváním osob s vrozenými vadami horních končetin. Avšak jde o biometrické charakteristiky, u kterých je jejich univerzálnost považována za velkou přednost. Většina jedinců má alespoň jednu ruku, takže lze získat biometrický vzorek, geometrie ruky, krevního řečiště, otisku prstu a dalších.

Ne všechny biometrické charakteristiky na ruce mají stejnou stálost. Topografie krevního řečiště je celkově velmi stálou charakteristikou. Zatímco například otisky prstů, bývají často poškozené při těžké manuální práci, avšak po zahojení pokožky jsou otisky prstů stejné jako před poraněním. Tvar a geometrie ruky nejsou zcela odolné vůči vlivu stárnutí (využití této charakteristiky se nedoporučuje u dětí, protože u nich se charakteristika často mění), nebo problém může nastat při změně hmotnosti osoby. Tvar a geometrii ruky mohou změnit také nemoci například revmatismus.

U praktických biometrických systémů je, kladen důraz i na další požadavky [84]:

- Výkon – týká se úrovně přesnosti a rychlosti rozpoznání. Dále se týká zdrojů potřebných k dosažení požadované přesnosti a rychlosti rozpoznávání, jakož i provozních a environmentálních faktorů, které přesnost a rychlost ovlivňují.
- Uživatelská přijatelnost – udává do jaké míry jsou uživatelé ochotni využívat danou biometrickou charakteristiku. Biometrická charakteristika musí být snadno a pohodlně měřitelná.
- Odolnost proti obcházení – jde o stupeň obtížnosti poražení nebo obejití biometrického systému pomocí podvodných metod.

Porovnání vybraných biometrických charakteristik ruky vzhledem k výše uvedeným požadavkům na charakteristiky je uvedeno v tabulce 1. Splnění požadavků je hodnoceno tříbodovou stupnicí vysoké, střední, nízké.

Tabulka 1: Porovnání vybraných biometrických charakteristik ruky

Biometrická charakteristika/ požadavek	Jedinečnost	Univerzálnost	Stálost	Měřitelnost	Výkon	Přijatelnost	Odolnost
Otisk prstu	vysoké	střední	vysoké	vysoké	vysoké	střední	střední
Otisk dlaně	vysoké	střední	vysoké	střední	vysoké	střední	střední
Geometrie ruky	střední	střední	střední	vysoká	střední	střední	střední
Krevní řečiště ruky	střední	střední	střední	střední	střední	střední	vysoká

Zdroj: [84]

Výběr konkrétní biometrické charakteristiky velmi záleží na daném využití biometrického systému. Žádná biometrická charakteristika nepřekoná ostatní biometrické charakteristiky ve všech provozních prostředích, jinými slovy neexistuje žádná optimální biometrická charakteristika [46]. Například všeobecně je přesnější otisk prstu než geometrie ruky, pokud však bude systém využíván převážně dělníky (lidmi, kteří fyzicky pracují a mají poškozené otisky prstů) je vhodnější využít pro rozpoznání osob geometrii ruky [169].

1.3 Historický vývoj biometrických systémů na bázi ruky

Historie biometrických systémů na bázi ruky sahá velmi hluboko do minulosti. Je možné, že první využití charakteristik ruky pro identifikaci osob sahá až do hlubokého pravěku. Zmínky o otiscích prstů, jako biometrické charakteristice, lze taky nalézt ve starověkých zákonících. První výzkumy biometrického rozpoznávání osob na bázi ruky jsou datovány na začátek novověku. První novodobé systémy na bázi ruky byly patentovány v 70. letech 20. století.

1.3.1 Biometrické systémy na bázi ruky do roku 1900

Prehistorické malby, nalezené v jeskyni Chauvet ve Francii, jsou datovány do roku 29 000 před naším letopočtem. Vedle maleb zvířat jsou otisky rukou. Někteří badatelé považují tyto otisky rukou za jedinečné podpisy umělců, může tak jít o prvním známé použití tvaru ruky jako metody identifikace. [50]

Archeologické výzkumy na území dnešní Číny a Iráku dokazují, že otisky prstů byly využívány pro identifikaci osob, běžně se používali v Asýrii a Číně již v 6. až 7. tisíciletí před naším letopočtem. Lze také nalézt ve Starém čínském zákoníku nařízení, které přikazuje přidání otisku prstu na vybrané dokumenty. [145]

V roce 1858 sir William Herschel použil otisku ruky pro „podepsání“ obchodní smlouvy. Herschel chtěl zajistit, aby jeho obchodní partner Rajaadhar Konai dodržel smlouvu o dodání materiálu a nepopřel svůj podpis, tak ji Konai vedle podpisu musel stvrdit i otiskem ruky. Myšlenkou této praxe je, že otisk ruky by měl být méně popíratelný než prostý podpis. Herschel používal tuto metodu po mnoho let. Došel také k závěru, že pro rozlišení osob stačí otisk jednoho prstu. [88]

1.3.2 První novodobé biometrické systémy na bázi ruky

První novodobé biometrické systémy vyživaly jako biometrickou charakteristiku geometrii ruky. Tehdy šlo o biometrické systémy ve verifikačním režimu (uživatel předložil totožnost a ta byla následně potvrzena nebo zamítnuta). Problematikou biometrických systémů na bázi ruky se v šedesátých letech zabýval Robert Miller, jenž na základě výzkumu vytvořil ve Stanfordském výzkumném institutu zařízení (obrázek 3a), které patentoval v roce 1971 [123]. Rozpoznávání osob toto zařízení provádělo čistě mechanickými prostředky, kdy čtyři pružinové tyče sjely k prstům uživatele a následně byla změřena délka prstů uživatele.

Pokud délky prstů odpovídaly vzoru vyraženému v průkazu totožnosti daného uživatele, byl aktivován jednoduchý spínač, který se používal pro ovládání elektrického zámku [88].

Prvním komerčním ručním skenerem byl Identimat (obrázek 3b), který vznikl na základě patentu Roberta Millera [123]. Měření ruky probíhalo pomocí fotobuněk umístěných pod drážkami. Na drážky uživatel přikládal ruku (prsty), která část fotobuněk v drážkách zastínila. Nad rukou bylo světlo o výkonu 1 000 Wattů. Na tento jednoduchý skenovací mechanismus byla připevněna čtecí hlava s magnetickým proužkem, ke kterému se při verifikaci přiložila magnetická karta uživatele. Pokud se impulzy na kartě shodovaly s impulzy ze snímačů fotobuněk v rozmezí prahové hodnoty, byla totožnost uživatele ověřena. Tento systém byl úspěšně použit v různých aplikacích. První využití bylo vojenského charakteru, šlo o zabezpečení jaderných zbraní. Později se Identimat využíval pro přístup do jaderných elektráren USA a také pro kontrolu docházky zaměstnanců v investiční společnosti na Wall Street. Druhá vývojová řada Identimatu již byla dvourozměrně orientovaná, měřila se nejenom délkou, ale i šířkou všech prstů na jedné ruce. [88], [122]

Historie praktické implementace rozpoznávání osoby na základě geometrie ruky je dále spojena se jménem David Sidlauskas a jeho firmou Recognition System Inc., kterou založil v roce 1986. Tato firma se jako první na světě začala zabývat vývojem a prodejem moderních skenerů ruky. David Sidlauskas v polovině 80. let patentoval první biometrický systém, který využíval třírozměrný obraz ruky [157]. Patentovaný systém se skládá z kamery a optické měřicí desky. Kamera má půdorysný pohled a boční pohled na ruku. Identifikační kód se zadává pomocí klávesnice. Na základě tohoto patentu vznikl první komerčně úspěšný biometrický systém s využitím geometrie ruky skener Handkey ID3D.


1.3.3 Biometrických systémů na bázi ruky na přelomu tisíciletí

Společnost BioMet Partners, Inc. vyvinula dvouprstovou verzi skeneru ruky, jenž nese označení Digi-2 (obrázek 3c) a na trh byl uveden v roce 1995. Skener snímá pomocí CCD (Charge-Coupled Device) kamery pouze ukazovák a prostředník a získá jejich 3D obraz. [50]

V 90. letech 20. století byly biometrické skenery ruky vyžívány v programu INSPASS, šlo o program na vybraných amerických letištích, který zrychloval odbavení často cestujících osob. Tyto osoby mohly požádat o zařazení do programu, v rámci kterého jim nasnímána geometrie ruky a poté získaly identifikační kartu s biometrickou šablonou. Následně mohly na vybraných letištích procházet letištní kontrolu zrychleně za pomoci nainstalovaných skenerů ruky. [79]

Dalším projektem rozpoznávání osob pomocí skenerů ruky byl izraelský projekt, který automatizoval kontrolu pohybu na izraelsko-palestinské hranici. Během navrhování biometrického systému byly vybírány vhodné biometrické charakteristiky, v úvahu tehdy přicházely jako biometrické charakteristiky tváře, geometrie ruky a otisk prstu. Zvolen byl multi-biometrický systém, který kombinoval rozpoznávání tváře a geometrii rukou, která byla vybrána především z důvodu, že největší část osob přecházejících hranici tvoří dělníci, jejichž otisky prstů nejsou spolehlivé pro biometrické porovnání [169].

Pokud jde o zajištění bezpečnosti, byly skenery ruky využity i na Olympijských hrách v Atlantě v roce 1996, kde byl prostřednictvím nich kontrolován přístup do olympijské vesnice (obrázek 3d). Skenery ruky také využíval kolumbijský zákonodárny sbor, který jejich prostřednictvím bezpečně hlasoval [122].



Obrázek 3: Vývoj biometrických systémů na bázi ruky a) Kresba mechanického skeneru ruky b) Identimat c) dvouprstý skener ruky od Biomet d) skener geometrie ruky z Olympijských her v Atlantě

Zdroj: [88], [114], [123], [145]

1.4 Klasické metody v biometrických systémech na bázi ruky

V literatuře většina biometrických systémů na bázi ruky využívá klasický přístup, kdy se provádí poměrně složité předzpracování dat a speciálně zkonstruované extraktory extrahují biometrické rysy, poté následuje klasifikace pomocí individuálních klasifikátorů [4]. Názvy jednotlivých podkapitoly korespondují s moduly v obecném modelu biometrického systému, který je znázorněn na obrázku 1.

1.4.1 Senzor

Pro sejmутí biometrické charakteristiky geometrie a tvaru ruky se v současné době nejčastěji využívají kamery s CCD čipem, což je světlocitlivý detektor obrazu, který využívají například

digitální fotoaparáty, videokamery [1], [157]. V dřívějších dobách se často při výzkumech využívaly kancelářské skenery [55], [57], [66]. V komerční sféře se nejčastěji setkáváme se speciálními biometrickými skenery ruky.

Senzor zachytí buď 2D [33], [67], [196] nebo 3D [83], [136], [150] obraz ruky. 3D obrazy se získávají pomocí dvou kamer, za pomoci zrcadel, nebo je lze získat pomocí 3D digitizéru [93]. S 3D obrazy ruky se v biometrii setkáváme mnohem méně než s 2D obrazy ruky.

Při získávání biometrického vzorku hraje významnou roli i osvětlení. Některé senzory mají vlastní zdroj osvětlení, jde především o komerční biometrické skenery. Většina sensorů získává obrazy ruky při viditelném světle, některé však využívají i infračerveného záření [18], [70], [108]. Při jehož využití lze dosáhnout vyšší přesnosti biometrického rozpoznávání především při zhoršených světelných podmínkách, jelikož termální snímky nejsou závislé na osvětlení [126].

V dnešní době komerčně dostupné biometrické skenery ruky využívají téměř výhradně distanční kolíčky, které pevně určují polohu ruky při snímání (omezený systém) [83], [85], [136]. Jelikož distanční kolíčky mohou deformovat tvar ruky [54], do popředí se ve vědeckých kruzích dostaly systémy bez distančních kolíčků (neomezené systémy) [1], [25], [53]. Nejnovější možností jsou bezkontaktní systémy [22], [42], [45], [68], kde kromě distančních kolíčků není potřeba ani přímý kontakt se čtečkou. Tyto systémy jsou považovány za uživatelsky nejvhodnější, hlavně kvůli odstranění nutnosti fyzického kontaktu [132].

1.4.2 Zpracování obrazu

Získaný snímek většinou nemá takové vlastnosti, aby z něj mohly být snadno extrahovány rysy. Proto je nutné obraz zpracovat, jeho zpracování má usnadnit extrahování rysů. Složitost zpracování obrazu a výběr pro to vhodných algoritmů velmi záleží na druhu systému. Pokud je systém omezený (systém s distančními kolíčky) je zpracování obrazu jednodušší, než když jde o neomezený systém (bez distančních kolíčků). Nejsložitější zpracování obrazu je

u bezdotykových systémů. Při zpracování obrazu jsou snímky ruky upraveny do standardní podoby. Zpracování obrazu probíhá ve třech krocích:

1. předzpracování obrazu,
2. segmentace obrazu,
3. zarovnání obrazu.

Prvním krokem zpracování obrazu je předzpracování obrazu. Pro předzpracování obrazu je využíván soubor metod, které jsou na obraz aplikovány, protože jen minimální procento obrazů ruky je pořízeno v optimálních podmínkách. Téměř žádný pořízený obraz není zcela bez šumu, není dokonale zaostřený, získaný v optimálních světelných podmínkách a podobně. Z těchto důvodů se používají filtry k zaostření obrazu nebo k odstranění šumu. Pomocí metod bodové nebo algebraické operace je také možné změnit jas obrazu, aby byla usnadněna extrakce rysů. [163]

Následuje segmentace obrazu, ta spočívá v rozdělení obrazu do dvou či více oblastí za účelem získání užitečných informací o snímku. Cílem segmentace v biometrických systémech na bázi ruky je automaticky oddělit ruku od zbytku obrazu (pozadí). Čím je obraz ruky získán v omezenějších podmínkách, tím je segmentace jednodušší a lze ji provést rychlejšími metodami. Segmentační metody lze rozdělit do následujících skupin [163]:

- Statistické metody – základem těchto metod je statistická analýza obrazových dat, nejčastěji hodnot pixelů. Nahlíží na detekci ruky jako na klasifikační problém dvou tříd (ruka, ostatní).
- Metody založené na detekci hran – jde o metody orientované na detekci významných hran v obraze. Hrany jsou detekovány pomocí hranových detektorů na základě rozdílu hodnot okolních pixelů.
- Znalostní metody – metody využívající znalost vlastností segmentovaných objektů (tvar, barva, struktura apod.) pomocí atlasu předloh (generovaný automaticky, nebo na základě lidské zkušenosti o typických vlastnostech ruky).
- Hybridní metody – pokud je u některých metod těžké zařadit je do jedné z předchozích kategorií, protože obsahují prvky z více skupin, jde o hybridní metody.
- Kombinace metod – protože ne vždy mají jednotlivé metody požadovanou přesnost, využívají se často kombinace výše zmíněných metod.

Prahování obrazu je nejjednodušší statistická metoda segmentace založená na hodnocení jasu pixelů. Pokud je obraz ruky získán na skeneru (kancelářském, nebo komerčním skeneru ruky),

je pozadí konstantní a segmentace poměrně jednoduchá. Lze pak využít segmentační metodu prahování obrazu [10], [38]. Při prahování však vznikají problémy s prstýnkou, náramky nebo špinavou pokožkou [10], [15], [65].

Segmentaci obrazu ruky lze také provést pomocí metod založených na detekci hran. Hrany se detekují hranovými detektory na základě významných rozdílů hodnot jasu sousedních pixelů a jsou popsány velikostí a směrem. Hranové detektory jsou poměrně často využívanou segmentační metodou v biometrických systémech na bázi ruky [125], [151].

Existují i kombinace více metod segmentace. Kombinace metod dokáže detekovat ruku i z přeplněného pozadí. Příkladem takové kombinace metod, je využití znalostní metody, která detekuje kůži podle barvy a následuje detekce tvaru ruky hranovými detektory [16].

Další kombinační metodou segmentace a zároveň i extrakce biometrických rysů je Active Appearance Model (AAM) [67]. Metoda AAM prezentuje ruku pomocí modelu vzhledu, ten je vytvořen z modelu tvaru a z modelu textury ruky na základě statistické metody – analýza hlavních komponent (PCA) [100]. Výhodou metody je komplexnost informace, kterou o ruce obsahuje.

Mezi hybridní metody segmentace patří matematická morfologie, jde o nauku o tvarech. Pro segmentaci cévního řečiště ji využili autoři Zana a Klein [203]. Matematická morfologie je zároveň využívána i pro odstranění prstýnků, náramků, nebo hodinek [33], [92]. Matematická morfologie dokáže také vyřešit problém s přerušением siluety ruky [38]. Ten vzniká při využití některých metod segmentace.


Pokud není pozice ruky při získávání obrazu pevně zafixovaná, je nutné (pro většinu z těchto systémů) provést ještě poslední krok zpracování obrazu – obraz ruky zarovnat. To lze provést pomocí orientačních bodů, což mohou být například různé extrémy (konečky prstů, údolí prstů) [60], [89], [196], těžiště, nebo pevně určený referenční bod na zápěstí [155].

1.4.3 Extrakce biometrických rysů

Po zpracování obrazu následuje samotná extrakce biometrických rysů. Extrakce biometrických rysů je v [39] definována jako: „*Proces aplikovaný na biometrický vzorek se záměrem izolovat a získat opakovatelný výstup charakteristických čísel nebo označení, která mohou být porovnána s rysy, extrahovanými z dalších biometrických vzorků.*“

U biometrické charakteristiky geometrie ruky jsou biometrickými rysy geometrická měření, mezi které patří například délky a šířky prstů, plocha prstu, poloměry kružnic na prstech a dlani a úhly mezi prsty. Na obrázku 4 je znázorněno 30 různých geometrických měření (biometrických rysů), avšak existují i systémy, které využívají jiný počet geometrického měření, nejčastěji jde o 13–50 geometrických měření [5], [55], [59].

Pro zlepšení výkonu systémů na bázi geometrie ruky využili Kumar a Zang v [103] diskretizaci extrahovaných rysů. Myšlenkou diskretizace je promítnout spojité hodnoty rysů do diskretních tak, aby zůstalo zachováno důležité rozlišení mezi různými uživateli.



Obrázek 4: Geometrické rysy ruky

Zdroj: [193]

Více informací než jednotlivá geometrická měření ruky, poskytuje tvar ruky (obrázek 5), čehož využívají mnohé systémy [10], [199]. Tvar ruky může být explicitně modelován jako sada souřadnic orientačních bodů nacházejících se na obrysu ruky [182]. Nebo implicitně jako binární obraz ruky na prázdném pozadí [199], [200].

Tyto systémy využívají k extrakci biometrických rysů například algoritmus scale invariant feature transform (SIFT) [34]. Takto extrahované prvky jsou invariantní vůči změnám měřítka, afinnímu zkreslení, rotaci, šumu a změnám osvětlení. Briceno et al. [28] navrhli systém rozpoznání tvaru ruky založený na skrytých Markovových modelech (HMM). Hu et al. [77] navrhli systém rozpoznávání tvaru ruky založený na souvislostech koherentních vzdáleností tvarů. Yoruk et al. [200] využili pro extrakci rysů tvaru ruky analýzu nezávislých komponent (ICA), analýzu hlavních komponent (PCA), úhlovou radiální transformaci (ART) a distanční transformaci.



Obrázek 5: Tvar ruky

Zdroj: [10]

Více informací, než geometrie ruky, také poskytuje textura ruky. Pro extrakci rysů textury ruky lze využít analýzu hlavních komponent (PCA) nebo angular radial transform (ART) [200].

Některé systémy extrahují biometrické rysy geometrie ruky a zároveň tvaru ruky, extraktory jsou speciálně přizpůsobené tvaru a geometrii ruky [21], [155].

Nedávné výzkumy využívají hluboké neuronové sítě pro extrakci většího množství rysů ruky (tvaru a textury), jmenovitě jde o konvoluční neuronové sítě [142], [175], nebo siamské sítě [175].

1.4.4 Porovnání s biometrickou šablonou

V této fázi se porovnává sada biometrických rysů, která byla získána z biometrického vzorku rozpoznávané osoby s biometrickou šablonou (verifikace) nebo šablonami (identifikace) uloženými v databázi uživatelů. Porovnání se provádí pomocí následujících metod:

- statistické metody
 - minimální vzdálenost (Euklidovská metrika, Hammingova metrika, Čebyševova metrika),
 - Kullback–Leiblerova divergence,
 - korelační koeficient,
 - Gaussovské mixovací modely (GMM),
- strojové učení
 - podpůrné vektorové stroje (SVM),
 - metoda k-nejbližších sousedů,

- Bayesovské sítě,
- neuronové sítě.

Statistické metody

Mezi statistické metody porovnání sady biometrických rysů, která byla získána z biometrického vzorku, s biometrickou šablonou při rozpoznání osoby na základě geometrie a tvaru ruky patří například porovnání podle minimální vzdálenosti. Je-li v datové sadě uloženo S biometrických šablon $\mathbf{x}_1^B, \mathbf{x}_2^B, \dots, \mathbf{x}_S^B$ (S uživatelů) vypočítá se minimální vzdálenost biometrického vzorku ruky od biometrické šablony následovně:

$$\text{minimální vzdálenost} = \min_{\forall i} \|\mathbf{x}_i^B - \mathbf{x}\| \quad (1)$$

Kde:

- \mathbf{x}_i^B vektor i -té biometrické šablony,
- S počet biometrických šablon,
- \mathbf{x} vektor biometrických rysů,
- $\|\mathbf{x}_i^B - \mathbf{x}\|$ norma rozdílu vektorů.

Při rozpoznávání osoby na základě geometrie a tvaru ruky se používají k určení vzdálenosti biometrického vzorku ruky a biometrické šablony různé metriky vzdálenosti, například Euklidovská metrika [10], [33], [151], Hammingova metrika [131], nebo Čebyševova metrika [59].

Pro porovnání biometrického vzorku ruky a biometrické šablony lze využít i Kullback-Leiblerovu divergenci, která vyjadřuje míru nepodobnosti dvou pravděpodobnostních distribucí [60]. Jako míru podobnosti lze použít i korelační koeficient [104], [193].

Na rozhraní statistických a strojových metod se nachází Gaussovské mixovací modely (GMM). Jedná se o metodu rozpoznávání vzoru, která je založená na schopnosti GMM aproximovat jakoukoliv hustotu pravděpodobnosti pomocí směsi Gaussovských hustot. Pravděpodobnost vektoru biometrických rysů \mathbf{x} je odhadována jako vážený součet Gaussovských hustot. Výsledkem je tedy pravděpodobnost, s jakou vzor (biometrický vzorek) patří do dané třídy (biometrická šablona). Tato metoda dává v oblasti rozpoznávání osoby na základě geometrie ruky lepší výsledky, než metody pracující s minimální vzdáleností. [150], [151]

Gaussovský mixovací model je definován vztahem:

$$p(\mathbf{x}|u) = \sum_{i=1}^M \frac{c_i}{\sqrt{(2\pi)^L |\Sigma_i|}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_i)^T \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) \right\} \quad (2)$$

Kde:

u identita osoby, ke které je obraz ruky přiřazen s pravděpodobností p ,

\mathbf{x} vektor biometrických rysů,

c_i váha i -tého Gaussovského modelu,

$\boldsymbol{\mu}_i$ průměrný vektor i -tého modelu,

Σ_i kovarianční matice i -tého modelu,

M počet modelů,

L dimenze vektoru biometrických rysů.

Strojové učení

Strojové učení je skupina algoritmů, které umožňují počítačovému systému se učit. Mitchell [124] definoval strojové učení takto: „*O počítačovém programu se říká, že se učí ze zkušenosti E s ohledem na některé třídy T a měřeného výkonu P , pokud se jeho výkon P , zlepšuje se zkušenostmi E .*“

Velkou a velmi často využívanou skupinou strojového učení jsou algoritmy označované jako podpůrné vektory neboli podpůrné vektorové stroje (SVM). SVM jako klasifikátor použili Vinodkumar a Srikantaswamy v multi-biometrickém systému, kde biometrickými charakteristikami byly geometrie ruky, otisky prstů a dlaně [184], využity však byly i v mnoha dalších uni-biometrických a multi-biometrických systémech na bázi ruky [13], [55], [57], [63].

Další často využívaná metoda strojového učení v biometrických systémech na bázi ruky je metoda k -nejbližších sousedů (k -NN) [66], [103]. Jde o jednu z nejjednodušších klasifikačních metod. Pro porovnání se vzorem lze využít také Bayesovské sítě [103].

Jako klasifikátory lze použít i některé druhy neuronových sítí, vícevrstvá neuronová síť (MLP) [56]. Jako klasifikátory, kterým nepředcházela extrakce rysů, byly použity zobecněná regresní neuronová síť (GRNN) [138].

1.4.5 Rozhodnutí

Konečné rozhodnutí o totožnosti uživatele je ve většině systémů založeno na prahové hodnotě, která je volena tak, aby biometrický systém splňoval požadavky bezpečnosti a propustnosti.

Skóre vypočítané v předchozím modulu systému se porovná s prahovou hodnotou. Pokud je skóre vyšší než prahová hodnota, uživatel je identifikován nebo verifikován, pokud je však skóre nižší než prahová hodnota, uživatel identifikován nebo verifikován není. Na výsledek rozhodnutí u biometrických systémů na bázi ruky má značný vliv školení uživatelů, se správnými návyky uživatelů se zvyšuje skóre (shoda porovnávaných vzorků) [48], [102].

1.5 Moderní metody v biometrických systémech na bázi ruky

Ve většině biometrických systémů na bázi ruky jsou využívány klasické metody [4]. Nicméně v poslední době zaznamenaly velmi dobré výsledky v oblasti počítačového vidění a zpracování přirozeného jazyka metody hlubokého učení. Hluboké učení je disciplína v rámci strojového učení, která se zabývá využitím algoritmů s více vrstvami např. hlubokých neuronových sítí.

Díky úspěchu, který hluboké učení zaznamenalo oblastech počítačového vidění, se začalo prosazovat i do oblasti biometrického rozpoznávání osob podle tváře [146], otisku prstů [164], otisku dlaně [116], duhovky [115], hlasu [111], podpisu [72] a chůze [177]. Především konvoluční neuronové sítě v poslední době překonávají tradiční přístupy v biometrických systémech. Problém může však nastat, když je k dispozici malé množství dat, protože pak je CNN náchylná k overfittingu (přeučení) [24]. I při malém počtu dat však lze využít CNNs pro extrakci rysů [4], [17]. Pro porovnání s biometrickou šablonou pak lze využít klasické klasifikátory.

Autoři, kteří využili metod hlubokého učení pro biometrické systémy na bázi ruky, pracovali především s nejstarší známou biometrickou charakteristikou – otisk prstu. Pro extrakci dat z otisku prstu byly využity konvoluční neuronové sítě (JungeNet a LocaleNet), snímky otisku prstu nebylo nutné předzpracovat, výjimkou je pouze normalizace dat [43]. CNNs byly využity také pro detekci pórů na otiscích prstů, extrahované rysy pórů byly následně využity v kombinaci s daktyloskopickými markanty [137]. Tyto daktyloskopické markanty byly extrahovány pomocí klasické metody (Gaborových filtrů) [137].

Otisky dlaní jsou stejně jako otisky prstů tvořeny papilárními liniemi, proto se při identifikaci osoby využívá podobných přístupů. Jde tedy o další biometrickou charakteristiku, při jejímž zpracování byly využity metody hlubokého učení. Pro extrakci rysů z nezpracovaného snímku otisku dlaně byly v literatuře využity CNNs, před extrakcí rysů nebyl vytvořen výběr oblasti zájmu (ROI) [2], [156]. Použita byla také konvoluční neuronová síť AlexNet pro extrakci biometrických rysů v kombinaci s ROI, klasifikace byla provedena pomocí Hausdorffovi

vzdálenosti [197]. Autoři Zhao a Wang. využili jinou z metod hlubokého učení, a to omezený Boltzmannův stroj (RBM) v kombinaci s výběrem oblasti zájmů (ROI) o velikosti 32×32 pixelů [206]. Mezi nejnovější metody využívané pro extrakci biometrických znaků z otisku dlaně patří siamské sítě [208]. Tyto sítě mají symetrickou strukturu a sdílí mezi sebou hodnoty některých parametrů.


V literatuře se lze také setkat s biometrickými systémy na bázi ruky, kde je využita konvoluční [143] nebo zobecněná regresní neuronová síť (GRNN) [138] pro extrakci biometrických rysů i následnou klasifikaci.

1.6 Metody v biometrických systémech využívající infračervené záření

Rychlý vývoj v oblasti informačních technologií a zvýšení bezpečnostních rizik vede ke snaze zlepšit spolehlivost biometrických systémů. Jednou z možností, jak zlepšit spolehlivost biometrického systému, je využití infračervené části elektromagnetického spektra.

1.6.1 Infračervené záření

Elektromagnetické spektrum je škála elektromagnetického vlnění. Elektromagnetické spektrum je rozděleno na části podle vlnové délky, kde nejkratší vlnovou délku má rentgenové záření (RTG), následují ultrafialové záření (UV), viditelné světlo, infračervené záření (IR), mikrovlny a radiové vlny. Elektromagnetické spektrum je zobrazeno na obrázku 6. Infračervené záření je záření s vlnovou délkou mezi 760 nm a 1 mm.



Obrázek 6: Jednotlivé části elektromagnetického spektra

Zdroj: [178]

Zachycením infračerveného záření a následným grafickým znázorněním povrchové teploty pozorovaného objektu se zabývá zobrazovací technika – infračervená termografie. První, kdo

zobrazil termální neboli infračervený snímek, byl John Herschel, syn objevitele infračerveného spektra [178].

V současnosti se termální snímky získávají za pomoci termální kamery, přičemž detektor v termální kameře zjišťuje intenzitu infračerveného záření. Jelikož intenzita infračerveného záření přímo závisí na povrchové teplotě tělesa, dokáže termální kamera teplotu vypočítat a zobrazit. Povrchová teplota tělesa je zobrazena na termálním snímku (termogram).

Infračervené záření zachycené kamerou však nezávisí pouze na teplotě objektu, ale také na funkci emisivity. Termální snímek může být dále ovlivněn zářením pocházejícím z okolí a jeho následným odražením, záření objektu může také ovlivnit absorpce atmosféry. Pro přesné měření teploty je proto nutné kompenzovat účinky řady různých zdrojů záření.

1.6.2 Infračervené záření v biometrických systémech

V biometrii lze infračervené záření využít dvěma způsoby. Prvním způsobem je ozáření ruky infračerveným zářením, které zvýrazní kontrast mezi cévním řečištěm a okolní kůží [170], [212]. Cévní řečiště je zvýrazněno díky vyšší absorpci infračerveného záření hemoglobinem oproti nižší absorpci sousedních tkání.

Druhý způsob využívá toho, že každý předmět s teplotou vyšší než absolutní nula (-273 °C) vyzařuje infračervené záření a lze pomocí něj měřit teplotu na povrchu těla [178]. Informace o teplotě na povrchu těla lze také využít jako další biometrickou charakteristiku. Protože teplotní mapa naší kůže je důsledkem buněčného metabolismu, zpracování živin (sacharidy, lipidy a proteiny), jde tedy o individuální anatomickou charakteristiku [161]. Tělesná teplota se však může u jedince měnit z důvodu tělesné aktivity, teploty okolního prostředí, oblečení a nemoci. Grafickým znázorněním povrchové teploty částí těla vznikne termální snímek dané části těla.

Nejvíce výzkumů, které se zabývají rozpoznáním osoby s využitím termálních charakteristik, využívá termální snímky tváře [31], [71], [99]. Avšak existuje i několik málo výzkumů v oblasti rozpoznávání osob na základě tepelných charakteristik ruky. Cajka a Bulwan jsou autoři výzkumu, který se zabývá sestrojením hardwaru, jenž zachytí teplotní mapu ruky a následně je tato teplotní mapa využita pro verifikaci osoby [40]. Po sestrojení hardwaru byla vytvořena malá datová sada termálních snímků ruky, která byla použita pro testování biometrického systému, kde pro extrakci rysů byla použita lineární diskriminační analýza (LDA) v kombinaci

s analýzou hlavních komponent (PCA) a klasifikace proběhla pomocí metody nejbližšího souseda [40].

Druhá studie, které se zabývá rozpoznáváním osob pomocí termální biometrie, využívá metodu BDM (Biometric dispersion matcher) pro extrakci znaků a pro následnou klasifikaci diskriminační analýzu (DA) [52]. V této studii jsou využity pro rozpoznání osoby termální snímky ruky, ale i kombinace termálního snímku a viditelného snímku ruky s fúzí na úrovni skóre.

Mezi nejnovější studie v oblasti termálních charakteristik ruky patří studie, které využívají konvoluční neuronové sítě AlexNet [17] a VGG-16 [18] jak pro extrakci rysů, tak pro následnou klasifikaci. Dle provedené rešerše pravděpodobně dosud nebyl proveden další výzkum, který by se zabýval rozpoznáváním osob na základě termálních charakteristik ruky.

Tepelné charakteristiky ruky jsou však často využívané pro segmentaci, nebo se využívají jako podpůrná technika extrakce netermálních prvků. Autoři navrhují metodu segmentace založenou na Fisherově poměru (F-ratio), kdy se řeší, zda je rozptyl dostatečně velký, shlukové analýze a použití aktivního modelu tvarů (AMS) jak pro snímky získané při viditelném světle, tak pro termální snímky ruky [52], [58]. Tyto experimenty byly provedeny na snímcích získaných od 104 subjektů a přesnost segmentace ruky se blíží 85 %.

1.7 Porovnání vybraných studií

Biometrický systém má za cíl rozpoznat člověka a může pracovat ve dvou režimech, verifikace a identifikace. Výběr studií, které se objevily v časopisech a na konferencích je uveden v tabulce 2. Výběr se snaží porovnat reprezentativní vzorek systémů na bázi ruky se zaměřením na geometrii, obrys a texturu ruky, podle různých vlastností (režim, techniky použité pro extrakci rysů, techniky použité pro porovnání, velikost datové sady, výkon). Porovnat výkonnost jednotlivých biometrických systémů lze pomocí hodnot EER, FAR / FRR nebo přesnosti (Acc), někteří autoři hodnotí systémy pomocí ROC křivek, nebo plochy pod ROC křivkou (AUC).

Tabulka 2: Přehled vybraných studií – biometrické systémy na bázi ruky

Zdroje	Biometrické charakteristiky / režim	Techniky použité pro extrakci rysů	Techniky použité pro porovnání	Velikost datové sady	Výkon
Burques et al. [32]	Geometrie ruky / verifikace	Geometrická měření	Minimální vzdálenost	12 800	EER = 0,0016
Kumar & Zang [103]	Geometrie ruky / identifikace	Diskretizace rysů geometrie ruky	SVM	1 000	Acc = 0,9400
Shanmukhappa & Sanjeevakumar [12]	Geometrie ruky / identifikace	Vektor rysů je konstruován pomocí grafu obrazu ruky	SVM (Radiální báze funkce)	1 440	FRR = 0,0205
Jain et al. [86]	Geometrie ruky / verifikace	Geometrická měření	Euclidova vzdálenost	500	EER= 0,0600
Varchol & Levický [181]	Geometrie ruky / verifikace	Geometrická měření	Hammingova vzdálenost	408	EER = 0,0973
Villegas et al. [183]	Geometrie ruky / identifikace	Wavelet Features	Nejbližší soused	120	FAR = 0,1100 FRR = 0,1000
Varchol & Levický [181]	Geometrie ruky / verifikace	Geometrická měření	Gaussovský mixovací model	408	EER = 0,0462
Afifi [4]	Textura a obrys ruky / identifikace	CNNs + Lokální binární vzor (LBP)	SVM	11 076	EER = 0,009
Charfi et al. [34]	Obrys ruky / identifikace	V měřítku neměnná transformace rysů (SIFT)	SIFT Matching	1 170	EER = 0,0586
Yoruk et al. [200]	Obrys ruky / identifikace	Analýza nezávislých komponent (ICA)	L1 / L2 norma rozdílu vektorů rysů	458	Acc = 0,9731
Yoruk et al. [200]	Textura ruky / identifikace	Analýza hlavních komponent (PCA)	L1 / L2 norma rozdílu vektorů rysů	458	Acc = 0,9791
Yoruk et al. [200]	Textura ruky / identifikace	Angular radial transform (ART)	L1 / L2 norma rozdílu vektorů rysů	458	Acc = 0,9760
Chajka & Bulwan [40]	Termální charakteristiky / verifikace	Lineární diskriminační analýza (LDA) + Analýza hlavních komponent (PCA)	Nejbližší soused	3 600	EER = 0,0633
Bartuzi et al. [18]	Termální charakteristiky / identifikace	CNN (VGG-16)	CCN (Softmax)	21 000	EER = 0,17

Zdroj: autor

Starší systémy používají jako rysy geometrická měření a jsou většinou ve verifikačním režimu [86]. Novější systémy využívají kombinaci více biometrických charakteristik, jako je tvar a struktura ruky [4], [142]. Jsou z většiny v režimu identifikace a FRR, nebo EER mají méně než 1 %. Zároveň nejmodernější systémy využívají metod hlubokého učení především konvoluční neuronové sítě [18], [142].

1.8 Dosud nevyřešené výzvy biometrických systémů na bázi ruky

Po zjištění současnému stavu biometrického rozpoznávání osob na bázi ruky, byly definovány následující výzvy v této oblasti. Aby byly biometrické systémy na bázi ruky v reálných aplikacích více účinné, je potřeba překonat tyto problémy:

- **Možnost nízké variability mezi uživateli** – v reálném světě je často potřeba rozeznat velké množství identit, a přitom variabilita mezi některými jedinci může být velmi nízká.
- **Vysoká intrapersonální variace** – obvykle se vyžaduje více snímků od jednoho jedince, a to z důvodu, že rozdíl mezi snímky jednoho jedince může být větší, než rozdíl mezi dvěma jednotlivci.
- **Ne vždy dostatečná kvalita vstupních dat** – díky pokroku snímacích senzorů bývá vstupní obraz získaný v reálné aplikaci za standardních světelných podmínek správně exponovaný. Při zhoršených světelných podmínkách se však kvalita snímků zhoršuje. Dalšími problémy, se kterými se potýkáme i přes velký pokrok senzorů, jsou správné zachycení barev, šum.
- **Nestálost biometrických charakteristik** – u biometrických charakteristik na bázi ruky je vysoká stálost v čase, není však úplná. U geometrie ruky, tvaru ruky a topografie krevního řečiště je problémem především biologické stárnutí a případná zranění.
- **Vliv změny okolního prostředí při snímání** – extrakce biometrických rysů ze snímků, ve kterých se vyskytuje velké množství šumu nebo je přeplněné pozadí, vyžaduje v současnosti zpravidla značné zpracování obrazu.
- **Útoky na systémy** – biometrické systémy na bázi ruky musí v reálných aplikacích čelit útokům na různých úrovních. Příkladem je útok na vstupní zařízení, kdy útočník padělá biometrický vzorek, protiopatřením může být detekce živosti.

- **Malé datové sady** – většina současných systémů je testována na poměrně malých datových sadách.

Vzhledem ke současnému stavu biometrického rozpoznávání osob na bázi ruky, a vzhledem k dosud nevyřešeným výzvám v této oblasti dané problematiky, je navrženo využít pro účely rozpoznání osob termální charakteristiky ruky v kombinaci s dalšími charakteristikami ruky. Důvodem volby této biometrické charakteristiky je především její uživatelská přívětivost. Uživatelská přívětivost je vlastnost systému, která je často opomíjena, avšak je velmi důležitá.

U navrženého výzkumu lze předpokládat, že přispěje k vyřešení následujících problémů:

- Vysoká intrapersonální variace – lze předpokládat, že multi-biometrický systém využívající současně snímky z viditelné části elektromagnetického spektra a termální snímky, sníží intrapersonální variaci.
- Ne vždy dostatečná kvalita vstupních dat – termální snímek není závislý na světelných podmínkách.
- Útoky na biometrické systémy – při využití termálního snímku také dochází k eliminaci některých druhů útoků na biometrické systémy, protože tepelnou mapu ruky, kterou zachycuje termální snímek, je velice obtížné napodobit a zároveň dochází i k detekci živosti.
- Malé datové sady – v rámci výzkumu byla vytvořena rozsáhlá datová sada termálních snímků a snímky ruky z viditelné části elektromagnetického spektra (dále viditelné snímky).

2 CÍL DISERTAČNÍ PRÁCE A POSTUP JEHO DOSAŽENÍ

2.1 Cíle disertační práce

Cílem disertační práce navržení a ověření nového způsobu biometrického rozpoznávání osob s využitím termálních charakteristik ruky v kombinaci s běžně používanými charakteristikami ruky.

Nový model biometrického rozpoznávání osob, bude využívat snímky z viditelné části elektromagnetického spektra a termálního snímku ruky. Součástí výzkumu je vytvoření rozsáhlé datové sady termálních snímků ruky a snímků ruky z viditelné části elektromagnetického spektra (dále jen viditelné snímky).

Lze předpokládat, že kombinace snímků získaných v různých elektromagnetických spektrech bude obsahovat více informací, než pouze snímek ruky z jednoho elektromagnetického spektra, a proto bude multi-biometrický systém dosahovat spolehlivějších výsledků identifikace. Využití termálního snímku by mělo zvýšit spolehlivost biometrického systému, zejména pokud bude snímek získán za zhoršených světelných podmínek a v neposlední řadě by mělo zabránit některým druhům útoku na biometrický systém, jelikož podvrhnout tepelnou mapu ruky je velice složité ne-li nemožné.

2.2 Obecný postup dosažení cíle disertační práce

Postup k dosažení cíle disertační práce se skládá z následujících kroků:

1. Shrnutí aktuálního stavu v oblasti biometrického rozpoznávání osob na bázi ruky.
2. Volba vhodných ukazatelů pro kvantitativní ohodnocení navrženého biometrického rozpoznávání osob.
3. Nalezení a teoretický popis vhodných metod umělé inteligence využitelných pro biometrické rozpoznávání osob.
4. Vytvoření rozsáhlé datové sady snímků ruky (ve dvou spektrech), využitelnou pro naučení a verifikaci modelu biometrického rozpoznávání.
5. Navržení modelu biometrického rozpoznávání.
6. Kvantitativní ohodnocení navrženého modelu biometrického rozpoznávání.

3 MĚŘENÍ VÝKONNOSTI BIOMETRICKÝCH SYSTÉMŮ

V této kapitole jsou popsány různé ukazatele výkonnosti jednotlivých modelů biometrické identifikace, které lze použít pro jejich vzájemné porovnání kvality. Tyto ukazatele, které měří výkonnost biometrických systémů slouží k porovnání, který biometrický systém je lepší potažmo nejlepší. Zároveň, ale není možné říci, který z mnoha existujících ukazatelů výkonnosti je nejlepší. Při vyhodnocování experimentálních výsledků mohou být využity následující ukazatele výkonnosti:

- přesnost – Acc (angl. Accuracy),
- operační křivka – ROC (angl. Receiver Operating Characteristic), respektive plocha pod křivkou – AUC (angl. Area Under Curve),
- míra chybného přijetí – FAR (angl. False Acceptance Rate),
- míra chybného odmítnutí – FRR (angl. False Rejection Rate),
- výpočetní čas – čas trénování a testování (angl. Computational time).

Jak již bylo zmíněno biometrická identifikace je klasifikační problém. Někteří ukazatelé, které budeme využívat pro hodnocení modelů, jsou všeobecně používání pro hodnocení modelů. Někteří jsou však specifické pouze pro oblast biometrických systémů (např. FAR, FRR).

3.1 Přesnost klasifikace

Jde o jeden ze standartních ukazatelů výkonnosti klasifikačních modelů. Přesnost (Acc) se vypočítá, jako procento správně identifikovaných osob. A to podle výskytů jednotlivých druhů rozhodnutí, které jsou zachyceny v matici záměn (confusion matrix). Tabulka 3 znázorňuje matice záměn ve tvaru, ve kterém se využívá v oblasti biometrických systémů.

Tabulka 3: Matice záměn

Skutečnost	Rozhodnutí	
	Přijmout	Odmítnout
Oprávněný uživatel	Správné přijetí TA	Chybné odmítnutí (chyba I. typu) FR
Neoprávněný narušitel	Chybné přijetí (chyba II. typu) FA	Správné odmítnutí TR

Zdroj: autor

$$\text{Acc} = \frac{\text{TA} + \text{TR}}{\text{TA} + \text{TR} + \text{FA} + \text{FR}} \quad (3)$$

Kde TA + TR + FA + FR jsou počty jednotlivých druhů rozhodnutí, správné přijetí (TA), správné odmítnutí (TR), chybné přijetí (FR), a chybné odmítnutí (FA).

3.2 Míra chybného odmítnutí

Míra chybného odmítnutí (FRR) je pravděpodobnost, že biometrický systém nerozpozná oprávněného uživatele. Dojde k chybnému odmítnutí neboli k chybě 1. typu. Pokud dojde k chybě tohoto typu může se uživatel opětovně pokusit prokázat svoji identitu. Výpočet FRR se provádí podle vzorce [82], [141]:

$$\text{FRR} = P(\text{FR}/\text{OU}) = \lim_{N_{\text{OU}} \rightarrow \infty} \frac{N_{\text{FR}}}{N_{\text{OU}}} \quad (4)$$

Kde:

- FR výskyt chyby odmítnutí,
- OU identifikace oprávněným uživatelem,
- N_{FR} počet chybných odmítnutí,
- N_{OU} počet pokusů oprávněnými uživateli o identifikaci.

3.3 Míra chybného přijetí

Míra chybného přijetí (FAR) je pravděpodobnost, že biometrický systém přijme neoprávněného narušitele, dojde k chybnému přijetí neboli k chybě 2. typu. Výpočet FAR se provádí podle vzorce:

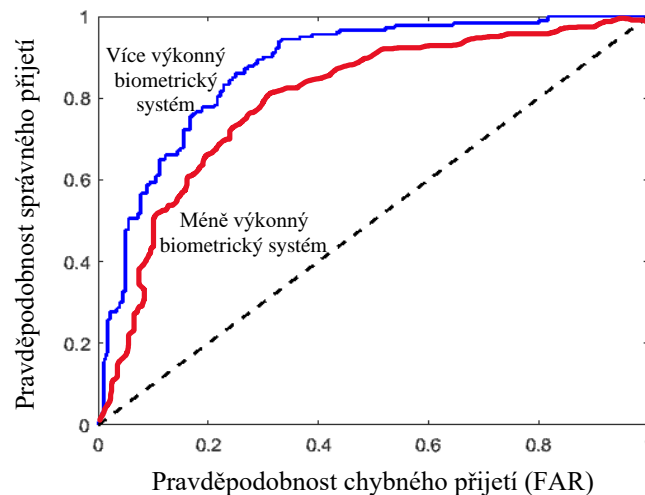
$$\text{FAR} = P(\text{FA}/\text{NN}) = \lim_{N_{\text{NN}} \rightarrow \infty} \frac{N_{\text{FA}}}{N_{\text{NN}}} \quad (5)$$

Kde:

- FA výskyt chyby přijetí,
- NN identifikace neoprávněným narušitelem,
- N_{FA} počet chybných přijetí,
- N_{NN} počet pokusů neoprávněnými narušiteli o identifikaci.

3.4 Operační křivka ROC a plocha pod křivkou AUC

ROC křivka je pravděpodobnostní křivka, která je daná vztahem pravděpodobnosti chybného přijetí (FAR) na ose x a odpovídající pravděpodobnosti správného přijetí na ose y pro všechny přípustné hodnoty prahu. Pomocí ROC křivek lze porovnat více modelů mezi sebou. Porovnání a vyhodnocení více ROC křivek se provádí pomocí ploch AUC, které se nachází pod jednotlivými ROC křivkami. Ilustrační ROC křivky jsou znázorněny na obrázku 7. [171]



Obrázek 7: ROC křivky

Zdroj: [171]

3.5 Výpočetní čas

Algoritmy strojového učení a hlubokého učení bývají velmi náročné na výpočetní zdroje, zejména jde o časovou náročnost, o to více pokud se výpočty provádějí na centrální procesorové jednotce (CPU). Zatímco testování modelu zabere nevýznamné množství času, trénování modelu může zabrat značné množství času. Doba trénování (testování) se hodnotí pomocí množství času stráveného učením (testováním) v sekundách.

4 MULTI-BIOMETRIE

Cílem disertační práce navržení a ověření nového způsobu biometrického rozpoznávání osob s využitím termálních charakteristik ruky v kombinaci s běžně používanými charakteristikami ruky. Výzkum byl proto zaměřen na multi-biometrický systém, který je založen na termálních a dalších charakteristikách ruky. Taková to kombinace více zdrojů informací vyžaduje fúzi informací.

4.1 Multi-biometrické systémy

Multi-biometrický systém využívá více než jeden zdroj biometrických informací pro biometrické rozpoznávání osob. Tyto systémy dosahují vyšší přesnosti, než biometrické systémy využívající pouze jednu biometrickou charakteristiku (uni-biometrické systémy) [148]. Multi-biometrické systémy lze zařadit do jedné z následujících šesti podkategorií (obrázek 8):

- **Multi-senzorový systém** – používá více senzorů k zachycení jedné biometrické charakteristiky. Například ke snímání ruky může být použito více kamer. Jedna snímá obraz ruky ve viditelném elektromagnetickém spektru a druhá kamera snímá obraz ruky v infračerveném spektru. Použití více senzorů může vést k získání doplňkových informací, které mohou zlepšit schopnost systému rozpoznat osobu. V současné době se využívají především multispektrální kamery pro snímání obličeje [194].
- **Multi-algoritmický systém** – využívá různé algoritmy na stejný biometrický vzorek. Existují dva typy těchto systémů, první typ využívá více algoritmů pro extrakci biometrických rysů (například z prstu [147]). Druhý typ využívá více algoritmů pro porovnání jedné sady biometrických rysů se šablonou (například obličeje [204]). Tyto dva typy lze také kombinovat. Výhodou tohoto přístupu je menší finanční náročnost řešení oproti ostatním multi-biometrickým systémům, nevýhoda je zvýšení výpočetní složitosti.
- **Multi-istanční systém** – se zabývají více instancemi stejných biometrických charakteristik. Jinými slovy tyto systémy využívají toho, že osoby mají některé biometrické charakteristiky ve více „vydáních“, jako jsou prsty, uši, oči, otisky dlaní a klouby. Systém využívá například levou i pravou duhovku jedince [23].



- **Multi-vzorkový systém** – jeden senzor může být použit k získání více vzorků stejné biometrické charakteristiky, aby se zohlednily variace, které se mohou v biometrické charakteristice vyskytnout, nebo aby byla získána úplnější prezentace základní biometrické charakteristiky. Senzor může například zachytit přední profil obličeje spolu s levým a pravým profilem, aby se zohlednily odchylky v pozici obličeje [75].
- **Multi-modální systém** – k rozpoznávání osoby využívá více biometrických charakteristik. Příkladem může být využití geometrie ruky a topografie krevního řečiště [70], [108]. Nevýhodou systému je většinou vyšší finanční náročnost (více senzorů) a zvýšení výpočetní složitosti.

Multi-senzorový systém



Multi-spektrální kamera

Multi-algoritmický systém



Markanty, textura

Multi-istanční systém



Pravá a levá duhovka

Multi-vzorkový systém




Z
D
R
O
J
E



Více pohledů na obličej

I
N
F
O
R
M
A
C
Í

Multi-modální systém



Více biometrických charakteristik (tvář, duhovka)

Obrázek 8: Kategorie multi-biometrického systému

Zdroj: autor a [149]

- **Hybridní systém** (hybrid system) – tento systém kombinuje některé z výše uvedených multi-biometrických systémů. Příkladem může být systém, kde je využíváno rozpoznání hlasu a obličeje, zároveň je k rozpoznání každé z těchto biometrických charakteristik použito alespoň dvou algoritmů [30]. Systém je multi-modální a zároveň multi-algoritmický.

Výhody multi-biometrického systému

Kromě zvýšení přesnosti mají multi-biometrické systémy další výhody oproti uni-biometrickým systémům [149]:

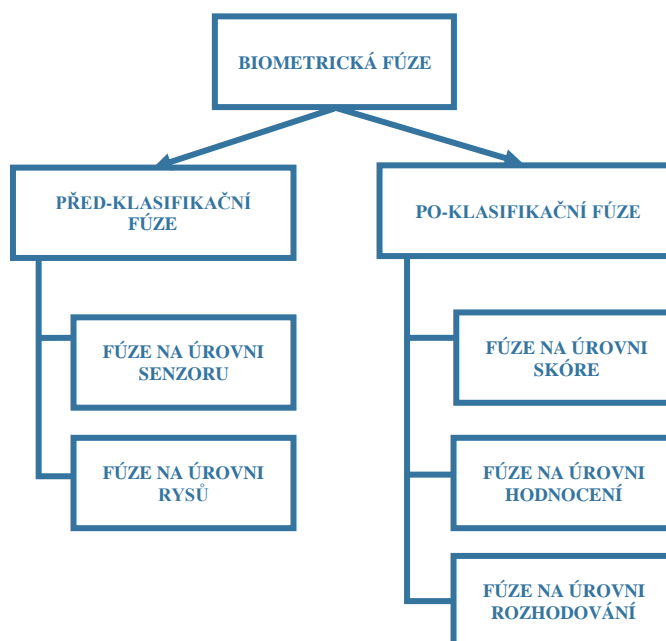
- Multi-biometrické systémy pomáhají řešit problém neuniverzálnosti biometrických charakteristik (ne u všech osob existuje daná charakteristika). Pokud je možné využít pro rozpoznání kombinaci dvou biometrických charakteristik ze tří charakteristik například obličej, hlas a otisk prstu. Může biometrický systém využívat i člověk, který je němí.
- Multi-biometrické systémy mohou usnadnit filtrování nebo indexování rozsáhlých biometrických databází. Například v multi-biometrickém systému se dvěma biometrickými charakteristikami (otisk dlaně a termální charakteristiky ruky) Pomocí biometrických rysů získaných z termálních charakteristik se vypočítá hodnota indexu pro extrahování kandidátního seznamu identit. Pomocí otisku dlaně pak lze z tohoto omezeného seznamu kandidátů určit konečnou identitu.
- Pro podvodníka je mnohem obtížnější (ne-li nemožné) podvrhnout více biometrických vzorků legitimně zapsaného jedince. Pokud každý podsystém udává pravděpodobnost, že určitý biometrický vzorek je „zfalšovaný“, pak lze použít vhodná fúzní schémata k určení, zda je uživatel ve skutečnosti podvodník.
- Multi-biometrické systémy také účinně řeší problém zašumění dat. Když je biometrický vzorek získaný z jedné biometrické charakteristiky narušen šumem, dostupnost jiných (méně hlučných) vzorků může napomoci spolehlivému určení identity. Některé systémy zohledňují kvalitu jednotlivých biometrických vzorků během procesu fúze. Když rozpoznávání probíhá za nepříznivých podmínek, kdy nelze spolehlivě extrahovat určité biometrické rysy, je to velká výhoda. Například v přítomnosti okolního akustického hluku, kdy nelze přesně změřit hlasové charakteristiky jednotlivce, může multi-biometrický systém použít k provedení autentizace především rysy

obličej. Odhadování kvality získaných dat je náročným problémem, ale pokud je správně provedeno, velmi zvýhodní multi-biometrické systémy.

- Na multi-biometrický systém lze také nahlížet jako na systém odolný proti chybám. systém pokračuje v provozu, i když se některé biometrické zdroje stanou nespolehlivé kvůli poruše senzoru, softwaru, nebo úmyslné manipulaci uživatelem. Odolnost vůči chybám je zvláště užitečná u rozsáhlých biometrických systémů zahrnujících velký počet subjektů (jako je například aplikace hraniční kontroly).

4.2 Fúze na různých úrovních biometrického systému

Kombinace více zdrojů biometrických informací v jednom biometrickém systému vyžaduje fúzi, což je propojení informací. Fúze lze dosáhnout na různých úrovních biometrického systému [149]. Jednotlivé fúze na různých úrovních biometrického systému jsou znázorněny na obrázku 9.



Obrázek 9: Fúze na různých úrovních biometrického systému

Zdroj: [149]

4.2.1 Před-klasifikační fúze

Před-klasifikační fúze je, první ze dvou širokých kategorií fúze, která probíhá před klasifikací v biometrickém systému. Tato široká kategorie fúze je definována, protože je-li použita před-klasifikační fúze, množství informací, které jsou k dispozici po fúzi, se sníží. Zároveň se sníží výpočetní složitost. Mezi fúze patřící do této kategorie jsou:

- **Fúze na úrovni senzoru** – fúze na úrovni senzoru může být provedena dvěma způsoby. Buď sloučením nezpracovaných dat získaných pomocí více senzorů, nebo sloučením více snímků jedné biometrické charakteristiky [159]. V literatuře lze nalézt jen velmi málo prací o fúzi na úrovni senzoru [7], [165]. Velká výhoda této úrovně fúze je však její nízká výpočetní složitost [7]. Aldjia a Leila využili konvoluční neuronovou síť (CNN), ve které provedli fúze na úrovni senzoru. Fúzi snímků obličeje, otisku dlaně a duhovky, naskládáním tří biometrických kanálů, jako RGB kanálů [7].
- **Fúze na úrovni rysů** – při této fúzi jsou sloučeny vektory rysů, které byly extrahovány z dat získaných pomocí více senzorů, nebo bylo k extrakci využito více algoritmů. Na této úrovni fúze probíhá normalizace, transformace a redukce vektorů rysů za účelem získání konsolidovaného vektoru rysů [149]. Fúzi na úrovni rysů, využili autoři Soleymani et al. ve své práci, když navrhli sloučení obličeje, duhovky a otisku prstu na úrovni rysů pomocí společné architektury CNN [162].

4.2.2 Po-klasifikační fúze

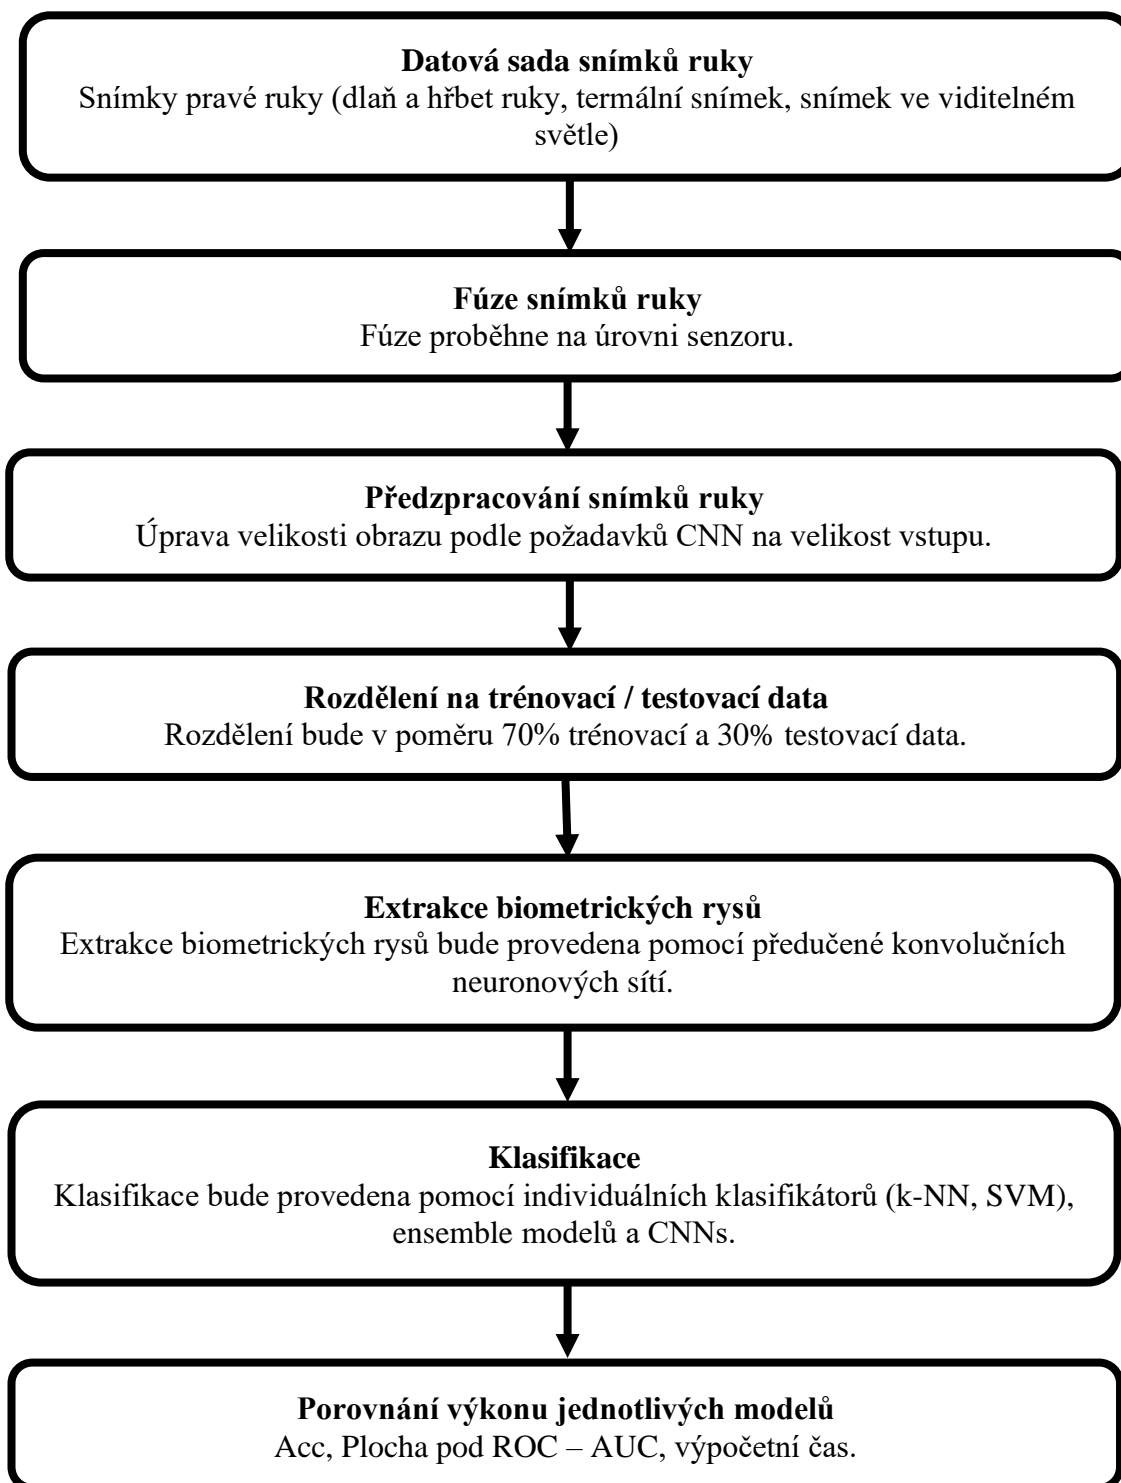
Po-klasifikační fúze je druhá ze dvou širokých kategorií fúze, která probíhá až po klasifikaci v biometrickém systému. Je-li použita po-klasifikační fúze, množství informací v systému je větší než při před-klasifikační fúzi. Zároveň se zvýší výpočetní složitost. Mezi fúze patřící do této kategorie jsou:

- **Fúze na úrovni skóre** – potom co dojde k porovnání biometrických rysů, které byly extrahovány z biometrického vzorku rozpoznávané osoby s biometrickou šablonou je získáno skóre. Skóre je vypočítáno pro každý charakteristický rys zvlášť a následně dojde k fúzi a je získáno celkové skóre. V [36] je představen multimodální biometrický rozpoznávací systém, který kombinuje otisky prstů, žíly prstů a obrazy obličeje, využívající architektury CNN a dva klasifikátory, kterými jsou Softmax a náhodný les. Skóre získané z těchto systémů jsou sloučeny, aby se zlepšila identifikace lidí.

- **Fúze na úrovni hodnocení** – dojde ke spojení hodnocení jednotlivých biometrických systémů, ze kterých se multi-biometrický systém skládá a je získáno celkové výstupní hodnocení. V [6] autoři představili multimodální biometrický systém založený na hlubokém učení, ve kterém je kombinována pravá a levá duhovka člověka pomocí jednoho z fúzních algoritmů ve fázi hodnocení.
- **Fúze na úrovni rozhodování** – dojde k rozhodnutí na úrovni jednotlivých biometrických systémů, ze kterých se multi-biometrický systém skládá (přijato nebo odmítnuto). Poté dojde k fúzi těchto rozhodnutí a je získáno konečné rozhodnutí.

5 POSTUP VÝZKUMU

Postup výzkumu disertační práce je znázorněn na obrázku 10. Nejprve byly shromážděny snímky ruky (termální snímky, snímky ve viditelné části elektromagnetického spektra). Poté byla provedena fúze na úrovni senzoru, kdy došlo k vytvoření multispektrálního snímku ruky. Následovalo předzpracování obrazu, vzhledem k využití konvolučních neuronových sítí, šlo o změnu velikosti snímků, aby měly požadovanou velikost (podle požadavků na velikost vstupu dané konvoluční neuronové sítě). Experimenty byly prováděny na trénovacích a testovacích datech, rozdělení dat na trénovací a testovací data bylo provedeno pomocí v poměru 70 % (trénovací) a 30 % (testovací) data a také 5násobné křížové validace, aby byla zajištěna spolehlivost výsledků. V pátém kroku byla provedena extrakce biometrických rysů pomocí konvoluční neuronové sítě AlexNet, z multispektrálního snímku pravé ruky (dlaň i hřbet ruky). Pro následnou klasifikaci byly využity individuální klasifikátory (např. k-NN, SVM) a ensemble modely (homogenní). Provedena byla také společná extrakce rysů a klasifikace pomocí CNNs (AlexNet, GoogLeNet, VGG-16 a VGG-19). K učení konvolučních neuronových sítí byl využit algoritmus zpětného šíření chyby (back propagation), jenž využívá pro minimalizaci chyb optimalizační algoritmus stochastického gradientního sestupu (SGD). V poslední fázi byly porovnány výkony všech modelů. A byly změřeny časy trénování a testování za účelem vyhodnocení časové složitosti jednotlivých algoritmů.



Obrázek 10: Postup výzkumu

Zdroj: autor

6 METODY VHODNÉ PRO DOSAŽENÍ CÍLE DISERTAČNÍ PRÁCE

Tato část práce popisuje metody vhodné pro dosažení cíle disertační práce. Cílem disertační práce je navržení a ověření nového způsobu biometrického rozpoznávání osob s využitím termálních charakteristik ruky v kombinaci s běžně používanými charakteristikami ruky.

Rozpoznávání osob lze chápat jako úlohu rozpoznávání vzorů. V klasickém postupu rozpoznávání vzorů se využívají metody strojové učení. Prvky jsou nejprve extrahovány procesem extrakce prvků a klasifikátor předpovídá z těchto vlastností. Druhou možností postupu při rozpoznávání vzorů je využití konvoluční neuronové sítě. Tento přístup je odlišný klasického přístupu (porovnání obrázku 11 a 12). CNN jasně nerozdělují extrakci rysů a klasifikaci. To umožňuje trénovat i extrakci rysů, což může být užitečné pro řešení aktuální úlohy.



Obrázek 11: Klasický postup rozpoznávání vzorů

Zdroj: autor



Obrázek 12: Využití CNN pro rozpoznávání vzorů

Zdroj: autor

6.1 Metody vhodné pro zpracování obrazu a extrakci rysů

Po získání obrazu je nutné obraz zpracovat. Jaké metody zpracování obrazu je potřeba zvolit, ale velmi záleží na metodách použitých pro extrakci rysů z biometrického vzorku. Pokud jsou použity pro samotnou extrakci biometrických rysů nebo pro extrakci a následnou klasifikaci konvoluční neuronové sítě, je potřeba zpracování obrazu velmi malá, jde především o změnu velikosti vstupu, tak aby vyhovovala architektuře využití konvoluční neuronové sítě a následně je potřeba normalizace obrazu.

Po předzpracování obrazu je nutné extrahovat biometrické rysy z biometrických charakteristik. Existují dva přístupy extrakce biometrických rysů. V prvním přístupu odborník zkonstruuje speciální extraktory, na míru dané biometrické charakteristice. Tato metoda může být zdoluhavá, zvláště když je vstupní vektor rozměrný. V současné době je na vzestupu druhý přístup k extrakci rysů. Ve druhém přístupu se biometrické rysy získávají pomocí učení z dat, takto se učí například neuronové sítě. Jako extraktory u obrazů lze využít konvoluční neuronové sítě, pokud jsou využity konvoluční neuronové sítě velmi se zjednoduší také předzpracování obrazu [4], [112]. Konvoluční neuronové sítě však byly primárně vytvořeny pro společnou extrakci rysů a klasifikaci. Výhodou využití konvolučních neuronových sítí je také možnost využití přenosu učení, protože se velmi urychlí proces učení sítě. Přenosem učení je označován proces, kdy se neuronová síť natrénuje na rozsáhlé skupině dat. Takto předtrénovaná síť je poté využita pro trénování a klasifikaci na jiné skupině dat (může být menší než původní). Například neuronová síť *i* s parametry, které získala při trénování rozpoznávání obličeje (viditelné snímky) může být přeučena pomocí nové datové sady na rozpoznání obličeje (termální snímky). Poprvé přenos učení představil Lorien Pratta v roce 1992 v práci s názvem „*Discriminability-based Transfer between Neural Networks*“ [139]. Přehled vybraných konvolučních neuronových sítí, které jsou použity v této práci pro extrakci rysů nebo společnou extrakci rysů a klasifikaci, je uveden v tabulce 4.

Tabulka 4: Přehled použitých metod pro extrakci rysů a extrakci rysů s klasifikací

Kategorie metod	Metoda
Konvoluční neuronové sítě	AlexNet
	GoogLeNet
	VGG-16
	VGG-19


Zdroj: autor

Konvoluční neuronové sítě

Konvoluční neuronové sítě patří do velké skupiny metod hlubokého učení. Při hlubokém učení se počítačový model učí provádět klasifikační úkoly přímo z obrázků, textu nebo zvuku. Modely hlubokého učení mohou dosahovat vysoké přesnosti, někdy převyšující lidské schopnosti. Většina metod hlubokého učení využívá architektury neuronových sítí, a proto se modely hlubokého učení často označují jako hluboké neuronové sítě. Termín „hluboký“ obvykle označuje velký počet skrytých vrstev v neuronové síti. Tradiční neuronové sítě

obsahují pouze 2–3 skryté vrstvy, zatímco hluboké sítě jich mohou mít až 150. První konvoluční neuronovou síť představil ve své práci roce 1989 Yann LeCun, který ji použil k rozpoznávání číslic [107].

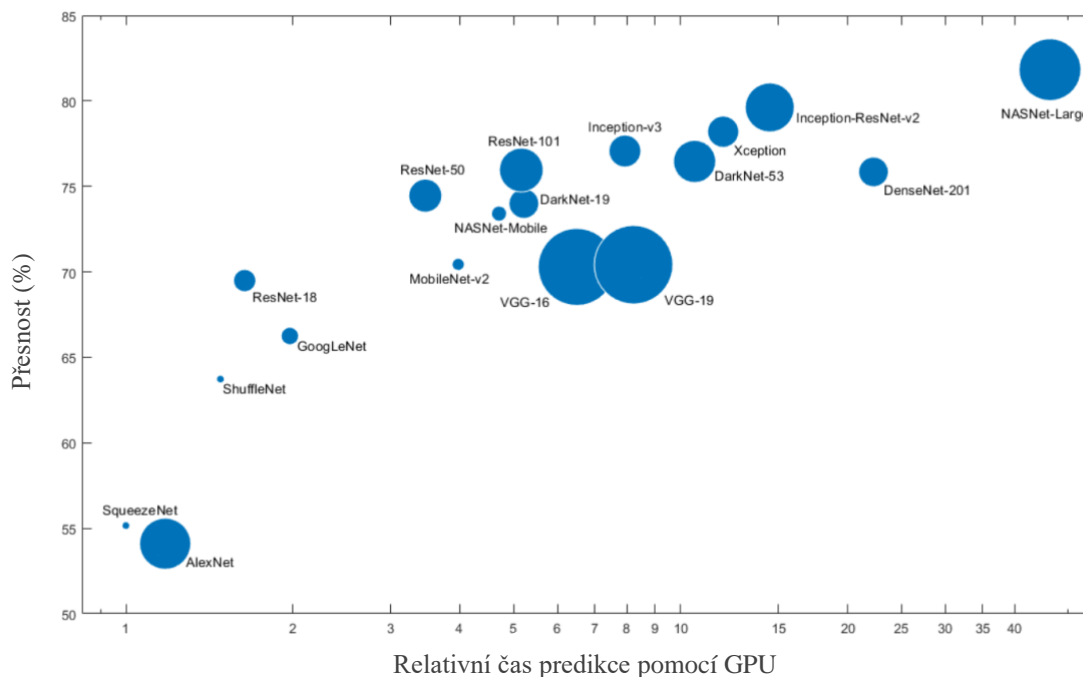
Konvoluční neuronová síť se skládá ze vstupní vrstvy a skrytých vrstev s různými funkcemi. První skrytá vrstva je konvoluční vrstva s aktivační funkcí, velmi často je využívána aktivační funkce Relu. První konvoluční vrstva extrahuje rysy, slouží k detekci barev a hran. Hlubší konvoluční vrstvy detekují složitější rysy. Druhá skrytá vrstva je poolingová (sdružovací) vrstva, tato vrstva zmenšuje obraz. Následují další konvoluční vrstvy s aktivační funkcí, které jsou opět následovány poolingovou vrstvou. Na konci konvoluční neuronové sítě jsou plně propojené vrstvy s aktivační funkcí Softmax sloužící ke klasifikaci. Typická architektura konvolučních neuronových sítí je na obrázku 13.



Obrázek 13: Architektura konvoluční neuronové sítě

Zdroj: [80]

Konvoluční neuronové sítě, extrahují rysy přímo z dat bez nutnosti využití speciálních extraktorů a následuje klasifikace. Konvoluční neuronové sítě jsou trénovány pomocí velkých označených datových sad (trénování s učitelem). Trénování těchto hlubokých sítí od začátku je velmi časově a výpočetně náročné. Kvůli tomu se využívají možnosti přenosu učení, model, který byl trénován pro jeden úkol, se používá jako výchozí bod pro model, který provádí podobný úkol. Aktualizace a přeučení sítě pomocí přenosu učení je obvykle mnohem rychlejší a jednodušší než trénování sítě od začátku. Na obrázku 14 jsou porovnány modely vybraných předtrénovaných konvolučních neuronových sítí z hlediska velikosti modelu, rychlosti a přesnosti.



Obrázek 14: Porovnání velikosti modelu, rychlosti a přesnosti pro předtřénované sítě

Zdroj: [172]

V tabulce 5 je porovnání vybraných konvolučních neuronových sítí. Porovnávají jsou vzhledem k použitému hardwarovému vybavení, při prováděných experimentech, konvoluční neuronové sítě, které nemají příliš vysoké nároky na hardware. Jde o sítě, kde nejméně hluboká je síť AlexNet s 8 vrstvami a nejhlubší je síť GoogLeNet s 22 vrstvami. Největší počet parametrů mají zase sítě VGG. Požadovaná velikost vstupu je až na AlexNet $224 \times 224 \times 3$.

Tabulka 5: Porovnání konvolučních neuronových sítí

Network	Počet vrstev (hloubka)	Velikost	Počet parametrů (miliony)	Velikost vstupu
AlexNet	8	227 MB	60	$227 \times 227 \times 3$
GoogLeNet	22	27 MB	7	$224 \times 224 \times 3$
VGG-16	16	515 MB	138	$224 \times 224 \times 3$
VGG-19	19	535 MB	144	$224 \times 224 \times 3$


Zdroj: [20]

AlexNet

V roce 2012 vyhrál Alexandr Krizhevsky soutěž ImageNet Large Scale Visual Recognition Challenge (ILSVRC) s konvoluční neuronovou sítí AlexNet, to pomohlo popularizaci tohoto

druhu neuronové sítě [101]. V původní architektuře AlexNet byly dva paralelní proudy zpracování obrazu. Dvouproudová síť byla navržena kvůli využití dvou GPU (grafických procesorů) spolupracujících na vytvoření tréninkového modelu s vyšší rychlostí a sdílením paměti. V dnešní době už se využívá jedнопroudová síť, která je znázorněna na obrázku 15.

AlexNet má 60 milionů parametrů v 8 vrstvách – 5 konvolučních a 3 plně propojených. AlexNet vychází z architektury LeNet-5, ke které přidávají další vrstvy. Autoři při publikování poukázali na to, že jejich architektura byla „jednou z největších konvolučních neuronových sítí, které byly doposud trénovány na datové sadě ImageNet“ [101].



Obrázek 15: Architektura konvoluční neuronové sítě AlexNet

Zdroj: [144]

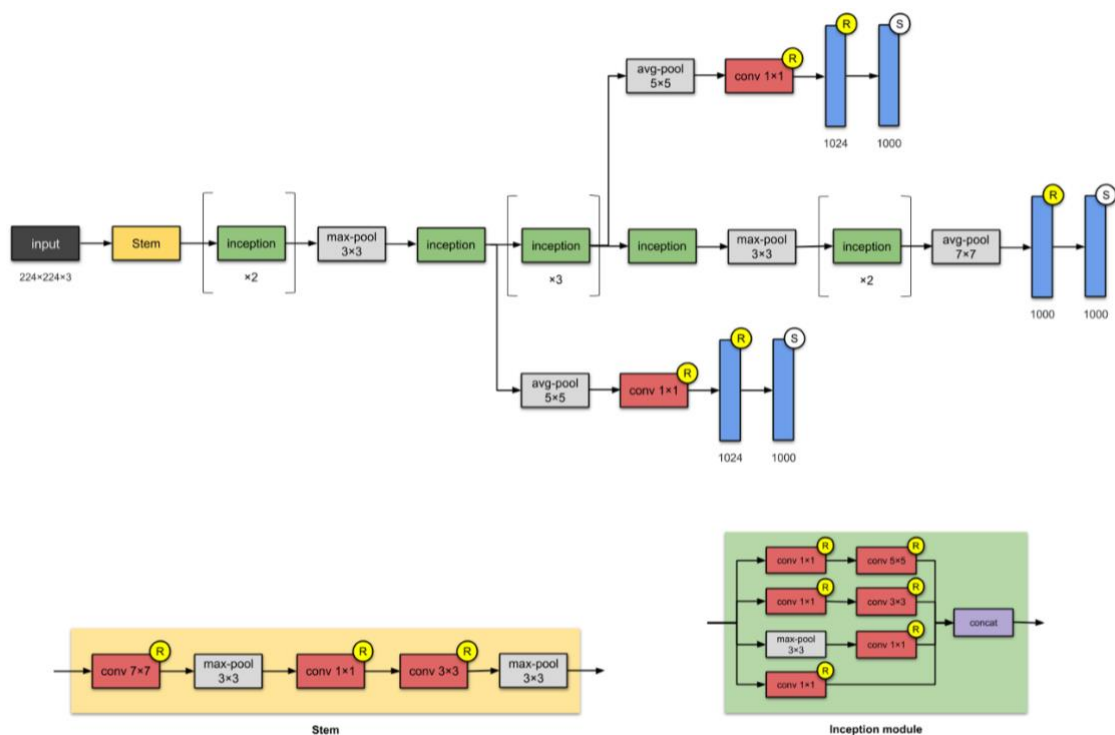
Síť AlexNet a její obměny byly v oblasti biometrie využity například k rozpoznání obličeje v reálném čase [134] nebo rozpoznání ucha [9]. Dále byl algoritmus AlexNet využit pro rozpoznání druhů ryb [90].

GoogLeNet

Síť GoogLeNet (neboli Inception v1) navrhl tým vědců z univerzit Michiganu a Severní Karolíny a z firem Google a Magic Leap [166]. Jde o 22 vrstvou architekturu se 7 miliony parametrů (obrázek 16). Architektura GoogLeNet byla vítězem soutěže ILSVRC.

GoogLeNet přinesl inovaci v podobě inception (počátečního) modulu. Inception modul je síť v rámci sítě. Základní myšlenkou inception modulu je, že klíčové informace v obrazech jsou dostupné na různých úrovních detailů. Pokud je použit velký filtr, zachytí informace ve větší oblasti s omezenými variacemi. Pokud je použit menší filtr, zachytí detailní informace na menší ploše. V GoogLeNet v inception modulu se paralelně spojují tři různé velikosti filtrů. Tyto velikosti filtrů jsou 1×1 , 3×3 a 5×5 .

GoogLeNet je stavěna z modulů (bloků), které obsahují konvoluční vrstvy, místo vrstvení samotných konvolučních vrstev. Odtud název Inception (s odkazem na sci-fi film Inception z roku 2010 s Leonardem DiCapriem v hlavní roli) [144].



Obrázek 16: Architektura konvoluční neuronové sítě GoogLeNet

Zdroj: [144]


Síť GoogLeNet a její obměny byly v oblasti biometrie využity například k rozpoznání obličeje [201]. Dále byl algoritmus GoogLeNet využit pro rozpoznání ručně psaných čínských znaků [209].

VGG

Síť VGG-16 (Visual Geometry Group) navrhli Karen Simonyan a Andrew Zisserman v roce 2014 na Oxfordské univerzitě v Anglii [158], umístila těsně na druhém místě v soutěži ILSVRC za GoogLeNet. VGG-16 má 13 konvolučních vrstev a 3 plně propojené vrstvy, stejně jako AlexNet je v její architektuře využívána aktivační funkce ReLu (obrázek 17). Skládá se ze 138 milionů parametrů a zabírá cca 500 MB úložného prostoru. VGG sítě byly navrženy v různých konfiguracích s velikostí mezi 11 a 19 vrstvami, nejvýkonnější jsou sítě s 16 a více vrstvami.

U těchto sítí je vidět vývojový trend – zvětšování hloubky sítí. Je to nepřímější způsob, jak zlepšit výkon hlubokých neuronových sítí [166]. Ilustroval i další důležitou inovaci, která se stala standardem v novějších architekturách CNNs. Důležitou inovací VGG je, že tyto sítě se zvětšením hloubky sítě zároveň zmenšily velikosti filtrů. Zmenšená velikost filtrů vyžaduje větší hloubku. Je to proto, že malý filtr dokáže zachytit pouze malou oblast obrazu (filtry

s malou velikostí 3×3 , je nejmenší filtr, který dokáže zachytit dojem vpravo, vlevo, dole, nahoře nebo ve středu), pokud není síť hluboká.



Obrázek 17: Architektura konvoluční neuronové sítě VGG-16

Zdroj: [144]

Síť VGG a její obměny byly v oblasti biometrie využity například k rozpoznání výrazu obličeje [135]. Dále byl algoritmus VGG využit pro rozpoznání dopravních značek nebo zeleniny [113].

6.2 Metody vhodné pro klasifikaci

Po extrakci rysů je nutné provést klasifikaci. Pro samotnou klasifikaci lze využít individuální metody (individuální klasifikátory) nebo kombinaci individuálních metod (ensemble metody). Je také možné provést extrakci rysů a klasifikaci zároveň pomocí konvolučních neuronových sítí. Přehled relevantních metod pro klasifikaci, které jsou použity v této práci je uveden v tabulce 6.

Tabulka 6: Přehled použitých metod pro klasifikaci a společnou extrakci rysů s klasifikací

Kategorie metod	Metoda
Individuální metody klasifikace	Diskriminační analýza
	Naivní Bayesův klasifikátor
	Rozhodovací stromy
	Algoritmus k-nejbližších sousedů (k-NN)
	Podpůrné vektorové stroje (SVM)
	Neuronové sítě
Ensemble metody	Bagging
	Boosting
	Random subspace
	Náhodný les

Zdroj: autor

6.2.1 Individuální metody klasifikace

V této podkapitole budou blíže přiblíženy klasické metody strojového učení, tyto metody jsou vhodné pro klasifikaci, pokud je již provedena extrakce rysů. Jde o tradiční statistické metody, rozhodovací stromy, k-NN, SVM a neuronové sítě.

Diskriminační analýza

Diskriminační analýza je jednou z metod mnohorozměrné statistické analýzy. Diskriminační analýza hledá zákonitosti v rozdělení do skupin a formuluje pravidla, která umožní zařadit nový objekt do konkrétní skupiny podle měřených rysů.

Diskriminační analýza předpokládá, že různé třídy obsahují data s Gaussovým rozdělením. Trénink modelu diskriminační analýzy zahrnuje nalezení parametrů pro Gaussovo rozdělení pro každou třídu. Distribuční parametry se používají k výpočtu hranic, což mohou být lineární nebo kvadratické funkce. Tyto hranice se používají k určení třídy nových dat. Existuje i neparametrický přístup diskriminační analýzy.



Obrázek 18: Diskriminační analýza

Zdroj: [14]

Diskriminační funkce hledá takovou kombinaci proměnných, která maximalizuje rozdíl mezi dvěma třídami a minimalizuje pravděpodobnost chybné klasifikace [106]. Jednou z možností, jak definovat model diskriminační analýzy, je následující [109]:

$$Z = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k \quad (6)$$

Kde:

- Z diskriminační skóre,
- x_1, \dots, x_k nezávislé proměnné,
- β_0 konstanta,
- β_1, \dots, β_k koeficienty.

Diskriminační analýza se využívá v mnoha studiích zabývajících se rozpoznáváním osob na základě ruky [40], [52]. Zároveň je diskriminační analýza využívána i v mnoha podobných oblastech jako je třeba rozpoznávání gest rukou [43], [2], [137].

Naivní Bayesův klasifikátor

Jedna z nejstarších forem strojového učení je aplikace principů statistiky na analýzu dat, která je ale dodnes velmi rozšířená. Jedním z nejpoužívanějších algoritmů je v této oblasti naivní Bayesův klasifikátor, jde o typ učícího se klasifikátoru, který je založen na Bayesově větě [37]. Bayesova věta je definována následující rovnicí:


$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)} \quad (7)$$

Kde:

- $P(A)$ apriorní pravděpodobnost jevu A ,

- $P(A|B)$ aposteriorní (podmíněná) pravděpodobnost jevu A za předpokladu, že nastal jev B ,
- $P(B|A)$ aposteriorní (podmínečná) pravděpodobnost jevu B za předpokladu, že nastal jev A ,
- $P(B)$ pravděpodobnost jevu B .

Naivní Bayesův klasifikátor předpokládá, že přítomnost určitého znaku (rysu) ve třídě nesouvisí s přítomností jakéhokoli jiného znaku. Tento předpoklad je silný neboli naivní odtud také označení tohoto klasifikátoru. Naivní Bayes klasifikuje nová data na základě nejvyšší pravděpodobnosti, že patří do určité třídy.



Obrázek 19: Naivní Bayesův klasifikátor

Zdroj: [14]

Naivní Bayesův klasifikátor lze využít pro klasifikaci obrazových pixelů na základě barvy nebo textury, toho lze využít i v biometrii [156].

Rozhodovací stromy

Rozhodovací stromy jsou tvořeny soustavou pravidel (uspořádanou ve stromu od kořene, až po koncové větve). Pomocí těchto pravidel se rozdělí objekty do podmnožin, ve kterých převládají objekty jedné třídy. Počet větví se zjišťuje v tréninkovém procesu. Pro zjednodušení modelu lze použít další úpravy nebo prořezávání.

Pro vytváření (růst) rozhodovacích stromů bylo vyvinuto velké množství algoritmů. Nejvíce používané jsou CART, ID3, C4.5, AID, CHAID a QUEST. Algoritmus CART poprvé popsali autoři Breiman, Freidman, Olshen a Stone v roce 1984 ve článku „*Classification and Regression trees*“ [26].


Algoritmus CART (Breiman, Freidman, Olshen a Stone, 1984) [26]

Vstup: Trénovací množina D

- 1) Jestliže D je prázdná množina, nebo algoritmus splňuje kritéria ukončení, potom algoritmus končí;
 - 2) Začátek v kořenovém uzlu;
 - 3) Pro každou proměnnou X ,

převést na neuspořádanou proměnnou X' seskupením jejích hodnot v uzlu do malého počtu intervalů,

pokud je proměnná X neuspořádaná, pak $X'=X$;
 - 4) Provést chí-kvadrát test nezávislosti každé proměnné X' a Y na datech v uzlu a vypočítat pravděpodobnost její významnosti;
 - 5) Výběr proměnné X^* související s X' , která má nejmenší pravděpodobnost významnosti;
 - 6) Nalezení dělené sady $\{X^* \in S^*\}$, která minimalizuje součet Giniho indexů, a použijte ji k rozdělení uzlu na dva podřízené uzly;
 - 7) Pokud je dosaženo kritéria zastavení, konec, v opačném případě opakovat kroky 2-5;
 - 8) Prořezávejte strom metodou CART;
- Výstup: Výsledný rozhodovací strom.
-



Obrázek 20: Rozhodovací stromy

Zdroj: [14]

Metoda rozhodovacích stromů není často používanou metodou v oblasti rozpoznávání obrazu. Avšak existují studie, kde jsou rozhodovací stromy využívány pro klasifikaci obrazu, jde

například o studii, kde se při dálkové průzkumu země využívají multispektrální snímky, které jsou klasifikovány pomocí metody rozhodovacích stromů [197]. Další studie využívá rozhodovací stromy pro klasifikaci snímků očního pozadí, aby detekovala diabetickou retinopatii [120].

Algoritmus k-nejbližších sousedů (k-NN)

Algoritmus k-NN klasifikuje objekty na základě tříd jejich nejbližších sousedů v datové sadě. Základ algoritmu k-NN je předpoklad, že objekty blízko sebe jsou podobné. Písmeno k v názvu algoritmu určuje počet sousedů, pomocí nichž se rozhodne o klasifikaci nového objektu. K nalezení nejbližšího souseda se používají metriky vzdálenosti, například Euklidovská metrika, Čebyševova metrika, Manhattanská metrika, metrika kosinové podobnosti.



Obrázek 21: Algoritmus k-NN, pro $k=6$

Zdroj: [14]


Jde o klasickou klasifikační metodu, která byla využívána jako jedna z prvních v oblasti rozpoznávání osob [66]. Avšak je využívána dodnes, například v roce 2021 ji Guo používá jako klasifikační metodu pro rozpoznání tváře [69].

Podpůrné vektorové stroje (SVM)

Podpůrné vektorové stroje (angl. Support vector machine) jsou nejznámější metodou ze skupiny jádrových metod. SVM byly původně navrženy pro řešení úloh binární klasifikace a jejími autory jsou Vapnik a Chervonenkis [179]. V roce 1995 byla publikována Vapnikem a Cortesovou moderní formulace SVM jenž byla vyvinuta na počátku devadesátých let v laboratořích Bell Labs [37], [180], SVM začali využívat i pro vícetřídní klasifikaci a regresi.

Princip SVM spočívá v nalezení lineární rozhodovací nadroviny, která odděluje všechny objekty jedné třídy od objektů druhé třídy. To za pomoci převedení (transformace) původního vstupního prostoru do vícedimenzionálního prostoru, ve kterém lze jednotlivé třídy lineárně

oddělit. K této transformaci slouží jádrové funkce. Nejlepší nadrovina SVM je ta, jenž má největší rezervu mezi těmito dvěma třídami, kdy jsou data lineárně oddělitelná. Pokud data nejsou lineárně oddělitelná, použije se ztrátová funkce k penalizaci bodů na špatné straně nadroviny. U SVM je dovoleno dosažení určité úrovně chyby na trénovacích datech čímž se zabraňuje overfittingu modelu. Při klasifikaci nových datových bodů, stačí zkontrolovat na které straně rozhodovací hranice jsou tyto klasifikované body.




Obrázek 22: Podpůrné vektorové stroje

Zdroj: [14]

Publikací, ve kterých bylo využito podpůrných vektorových strojů v oblasti rozpoznávání osob, bylo mnoho, jsou to například tyto: [13], [55], [57], [63].

Neuronové sítě


Neuronové sítě jsou alternativou ke klasickým statistickým metodám, především pokud závislé a nezávislé proměnné vykazují složité nelineární vztahy [109]. Možností, jak definovat pojem umělé neuronové sítě je více, např. v [133] je neuronová síť definována jako: „*Masivně paralelní procesor, který má sklon k uchování experimentálních znalostí a jejich dalšímu využívání.*” Neuronové sítě jsou využívány jako klasifikátory nebo extraktory znaků (rysů). Jako mnoho algoritmů i neuronové sítě jsou inspirovány biologií, přesněji nervovou soustavou, která zachycuje a zpracovává podněty, které působí na živý organismus a následně zajišťuje reakci na daný podnět.



Obrázek 23: Neuronová síť

Zdroj: [14]

Základní stavební jednotkou umělé neuronové sítě je umělý neuron. Jde o matematický model biologického neuronu. Existuje celá řada modelů neuronu. Prvním modelem neuronu je McCulloch-Pittsův model z roku 1943, který je zobrazen na obrázku 24 [181]. V současné době dopředné neuronové sítě využívají model umělého neuronu odvozený z modelu výše zmíněného neuronu.



Obrázek 24: McCulloch-Pittsův model neuronu

Zdroj: [133]

Umělý neuron je tvořen těmito prvky:

- x_i – vstupy neuronu (výstupy n neuronů z předcházející vrstvy, nebo vstupní vektory),
- w_i – synaptické váhy,
- y_a – vstupní potenciál neuronu,
- f – aktivační funkce neuronu,
- $o(f)$ – výstupní funkce neuronu,
- θ – prahová hodnota neuronu,
- y – výstup neuronu.

Neuronová síť typu perceptron je nejjednodušší jednovrstvá neuronová síť s dopředným šířením. Jde o neuronovou síť s učitelem. Což znamená, že při učení je nutné, aby síť měla

k dispozici nejen vstupní vektor, ale i k němu přiřazený výstupní vektor. Během učení s učitelem se v neuronové síti porovnávají skutečné výstupy a požadované výstupy a dochází ke změnám vah tak, aby se snížil rozdíl mezi skutečným a požadovaným výstupem.

Vícevrstvá neuronová síť typu perceptron

Vícevrstvá neuronová síť typu perceptron (MLP), je dopředná plně propojená síť tvořená neurony (perceptrony). Skládá se ze vstupní vrstvy skryté vrstvy nebo několika skrytých vrstev a výstupní vrstvy. Právě počty skrytých vrstev a počty neuronů v jednotlivých vrstvách jsou parametry struktury neuronové sítě. Počet (vstupních) neuronů ve vstupní vrstvě závisí na počtu vstupů do sítě. Počet skrytých vrstev a v nich počty neuronů se volí podle složitosti v našem případě klasifikační úlohy. Počet výstupních neuronů v poslední výstupní vrstvě se volí podle počtu klasifikačních tříd.

Vícevrstvá neuronová síť typu perceptron se většinou učí pomocí algoritmu zpětného šíření chyby, jenž využívá pro minimalizaci chyb optimalizační gradientní algoritmy. U tohoto typu algoritmu se vyskytuje riziko uvíznutí v lokálním minimu, existují metody, jak toto riziko zmenšit, jednou z nich je zavedení momentu do učícího algoritmu. [133]

Existuje mnoho typů modelů neuronových sítí, které jsou neustále využívány v mnoha oblastech, jako je počítačové vidění a bezpečnost [8]. Ferrer et al. [56] využil pro rozpoznání osoby vícevrstvou neuronovou síť typu perceptron.

6.2.2 Ensemble metody

Základní myšlenkou ensemble (kombinace) přístupu je vytvoření a použití více modelů. Místo jednoho modelu (nejčastěji rozhodovacího stromu) se použije více modelů a jejich výsledky se spojují do konečného rozhodnutí, aby se dosáhlo zlepšených výsledků. Základní myšlenka se také dá shrnout do jedné otázky, kterou položili Kearns a Valiant [94] „*Může skupina slabých klasifikátorů vytvořit jediný silný klasifikátor?*“

Ensemble metody lze rozdělit do následujících skupin:

- bagging,
- boosting,
- random subspace,
- náhodný les (random forest).

Dalším kritériem dělení ensemble přístupů je způsob vytváření modelů. Modely totiž mohou být vytvářeny paralelně (souběžně) – *Bagging* a kombinační metody, nebo sekvenčně (postupně) – *Boosting*.

Bagging

Metoda bagging je jednou z hlavních metod ensemble přístupu. Označení bagging je zkratkou dvou slov „*bootstrap aggregating*“. Bagging je metoda, která využívá pro souběžné trénování jednotlivých klasifikátorů, nové bootstrap množiny, které jsou vytvořené z původní trénovací množiny. Bootstrap množiny obsahují stejné množství prvků jako původní trénovací množina a některé prvky se mohou opakovat. Výsledná klasifikace se provádí pomocí metody průměrování (averaging) nebo hlasování (voting). Takže objekt je klasifikován podle většiny jednotlivých klasifikátorů. Cílem metody je snížit rozptyl klasifikátoru. [27]

Algoritmus Bagging (Breiman, 1996) [27]

Vstup: Trénovací množina $D = \{x, y\}_{i=1}^m$ ($x \in \mathbb{R}^n, y \in Y$)

Inicializace: klasifikátor C

Pro $t = 1, \dots, T$:

- Vytvoření bootstrap vzorku D_t náhodným výběrem o velikosti n z D
- Učení základního klasifikátoru C_t na bootstrap vzorku D_t

$$C^*(x) = \arg \max_{y \in Y} \sum_{t=1}^T 1(C_t(x) = y)$$

Výstup: klasifikátor C^*

Metoda bagging je využívána v oblasti rozpoznávání osob, příkladem můžou být studie kdy se metoda bagging využívá pro rozpoznávání výrazu obličeje [64], nebo chůze [202]. Dále byla metoda využita i pro rozpoznání perských číslic [127].

Boosting

Metoda boosting je jednou z dalších hlavních metod ensemble přístupu. Stejně jako předchozí metoda bagging používá více trénovacích množin pro trénování klasifikátoru, které jsou vytvořeny z původní trénovací množiny. Při využití této techniky se učí klasifikátory postupně a postupně se „posilují,“ nový klasifikátor je ovlivněn předchozím klasifikátorem. Cílem je zlepšit přesnost následujícího klasifikátoru oproti předchozímu klasifikátoru.

Algoritmus AdaBoost, jehož název je zkratkou dvou slov „*adaptive boosting*“ ve svém článku představili autoři Freund a Schapire v roce 1996 [61]. Autoři navrhli AdaBoost, vytvořili dvě verze tohoto algoritmu a označili je AdaBoost.M1 a AdaBoost.M2. Tyto dvě verze jsou ekvivalentní pro problémy s binární klasifikací a liší se pouze svým zpracováním. Hlavní nevýhodou AdaBoost.M1 je, že nedokáže zpracovat slabé hypotézy s chybou větší než 1/2. AdaBoost.M2, se však snaží tyto problémy překonat rozšířením komunikace mezi posilovacím algoritmem a slabým klasifikátorem. [61]

Algoritmus AdaBoostM2 (Freund a Schapire, 1996) [61]

Vstup: množina m příkladů $\{(x_1, y_1) \dots (x_m, y_m)\}$, $x_i \in X$, se štítky $y_i \in Y$, $Y = \{1, \dots, k\}$

Slabý klasifikační algoritmus

Celé číslo T určující počet iterací

Nechť $B = \{(i, y) : i=1, \dots, m, y \neq y_i\}$

Inicializace: $D_1(i) = 1/|B|$ pro $(i, y) \in B$

Pro $t = 1, \dots, T$:

- Trénování slabého klasifikátoru L_t použitím distribuce D_t
- Výpočet slabé hypotézy $h_t: X \times Y \rightarrow [0, 1]$
- Výpočet pseudoztrátu hypotézy h_t :

$$\varepsilon_t = 1/2 \sum_{(i,y) \in B} D_t(i,y) (1 - h_t(x_i, y_i) + h_t(x_i, y))$$

- Nastavení

$$\beta_t = \frac{\varepsilon_t}{1-\varepsilon_t} \text{ a } w_t = 1/2 (1 - h_t(x_i, y) + h_t(x_i, y_i))$$

- Aktualizace D_i : $D_{t+1}(i, y) = \frac{D_t(i,y)}{Z_t} * \beta_t^{w_t}$

kde Z_t je normalizační faktor vybraný tak, aby D_{t+1} zůstalo distribucí

Výsledná hypotéza: $h_{fin}(x) = \arg \max_{y \in Y} \sum_{t=1}^T (\log \frac{1}{\beta_t}) * h_t(x, y)$

Metoda boosting je využívána v oblasti rozpoznávání osob, příkladem můžou být studie kdy se metoda boosting využívá pro rozpoznávání duhovky [205], nebo obličeje [195].

Random subspace

Další metodou ensemble přístupu je random subspace (RSM). Metoda byla navržena tak, aby řešila problém kompromisu mezi overfittingem a dosažením nejvyšší přesnosti. A to tím, že se sníží korelace mezi klasifikátory, pomocí podprostoru rysů. Každý individuální klasifikátor totiž nepracuje s celou množinou rysů, ale pouze s náhodným podprostorem rysů. Jinak je random subspace podobný algoritmu bagging. S využitím random subspace metody se setkáváme například u autorů Barushka a Hájek, kteří ho využívají pro filtraci spamu [19].

Pro rozhodovací stromy byla použita metoda random subspace v kombinaci s bagging a výsledný model se nazývá náhodný les. Dále byla metoda random subspace aplikována na další klasifikátory, například lineární klasifikátory [160], nejbližší sousedy [76], [173].

Náhodný les

Náhodný les (angl. random forest) je jedním z algoritmů ensemble metod. Jde o kombinaci více stromů typu CART. Tento algoritmus byl publikován Breimanem v roce 1996. Algoritmus náhodný les kombinuje metodu bagging s random subspace. Jednotlivé stromy jsou určeny bootstrapovým výběrem a zároveň se stromy opakují nebo nejsou vybrány vůbec.

Náhodný les (Breiman, 1996) [27]

Vstup: Trénovací množina D

Pro $t = 1, \dots, T$:

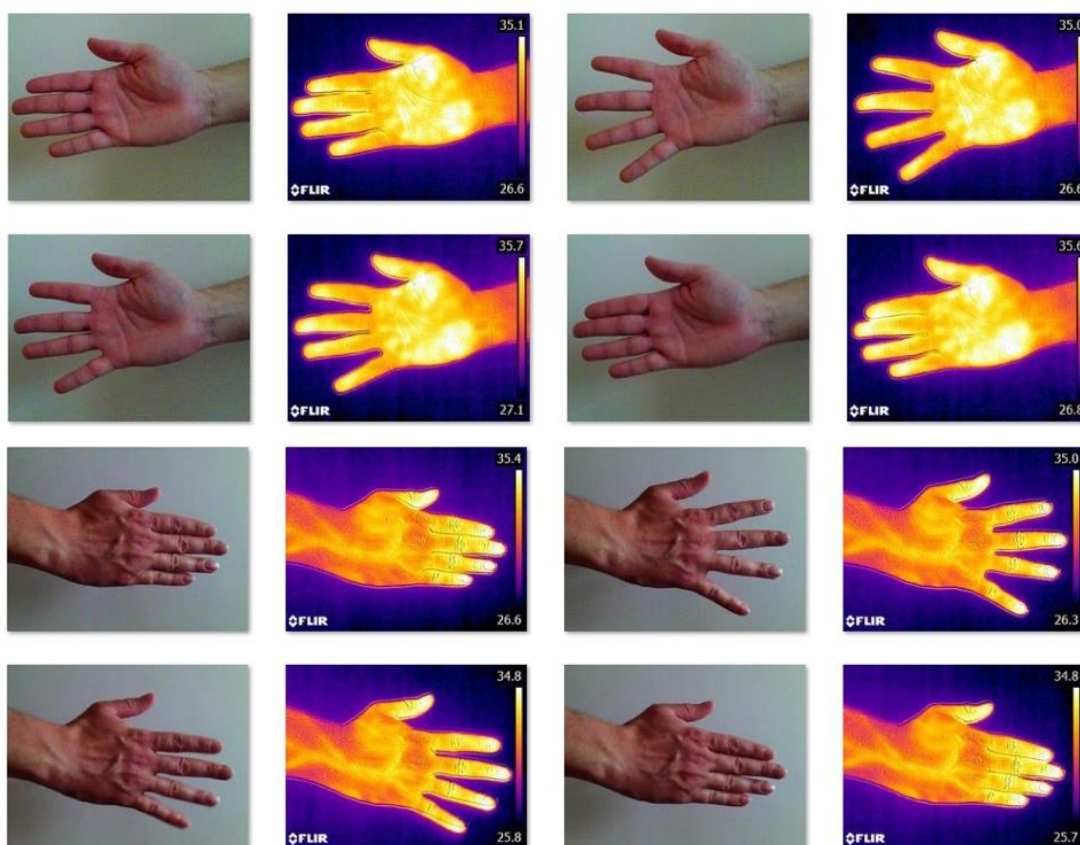
- Z trénovací množiny D se vytvoří náhodným výběrem s vracením bootstrap vzorek s n trénovacími daty a náhodně vybranými k proměnnými
- Každý bootstrap vzorek se použije k sestrojení jednoho stromu

Výstup: Výsledný les, který je dán většinovým hlasováním se stejnými vahami

Náhodný les byly v oblasti biometrie využity například k rozpoznání obličeje [154], nebo hlasu [95]. Dále byl algoritmus náhodného lesa využit pro detekci dopravních značek [47].

7 DATOVÁ SADA SNÍMKŮ RUKY

Pro potřeby experimentů byla vytvořena nová rozsáhlá datová sada obsahující celkem 10 000 snímků pravých rukou (dlaň i hřbet) od 50 subjektů. Jedná se o 22 mužů a 28 žen. Jde o datovou sadu termálních snímků a snímků z viditelné části elektromagnetického spektra rukou. Dvojice termálního a viditelného snímku byla získána současně během jednoho snímání pomocí vytvořeného biometrického skeneru s kamerou FLIR E5xt (ta je kombinací digitální a termální kamery). Obrázek 25 ukazuje příklady snímků z datové sady.




Obrázek 25: Snímky z datové sady – hřbet a dlaň ruky termální a viditelný snímek

Zdroj: autor


7.1 Biometrický skener ruky

Skener je sestaven z termální kamery, stativu, „Kapa“ desky, speciálně vyrobeného úchytu na termální kameru, slideru a jednoho kolíčku. Jak tento biometrický skener vypadá je znázorněno na následujících obrázcích, pohled zepředu (obrázek 26) a z perspektivy (obrázek 27), které byly vyexportovány z 3D programu Rhino 7. Skener byl zakreslen ve 3D programu především proto, aby bylo možné některé jeho části (úchyty na termální kameru a



Obrázek 26: Biometrický skener pohled zepředu


Zdroj: autor



Obrázek 27: Biometrický skener pohled z perspektivy

Zdroj: autor

„Kapa“ desku i kolíček) vytisknout na 3D tiskárně. V případě potřeby je možné tento biometrický skener rozložit. Na vytvoření biometrického skeneru ruky byl použit běžný stativ, na nějž byl připevněn úchyt na termální kameru s dalšími částmi. Speciální úchyt byl navržen podle tvaru termální kamery. Dále bylo nutné zajistit vzdálenost 300 mm mezi rukou a termální kamerou (ruka se při této vzdálenosti přesně vejde na snímky a také je možné při této vzdálenosti vytvořit multispektrální snímky ruky). Přesná vzdálenost byla zajištěna pomocí slideru, na který byla připevněna „Kapa“ deska s kolíčkem. Kolíček je umístěn ve vzdálenosti 330 mm od kamery, na šířku ruky je počítáno s 30 mm. „Kapa“ deska má rozměry šířka: 520 mm, výška: 420 mm, tloušťka: 5 mm a je potažená bílým matným papírem. Matný bílý papír byl vybrán kvůli vysoké emisivitě 0,93 [91]. Při vysoké emisivitě je nižší zdánlivě odražená teplota → na pozadí nebude tepelný odraz ruky v infračerveném spektru patrný. Kolíček je přidán na „Kapa“ desku kvůli tepelné stopě. Pokud by byla využita pouze „Kapa“ deska a ruku by osoby přikládaly pouze na desku, vytvářely by se na ní tepelné stopy, jak je vidět na obrázku 28 a před vyfocení každého snímku by se muselo čekat na zmizení tepelné stopy.



Obrázek 28: Tepelná stopa ruky na „Kapa“ desce

Zdroj: autor

7.2 Termální kamera a její nastavení

V biometrickém skeneru je využita termální kamery FLIR E5xt, jenž je kombinací termální a digitální kamery. Termální kamera je vybavena mikrobiologickým detektorem s rozlišením 120 × 90 pixelů. Teplotní citlivost přístroje je deklarována výrobcem <math><0,1\text{ }^\circ\text{C}</math>.

Termální kamera zaznamenává infračervené záření, na jehož základě určuje teplotu objektu, a to díky skutečnosti, že infračervené záření přímo závisí na povrchové teplotě objektu. Avšak infračervené záření, které termální kamera zaznamená nezávisí pouze na teplotě, ale také na emisivitě objektu a okolních podmínkách. To vše je potřeba brát v potaz při určení teploty objektu. Termální kamera dokáže při výpočtu kompenzovat okolní podmínky a počítá i s emisivitou objektu. Avšak v kameře musí být správně nastaveny následující parametry [178]:


- Emisivita – je poměr množství záření emitovaného objektem a záření dokonalého černého tělesa stejné teploty. Černé těleso je teoretický objekt, který při dané teplotě vyzařuje největší možné množství energie, a naopak pohltí veškerou energii, která na něj dopadá. Emisivita lidské pokožky je 0,98 [167].
- Zdánlivě odražená teplota – charakterizuje tepelné záření, které se od povrchu měřeného objektu odráží. Množství odražené energie závisí na emisivitě měřeného objektu, čím vyšší je emisivita objektu tím nižší je zdánlivě odražená teplota. Vzhledem k vysoké emisivitě lidské pokožky není přesné nastavení parametru tak důležité. Parametr tedy nastavujeme na hodnotu teploty okolního vzduchu [186].
- Vzdálenost mezi objektem a kamerou – parametr se využívá ke kompenzaci dvou vlivů. Prvním vlivem je absorbování záření měřeného objektu atmosférou. Druhým vlivem je záření atmosféry, které je detekováno termální kamerou [178]. V našem případě byla vzdálenost 30 cm.
- Relativní vlhkost – propustnost atmosféry také závisí na její relativní vlhkosti, pro malé vzdálenosti, což je případ snímků ruky, může být hodnota relativní vlhkosti ponechána na předvolených 50 % [178].

7.3 Vytváření datové sady

Pro vytvoření rozsáhlé kvalitní datové sady je nutné stanovit podmínky pro snímání snímků ruky:

- Každý subjekt byl při snímání požádán, aby náhodně roztáhl prsty pravé ruky a během snímání polohu prstů měnil. Ruka byla vyfotografována z obou stran (hřbet a dlaň). Vzdálenost ruky od kamery byla vždy 30 cm.

- Proces snímání se opakoval nejméně dvakrát v různých dnech a časech dne, aby se zohlednily variace, které se mohou v průběhu času objevit.
- Snímky ruky byly pořizovány nejdříve 30 minut po poslední tělesné námaze. Tělesná námaha výrazně zvyšuje tělesnou teplotu [186]. Na obrázku 29 je vlevo snímek ruky 20 minut po tělesné námaze, vpravo snímek byl pořízen hodinu po tělesné námaze.
- Osoby neměly během snímání symptomy infekčního onemocnění, jako je například zvýšená tělesná teplota.
- Snímání probíhalo v interiéru, při konstantních podmínkách s teplotou v místnosti 21 °C – 23 °C, (jedná se o teploty, které zajišťují tepelný komfort průměrných osob [51]) snímaná osoba byla v místnosti aklimatizovaná. Osvětlení nebylo konstantní.



Obrázek 29: Porovnání snímků ruky po tělesné aktivitě

Zdroj: autor

Získané snímky byly zkontrolovány ručně, pro kontrolu byl využit program FLIR Tools, který umožňuje kontrolu a opravu nastavené odražené teploty, emisivity, teploty prostředí, vlhkosti. Lze změnit také rozsah zobrazených teplot, formát obrazu, barevné palety, nebo je možné exportovat naměřené hodnoty teplot. Rozmazané a oříznuté snímky byly po vizuální kontrole odstraněny.

7.4 Popisná statistika datové sady


Získali jsme 100 termálních snímků a 100 viditelných snímků od každého subjektu. Snímali jsme pouze pravou ruku, vždy dlaň a hřbet ruky. Datová sada tedy obsahuje od každého

subjektu 50 snímků (hřbetu ruky ve viditelném spektru, hřbetu ruky v infračerveném spektru, dlaně ruky ve viditelném spektru, dlaně ruky v infračerveném spektru).

Na následujících obrázcích jsou grafy, které znázorňují základní statistiky vytvořeného datového souboru. Na obrázku 30 je graf na němž je zobrazen počet subjektů v jednotlivých věkových skupinách. Obrázek 31 shrnuje základní statistiky datového souboru (22 mužů, 28 žen), jako jsou informace o počtu rukou s doplňky (hodinky, řetízky, náramky), nalakovanými nehty, dlouhými rukávy a poraněním (puchýře mozoly). Tabulka 7 znázorňuje porovnání naší datové sady s jinými datovými sadami. Naše datová sada obsahuje mnoho snímků rukou (10 000) s velkým počtem snímků od jedné osoby (200). Jde o teprve druhou a zároveň největší datovou sadu termálních a viditelných snímků rukou.


Snímání rukou se celkem zúčastnilo 50 osob. Jak je vidět z grafu na obrázku 30, nejpočetnější skupinu tvořilo 24 osob v rozmezí věku 45–59 let a to celkem 48 % zúčastněných. Druhou nejpočetnější skupinou byly osoby v rozmezí 30–44 let šlo o 14 osob. Dále se snímání rukou zúčastnilo 5 osob ve větu 15–29 let a 60–74 let. Nejméně početně zastoupenou skupinou jsou osoby starší 75 let a to 2 osoby.

Během rozpoznávání rukou mají některé systémy problémy s doplňky, dlouhými rukávy, nebo lakovanými nehty. Termální charakteristiky mohou být poškozeny poraněním ruky, což také může systémům způsobovat problémy. Datová sada obsahuje u obou pohlaví po 150 snímcích ruky s mozoly a puchýři. A také více než 350 snímků na kterých se vyskytují doplňky, lakované nehty, dlouhé rukávy a to pro každé pohlaví, výjimkou jsou lakované nehty u mužů.



Obrázek 30: Počty osob v jednotlivých věkových skupinách

Zdroj: autor



Obrázek 31: Základní statistiky datové sady

Zdroj: autor

Tabulka 7: Srovnání vytvořené datové sady s již dostupnými datovými sadami

	Navrhovaná datová sada	Afifi [4]	Sun et al. [207]	Czajka & Bulwan [40]	Bartuzi et al. [18]	Faundez-Zanuy et al. [52]
Celkový počet obrázků	10 000	11 076	5 616	3 600	21 000	6 000
Počet subjektů	50	190	312	50	70	100
Průměrný počet obrázků na subjekt	200	58	8	72	300	60
Termální / viditelné obrázky	Termální a viditelné	Viditelné	Viditelné	Termální	Termální	Termální a viditelné
Levá / pravá	Pravá	Pravá a levá	Pravá a levá	Pravá	Pravá a levá	Pravá
Strana ruky	Dlaň a hřbet	Dlaň a hřbet	Dlaň	Dlaň	Dlaň	Dlaň a hřbet
Rozlišení	320 × 240	1600 × 1200	600 × 480	23 × 44	640 × 480	300 × 240 640 × 480
Věk	Ano	Ano	Ne	Ne	Ne	Ne
Pohlaví	Ano	Ano	Ano	Ne	Ano	Ne

Zdroj: autor

Vytvořená datová sada termálních a viditelných snímků ruky obsahuje 10 000 snímků, jde o největší datovou sadu tohoto typu. Počet snímků na osobu je 200, jde o velký počet snímků na osobu v porovnání s ostatními datovými sadami. Osobám byly snímány pouze pravé ruce, a to z obou stran (hřbet a dlaň). U jednotlivých snímků je zařazení do věkových kategorií a informace o pohlaví, tyto informace v ostatních datových sadách nejsou samozřejmostí.

8 SPECIFIKACE VYUŽITÉHO HARDWARU A SOFTWARE

Všechny experimenty byly provedeny na počítači MacBook Air s následující hardwarovou specifikací: procesor Intel Core i7 běžel na frekvenci 1,2 GHz. Využity byly paralelní výpočty na 4 jádrech najednou. Paměť je 16 GB 3733 MHz LPDDR4X.

Na počítači byl spuštěn operační systém macOS Big Sur verze 11.6. Experimenty byly prováděny v programovém prostředí MATLAB R_2021a. Konkrétně byly využity především aplikační knihovny Deep Learning, Statistics and Machine Learning.

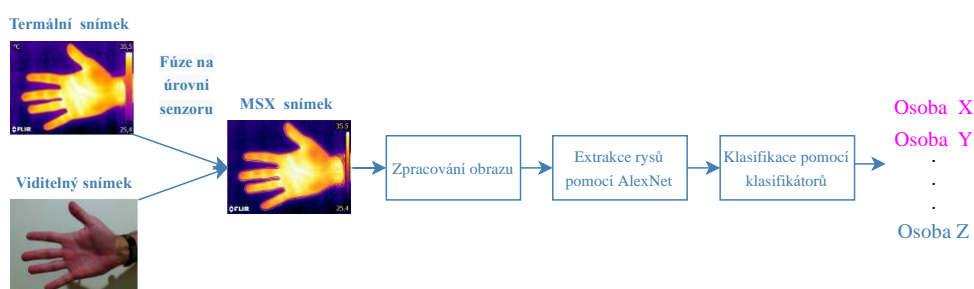
MATLAB (MATrix LABoratory) je velmi rozšířené interaktivní prostředí od firmy MathWorks. S jeho grafickými a výpočetními nástroji lze provádět maticové výpočty, analýzy a vizualizaci dat, vytvářet simulace, modely a dokonce i aplikace. Má vlastní skriptovací programovací jazyk a velké množství aplikačních knihoven, tzv. toolboxů, zaměřených na různé vědní obory.

Dvě aplikační knihovny, které byly hlavně využívány jsou Deep Learning a Statistics and Machine Learning. Deep Learning Toolbox poskytuje rámec pro navrhování a implementaci hlubokých neuronových sítí, lze pracovat s předem připravenými modely a aplikacemi. K provádění klasifikace a regrese na obrazech, časových řadách nebo textových datech lze použít konvoluční neuronové sítě a neuronové sítě s dlouhou krátkodobou pamětí (LSTM).

Statistics and Machine Learning Toolbox poskytuje funkce a aplikace pro popis, analýzu a modelování dat. Součástí tohoto Toolboxu je aplikace Classification Learner, jenž obsahuje klasifikační algoritmy umožňující vyvozovat závěry z dat a vytvářet klasifikační modely. Tato aplikace vytváří klasifikační modely interaktivně. K dispozici jsou algoritmy podpůrných vektorových strojů (SVM), posílených rozhodovacích stromů, mělkých neuronových sítí, k-nejbližších sousedů a dalších metod.

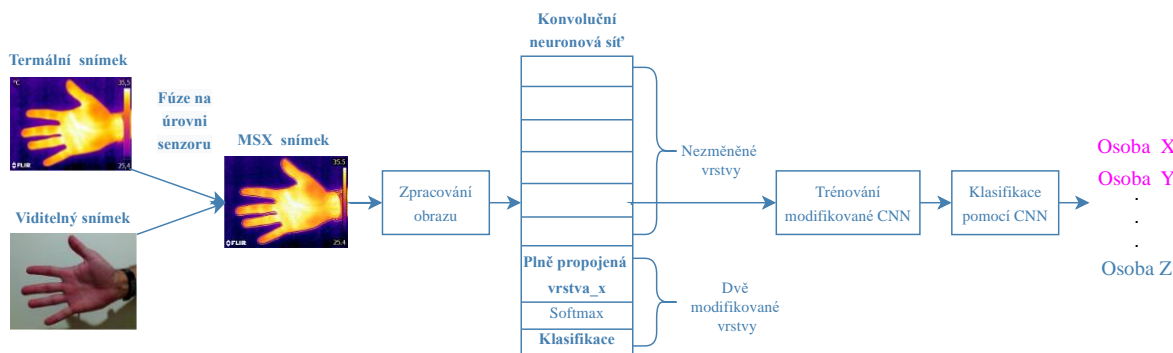
9 NAVRHOVANÝ MULTI-BIOMETRICKÝ SYSTÉM

Navrhovaný multi-biometrický systém, využívá fúzi na úrovni senzoru. Navrhovány jsou dva přístupy, které využívá multi-biometrický systém. První přístup využívá předtrénovaný model konvoluční neuronové sítě AlexNet jako extraktor rysů a pro klasifikaci jsou využity různé klasifikátory. Tento přístup je znázorněn na obrázku 32. Druhý přístup přizpůsobuje (jemné ladění) modely konvolučních neuronových sítí (AlexNet, GoogLeNet, VGG-16 a VGG-19) datové sadě MSX snímků namísto datové sady ImageNet. Druhý přístup je znázorněn na obrázku 33.



Obrázek 32: Navrhovaný multi-biometrický systém – první přístup

Zdroj: autor



Obrázek 33: Navrhovaný multi-biometrický systém – druhý přístup

Zdroj: autor

9.1 Fúze na úrovni senzoru

Provedena byla fúze na úrovni senzoru, největším kladem této úroveň fúze je, že algoritmus pro rozpoznání osob je méně výpočetně náročný než při využití ostatních možností fúze [7]. Datová sada obsahuje termální a viditelné snímky, které byly získány pomocí termální kamery

FLIR E5xt. Fúzí tepelných a viditelných snímků na úrovni senzoru, které byly sejmuty ve stejný okamžik vznikne MSX snímek (Multi-spektrální dynamický snímek). MSX snímek není pouhým proložením termálního a viditelného snímku. Software vytvořený společností FLIR je navržen tak, aby zachytil užitečné detaily na viditelných snímcích, jako jsou čáry a hrany, které jsou pak superponovány přímo na termální snímek [192]. Z termálního snímku se přitom neztratí žádné informace. MSX snímek je druh multi-spektrálního snímku. Obrázek 34 znázorňuje jeden snímek ruky v obou spektrech a vytvořený MSX. Vytvořená datová sada MSX snímků je vstupem pro konvoluční neuronové sítě.



Obrázek 34: Příklad termálního, viditelného a MSX snímku

Zdroj: autor

9.2 Zpracování obrazu

Pro extrakci biometrických rysů nebo pro společnou extrakci s klasifikací byly použity konvoluční neuronové sítě, tedy metody, které nevyžadují cílené předzpracování obrazu. Provedena byla pouze úprava velikosti vstupních MSX snímků, tak aby splňovaly požadavky konvolučních neuronových sítí na velikost vstupu. Konvoluční neuronové sítě pomocí jednotlivých vrstev extrahují velké množství rysů (konvoluční vrstva) a sdružují (poolingová vrstva) je do tzv. příznakových map. Po zpracování obrazu se kroky, v obou přístupech pro navrhované multi-biometrické systémy, shodují, dále se však již liší.

9.3 Konvoluční neuronová síť jako extraktor rysů

V navrhovaném multi-biometrickém systému (první přístup), byla použita pro extrakci biometrických rysů konvoluční neuronová síť AlexNet (s váhami předem natrénovaného modelu). Síť vytváří hierarchickou reprezentaci vstupních obrazů. Hlubší vrstvy obsahují znaky vyšší úrovně, vytvořené pomocí rysů nižší úrovně předchozích vrstev. Cílem bylo získat

znaky vyšší úrovně z trénovacích i testovacích obrazů, proto byly rysy extrahovány ze 7. konvoluční vrstvy AlexNet 'fc7'.

Klasifikace se provádí pomocí „hlubokých“ rysů s individuálními klasifikátory (diskriminační analýza, naivní Bayesův klasifikátor, rozhodovací stromy, algoritmus k-nejbližších sousedů, podpůrné vektorové stroje, neuronové sítě) nebo ensemble metodami (bagging, random subspace).

9.4 Ladění konvolučních neuronových sítí pro klasifikaci

V navrhovaném multi-biometrickém systému (druhý přístup), byly použity pro klasifikaci vyladěné konvoluční neuronové sítě (AlexNet, GoogLeNet, VGG-16 a VGG-19).

U všech laděných konvolučních neuronových sítí byla nahrazena plně propojená vrstva (třetí od konce), aby bylo přijato nastavení předtrénované konvoluční neuronové sítě k vyřešení našeho problému. Dále byla nahrazena poslední klasifikační vrstva, ve které je počet tříd 50 místo 1000.

Dále se trénují upravené konvoluční neuronové sítě. Algoritmus zpětného šíření chyby byl použit pro učení čtyřech vybraných neuronových sítí pomocí optimalizačního algoritmu stochastického gradientního sestupu pro minimalizaci chyb. Bylo provedeno mnoho testovacích scénářů pro nalezení optimálních parametrů sítě. Klasifikace se provádí pomocí nově vytvořených hlubokých modelů.

10 VÝSLEDKY VÝZKUMU

V této kapitole jsou uvedeny výsledky experimentů provedených za účelem empirického vyhodnocení účinnosti navržených modelů rozpoznávání osob. Modely biometrického rozpoznávání byly vytvořeny a vyhodnoceny v prostředí Matlab (R2021a). Experimenty byly prováděny na vytvořené datové sadě 10 000 viditelných a termálních snímků rukou.


Všechny obrázky z vytvořené datové sady jsou změněny na vhodnou velikost pro každý model CNN – $227 \times 227 \times 3$ jako vstup pro AlexNet a $224 \times 224 \times 3$ jako vstup pro GoogLeNet, VGG-16 a VGG-19.

Vyhodnoceny byly dva navrhované přístupy biometrického rozpoznávání: extrakce rysů pomocí CNN a ladění CNN. V první přístupu byla extrakce rysů provedena pomocí předtrénovaného modelu AlexNet, rysy jsou extrahovány ze sedmé konvoluční neuronové vrstvy 'fc7'. Posledním krokem bylo trénování a testování jednotlivých klasifikátorů (individuální klasifikátory a ensemble metody). Využity byly individuální klasifikátory (diskriminační analýza, naivní Bayesovský klasifikátor, algoritmus k-nejbližších sousedů, SVM, a neuronové sítě) a ensemble metody. Výsledky těchto experimentů jsou uvedeny mimo jiné jako průměrné míry přesnosti rozpoznávání po 5násobné křížové validaci.

V druhém přístupu byly využity metody jemného ladění konvolučních neuronových sítí (AlexNet, GoogLeNet, VGG-16 a VGG-19). Upravené modely vybraných neuronových sítí byly trénovány pomocí podmnožiny datové sady MSX snímků (70 %). Na obrázku 35 jsou vizualizace aktivací první konvoluční vrstvy natrénované sítě AlexNet. Tyto vizualizace ukazují, jaké rysy se síť naučila na obou stranách ruky (dlaň a hřbet). Jde především o obrysy ruky, ale i tělesnou teplotu ruky.

10.1 Výkon biometrické identifikace z hlediska přesnosti

Výkon modelů rozpoznávání osob je možné porovnat z hlediska jejich přesnosti nebo AUC. Jak je uvedeno v tabulce 8, využití individuální klasifikátory (první přístup) dosahují až na jeden všechny přesnosti přes 90 %. Individuální klasifikátory byly testovány na snímcích hřbetu i dlaně ruky. Nelze jednoznačně říci, jestli je výkonnější biometrický systém, který využívá snímky dlaně nebo hřbetu ruky. Nejvyšší přesnosti bylo dosaženo při využití lineární diskriminační analýzy u hřbetu i dlaně ruky. Lepších výsledků lineární diskriminační analýzy



Obrázek 35: Vizualizace aktivací první konvoluční vrstvy trénované sítě AlexNet

Zdroj: autor

dosahuje při využití snímků dlaně ruky. Poměrně špatných výsledků biometrické identifikace je dosaženo při využití naivních Bayesovských klasifikátorů.

Další možností, jak porovnat výkon modelů rozpoznávání osob je podle hodnoty AUC. Jak je uvedeno v tabulce 8, z využitých individuálních klasifikátorů (první přístup), jsou nejlépe podle hodnoty AUC hodnoceny podpůrné vektorové stroje se všemi typy jader (lineární, kvadratické, kubické a Gaussovské). Stejně jako podle přesnosti klasifikace, tak i podle hodnoty AUC dosahují naivní Bayesovské klasifikátory poměrně špatných výsledků.

Tabulka 8: Výkon biometrické identifikace z hlediska přesnosti – individuální klasifikátory

Strana ruky	Individuální klasifikátor	Přesnost tréninku	Přesnost testování (Acc)	AUC
Hřbet	Lineární diskriminační analýza	100,0 %	97,6 %	0,9898
	Gaussovský naivní Bayesův klasifikátor	99,1 %	90,8 %	0,9528
	Jádrový naivní Bayesův klasifikátor (jádro – Gaussovské)	99,4 %	92,5 %	0,9642
	k-nejbližších sousedů (1 soused, euklidovská vzdálenost)	100,0 %	95,7 %	0,9784
	k-nejbližších sousedů (10 sousedů, euklidovská vzdálenost)	99,1 %	93,7 %	0,9918
	k-nejbližších sousedů (10 sousedů, kosinová vzdálenost)	98,7 %	94,4 %	0,9938
	Podpůrné vektorové stroje (jádro – lineární)	99,9 %	95,2 %	0,9996
	Podpůrné vektorové stroje (jádro – kvadratické)	99,9 %	95,3 %	0,9996
	Podpůrné vektorové stroje (jádro – kubické)	100,0 %	95,2 %	0,9998
	Podpůrné vektorové stroje (jádro – Gaussovské)	99,6 %	94,4 %	0,9996
	Neuronová síť (široká)	99,9 %	94,9 %	0,9982
	Neuronová síť (střední)	99,6 %	93,1 %	0,9944
	Dlaň	Lineární diskriminační analýza	100,0 %	98,8 %
Gaussovský naivní Bayesův klasifikátor		97,1 %	87,9 %	0,9418
Jádrový naivní Bayesův klasifikátor (jádro – Gaussovské)		98,6 %	91,5 %	0,9582
k-nejbližších sousedů (1 soused, euklidovská vzdálenost)		99,9 %	98,5 %	0,9934
k-nejbližších sousedů (10 sousedů, euklidovská vzdálenost)		98,0 %	97,2 %	0,9968
k-nejbližších sousedů (10 sousedů, kosinová vzdálenost)		97,7 %	96,1 %	0,9960
Podpůrné vektorové stroje (jádro – lineární)		99,6 %	95,7 %	0,9998
Podpůrné vektorové stroje (jádro – kvadratické)		99,7 %	96,5 %	0,9998
Podpůrné vektorové stroje (jádro – kubické)		99,6 %	95,7 %	0,9998
Podpůrné vektorové stroje (jádro – Gaussovské)		97,7 %	95,5 %	0,9998
Neuronová síť (široká)		99,0 %	90,7 %	0,9996
Neuronová síť (střední)		99,7 %	97,5 %	0,9902

Zdroj: autor

Tabulka 9: Výkon biometrické identifikace z hlediska přesnosti – ensemble metody

Strana ruky	Ensemble metody	Přesnost tréninku	Přesnost testování (Acc)	AUC
Hřbet	Bagged tree	99,7 %	92,8 %	0,9986
	Subspace discriminant	100,0 %	97,7 %	0,9998
	Subspace k-NN	100,0 %	95,3 %	0,9866
Dlaň	Bagged tree	99,9 %	95,9 %	0,9998
	Subspace discriminant	100,0 %	98,9 %	0,9998
	Subspace k-NN	99,8 %	98,4 %	0,9960

Zdroj: autor

Tabulka 10: Výkon biometrické identifikace z hlediska přesnosti – CNN

Strana ruky	Individuální klasifikátor	Přesnost tréninku	Přesnost testování (Acc)	AUC
Hřbet	AlexNet	100,0 %	96,8 %	0,9996
	GoogLeNet	100,0 %	95,6 %	0,9996
	VGG-16	100,0 %	94,9 %	0,9990
	VGG-19	100,0 %	96,1 %	0,9994
Dlaň	AlexNet	100,0 %	99,7 %	0,9998
	GoogLeNet	100,0 %	97,7 %	0,9994
	VGG-16	100,0 %	98,1 %	0,9996
	VGG-19	100,0 %	97,5 %	0,9994

Zdroj: autor

V tabulce 9 jsou srovnávány ensemble metody nejlepší metodou je Subspace discriminant, jak podle přesnosti klasifikace, tak podle AUC dosahuje nejlepších výsledků. Při využití ensemble metod pro klasifikaci je dosahováno vyšších přesností rozpoznávání pomocí snímků dlaně ruky. Z tabulky 8 a 9 vyplývá, že předtrénovaný model AlexNet je velmi dobrý nástrojem pro extrakci rysů, kde nejvyšší přesnost 98,9 % je získána kombinací modelu AlexNet a klasifikátoru Subspace diskriminant, při využití snímků dlaně ruky.

V tabulce 10 jsou výsledky biometrické identifikace, při které se jak pro extrakci biometrických rysů, tak pro následnou klasifikaci využívají konvoluční neuronové sítě (druhý přístup).

Nejlepších výsledků dosahuje konvoluční neuronová síť AlexNet, jak z hlediska přesnosti (99,7 %) tak z hlediska AUC.

Nejlepší výkon biometrické identifikace z hlediska její přesnosti z testovaných metod dosahuje AlexNet pro snímky dlaně ruky a to 99,7 %. Nižší přesnost dosahují metody při využití snímků hřbetu ruky. U hřbetu ruky dosahuje nejvyšší přesnosti metoda Subspace discriminant 98,9 %.

10.2 Výkon biometrické identifikace z hlediska výpočetní složitosti

Další možnost, jak porovnat výkon biometrické identifikace, je porovnání z hlediska výpočetní složitosti. V tabulkách 11, 12 a 13 jsou porovnávány modely na základě jejich výpočetní složitosti. Pokud jde o dobu tréninku, je nejméně náročnou metodou lineární diskriminační analýza. Z pohledu rychlosti klasifikace (počet klasifikací za sekundu) jsou z individuálních klasifikátorů nejvýkonnější neuronové sítě. Z tohoto pohledu je výkonná také jedna ensemble metoda a to bagged tree. Avšak nejvyšší rychlosti klasifikace dosahují konvoluční neuronové sítě, které jsou ale zároveň nejnáročnější, co se týče požadavků na čas trénování těchto sítí.

Rozdíl mezi dobou potřebnou pro trénování modelů s metodami strojového učení a konvolučních neuronových sítí jsou velmi odlišné, doba potřebná pro trénování metod strojového učení je řádově mnohem nižší než pro konvoluční neuronové sítě.

Tabulka 11: Výkon biometrické identifikace z hlediska časové složitosti – individuální klasifikátory

Strana ruky	Individuální klasifikátor	Doba tréninku (s)	Rychlost klasifikace (poz/s)
Hřbet	Lineární diskriminační analýza	95,8	180,0
	Gaussovský naivní Bayesův klasifikátor	902,0	100,0
	Jádrový naivní Bayesův klasifikátor (jádro – Gaussovské)	8 452,3	3,3
	k-nejbližších sousedů (1 soused, euklidovská vzdálenost)	2 428,6	47,0
	k-nejbližších sousedů (10 sousedů, euklidovská vzdálenost)	2 582,7	49,0
	k-nejbližších sousedů (10 sousedů, kosinová vzdálenost)	2 900,2	50,0
	Podpůrné vektorové stroje (jádro – lineární)	1 091,8	33,0
	Podpůrné vektorové stroje (jádro – kvadratické)	1 969,8	13,0
	Podpůrné vektorové stroje (jádro – kubické)	2 044,2	12,0
	Podpůrné vektorové stroje (jádro – Gaussovské)	2 985,9	12,0
	Neuronová síť (široká)	5 623,1	340,0
	Neuronová síť (střední)	5 579,6	400,0
	Dlaň	Lineární diskriminační analýza	97,8
Gaussovský naivní Bayesův klasifikátor		860,7	110,0
Jádrový naivní Bayesův klasifikátor (jádro – Gaussovské)		8 859,9	3,4
k-nejbližších sousedů (1 soused, euklidovská vzdálenost)		2 592,6	42,0
k-nejbližších sousedů (10 sousedů, euklidovská vzdálenost)		2 760,2	46,0
k-nejbližších sousedů (10 sousedů, kosinová vzdálenost)		3 095,4	47,0
Podpůrné vektorové stroje (jádro – lineární)		1 076,1	32,0
Podpůrné vektorové stroje (jádro – kvadratické)		2 040,4	11,0
Podpůrné vektorové stroje (jádro – kubické)		2 070,2	11,0
Podpůrné vektorové stroje (jádro – Gaussovské)		3 187,2	10,0
Neuronová síť (široká)		5 838,1	360,0
Neuronová síť (střední)		5 794,5	410,0

Zdroj: autor

Tabulka 12: Výkon biometrické identifikace z hlediska časové složitosti – ensemble metody

Strana ruky	Individuální klasifikátor	Doba tréninku (s)	Rychlost klasifikace (poz/s)
Hřbet	Bagged tree	3 365,5	180,0
	Subspace discriminant	5 252,9	4,9
	Subspace k-NN	5 492,8	5,0
Dlaň	Bagged tree	3 494,4	370,0
	Subspace discriminant	5 391,0	4,8
	Subspace k-NN	5 718,9	5,0

Zdroj: autor

Tabulka 13: Výkon biometrické identifikace z hlediska časové složitosti – CNN

Strana ruky	Individuální klasifikátor	Doba tréninku (s)	Rychlost klasifikace (poz/s)
Hřbet	AlexNet	2 990	517
	GoogLeNet	8 161	486
	VGG-16	19 499	473
	VGG-19	21 207	441
Dlaň	AlexNet	2 719	539
	GoogLeNet	9 420	498
	VGG-16	42 480	461
	VGG-19	21 108	452

Zdroj: autor

10.3 Srovnání navrhovaného multi-biometrického a uni-biometrického systému

Kromě samotného výkonu biometrického systému je důležité také srovnání s dalšími biometrickými systémy. V tabulce 14 je srovnání navrhovaného multi-biometrického systému a uni-biometrického systému, který na vstupu využívá pouze termální snímky ruky z vytvořené datové sady. Uni-biometrické systémy mají nižší přesnost, než multi-biometrické systémy. V uni-biometrickém systému je dosaženo nejvyšší přesnosti klasifikace při využití AlexNet a VGG. I uni-biometrické systémy dosahují vyšší přesnosti při využití termálních snímků dlaně.

Tabulka 14: Srovnání uni-biometrického a multi-biometrického systému

Strana ruky	Algoritmy použité pro biometrické rozpoznávání	Acc uni-biometrický systém (termální snímky)	Acc multi-biometrický systém
Hřbet	AlexNet + Subspace discriminant	92,2 %	97,7 %
	AlexNet + Lineární diskriminační analýza	90,5 %	97,6 %
	AlexNet	93,8 %	96,8 %
	VGG-19	93,1 %	96,1 %
Dlaň	AlexNet	96,8 %	99,7 %
	AlexNet + Subspace discriminant	93,2 %	98,9 %
	AlexNet + Lineární diskriminační analýza	91,3 %	98,8 %
	VGG-16	95,6 %	98,1 %

10.4 Srovnání s předchozími studiemi

Tabulka 15 srovnává navržené metody se souvisejícími pracemi. Podle mého nejlepšího vědomí, jde o první výzkum, který se zabývá biometrickým rozpoznáváním osob s využitím tepelných charakteristik ruky v kombinaci s běžně používanými charakteristikami ruky s fúzí na úrovni senzoru. Není tedy možné porovnat přesnost klasifikace s multi-biometrickým systémem s fúzí na úrovni senzoru. Ale ve srovnání s metodami, které používají buď termální snímky ruky, nebo termální snímky a viditelné snímky a fúze probíhá na úrovni fúze skóre, navrhovaná metoda má velmi dobré výsledky. Všechny výsledky ukazují robustnost a efektivitu navrhovaného multi-biometrického systému.

Tabulka 15: Srovnání se souvisejícími výzkumy

Zdroj	Strana ruky	Zdroj informací	Fúze	Algoritmy použité pro biometrické rozpoznávání	Velikost datové sady	Acc
Faundez-Zanuy et al. [52]	Dlaň + hřbet	Termální snímky	–	BDM (Biometric dispersion matcher) + diskriminační analýza	2 000	82,0 %
Faundez-Zanuy et al. [52]	Dlaň + hřbet	Termální + viditelné snímky	Fúze na úrovni skóre	BDM algoritmus + diskriminační analýza	2 000	98,2 %
Bartuzi & Trokielewicz [17]	Dlaň	Termální snímky	–	AlexNet	–	86,8 %
Bartuzi & Trokielewicz [17]	Dlaň	Termální + viditelné snímky	Fúze na úrovni skóre	AlexNet	–	99,4 %
Navrhovaná metoda	Dlaň	Termální + viditelné snímky	Fúze na úrovni senzoru	AlexNet	10 000	99,7 %
Navrhovaná metoda	Hřbet	Termální + viditelné snímky	Fúze na úrovni senzoru	AlexNet + Subspace discriminant	10 000	97,7 %

Zdroj: autor


10.5 Analýza chyb

Pro lepší posouzení výkonnosti navrhovaného multi-biometrického systému, je důležité také zanalyzovat chyby, které vznikly při biometrické identifikaci. Chybně byly klasifikovány při využití AlexNet (dlaň) a AlexNet + Subspace discriminant (hřbet) dvě stejné osoby (jedna žena a jeden muž). Příklady chybně klasifikovaných snímků jsou na obrázku 36.

Charakteristika chybně klasifikovaných osob je následující, žena ve věkové skupině 45–59 let (prstýnky, na dlaních mozoly a puchýře, v datové sadě snímky ruky potomka), muž ve věkové skupině 45–59 let (na dlaních mozoly a puchýře, v datové sadě snímky ruky potomka a sourozenců).

Dlaň ženy byla chybně klasifikována jako dlaň mužská (stejná věková kategorie). Dlaň muže byla chybně klasifikována jako dlaň muže ve věkové kategorii (75 let a starší). Hřbet ruky ženy byl převážně chybně klasifikován jako hřbet ruky jiné ženy ve stejné věkové kategorii. Hřbet ruky muže byl klasifikován jako hřbet ruky jiného muže ve stejné věkové kategorii.

Při chybných klasifikacích u AlexNet a AlexNet + Subspace discriminant nedocházelo k záměně mezi sourozenci ani mezi dětmi a jejich rodiči. U chybných klasifikací dlaně šlo o ruce, na kterých byly mozoly a puchýře, avšak osoby za které byly označeny mozoly ani puchýře neměli.



Obrázek 36: Chybné klasifikace

Zdroj: autor

11 DALŠÍ SMĚRY VÝZKUMU

Vzhledem k tomu, že během této výzkumné práce byla vytvořena rozsáhlá datová sada termálních a viditelných snímků rukou, bylo by možné rozšířit výzkum na úkol detekce lidí se zvýšenou tělesnou teplotou, což je jeden z příznaků virových onemocnění. V poslední době je největším problémem virové onemocnění COVID-19. Rozpoznání lidí s horečkou by mohlo být jedním ze způsobů, jak bojovat proti této nemoci.

Datová sada termálních a viditelných snímků byla vytvořena v omezených podmínkách a s omezenými podmínkami pracují omezené biometrické systémy. Dalším směrem výzkumu, by proto mohl být bezkontaktní biometrický systém, což by zvýšilo uživatelskou přívětivost systému.

Další možností výzkumu je zaměřit se na jiné typy fúze, jako je fúze na úrovni skóre. Použijeme-li tento typ fúze, nedojde k žádnému snížení biometrických údajů, na druhou stranu zvýší se výpočetní složitost systému.

Některé biometrické charakteristiky mohou být využity nejen pro biometrické rozpoznávání, ale obsahují informace pomocí, kterých lze rozpoznat demografické charakteristiky lidí jako je například věk, pohlaví a etnický původ. Další směr výzkumu by se tedy mohl zaměřit na otázku, zda je možné pomocí multispektrálních snímků ruky identifikovat pohlaví osoby.

11.1 Rozpoznání pohlaví na základě MSX snímků ruky

Demografické charakteristiky (věk, pohlaví a etnický původ, ...) patří do oblasti měkké biometrie. V měkké biometrii je setkáváme kromě fyziologických, behaviorálních vlastností také se „zvyklostními“ lidskými vlastnostmi, ty lze zařadit do předem definovaných kategorií vyhovujících člověku [3]. Tyto kategorie jsou stanoveny a ověřeny lidmi s cílem rozlišit jednotlivce. Dále se zaměříme pouze na jednu demografickou charakteristiku a to pohlaví.

V literatuře jsou zmiňovány různé znaky pomocí, kterých lze určit pohlaví. Znaky s největší pohlavní diverzitou jsou znaky v obličeji a pánvi [117]. Člověk na základě obličeje dokáže snadno klasifikovat muže a ženu s vysokou přesností 95 % [29]. Však v oblasti počítačového vidění jde o velmi složitý úkol. Výzkumníci využili pro klasifikaci pohlaví nejen znaky v obličeji [210], ale byla využita i duhovka [168], chůze [118], řeč [206], nebo ruka [121].

Rozpoznávání pohlaví má široké možnosti využití v reálných aplikacích. Od zlepšení přesnosti biometrických systémů, přes zobrazování reklamy zákazníkům podle pohlaví, kontroly přístupu do prostoru budovy, vlakového vagonu, šatny [41], [119]. Především systémy, které zajišťují přístup do budov (místností), mohou mít problémy se světelnými podmínkami. Ať už jde o nedostatečné osvětlení v místnosti, nebo pokud jde o venkovní vstup velké problémy mohou nastat v noci.

11.2 Současný stav řešené problematiky – rozpoznání pohlaví

Většina studií využívá pro rozpoznávání pohlaví snímky charakteristických znaků získané ve viditelném spektru. Přesto však existuje několik studií, které pracují s termálními snímky obličeje [140], [188] nebo celého těla [129].

Problém rozpoznání pohlaví ve venkovních prostranstvích je řešen v jedné studii, za pomoci UAV (bezpilotního letadla) s termální kamerou [140]. V tomto příspěvku je navržen model řízeného letu UAV, během kterého jsou získány termální snímky osob, následně jsou detekovány obličeje osob. V posledním kroku je provedena binární klasifikace detekovaných obličejů s přesností 82,3 % pro AlexNet a 81,6 % pro GoogLeNet.

Navržena byla také hybridní metoda rozpoznávání pohlaví, kde je využita fúze viditelných a termálních snímků [188]. Fúze snímků je provedena na úrovni rysů a rozhodnutí. Výsledky studie ukazují, že fúze na obou úrovních zlepšují výkonnost rozpoznávání pohlaví ve srovnání s výkonností při použití pouze jednoho snímku (termální nebo viditelný).

Chen a Ross provedli studii k rozpoznání pohlaví z termálních obrazů obličeje [35]. Nejprve extrahovali rysy pomocí algoritmu lokální binární vzor (LBP) a poté vyhodnotili různé klasifikátory pohlaví na blízkých infračervených snímcích.

11.3 Metody a výsledky rozpoznávání pohlaví

Dále je nastíněn další možný směr výzkumu – systém rozpoznávání pohlaví, který na vstupu využívá MSX snímky ruky (termální snímek a viditelný snímek – fúze na úrovni senzoru). V prvním přístupu jsou pro extrakci rysů jsou využity metody hlubokého učení a následná klasifikace probíhá pomocí metod strojového učení. V druhém přístupu extrakci i klasifikaci provádějí metody hlubokého učení. Cílem je zjistit, zda je možné termální charakteristiky ruky v kombinaci s běžně používanými charakteristikami ruky využít pro určení pohlaví.

Pro extrakci rysů je využita konvoluční neuronovou sít' AlexNet i s počátečními předtrénovanými hodnotami sítě. V prvním kroku jsou MSX snímky rukou převzorkovány pomocí metody interpolace nejbližšího souseda na velikost $227 \times 227 \times 3$, která odpovídá požadované velikosti vstupu AlexNet.

Datová sada snímků byla rozdělena na tréninková (70 %) a testovací data (30 %). Tedy tréninková data jsou snímky od 16 mužů a žen, testovací data jsou snímky od 7 mužů a žen. Bylo dbáno na to, aby snímky od stejné osoby nebyly jak v trénovacích, tak v testovacích datech. Takto rozdělená datová sady snímků byla využita pro všechny provedené experimenty.

Následovala extrakce rysů pomocí AlexNet. Sít' vytváří hierarchickou reprezentaci vstupních obrazů. Hlubší vrstvy obsahují znaky vyšší úrovně, vytvořené pomocí rysů nižší úrovně předchozích vrstev. Cílem bylo získat znaky vyšší úrovně z trénovacích i testovacích obrazů, proto byly rysy extrahovány ze 7. konvoluční vrstvy AlexNet 'fc7'.

Po extrakci znaků bylo testováno a optimalizováno několik druhů klasifikátorů – podpůrné vektorové stroje, lineární diskriminant, naivní Bayesův klasifikátor, neuronové sítě.

Další možností, jak řešit problém rozpoznávání pohlaví, je využití konvolučních neuronových sítí pro extrakci i následnou klasifikaci. Jsou využity předtrénované sítě AlexNet, GoogLeNet, VGG-16 a VGG-19 s počátečními hodnotami.

Termální snímky rukou byly převzorkovány pomocí metody interpolace nejbližšího souseda na velikosti ($227 \times 227 \times 3$ pro AlexNet a $224 \times 224 \times 3$ pro GoogLeNet, VGG-16 a VGG-19), jde o požadované velikosti vstupů pro dané konvoluční neuronové sítě. Datová sada snímků použitá pro tyto experimenty je stejná jako pro experimenty s AlexNet a jednotlivými klasifikátory.

Nejprve byly konvoluční neuronové sítě trénovány na trénovacích datech. Pro učení byl využit algoritmus zpětného šíření chyby, jenž využívá pro minimalizaci chyb optimalizační algoritmus stochastického gradientního sestupu. Dále byly CNNs testovány pomocí testovacích dat.

Tabulka 16: Přesnost klasifikace vybraných metod

Metody rozpoznávání pohlaví	Přesnost klasifikace	
	Hřbet	Dlaň
<i>Strojové učení (jádro)</i>		
AlexNet + SVM (Gaussovské)	87,1 %	87,3 %
AlexNet + lineární diskriminant	85,9 %	89,7 %
AlexNet + SVM (lineární)	85,6 %	88,3 %
AlexNet + široká neuronová síť	85,1 %	86,3 %
Alex Net + Naivní Bayesovský klasifikátor	84,4 %	88,3 %
AlexNet + SVM (kubické) + PCA	84,1 %	83,0 %
<i>CNNs</i>		
AlexNet	85,6 %	92,7 %
GoogLeNet	82,6 %	90,1 %
VGG-16	89,9 %	93,0 %
VGG-19	86,1 %	94,9 %

Obecně platí, že vyšší přesnosti rozpoznání pohlaví se dosahuje s obrázky dlaně, bez ohledu na použitý klasifikátor nebo neuronovou síť. Nejlepších výsledků je dosahováno pomocí konvolučních neuronových sítí VGG-16 (89,9 %) pro hřbet ruky a VGG-19 pro dlaň ruky (94,9 %).

12 PŘÍNOSY DISERTAČNÍ PRÁCE

Na základě analýzy současného stavu řešení v oblasti biometrického rozpoznávání na bázi ruky byl definován cíl práce navržení a ověření nového způsobu biometrického rozpoznávání osob s využitím termálních charakteristik ruky v kombinaci s běžně používanými charakteristikami ruky. Vědecké a aplikační přínosy tohoto rozpoznávání jsou následující.

12.1 Vědecké přínosy

Cíle disertační práce byly řešeny v rámci interních grantů: Informační prostředí chytrých měst a regionů z hlediska konkurenceschopnosti, efektivity a bezpečnosti, Transparentnost a konkurenceschopnost obcí a regionů v rámci rozvoje konceptu chytrých měst a regionů, Pokročilá podpora rozvoje chytrých měst a regionů, Zvyšování kvality informačních systémů veřejné správy, Nástroje a postupy zvyšování kvality informačních systémů veřejné správy. Výsledky grantů a dílčí výsledky byly publikovány. Seznam publikací je uveden v samostatné kapitole.

Za vědecké přínosy disertační práce lze považovat:

- Vytvoření rozsáhlé rešerše současného stavu v oblasti biometrického rozpoznávání na bázi ruky.
- Analýza různých ukazatelů, které jsou vhodné pro kvantitativní ohodnocení biometrického rozpoznávání na bázi ruky.
- Vytvoření rozsáhlé datové sady snímků ruky. Jde o snímky získané ve dvou spektrech viditelném a termálním elektromagnetickém spektru. Takto vytvořená datová sada může být využita pro učení a verifikaci modelů multi-biometrických systémů.
- Vytvoření modelu multi-biometrického systému založeného na hlubokém učení (dva přístupy). Jedná se o první výzkum, který kombinuje termální snímky ruky a viditelné snímky na úrovni senzoru za účelem rozpoznání pohlaví.
- Specifikace parametrů jednotlivých metod (konvolučních neuronových sítí, ensemble metod a dalších).
- Komparace výsledků z různých hledisek.

12.2 Aplikační a ekonomické přínosy

Vzhledem k aplikaci navržených modelů na reálných datech (snímcích rukou) má práce také několik aplikačních a ekonomických přínosů:

- Multi-biometrický systém, jak již bylo prokázáno předchozími výzkumy, ale i v této práci, zvyšuje míru bezpečnosti proti uni-biometrickému systému. Navržený model multi-biometrického systému má vyšší přesnost rozpoznání osoby, než uni-biometrický systém, který využívá pouze tepelné charakteristiky ruky.
- Navržený model využívá fúzi na úrovni senzoru, jde o úroveň fúze, která je méně výpočetně náročná než pozdější úroveň fúze, což je v některých reálných aplikacích velmi žádaná vlastnost.
- Uplatnění tohoto multi-biometrického systému, by bylo výhodné v místech, kde nejsou optimální světelné podmínky, protože kvalita termálních snímků nezáleží na osvětlení.
- Zvýšením přesnosti multi-biometrického systému, se sníží náklady, které mohou vzniknout při chybné identifikaci osoby.

ZÁVĚR

V dnešním moderním světě je spolehlivé a automatické rozpoznávání osob často zásadní, a to především kvůli zvýšeným bezpečnostním rizikům. Disertační práce se právě z tohoto důvodu zabývá automatickým rozpoznáváním osob. Cílem disertační práce je navržení a ověření nového způsobu biometrického rozpoznávání osob s využitím termálních charakteristik ruky v kombinaci s běžně používanými charakteristikami ruky, jako je textura a tvar ruky (se spojením na úrovni senzoru).

V rámci výzkumu bylo dosaženo výsledků ve dvou hlavních oblastech, které odpovídají cíli této disertační práce – navržení nového způsobu biometrického rozpoznávání osob na bázi ruky a vytvoření rozsáhlé datové sady vhodné k ověření nového způsobu biometrického rozpoznávání osob.

Součástí výzkumu bylo vytvoření nové rozsáhlé multi-senzorové (viditelné spektrum a infračervené spektrum) a multi-relační (2–4 sezení) datové sady snímků ruky a to i s popisem jejího vytváření. Tato datová sady je vhodná pro ověření metod biometrického rozpoznávání nebo rozpoznávání pohlaví v uni-modálních i multi-modálních (dlaň a dorzální snímky) a multi-senzorových přístupech.

Testována byla sada nejmodernějších metod hlubokého učení a strojového učení pro biometrické rozpoznávání lidí. Bylo zjištěno, že tepelné charakteristiky dlaně a hřbetu ruky v kombinaci s běžně používanými charakteristikami ruky se zdají být slibným přístupem pro biometrické rozpoznávání.

V rozsáhlých experimentech byly testovány dva přístupy k vytvoření multi-biometrického systému s fúzí na úrovni senzoru. První přístup využívá předtrénovaný model konvoluční neuronové sítě AlexNet jako extraktor rysů a pro klasifikaci jsou využity různé klasifikátory. Velmi dobrých výsledků dosahuje AlexNet v kombinaci s lineární diskriminační analýzou, a to jak z hlediska přesnosti (hřbet – 97,6 % a dlaň – 98,8 %) a časové náročnosti. Další dobrých výsledků je dosahováno kombinací AlexNet a ensemble metody – Subspace discriminant (hřbet – 97,7 % a dlaň – 98,9 %).

Druhý přístup přizpůsobuje (jemné ladění) modely konvolučních neuronových sítí (AlexNet, GoogLeNet, VGG-16 a VGG-19) datové sadě MSX snímků namísto datové sadě ImageNet. Z hlediska přesnosti bylo dosaženo nejlepšího výsledku právě tímto přístupem. U snímků dlaně ruky bylo dosaženo přesnosti klasifikace (AlexNet) 99,7 %, u snímků hřbetu ruky dosahuje

nejvyšší přesnosti také AlexNet s 96,8 %. Časová náročnost konvolučních neuronových sítí je řádově vyšší, než časová náročnost ostatních testovaných metod.

Experimenty ukázaly, že uni-biometrické systémy mají nižší přesnost, než multi-biometrické systémy. Zároveň fúze na úrovni senzoru, která je jednou z méně prozkoumaných úrovní fúze, dosahuje slibných výsledků ve srovnání s nejmodernějšími metodami biometrického rozpoznávání. Vyšší přesnosti identifikace je až na výjimky dosaženo u MSX snímků dlaně ruky.

POUŽITÁ LITERATURA

- [1] ADÁN, Miguel, Antonio ADÁN, Andrés S. VÁZQUEZ a Roberto TORRES. Biometric verification/identification based on hands natural layout. *Image and Vision Computing*. 2008, **26**(4), s. 451-465. ISSN 02628856. DOI: 10.1016/j.imavis.2007.08.010.
- [2] AĐUAN, Feng, Xina REN a Yikang YANG. A Gesture Recognition System Based on Time Domain Features and Linear Discriminant Analysis, In: *IEEE Transactions on Cognitive and Developmental Systems*, **13**(1), s. 200-208, 2021, DOI: 10.1109/TCDS.2018.2884942.
- [3] AFIFI, Mahmoud, Marwa NASSER, Mostafa KORASHY, Katherine ROHDE a Aly A. MOHAMED. Can we boost the power of the Viola–Jones face detector using preprocessing? An empirical study. *Journal of Electronic Imaging*. 2018, **27**(4). ISSN 1017-9909. DOI: 10.1117/1.JEI.27.4.043020.
- [4] AFIFI, Mahmoud. 11K Hands: Gender recognition and biometric identification using a large dataset of hand images. *Multimedia Tools and Applications*. 2019, **78**(15), s. 20835-20854. ISSN 1380-7501. DOI: 10.1007/s11042-019-7424-8.
- [5] AGHILI, Bahareh a Hamed SADJEDI. Personal Authentication Using Hand Geometry. In: *2009 International Conference on Computational Intelligence and Software Engineering*. IEEE, 2009, s. 1-4. ISBN 978-1-4244-4507-3. DOI: 10.1109/CISE.2009.5363947.
- [6] AL-WAISY, Alaa S., Rami QAHWAJI, Stanley IPSON, Shumoos AL-FAHDAWI a Tarek A. M. NAGEM. A multi-biometric iris recognition system based on a deep learning approach. *Pattern Analysis and Applications*. 2018, **21**(3), s. 783-802. ISSN 1433-7541. DOI: 10.1007/s10044-017-0656-1.
- [7] ALDJIA, Boucetta a Boussaad LEILA. Sensor Level Fusion for Multi-modal Biometric Identification using Deep Learning. In: *2021 International Conference on Recent Advances in Mathematics and Informatics (ICRAMI)*. IEEE, 2021, s. 1-5. ISBN 978-1-6654-4171-1. DOI: 10.1109/ICRAMI52622.2021.9585900.
- [8] ALI, Waqar, Wenhong TIAN, Salah Ud DIN, Desire IRADUKUNDA a Abdullah Aman KHAN. Classical and modern face recognition approaches: a complete

- review. *Multimedia Tools and Applications*. 2021, **80**(3), s. 4825-4880. ISSN 1380-7501. DOI: 10.1007/s11042-020-09850-1.
- [9] ALMISREB, Ali Abd, Nursuriati JAMIL a N. Md DIN. Utilizing AlexNet Deep Transfer Learning for Ear Recognition. In: *2018 Fourth International Conference on Information Retrieval and Knowledge Management (CAMP)*. IEEE, 2018, s. 1-5. ISBN 978-1-5386-3812-5. DOI: 10.1109/INFRKM.2018.8464769.
- [10] AMAYEH, Gholamreza, George BEBIS, Ali EROL a Mircea NICOLESCU. Peg-Free Hand Shape Verification Using High Order Zernike Moments. In: *2006 Conference on Computer Vision and Pattern Recognition Workshop (CVPRW'06)*. New York: IEEE, 2006, s. 40-40. ISBN 0-7695-2646-2. ISSN 2160-7508. DOI: 10.1109/CVPRW.2006.155.
- [11] AMBETH KUMAR, V. D. a M. RAMAKRISHNAN. Multiple Feature Extraction for Footprint Image. *National Journal of System and Information Technology*. 2012, **5**(2), s. 142. ISSN 0974-3308.
- [12] ANGADI, Shanmukhappa a Sanjeevakumar HATTURE. Hand geometry-based user identification using minimal edge connected hand image graph. *IET computer vision*. 2018, **12**(5), s. 744-52. DOI: 10.1049/iet-cvi.2017.0053.
- [13] ANGADI, Shanmukhappa A. a Sanjeevakumar M. HATTURE. Biometric Person Identification System: A Multimodal Approach Employing Spectral Graph Characteristics of Hand Geometry and Palmprint. *International Journal of Intelligent Systems and Applications*. 2016, **8**(3), s. 48-58. ISSN 2074904X. DOI: 10.5815/ijisa.2016.03.06.
- [14] Applying Supervised Learning. In: The MathWorks, [online]. 2016. [cit. 2022-02-03]. Dostupné z: https://www.mathworks.com/content/dam/mathworks/tag-team/Objects/i/90221_80827v00_machine_learning_section4_ebook_v03.pdf
- [15] BADAWI, Ahmed M. a Mohamed Samel KAMEL. Free style hand geometry verification system. In: *2003 46th Midwest Symposium on Circuits and Systems*. IEEE, 2003, s. 324-327. ISBN 0-7803-8294-3. ISSN 1548-3746. DOI: 10.1109/MWSCAS.2003.1562284.
- [16] BAPAT, Akshay a Vivek KANHANGAD. Segmentation of hand from cluttered backgrounds for hand geometry biometrics. In: *2017 IEEE Region 10 Symposium*

- (TENSYP). IEEE, 2017, s. 1-4. ISBN 978-1-5090-6255-3. DOI: 10.1109/TENCONSpring.2017.8070016.
- [17] BARTUZI, Ewelina a Mateusz TROKIELEWICZ. Thermal Features for Presentation Attack Detection in Hand Biometrics. In: *2018 IEEE 9th International Conference on Biometrics Theory, Applications and Systems (BTAS)*. IEEE, 2018, s. 1-6. ISBN 978-1-5386-7180-1. DOI: 10.1109/BTAS.2018.8698546
- [18] BARTUZI, Ewelina, Katarzyna ROSZCZEWSKA, Adam CZAJKA a Andrzej PACUT. Unconstrained biometric recognition based on thermal hand images, In: *2018 International Workshop on Biometrics and Forensics (IWBF)*, IEEE, Sassari: 2018, s. 1-8. ISBN 978-1-5386-1366-5. DOI: 10.1109/IWBF.2018.8401567.
- [19] BARUSHKA, Aliaksandr a Petr HAJEK. Spam Filtering in Social Networks Using Regularized Deep Neural Networks with Ensemble Learning. ILIADIS, Lazaros, Ilias MAGLOGIANNIS a Vassilis PLAGIANAKOS, ed. *Artificial Intelligence Applications and Innovations* [online]. Cham: Springer International Publishing, 2018, 2018-05-22, s. 38-49. IFIP Advances in Information and Communication Technology. ISBN 978-3-319-92006-1. DOI: 10.1007/978-3-319-92007-8_4.
- [20] BEALE Mark Hudson, HAGAN Martin T. a DEMUTH Hagan Howard B. Deep Learning Toolbox™, User's Guide. MatlabWorks. 2021
- [21] BERA, Asish a Debotosh BHATTACHARJEE. Human Identification Using Selected Features from Finger Geometric Profiles. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. 2020, **50**(3), s. 747-761. ISSN 2168-2216. DOI: 10.1109/TSMC.2017.2744669.
- [22] BERA, Asish, Debotosh BHATTACHARJEE a Mita NASIPURI. Finger contour profile-based hand biometric recognition. *Multimedia Tools and Applications*. 2017, **76**(20), s. 21451-21479. ISSN 1380-7501. DOI: 10.1007/s11042-016-4075-x.
- [23] BHARADI, V. A., D. N. SHAH, N. T. THAPA, B H. PANDYA a G. COSMA. Multi-Instance Iris Recognition. In: *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*. IEEE, 2018, 2018, s. 1-6. ISBN 978-1-5386-5257-2. DOI:10.1109/ICCUBEA.2018.8697811.

- [24] *Biometric systems: technology, design and performance*. Editor James WAYMAN. London: Springer-Verlag, 2005. ISBN 1852335963.
- [25] BOREKI, Guilherme a Alessandro ZIMMER. Hand Geometry: A New Approach for Feature Extraction. In: *Fourth IEEE Workshop on Automatic Identification Advanced Technologies (AutoID'05)*. IEEE, 2005, s. 149-154. ISBN 0-7695-2475-3. DOI: 10.1109/AUTOID.2005.33.
- [26] BREIMAN, Leo, Jerome FRIEDMAN, R. A. OLSHEN, a Charles J. STONE. Classification and Regression Trees. *Biometrics*, 1984, **40**(3), s. 358-361.
- [27] BREIMAN, Leo. Bagging predictors. *Machine Learning*. 1996, B.m.: Kluwer Academic Publishers, **24**(2), s. 123-140. ISSN 0885-6125. Dostupné z: <https://link.springer.com/content/pdf/10.1007/BF00058655.pdf>
- [28] BRICENO, Juan C., Carlos. M. TRAVIESO, Jesus B. ALONSO a Miguel A. FERRER. Biometric Identification Based on Hand-Shape Features Using a HMM Kernel. In: *2011 International Conference on Hand-Based Biometrics*. IEEE, 2011, 2011, s. 1-6. ISBN 978-1-4577-0490-1. DOI: 10.1109/ICHB.2011.6094315.
- [29] BRUCE, Vicki, A Mike BURTON, Elias HANNA, Pat HEALEY, Oli MASON, Anne COOMBES, Rick FRIGHT a Alf LINNEY. Sex Discrimination: How Do We Tell the Difference between Male and Female Faces?. *Perception*. 1993, **22**(2), s. 131-152. ISSN 0301-0066. DOI: 10.1068/p220131.
- [30] BRUNELLI, Roberto a Daniele FALAVIGNA. Person identification using multiple cues. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1995, **17**(10), s. 955-966. ISSN 0162-8828. DOI:10.1109/34.464560
- [31] BUDDHARAJU, Pradeep, Ioannis T. PAVLIDIS, Panagiotis TSIAMYRTZIS a Mike BAZAKOS. Physiology-Based Face Recognition in the Thermal Infrared Spectrum. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2007, **29**(4), s. 613-626. ISSN 0162-8828. DOI: 10.1109/TPAMI.2007.1007.
- [32] BURGUES, Javier, Julian FIERREZ, Daniel RAMOS, Maria PUERTAS a Javier ORTEGA-GARCIA. Detection Invalid Samples in Hand Geometry Verification via Geometric Measurements. In: *2010 International Workshop on Emerging Techniques and*

- Challenges for Hand-Based Biometrics*. IEEE, Istanbul, 2010, s. 1-6. DOI: 10.1109/ETCHB.2010.5559296.
- [33] CHARFI, Nesrine, Hanene TRICHILI, Adel M. ALIMI a Basel SOLAIMAN. Personal recognition system using hand modality based on local features. In: *2015 11th International Conference on Information Assurance and Security (IAS)*. IEEE, 2015, 2015, s. 13-18. ISBN 978-1-4673-8715-6. DOI: 10.1109/ISIAS.2015.7492764.
- [34] CHARFI, Nesrine, Hanene TRICHILI, Adel M. ALIMI a Basel SOLAIMAN. Novel hand biometric system using invariant descriptors, In: *6th International Conference of Soft Computing and Pattern Recognition (SoCPaR)*. Tunis: 2014, s. 261-266, ISBN 978-1-4799-5934-1. DOI: 10.1109/SOCPAR.2014.7008016.
- [35] CHEN, Cunjian a Arun ROSS. Evaluation of gender classification methods on thermal and near-infrared face images. In: *2011 International Joint Conference on Biometrics (IJCB)*. IEEE, 2011, s. 1-8. ISBN 978-1-4577-1359-0. DOI: 10.1109/IJCB.2011.6117544.
- [36] CHERRAT, El Mehdi, Rachid ALAOUI a Hassane BOUZAHIR. Convolutional neural networks approach for multimodal biometric identification system using the fusion of fingerprint, finger-vein and face images. *PeerJ Computer Science*. 2020, **6**. ISSN 2376-5992. DOI:10.7717/peerj-cs.248.
- [37] CHOLLET, François a Rudolf PECINOVSKÝ. *Deep learning v jazyku Python: knihovny Keras, Tensorflow*. První vydání. Praha: Grada Publishing, 2019. ISBN 9788024731001.
- [38] COVAVISARUCH, Nongluk, Pipat PRATEEPAMORNKUL, Puripant RUCHIKACHORN a Piyanat TAKSAPHAN. Personal verification and identification using hand geometry. *ECTI Transactions on Computer and Information Technology (ECTI-CIT)*. 2005, **1(2)**, s. 134-140. Dostupné z: https://www.researchgate.net/publication/228970310_Personal_Verification_and_Identification_Using_Hand_Geometry
- [39] ČSN ISO/IEC 2382-37. *Informační technologie. Slovník - Část 37: Biometrika*. Praha: Úřad pro technickou normalizaci, metrologii a státní zkušebnictví, 2018, s. 32. Třídící znak 36 9001.

- [40] CZAJKA, Adam a Pawel BULWAN. Biometric verification based on hand thermal images. In: *2013 International Conference on Biometrics (ICB)*. IEEE, 2013, 2013, s. 1-6. ISBN 978-1-4799-0310-8. DOI: 10.1109/ICB.2013.6612982.
- [41] DANTCHEVA, Antitza, Petros ELIA a Arun ROSS. What Else Does Your Biometric Data Reveal? A Survey on Soft Biometrics. *IEEE Transactions on Information Forensics and Security*. 2016, **11**(3), s. 441-467. ISSN 1556-6013. DOI: 10.1109/TIFS.2015.2480381.
- [42] DE SANTOS SIERRA, Alberto, Javier Guerra CASANOVA, Carmen Sanchez AVILA a Vicente Jara VERA. Silhouette-based hand recognition on mobile devices. In: *43rd Annual 2009 International Carnahan Conference on Security Technology*. IEEE, 2009, s. 160-166. ISBN 978-1-4244-4169-3. DOI: 10.1109/CCST.2009.5335548.
- [43] DOAN, Huong-Giang, Thanh-Hai TRAN, Hai VU, Thi-Lan LE, Van-Toi NGUYEN, Sang Viet DINH, Thi-Oanh NGUYEN, Thi-Thuy NGUYEN a Duy-Cuong NGUYEN. Multi-view discriminant analysis for dynamic hand gesture recognition. In: *Asian Conference on Pattern Recognition*. Springer, Singapore, 2019. s. 196-210. DOI: 10.1007/978-981-15-3651-9_18.
- [44] DOSEDĚL, Tomáš. *Počítačová bezpečnost a ochrana dat*. Brno: Computer Press, 2004. ISBN 80-251-0106-1.
- [45] DOUBLET, Julien, Olivier LEPETIT a Marinette REVENU. Contactless Hand Recognition Based on Distribution Estimation. In: *2007 Biometrics Symposium*. IEEE, 2007, s. 1-6. ISBN 978-1-4244-1548-9. DOI: 10.1109/BCC.2007.4430547.
- [46] DRAHANSKÝ, Martin a Filip ORSÁG. *Biometrie*. Brno: Computer Press, s.r.o, 2011. ISBN 978-80-254-8979-6.
- [47] ELLAHYANI, Ayoub, Mohamed El ANSARI a Ilyas El JAAFARI. Traffic sign detection and recognition based on random forests. *Applied Soft Computing*. 2016, **46**, s. 805-815. ISSN 15684946. DOI: 10.1016/j.asoc.2015.12.041.
- [48] ELLIOTT, Stephen J., Benny SENJAYA, Eric P. KUKULA, Jason M. WERNER a Mark WADE. An evaluation of the Human Biometric Sensor Interaction using hand geometry. In: *44th Annual 2010 IEEE International Carnahan Conference on Security Technology*. IEEE, 2010, s. 259-265. ISBN 978-1-4244-7403-5. DOI: 10.1109/CCST.2010.5678710.

- [49] EMERŠIČ, Žiga, Vitomir ŠTRUC a Peter PEER. Ear recognition: More than a survey. *Neurocomputing*. 2017, **255**, s. 26-39. ISSN 09252312. DOI: 10.1016/j.neucom.2016.08.139.
- [50] *Encyclopaedia of biometrics*. New York: Springer, 2009. ISBN 978-0-387-73002-8.
- [51] FABBRI, Kristian. A Brief History of Thermal Comfort: From Effective Temperature to Adaptive Thermal Comfort. FABBRI, Kristian. *Indoor Thermal Comfort Perception*. Cham: Springer International Publishing, 2015, s. 7-23. ISBN 978-3-319-18650-4. DOI:10.1007/978-3-319-18651-1_2.
- [52] FAUNDEZ-ZANUY, Marcos, Jiri MEKYSKA a Xavier FONT-ARAGONES. A New Hand Image Database Simultaneously Acquired in Visible Near-infrared and Thermal Spectrums. *Cognitive Computation*. 2014, **6**(2), s. 230–240. ISSN 1866-9956. DOI: 10.1007/s12559-013-9230-3.
- [53] FAUNDEZ-ZANUY, Marcos. Biometric verification of humans by means of hand geometry. In: *Proceedings 39th Annual 2005 International Carnahan Conference on Security Technology*. IEEE, 2005, s. 61-67. ISBN 0-7803-9245-0. DOI: 10.1109/CCST.2005.1594816.
- [54] FERRER, Miguel A., Aythami MORALES, Carlos M. TRAVIESO a Jesus B. ALONSO. Influence of the pegs number and distribution on a biometric device based on hand geometry. In: *2008 42nd Annual IEEE International Carnahan Conference on Security Technology*. IEEE, 2008, s. 221-225. ISBN 978-1-4244-1816-9. DOI: 10.1109/CCST.2008.4751305.
- [55] FERRER, Miguel A., Aythami MORALES, Carlos M. TRAVIESO a Jesus B. ALONSO. Low-Cost Multimodal Biometric Identification System Based on Hand Geometry, Palm and Fingerprint Texture. In: *2007 41st Annual IEEE International Carnahan Conference on Security Technology*. IEEE, 2007, s. 52-58. ISBN 978-1-4244-1129-0. DOI: 10.1109/CCST.2007.4373467.
- [56] FERRER, Miguel A., Joan FABREGAS, Marcos FAUNDEZ, Jesus B. ALONSO a Carlos TRAVIESO. Hand geometry identification system performance. In: *43rd Annual 2009 International Carnahan Conference on Security Technology*. IEEE, 2009, s. 167-171. ISBN 978-1-4244-4169-3. DOI: 10.1109/CCST.2009.5335545.

- [57] FERRER, Miguel, Carlos TRAVIESO a Jesus ALONSO. Multimodal Biometric System based on Hand Geometry and Palm Print Texture. In: *Proceedings 40th Annual 2006 International Carnahan Conference on Security Technology*. IEEE, 2006, s. 92-97. ISBN 1-4244-0174-7. DOI: 10.1109/CCST.2006.313435.
- [58] FONT-ARAGONES, Xavier, Marcos FAUNDEZ-ZANUY a Jiri MEKYSKA. Thermal hand image segmentation for biometric recognition, *IEEE Aerospace and Electronic Systems Magazine*. IEEE, 2013, **28**(6), s. 4-14. DOI: 10.1109/CCST.2011.6095877.
- [59] FOTAK, Tomislav, Petra KORUGA a Miroslav BACA. Trends in Hand Geometry Biometrics. In: *Central European Conference on Information and Intelligent Systems*. Varazdin: Faculty of Organization and Informatics Varazdin, 2012, s. 319-324.
- [60] FOUQUIER, Geoffroy, Laurence LIKFORMAN, Jerome DARBON a Bulent SANKUR. The Biosecure Geometry-Based System for Hand Modality. In: *2007 IEEE International Conference on Acoustics, Speech and Signal Processing - ICASSP '07*. IEEE, 2007, ISBN 1-4244-0727-3. DOI: 10.1109/ICASSP.2007.366029.
- [61] FREUND, Yoav, a Robert E. SCHAPIRE. Experiments with a new boosting algorithm, *Proceedings of the Thirteenth International Conference on Machine Learning*, s. 325-332, 1996.
- [62] FRUMKIN, Dan, Adam WASSERSTROM, Ariane DAVIDSON a Arnon GRAFIT. Authentication of forensic DNA samples. *Forensic Science International: Genetics*. 2010, **4**(2), s. 95-103. ISSN 18724973. DOI: 10.1016/j.fsigen.2009.06.009.
- [63] FUERTES, Juan Jose, Carlos M. TRAVIESO, Miguel A. FERRER a Jesus B. ALONSO. Intra-modal biometric system using hand-geometry and palmprint texture. In: *44th Annual 2010 IEEE International Carnahan Conference on Security Technology*. IEEE, 2010, s. 318-322. ISBN 978-1-4244-7403-5. DOI: 10.1109/CCST.2010.5678697.
- [64] GHIMIRE, Deepak a Joonwhoan LEE. Extreme learning machine ensemble using bagging for facial expression recognition. *Journal of Information Processing Systems*. 2014, **10**(3), s. 443-458. ISSN 1976-913X. DOI: 10.3745/JIPS.02.0004.
- [65] GOLFARELLI, Matteo, Dario MAIO a D. MALTON. On the error-reject trade-off in biometric verification systems. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1997, **19**(7), s. 786-796. ISSN 01628828. DOI: 10.1109/34.598237.

- [66] GONZEILEZ, Santiago, Carlos M. TRAVIESO, Jesus B. ALONSO a Miguel A. FERRER. Automatic biometric identification system by hand geometry. In: *IEEE 37th Annual 2003 International Carnahan Conference on Security Technology, 2003. Proceedings.* IEEE, 2003, s. 281-284. ISBN 0-7803-7882-2. DOI: 10.1109/CCST.2003.1297573.
- [67] GROSS, Ralph, Yiheng LI, Latanya SWEENEY, Xiaoqian JIANG, Wanhong XU a Daniel YUROVSKY. Robust Hand Geometry Measurements for Person Identification using Active Appearance Models. In: *2007 First IEEE International Conference on Biometrics: Theory, Applications, and Systems.* IEEE, 2007, s. 1-6. ISBN 978-1-4244-1596-0. DOI: 10.1109/BTAS.2007.4401936.
- [68] GUO, Jing-Ming, Chih-Hsien HSIA, Yun-Fu LIU, Jie-Cyun YU, Mei-Hui CHU a Thanh-Nam LE. Contact-free hand geometry-based identification system. *Expert Systems with Applications.* 2012, **39**(14), s. 11728-11736. ISSN 09574174. DOI: 10.1016/j.eswa.2012.04.081.
- [69] GUO, Xinyu. A KNN Classifier for Face Recognition. In: *2021 International Conference on Communications, Information System and Computer Engineering (CISCE).* IEEE, 2021, 2021-5-14, s. 292-297. ISBN 978-1-6654-0352-8. DOI: 10.1109/CISCE52179.2021.9445908.
- [70] GUPTA, Puneet, Saurabh SRIVASTAVA a Phalguni GUPTA. An accurate infrared hand geometry and vein pattern-based authentication system. *Knowledge-Based Systems.* 2016, **103**, s. 143-155. ISSN 09507051. DOI: 10.1016/j.knosys.2016.04.008.
- [71] GUZMAN, Ana. M., Mohammed GORYAWALA, Jin WANG, Armando BARRETO, Jean ANDRIAN, Naphtali RISHE a Malek ADJOUADI. Thermal Imaging as a Biometrics Approach to Facial Signature Authentication. *IEEE Journal of Biomedical and Health Informatics.* IEEE, 2013, **17**(1), s. 214-222. ISSN 2168-2194. DOI: 10.1109/TITB.2012.2207729.
- [72] HAFEMANN, Luiz G., Robert SABOURIN a Luiz S. OLIVEIRA. Writer-independent feature learning for Offline Signature Verification using Deep Convolutional Neural Networks. In: *2016 International Joint Conference on Neural Networks (IJCNN).* IEEE, 2016, s. 2576-2583. ISBN 978-1-5090-0620-5. DOI: 10.1109/IJCNN.2016.7727521.

- [73] HAFS, Toufik, Layachi BENNACER, Mohamed BOUGHAZI a Amine NAIT-ALI. Empirical mode decomposition for online handwritten signature verification. *IET Biometrics*. 2016, **5**(3), s. 190-199. ISSN 2047-4938. DOI: 10.1049/iet-bmt.2014.0041.
- [74] *Hand-based biometrics: methods and technology*. Editor Martin DRAHANSKÝ. London: The Institution of Engineering and Technology, 2018. IET book series in advanced biometrics. ISBN 978-1-78561-224-4.
- [75] HILL, H. Information and viewpoint dependence in face recognition. *Cognition*. 1997, **62**(2), 201-222. ISSN 00100277. DOI:10.1016/S0010-0277(96)00785-8.
- [76] HO, Tin Kam. Nearest neighbors in random subspaces. AMIN, Adnan, Dov DORI, Pavel PUDIL a Herbert FREEMAN, ed. *Advances in Pattern Recognition*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1998, 1998-6-9, s. 640-648. Lecture Notes in Computer Science. ISBN 978-3-540-64858-1. DOI: 10.1007/BFb0033288.
- [77] HU, Rong-Xiang, Wei JIA, David ZHANG, Jie GUI a Liang-Tu SONG. Hand shape recognition based on coherent distance shape contexts. *Pattern Recognition*. 2012, **45**(9), 3348-3359. ISSN 00313203. DOI: 10.1016/j.patcog.2012.02.018.
- [78] HUB, Miloslav. *Bezpečnost a ochrana informací v prostředí internetu*. Pardubice: Univerzita Pardubice, 2013. ISBN 978-80-7395-701-8.
- [79] Immigration and naturalization service passenger accelerated service system pilot program. *Office of the Inspector General* [online]. Washington, D.C.
- [80] Introducing Deep Learning with MATLAB In: The MathWorks, [online]. 2016. [cit. 2022-02-03]. Dostupné z: https://www.mathworks.com/translate/goog/campaigns/offers/next/deep-learning-ebook.html?_x_tr_sl=en&_x_tr_tl=cs-CZ&_x_tr_hl=cs
- [81] ISLAM, Md Saiful a Naif ALAJLAN. Biometric template extraction from a heartbeat signal captured from fingers. *Multimedia Tools and Applications*. 2017, **76**(10), s. 12709-12733. ISSN 1380-7501. DOI: 10.1007/s11042-016-3694-6.
- [82] ISO/IEC 19795-1. *Information technology: Biometric performance testing and reporting*. 2016.

- [83] IULA, Antonio, Gabriel HINE, Alessandro RAMALLI a Francesco GUIDI. An Improved Ultrasound System for Biometric Recognition Based on Hand Geometry and Palmprint. *Procedia Engineering*. 2014, **87**, s. 1338-1341. ISSN 18777058. DOI: 10.1016/j.proeng.2014.11.709.
- [84] JAIN, A.K., A. ROSS a S. PRABHAKAR. An Introduction to Biometric Recognition. *IEEE Transactions on Circuits and Systems for Video Technology*. 2004, **14**(1), s. 4-20. ISSN 1051-8215. DOI: 10.1109/TCSVT.2003.818349.
- [85] JAIN, Anil K. a Nicolae DUTA. Deformable matching of hand shapes for user verification. In: *Proceedings 1999 International Conference on Image Processing (Cat. 99CH36348)*. IEEE, 1999, s. 857-861. ISBN 0-7803-5467-2. DOI: 10.1109/ICIP.1999.823019.
- [86] JAIN, Anil K., Arun ROSS a Sharath PANKANTI. A prototype hand geometry-based verification system, In: *Proc. Second Int. Conf. Audio and Video based Personal Authentication*, Washington: 1999, s. 166-171. Dostupné z: https://www.cse.msu.edu/~rossarun/pubs/RossHand_AVBPA99.pdf
- [87] JAIN, Anil K., Jianjiang FENG a Karthik NANDAKUMAR. Fingerprint Matching. *Computer*. 2010, **43**(2), s. 36-44. ISSN 0018-9162.
- [88] JAIN, Anil K., Patrick FLYNN a Arun A. ROSS. *Handbook of biometrics*. New York: Springer, c2008. ISBN 978-038-7710-419.
- [89] JIANG, Xiaoqian, Wanhong XU, Latanya SWEENEY, Yiheng LI, Ralph GROSS a Daniel YUROVSKY. New Directions in Contact Free Hand Recognition. In: *2007 IEEE International Conference on Image Processing*. IEEE, 2007, II - 389-II - 392. ISBN 978-1-4244-1436-9. DOI: 10.1109/ICIP.2007.4379174.
- [90] JU, Zhiyong a Yongjie XUE. Fish species recognition using an improved AlexNet model. *Optik*. 2020, **223**. ISSN 00304026. DOI: 10.1016/j.ijleo.2020.165499.
- [91] KADLEC, Karel. Teoretické základy bezdotykového měření teploty (část 1). *Automa: časopis pro automatizační techniku*. Ústí nad Labem: FCC Folprecht, 2014, **20**(2). ISSN 1210-9592.

- [92] KANHANGAD, Vivek, Ajay KUMAR a David ZHANG. Combining 2D and 3D hand geometry features for biometric verification. In: *2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*. IEEE, 2009, s. 39-44. ISBN 978-1-4244-3994-2. DOI: 10.1109/CVPRW.2009.5204306.
- [93] KANHANGAD, Vivek, Ajay KUMAR a David ZHANG. Human hand identification with 3D hand pose variations. In: *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition - Workshops*. IEEE, 2010, s. 17-21. ISBN 978-1-4244-7029-7. DOI: 10.1109/CVPRW.2010.5543236.
- [94] KEARNS, Michael a Leslie G. VALIANT. Cryptographic limitations on learning Boolean formulae and finite automata. In: *Proceedings of the twenty-first annual ACM symposium on Theory of computing - STOC '89*. New York, USA: ACM Press, 1989, s. 433-444. ISBN 0897913078. DOI:10.1145/73007.73049.
- [95] KHADAR NAWAS, K, Manish KUMAR BARIK, A. NAYEEMULLA KHAN, J. KANNAN R., P. KOMMERS a. QUADIR MD. Speaker Recognition using Random Forest. *ITM Web of Conferences*. 2021, **37**. ISSN 2271-2097. DOI: 10.1051/itmconf/20213701022.
- [96] KIM, Min-jae, Whoi-Yul KIM a Joonki PAIK. Optimum Geometric Transformation and Bipartite Graph-Based Approach to Sweat Pore Matching for Biometric Identification. *Symmetry*. 2018, **10**(5), s. 175. ISSN 2073-8994. DOI: 10.3390/sym10050175.
- [97] KIRTHIKA, A. a S. ARUMUGAM. Texture and color intensive biometric multimodal security using hand geometry and palm print. *International Journal of Advances in Engineering & Technology*. 2012, **4**(1), s. 226-235. ISSN 2231-1963. Dostupné z: <http://ezproxy.techlib.cz/login?url=https://search-proquest-com.ezproxy.techlib.cz/docview/1152018896?accountid=119841>
- [98] KONG, A.W.K., D. ZHANG a M.S. KAMEL. An Analysis of IrisCode. *IEEE Transactions on Image Processing*. 2010, **19**(2), s. 522-532. ISSN 1057-7149. DOI: 10.1109/TIP.2009.2033427.
- [99] KONG, Seong G., Jingu HEO, Faysal BOUGHORBEL, Yue ZHENG, Bisma R. ABIDI, Andreas KOSCHAN, Mingzhong YI a Mongi A. ABIDI. Multiscale Fusion of Visible

- and Thermal IR Images for Illumination-Invariant Face Recognition. *International Journal of Computer Vision*. 2007, **71**(2), s. 215-233. ISSN 0920-5691. DOI: 10.1007/s11263-006-6655-0.
- [100] KRÁL, Jiří. Rozpoznávání výrazu obličeje. Brno, 2010. Diplomová práce. Vysoké učení technické v Brně.
- [101] KRIZHEVSKY, Alex, Ilya SUTSKEVER a Geoffrey E. HINTON. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017, **60**(6), s. 84-90. ISSN 0001-0782. DOI: 10.1145/3065386.
- [102] KUKULA, Eric P., Bryan P. GRESOCK, Stephen J ELLIOTT a Nathan W. DUNNING. Defining Habituation using Hand Geometry. In: *2007 IEEE Workshop on Automatic Identification Advanced Technologies*. IEEE, 2007, s. 242-246. ISBN 1-4244-1299-4. DOI: 10.1109/AUTOID.2007.380627.
- [103] KUMAR, Ajay a David ZHANG. Hand-Geometry Recognition Using Entropy-Based Discretization. *IEEE Transactions on Information Forensics and Security*. 2007, **2**(2), s. 181-187. ISSN 1556-6013. DOI: 10.1109/TIFS.2007.896915.
- [104] KUMAR, Ajay, David C. M. WONG, Helen C. SHEN a Anil K. JAIN. Personal Verification Using Palmprint and Hand Geometry Biometric. In: *Audio- and Video-Based Biometric Person Authentication*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003, 2003-6-24, s. 668-678. Lecture Notes in Computer Science. ISBN 978-3-540-40302-9. DOI: 10.1007/3-540-44887-X_78.
- [105] LAJEVARDI, Seyed Mehdi, Arathi ARAKALA, Stephen A. DAVIS a Kathy J. HORADAM. Retina Verification System Based on Biometric Graph Matching. *IEEE Transactions on Image Processing*. 2013, **22**(9), s. 3625-3635. ISSN 1057-7149. DOI: 10.1109/TIP.2013.2266257.
- [106] LANE, Sylvia. Submarginal Credit Risk Classification. *The Journal of Financial and Quantitative Analysis*. Cambridge University Press, 1972, **7**(1), s. 1379–1385. ISSN 00221090.
- [107] LeCUN, Yann. Generalization and network design strategies. *Connectionism in perspective*. 1989, **19**(18) s. 143-155.

- [108] LEE, Eui Chul, Hyunwoo JUNG a Daeyeoul KIM. New Finger Biometric Method Using Near Infrared Imaging. *Sensors*. 2011, **11**(3), s. 2319-2333. ISSN 1424-8220. DOI: 10.3390/s110302319.
- [109] LEE, Tian-Shyug, Chih-Chou CHIU, Chi-Jie LU, I-Fei CHEN. Credit scoring using the hybrid neural discriminant technique. *Expert Systems with Applications*. 2002, **23**(3), s. 245-254. DOI: 10.1016/S0957-4174(02)00044-1.
- [110] LEE, Tracey K. M., Mohammed BELKHATIR a Saeid SANEI. A comprehensive review of past and present vision-based techniques for gait recognition. *Multimedia Tools and Applications*. 2014, **72**(3), s. 2833-2869. ISSN 1380-7501. DOI: 10.1007/s11042-013-1574-x.
- [111] LEI, Yun, Nicolas SCHEFFER, Luciana FERRER a Mitchell MCLAREN. A novel scheme for speaker recognition using a phonetically aware deep neural network. In: *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2014, s. 1695-1699. ISBN 978-1-4799-2893-4. DOI: 10.1109/ICASSP.2014.6853887.
- [112] LENG, Lu, Fumeng GAO, Qi CHEN a Cheonshik KIM. Palmprint recognition system on mobile devices with double-line-single-point assistance. *Personal and Ubiquitous Computing* [online]. 2018, **22**(1), s. 93-104. ISSN 1617-4909. DOI: 10.1007/s00779-017-1105-2.
- [113] LI, Zhenbo, Fei LI, Ling ZHU a Jun YUE. Vegetable Recognition and Classification Based on Improved VGG Deep Learning Network Model. *International Journal of Computational Intelligence Systems*. 2020, **13**(1). ISSN 1875-6883. DOI: 10.2991/ijcis.d.200425.001.
- [114] LINDSTROM, Bruce. Hand Geometry a Biometric Technology with a Pedigree. *BiometriTech June 2003 Bruce Lindstrom, Regional Sales Manager 2003*. Dostupné z: <https://slideplayer.com/slide/5032579/>
- [115] LIU, Nianfeng, Man ZHANG, Haiqing LI, Zhenan SUN a Tieniu TAN. DeepIris: Learning pairwise filter bank for heterogeneous iris verification. *Pattern Recognition Letters*. 2016, **82**, s. 154-161. ISSN 01678655. DOI: 10.1016/j.patrec.2015.09.016.

- [116] LIU, Yang a Ajay KUMAR. Contactless Palmprint Identification Using Deeply Learned Residual Features. *IEEE Transactions on Biometrics, Behavior, and Identity Science*. 2020, **2**(2), s. 172-181. ISSN 2637-6407. DOI: 10.1109/TBIOM.2020.2967073.
- [117] LOTH S. R., M. Y. ISCAN, *Sex Determination Encyclopedia of Forensic Sciences*, San Diego, CA, USA: Academic, 2000, **1**.
- [118] LU Jiwen, Gang WANG a Tomas S. HUANG, Gait-based gender classification in unconstrained environments, *Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012)*, 2012, s. 3284-3287. Dostupné z: <https://ieeexplore.ieee.org/document/6460866>.
- [119] MAKINEN, Erno a Roope RAISAMO. Evaluation of Gender Classification Methods with Automatically Detected and Aligned Faces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2008, **30**(3), s. 541-547. ISSN 0162-8828. DOI: 10.1109/TPAMI.2007.70800.
- [120] MANE, Vijay Mahadeo a D.V. JADHAV. Holoentropy enabled-decision tree for automatic classification of diabetic retinopathy using retinal fundus images. *Biomedical Engineering / Biomedizinische Technik*. 2017, **62**(3). ISSN 1862-278X. DOI: 10.1515/bmt-2016-0112.
- [121] MATKOWSKI, Wojciech Michal a Adams Wai KIN KONG. Gender and Ethnicity Classification based on Palmprint and Palmar Hand Images from Uncontrolled Environment. In: *2020 IEEE International Joint Conference on Biometrics (IJCB)*. IEEE, 2020, s. 1-7. ISBN 978-1-7281-9186-7. DOI: 10.1109/IJCB48548.2020.9304907.
- [122] MILLER, Benjamin. Vital signs of identity [biometrics]. *IEEE Spectrum*. 1994, **31**(2), s. 22-30. ISSN 0018-9235. DOI: 10.1109/6.259484.
- [123] MILLER, Robert. *Finger dimension comparison identification system*. USA. US3576538 (A). Zapsáno 27.4.1971.
- [124] MITCHELL, Tom M. *Machine learning*. Boston: McGraw-Hill, c1997. ISBN 00-704-2807-7.

- [125] MONTALVÃO, Jugurta, Lucas MOLINA a Jânio CANUTO. Robust hand image processing for biometric application. *Pattern Analysis and Applications*. 2010, **13**(4), s. 397-407. ISSN 1433-7541. DOI: 10.1007/s10044-010-0185-7.
- [126] MORALES, Anythami, Miguel A. FERRER, Jesus B. ALONSO a Carlos M. TRAVIESO. Comparing infrared and visible illumination for contactless hand based biometric scheme. In: *2008 42nd Annual IEEE International Carnahan Conference on Security Technology*. IEEE, 2008, 2008, s. 191-197. ISBN 978-1-4244-1816-9. DOI: 10.1109/CCST.2008.4751301.
- [127] NANEHKARAN, Y. A., Junde CHEN, Soheil SALIMI, Defu ZHANG, A pragmatic convolutional bagging ensemble learning for recognition of Farsi handwritten digits. *The Journal of Supercomputing*. 2021, **77**(11), s. 13474-13493. ISSN 0920-8542. DOI: 10.1007/s11227-021-03822-4.
- [128] NEDJAH, Nadia, Rafael Soares WYANT a Luiza DE MACEDO MOURELLE. Efficient biometric palm-print matching on smart-cards for high security and privacy. *Multimedia Tools and Applications*. 2017, **76**(21), s. 22671-22701. ISSN 1380-7501. DOI: 10.1007/s11042-016-4271-8.
- [129] NGUYEN, Dat a Kang PARK. Body-Based Gender Recognition Using Images from Visible and Thermal Cameras. *Sensors*. 2016, **16**(2). ISSN 1424-8220. DOI: 10.3390/s16020156.
- [130] NGUYEN, Dat, Tuyen PHAM, Young LEE a Kang PARK. Deep Learning-Based Enhanced Presentation Attack Detection for Iris Recognition by Combining Features from Local and Global Regions Based on NIR Camera Sensor. *Sensors*. 2018, **18**(8). ISSN 1424-8220. DOI: 10.3390/s18082601.
- [131] ODEN, Cenker, Aytul ERCIL a Burak BUKE. Combining implicit polynomials and geometric features for hand recognition. *Pattern Recognition Letters*. 2003, **24**(13), s. 2145-2152. ISSN 01678655. DOI: 10.1016/S0167-8655(03)00087-4.
- [132] OLADELE, Tinuke O., Kehinde ADENIYI a Taye O. ARO. Framework for User Authentication at a Distance for Mobile Phones Using Contactless Hand-based Multimodal Biometric System. *Journal of Computer Science and Control Systems*. ProQuest Central, 2019, **12**(1), s. 24-27. ISSN 1844-6043.

- [133] OLEJ, Vladimír a Petr HÁJEK. *Úvod do umělé inteligence: moderní přístupy: distanční opora*. Pardubice: Univerzita Pardubice, 2010, ISBN 978-80-7395-307-2.
- [134] OMOTOSHO, Lawrence O., Ibrahim K. OGUNDOYIN, Joshua O. OYENIYI a Oluwashina A. OYENIRAN. A Real Time Face Recognition System Using AlexNet Deep Convolutional Network Transfer Learning Model. *Journal of Engineering Studies and Research*. 2021, 27(2), ISSN 2068-7559.
- [135] PARIHAR, Aradhana Singh a Shweta AGRAWAL. Facial Expression Detection and Recognition using VGG- 16. *International Journal of Computer Applications*. 2021, **183**(41), s. 9-16. ISSN 0975-8887.
- [136] PARK, GiTae a Soowon KIM. Hand Biometric Recognition Based on Fused Hand Geometry and Vascular Patterns. *Sensors*. 2013, **13**(3), s. 2895-2910. ISSN 1424-8220. DOI: 10.3390/s130302895.
- [137] PHINYOMARK, Angkoon, Huosheng HU a Pornchai PHUKPATTARANONT. Application of linear discriminant analysis in dimensionality reduction for hand motion classification. *Measurement Science Review*, 2012, **12**(3) s. 82-89. ISSN 1335-8871. DOI: 10.2478/v10048-012-0015-8.
- [138] POLAT, O. a T. YILDIRIM. Hand geometry identification without feature extraction by general regression neural network. *Expert Systems with Applications*. 2008, **34**(2), s. 845-849. ISSN 09574174. DOI: 10.1016/j.eswa.2006.10.032.
- [139] PRATT, L. Y. Discriminability-Based Transfer between Neural Networks. *Advances in Neural Information Processing Systems 5 (NIPS 1992)*. 1992, s. 204-211. Dostupné z: <https://proceedings.neurips.cc/paper/1992/file/67e103b0761e60683e83c559be18d40c-Paper.pdf>
- [140] PŘÍHODOVÁ, Kateřina a Jakub JECH. Gender recognition using thermal images from UAV. In: *2021 International Conference on Information and Digital Technologies (IDT)*. IEEE, 2021, s. 83-88. ISBN 978-1-6654-3692-2. DOI: 10.1109/IDT52577.2021.9497627.
- [141] PŘÍHODOVÁ, Kateřina a Miloslav HUB. Biometric Privacy through Hand Geometry-A Survey. In: *2019 International Conference on Information and Digital Technologies (IDT)*. IEEE, 2019, s. 395-401. ISBN 978-1-7281-1401-9. DOI: 10.1109/DT.2019.8813660.

- [142] PŘÍHODOVÁ, Kateřina a Miloslav HUB. Hand-Based Biometric System Using Convolutional Neural Networks. *Acta Informatica Pragensia*, Praha: 2020, **9**(1), s. 48-57. DOI: 10.18267/j.aip.131.
- [143] PŘÍHODOVÁ, Kateřina. Convolutional neural networks in hand-based recognition system. In: *34th International Business Information Management Association Conference*. 2019, s. 4744-4750. ISBN 978-0-9998551-3-3.
- [144] RAIMI, Karim. Difference between AlexNet, VGGNet, ResNet, and Inception. *Towards Data Science* [online]. 2019 [cit. 2022-01-02]. Dostupné z: <https://towardsdatascience.com/illustrated-10-cnn-architectures-95d78ace614d#e971>
- [145] RAK, Roman, Václav MATYÁŠ a Zdeněk ŘÍHA. *Biometrie a identita člověka: ve forenzních a komerčních aplikacích* [online]. 1. elektronické vydání. Praha: Grada, 2008, ISBN 8024723654.
- [146] RAMAIAH, N. Pattabhi, Earnest Paul IJJINA a C. Krishna MOHAN. Illumination invariant face recognition using convolutional neural networks. In: *2015 IEEE International Conference on Signal Processing, Informatics, Communication and Energy Systems (SPICES)*. IEEE, 2015, s. 1-4. ISBN 978-1-4799-1823-2. DOI: 10.1109/SPICES.2015.7091490
- [147] ROSS, A., A. JAIN a J. REISMAN. A hybrid fingerprint matcher. In: *Object recognition supported by user interaction for service robots*. IEEE Comput. Soc, 2002, s. 795-798. ISBN 0-7695-1695-X. DOI:10.1109/ICPR.2002.1048138.
- [148] ROSS, Arun a Anil JAIN. Information fusion in biometrics. *Pattern Recognition Letters*. 2003, **24**(13), s. 2115-2125. ISSN 01678655. DOI: 10.1016/S0167-8655(03)00079-5.
- [149] ROSS, Arun. An introduction to multibiometrics. *2007 15th European Signal Processing Conference*. IEEE, 2007, s. 20-24. ISBN 8392134044. Dostupné z: <https://ieeexplore.ieee.org/document/7098756>
- [150] SANCHEZ-REILLO, R. Hand geometry pattern recognition through Gaussian mixture modelling. In: *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*. IEEE Comput. Soc, 2000, s. 937-940. ISBN 0-7695-0750-6. DOI: 10.1109/ICPR.2000.906228.

- [151] SANCHEZ-REILLO, Raul, Carmen SANCHEZ-AVILA a Anna GONZALEZ-MARCOS. Biometric identification through hand geometry measurements. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2000, **22**(10), s. 1168-1171. ISSN 01628828. DOI: 10.1109/34.879796.
- [152] SCHEIDAT, Tobias, Michael KALBITZ a Claus VIELHAUER. Biometric authentication based on 2D/3D sensing of forensic handwriting traces. *IET Biometrics*. 2017, **6**(4), s. 316-324. ISSN 2047-4938. DOI: 10.1049/iet-bmt.2016.0127.
- [153] ŠČUREK, Radomír. Biometrické metody identifikace osob v bezpečnostní praxi [online]. Praha, 2008 [cit. 2021-05-25]. Dostupné z: https://rucnepsanypodpis.cz/PDF/biometricke_metody.pdf
- [154] SEAL, Ayan, Debotosh BHATTACHARJEE a Mita NASIPURI. Human face recognition using random forest based fusion of à-trous wavelet transform coefficients from thermal and visible images. *AEU - International Journal of Electronics and Communications*. 2016, **70**(8), s. 1041-1049. ISSN 14348411. DOI: 10.1016/j.aeue.2016.04.016.
- [155] SHARMA, Shefali, Shiv Ram DUBEY, Satish Kumar SINGH, Rajiv SAXENA a Rajat Kumar SINGH. Identity verification using shape and geometry of human hands. *Expert Systems with Applications*. Elsevier, 2015, **42**(2), s. 821-832. ISSN 09574174. DOI: 10.1016/j.eswa.2014.08.052.
- [156] SHI, Xiaofeng a Roberto MANDUCHI, A Study on Bayes Feature Fusion for Image Classification, In: *2003 Conference on Computer Vision and Pattern Recognition Workshop*, 2003, s. 95-95, DOI: 10.1109/CVPRW.2003.10090.
- [157] SIDLAUSKAS, David. *3D hand profile identification apparatus*. 1988. USA. US4736203A. Zapsáno 5.4.1988.
- [158] SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [159] SINGH, Richa, Mayank VATSA, Arun ROSS a Afzel NOORE. Performance enhancement of 2D face recognition via mosaicing. In: *Fourth IEEE Workshop on Automatic Identification Advanced Technologies (AutoID'05)* IEEE, 2005, s. 63-68. ISBN 9780769524757. DOI: 10.1109/AUTOID.2005.39.

- [160] SKURICHINA, Marina a Robert P. W. DUIN. Bagging, Boosting and the Random Subspace Method for Linear Classifiers. *Pattern Analysis & Applications*. 2002, **5**(2), 121-135. ISSN 1433-7541. DOI: 10.1007/s100440200011.
- [161] SMRŽ, Martin. *Bezkontaktní měření teploty*. Brno, 2013. Bakalářská práce. Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií.
- [162] SOLEYMANI, Sobhan, Ali DABOUEI, Hadi KAZEMI, Jeremy DAWSON a Nasser M. NASRABADI. Multi-Level Feature Abstraction from Convolutional Neural Networks for Multimodal Biometric Identification. In: *2018 24th International Conference on Pattern Recognition (ICPR)*. IEEE, 2018, 2018, s. 3469-3476. ISBN 978-1-5386-3788-3. DOI:10.1109/ICPR.2018.8545061.
- [163] ŠPANĚL, Michal a Vítězslav BERAN. *Obrazové segmentační techniky: Přehled existujících metod*. Brno, 2006. Vysoké učení technické v Brně.
- [164] SU, Hong-Ren, Kuang-Yu CHEN, Wei Jing WONG a Shang-Hong LAI. A deep learning approach towards pore extraction for high-resolution fingerprint recognition. In: *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2017, s. 2057-2061. ISBN 978-1-5090-4117-6. DOI: 10.1109/ICASSP.2017.7952518.
- [165] SUPREETHA GOWDA, H. D., G. HEMANTHA KUMAR a Mohammad IMRAN. Multi-modal biometric system on various levels of fusion using LPQ features. *Journal of Information and Optimization Sciences*. 2017, **39**(1), s. 169-181. ISSN 0252-2667. DOI: 10.1080/02522667.2017.1372918.
- [166] SZEGEDY, Christian, WEI LIU, YANGQING JIA, et al. Going deeper with convolutions. In: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2015, s. 1-9. ISBN 978-1-4673-6964-0. DOI: 10.1109/CVPR.2015.7298594.
- [167] Tabulka emisivit. *Termokamera.cz* [online]. [cit. 2020-01-02]. Dostupné z: <http://www.termokamera.cz/tabulka-emisivit/>
- [168] TAPIA, Juan E., Claudio A. PEREZ a Kevin W. BOWYER. Gender Classification from the Same Iris Code Used for Recognition. *IEEE Transactions on Information Forensics*

and Security. 2016, **11**(8), s. 1760-1770. ISSN 1556-6013.
DOI: 10.1109/TIFS.2016.2550418.

- [169] *Technology assessment*. Edition ed. Washington, D.C. (P.O. Box 37050, Washington 20013): U.S. General Accounting Office, 2002.
- [170] TORO, Óscar Fernando Motato a Humberto Loaiza CORREA. Biometric identification using infrared dorsum hand vein images. *Ingeniería e Investigación*. 2009, **29**(1), s. 90-100. ISSN 0120-5609. DOI: 10.15446/ing.investig.
- [171] TOVÁREK, Jaromír. *Využití umělé inteligence pro vícenásobnou bezkontaktní biometrickou autentizaci*. Ostrava, 2017. Disertační práce. Vysoká škola báňská – Technická univerzita Ostrava.
- [172] Transfer Learning. In: The MathWorks, [online]. 2016. [cit. 2022-02-03]. Dostupné z: <https://www.mathworks.com/discovery/transfer-learning.html>.
- [173] TREMBLAY, G., R. SABOURIN a P. MAUPIN. Optimizing nearest neighbour in random subspaces using a multi-objective genetic algorithm. In: *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004*. IEEE, 2004, s. 208-211, **1**. ISBN 0-7695-2128-2. DOI: 10.1109/ICPR.2004.1334060.
- [174] UNAR, J.A., Woo Chaw SENG a Almas ABBASI. A review of biometric technology along with trends and prospects. *Pattern Recognition*. 2014, **47**(8), s. 2673-2688. ISSN 00313203. DOI: 10.1016/j.patcog.2014.01.016.
- [175] UNGUREANU, Adrian-Stefan, Saqib SALAHUDDIN a Peter CORNARAN. Towards unconstrained palmprint recognition on consumer devices: A literature review. *IEEE Access*. 2020, **8**, s. 86130-86148. ISSN 2169-3536. DOI: 10.1109/ACCESS.2020.2992219.
- [176] UNIVERSITY HONG KONG POLYTECHNIC. *Method and system for identifying a person using their finger-joint print*. US20090354537 20090115. Uděleno 3.10.2012. Dostupné z: <https://worldwide.espacenet.com/publicationDetails/biblio?FT=D&date=20121003&DB=EPODOC&CC=CN&NR=101794374B>
- [177] UPADHYAY, Jaychand, Tad GONSALYES, Rohan PARANJPE, Hiralal PUROHIT a Rohan JOSHI. Biometric Identification Using Gait Analysis by Deep Learning. In: *2020*

- IEEE International Conference for Innovation in Technology (INOCON)*, Bangluru, India: 2020, s. 1-4, DOI: 10.1109 / INOCON50539,2020,9298276.
- [178] *Uživatelská příručka: Řada FLIR Ex* [online]. Wilsonville (USA), 2013 [cit. 2020-03-12]. Dostupné z:
https://cw.fel.cvut.cz/b172/_media/courses/a6m31let/flir_e6_manual_cz.pdf
- [179] VAPNIK, Vladimir a CHERVONENKIS Alexey, A Note on One Class of Perceptrons, *Automation and Remote Control*. 1964, **25**.
- [180] VAPNIK, Vladimir a Corinna CORTEZ, Support-Vector Networks, *Machine Learning*. 1995, **20**(3), s. 273–297.
- [181] VARCHOL, Peter a Dusan LEVICKY. Using of hand geometry in biometric security systems. *Radioengineering*. 2007, **16**(4), s. 82-87. ISSN 1210-2512. Dostupné z:
<https://doaj.org/article/fc331c103a994f1589fda70c4b189a11>
- [182] VELDHUIS, Raymond N., Anil K. JAIN, Nalini K. RATHA, Asker M. BAZEN, Wim D. BOOIJ a Anne J. HENDRIKSE. Hand-geometry recognition based on contour parameters. In: *Proceedings Volume 5779, Biometric Technology for Human Identification II*. 2005. s. 344. DOI: 10.1117/12.602683.
- [183] VERFARA VILLEGAS, Osslán Osiris, Humberto de Jesús OCHOA DOMINGUEZ, Vianey Guadalupe CRUEZ SANCHEZ, Leticia ORTEGA a Hiram MADERO. Biometric Human Identification of Hand Geometry Features Using Discrete Wavelet Transform. *Discrete Wavelet Transforms - Biomedical Applications*. InTech, 2011, 09-12, 251-266. ISBN 978- 953-307-654-6. DOI: 10.5772/19508.
- [184] VINODKUMAR a R. SRIKANTASWAMY. Fusion of fingerprint, palmprint and hand geometry for an efficient multimodal person authentication system. In: *2016 2nd International Conference on Applied and Theoretical Computing and Communication Technology (iCATccT)*. IEEE, 2016, 2016, s. 565-570. ISBN 978-1-5090-2399-8. DOI: 10.1109/ICATCCCT.2016.7912064.
- [185] Voice biometrics growth likely. *Biometric Technology Today*. 2009, **17**(6), s. 3-4. ISSN 09694765. DOI: 10.1016/S0969-4765(09)70085-2.
- [186] W-TECHNIKA. Zvýšená tělesná teplota a jak ji správně měřit dotykovým teploměrem, bezdotykovým teploměrem i termokamerou. *W-TECHNIKA* [online]. 2019 [cit. 2021-02-

- 15]. Dostupné z: <https://www.termokamery-flir.cz/zvysena-telesna-teplota-a-jak-ji-spravne-merit-dotykovym-teplomerem-bezdotykovym-teplomerem-termokamerou-covid-19-koronavirus-coronavirus/>
- [187] WANG, Dong, Huchuan LU a Ming-Hsuan YANG. Kernel collaborative face recognition. *Pattern Recognition*. 2015, **48**(10), s. 3025-3037. ISSN 00313203. DOI: 10.1016/j.patcog.2015.01.012.
- [188] WANG, Shangfei, Zhen GAO, Shan HE, Menghua HE a Qiang JI. Gender recognition from visible and thermal infrared facial images. *Multimedia Tools and Applications*. 2016, **75**(14), s. 8419-8442. ISSN 1380-7501. DOI: 10.1007/s11042-015-2756-5.
- [189] WANG, Wei-Chang, Wen-Shiung CHEN a Sheng-Wen SHIH. Biometric recognition by fusing palmprint and hand-geometry based on morphology. In: *2009 IEEE International Conference on Acoustics, Speech and Signal Processing*. IEEE, 2009, s. 893-896. ISBN 978-1-4244-2353-8. DOI: 10.1109/ICASSP.2009.4959728.
- [190] WANG, Yiding, Di ZHANG a Qi. Liveness detection for dorsal hand vein recognition. *Personal and Ubiquitous Computing*. 2016, **20**(3), s. 447-455. ISSN 1617-4909. DOI: 10.1007/s00779-016-0922-z.
- [191] WAYMAN, James. *A Definition of "Biometrics". Collected works 1997-2000*. U.S. National Biometric Test Center. San José State University. August 2003. s. 20-23.
- [192] What is MSX? Teledyne FLIR LLC [online]. 2019 [cit. 2021-09-20]. Dostupné z: <https://www.flir.com/discover/professional-tools/what-is-msx/>
- [193] WOODARD, Damon L. a Patrick J. FLYNN. Finger surface as a biometric identifier. *Computer Vision and Image Understanding*. Elsevier, 2005, **100**(3), s. 357-384. ISSN 10773142. DOI: 10.1016/j.cviu.2005.06.003.
- [194] WU, Fei, Xiao-Yuan JING, Xiwei DONG, Ruimin HU, Dong Yue, Lina Wang, Yi-Mu JI, Ruchuan WANG, Guoliang CHEN, Intraspectrum Discrimination and Interspectrum Correlation Analysis Deep Network for Multispectral Face Recognition. *IEEE Transactions on Cybernetics*. 2020, **50**(3), s. 1009-1022. ISSN 2168-2267. DOI: 10.1109/TCYB.2018.2876591.

- [195] XU, Jing, Tszhang GUO, Yong XU, Zenglin XU a Kun BAI. MultiFace: A generic training mechanism for boosting face recognition performance. *Neurocomputing*. 2021, **448**, s. 40-47. ISSN 09252312. DOI: 10.1016/j.neucom.2021.03.043.
- [196] XU, Shuang, Min LI, Ji Feng DING a Yan Qiu CUI. Personal Identification by Fusing Hand Shape Geometry and Palmprint Features. *Applied Mechanics and Materials*. 2013, **278-280**, s. 1228-1231. ISSN 1662-7482. DOI: 10.4028/www.scientific.net/AMM.278-280.1228.
- [197] YANG, Chun-Chieh, Shiv O PRASHER, Peter ENRIGHT, Chandra MADRAMOOTOO, Magdalena BURGESS, Pradeep K GOEL, Ian CALLUM. Application of decision tree technology for image classification using remote sensing data, *Agricultural Systems*. 2003, **76**(3), s. 1101-1117, ISSN 0308-521X. DOI: 10.1016/S0308-521X(02)00051-3.
- [198] YANG, Fan a Baofeng MA. A New Mixed-Mode Biometrics Information Fusion Based-on Fingerprint, Hand-geometry and Palm-print. In: *Fourth International Conference on Image and Graphics (ICIG 2007)*. IEEE, 2007, 2007, s. 689-693. ISBN 978-0-7695-2929-5. DOI: 10.1109/ICIG.2007.39.
- [199] YÖRÜK, Erdem, Ender KONUKOGLU, Bülent SANKUR a Jérôme DARBON. Shape-based hand recognition. In: *IEEE Transactions on Image Processing*. IEEE, 2006, **15**(7), s. 1803-1815. ISSN 1057-7149. DOI: 10.1109/TIP.2006.873439.
- [200] YÖRÜK, Erdem, Helin DUTAĞACI a Bülent SANKUR. Hand biometrics. *Image and Vision Computing*. 2006, **24**(5), s. 483-497. ISSN 02628856. DOI: 10.1016/j.imavis.2006.01.020.
- [201] YU, Zhigang, Yunyun DONG, Jihong CHENG, Miaomiao SUN, Feng SU a Jian SU. Research on Face Recognition Classification Based on Improved GoogleNet. *Security and Communication Networks*. 2022, s. 1-6. ISSN 1939-0122. DOI: 10.1155/2022/7192306.
- [202] YUEWEI, Yang, Yang XINWU a Zhai FEI. Multi-Class Bagging Gait Recognition Method Based on Multi-Characteristic Attribute, 2014. Patent.
- [203] ZANA, F. a KLEIN, Jean-Claude. Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation. *IEEE Transactions on Image Processing*. 2001. **10**(7), s. 1010-1019. DOI: 10.1109/83.931095.

- [204] ZHANG NAN a SHI JUN. Face recognition based on classifier combinations. In: *2011 International Conference on System science, Engineering design and Manufacturing informatization*. IEEE, 2011, 2011, s. 267-270. ISBN 978-1-4577-0246-4. DOI: 10.1109/ICSSEM.2011.6081202.
- [205] ZHANG, Man, Zhaofeng HE, Hui ZHANG, Tieniu TAN a Zhenan SUN. Toward practical remote iris recognition: A boosting based framework. *Neurocomputing*. 2019, **330**, s. 238-252. ISSN 09252312. DOI: 10.1016/j.neucom.2017.12.053.
- [206] ZHAO, Huijuan a Ping WANG. A Short Review of Age and Gender Recognition Based on Speech. In: *2019 IEEE 5th Intl Conference on Big Data Security on Cloud (BigDataSecurity), IEEE Intl Conference on High Performance and Smart Computing, (HPSC) and IEEE Intl Conference on Intelligent Data and Security (IDS)*. IEEE, 2019, s. 183-185. ISBN 978-1-7281-0006-7. DOI: 10.1109/BigDataSecurity-HPSC-IDS.2019.00042
- [207] ZHENAN, Sun, Tan, TIENIU, Wang YUNHONG a S.Z. LI. Ordinal Palmprint Representation for Personal Identification. In: *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. IEEE, 2005, s. 279-284. ISBN 0-7695-2372-2. DOI: 10.1109/CVPR.2005.
- [208] ZHONG, Dexing, Yuan YANG a Xuefeng DU. Palmprint Recognition Using Siamese Network. ZHOU, Jie, Yunhong WANG, Zhenan SUN, Zhenhong JIA, Jianjiang FENG, Shiguang SHAN, Kurban UBUL a Zhenhua GUO, ed. *Biometric Recognition*. Cham: Springer International Publishing, 2018, s. 48-55. Lecture Notes in Computer Science. ISBN 978-3-319-97908-3. DOI:10.1007/978-3-319-97909-0_6.
- [209] ZHONG, Zhuoyao, Lianwen JIN a Zecheng XIE. High performance offline handwritten Chinese character recognition using GoogLeNet and directional feature maps. In: *2015 13th International Conference on Document Analysis and Recognition (ICDAR)*. IEEE, 2015, s. 846-850. ISBN 978-1-4799-1805-8. DOI: 10.1109/ICDAR.2015.7333881.
- [210] ZHOU, Shuren, Wenlong LIANG, Junguo LI a Jeong-Uk KIM. Improved VGG Model for Road Traffic Sign Recognition. *Computers, Materials & Continua*. 2018, **57**(1), s. 11-24. ISSN 1546-2226. DOI: 10.32604/cmc.2018.02617.

- [211] ZHU, Le-qing a San-yuan ZHANG. Multimodal biometric identification system based on finger geometry, knuckle print and palm print. *Pattern Recognition Letters*. 2010, **31**(12), s. 1641-1649. ISSN 01678655. DOI: 10.1016/j.patrec.2010.05.010.
- [212] ZHU, Qi, Zheng ZHANG, Ningzhong LIU a Han SUN. Near infrared hand vein image acquisition and ROI extraction algorithm. *Optik*. 2015, **126**(24), s. 5682-5687. ISSN 00304026. DOI: 10.1016/j.ijleo.2015.09.001.

PUBLIKACE DISERTANTKY VZTAHUJÍCÍ SE K ŘEŠENÉMU TÉMATU

Časopisy SCOPUS

PŘÍHODOVÁ, Kateřina a Miloslav HUB. Hand-Based Biometric System Using Convolutional Neural Networks. *Acta Informatica Pragensia*. 2020, **9**(1), s. 48-57. Praha: University of Economics – Prague. ISSN 1805-4951. DOI: 10.18267/j.aip.131.

PŘÍHODOVÁ, Kateřina a Miloslav HUB. Hand-Based Biometric Recognition Technique – Survey. *Special Issue on Multidisciplinary Innovation in Engineering Science & Technology*. 2020, **5**(6), s. 689-698. USA: ASTES Publishers. ISSN 2415-6698. DOI: 10.25046/aj050683.

Sborníky z konferencí

PŘÍHODOVÁ, Kateřina a Jakub JECH. Gender recognition using thermal images from UAV. In: *2021 International Conference on Information and Digital Technologies (IDT)*. IEEE, 2021, s. 395-401. ISBN 978-1-7281-1401-9. DOI: 10.1109/DT.2019.8813660.

PŘÍHODOVÁ, Kateřina a Miloslav HUB. Biometric Privacy through Hand Geometry-A Survey. In: *2019 International Conference on Information and Digital Technologies (IDT)*. IEEE, 2019, s. 395-401. ISBN 978-1-7281-1401-9. DOI: 10.1109/DT.2019.8813660.

PŘÍHODOVÁ, Kateřina. Convolutional neural networks in hand-based recognition system. In: *34th International Business Information Management Association Conference*. 2019, s. 4744-4750. ISBN 978-0-9998551-3-3.

PŘÍHODOVÁ, Kateřina a Jakub JECH. Low-cost gender recognition using convolutional neural network. In: *34th International Business Information Management Association Conference*. 2019, s. 6316-6322. ISBN: 978-0-9998551-3-3.

PŘÍHODOVÁ, Kateřina. Low-cost Prevention of the Spread of Viral Diseases Using Neural Networks. In: *SHS Web of Conferences Volume 129*. EDP Sciences, 2021. s. 02015. Slovakia. DOI: 10.1051/shsconf/202112902015.

PŘÍHODOVÁ, Kateřina a Jakub JECH. Prevention of the spread of viral disease using artificial intelligence from data obtained by UAVs. In: *SHS Web of Conferences Volume 92*. EDP Sciences, 2021. s. 01042. Slovakia. DOI: 10.1051/shsconf/20219201042.

PŘÍHODOVÁ, Kateřina a Miloslav HUB. Impact of Globalization on Data Security – Authentication Issues. In: *SHS Web of Conferences Volume 92*. EDP Sciences, 2021. s. 05009. Slovakia. DOI: <https://doi.org/10.1051/shsconf/20219205009>.

PŘÍHODOVÁ, Kateřina a Miloslav HUB. The impact of global changes on using of modern technologies to ensure the state security. In: KLIESTIK, Tomáš. In: *18th International Scientific Conference on Globalization and Its Socio-Economic Consequences*. Žilina: Žilinská univerzita, 2018, s. 303-309. ISBN 978-80-8154-249-7. ISSN 2454-0943.

PŘÍHODOVÁ, Kateřina a Miloslav HUB. The impact of global social changes on the security of password authentication. In: KLIESTIK, Tomáš. In: *18th International Scientific Conference on Globalization and Its Socio-Economic Consequences*. Žilina: Žilinská univerzita, 2018, s. 2061-2066. ISBN 978-80-8154-249-7. ISSN 2454-0943.

ČERMÁKOVÁ, Ivana, Kateřina PŘÍHODOVÁ, Jitka KOMÁRKOVÁ a Miloslav HUB. Using Modern Technologies to Ensure State Security. In: *Public Administration 2018*. Pardubice: Univerzita Pardubice, 2018, s. 36-45. ISBN 978-80-7560-161-2.

KATEŘINA PŘÍHODOVÁ

Pod Vinicí 2840, Pardubice 530 02 · katerina.prihodova@upce.cz

PRACOVNÍ ZKUŠENOSTI

2017 – DNES

VÝUKA ODBORNÝCH PŘEDMĚTŮ, UNIVERZITA PARDUBICE

Výuka předmětů Manažerská informatika a Praktikum z matematiky.

2016 – 2017

SPRÁVA PODPOROVANÝCH ZDROJŮ ENERGIE, OTE A.S

VZDĚLÁNÍ

2017 – DNES

DOKTORSKÉ STUDIUM, UNIVERZITA PARDUBICE

Fakulta ekonomicko-správní

Obor: Aplikovaná informatika

2014 – 2016

INŽENÝRSKÉ STUDIUM, UNIVERZITA PARDUBICE

Fakulta ekonomicko-správní

Obor: Pojistné inženýrství, management pojistných rizik

VÝZKUMNÉ PROJEKTY

- Informační prostředí chytrých měst a regionů z hlediska konkurenceschopnosti, efektivity a bezpečnosti (interní grant UPa 2018)
- Transparentnost a konkurenceschopnost obcí a regionů v rámci rozvoje konceptu chytrých měst a regionů (interní grant UPa 2019)
- Pokročilá podpora rozvoje chytrých měst a regionů (interní grant UPa 2020)
- Zvyšování kvality informačních systémů veřejné správy (interní grant UPa 2021)
- Nástroje a postupy zvyšování kvality informačních systémů veřejné správy (interní grant UPa 2022)

STÁŽE

DUBEN – KVĚTEN 2019

UNIVERSITY OF APPLIED SCIENCES

Eisenstadt, Rakousko

PŘÍLOHY

Příloha A – Architektura AlexNet

Příloha B – Parametry jednotlivých vrstev AlexNet

Příloha C – Architektura GoogLeNet

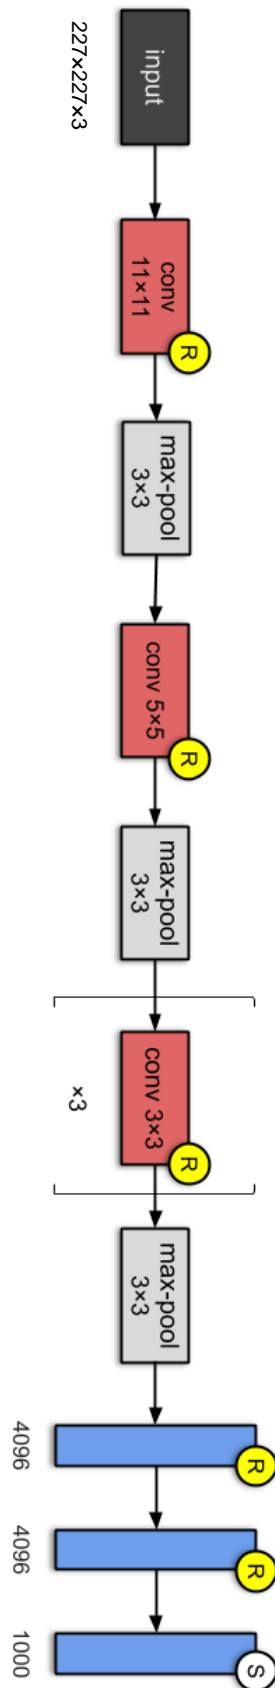
Příloha D – Parametry jednotlivých vrstev GoogLeNet

Příloha E – Architektura VGG-16

Příloha F – Parametry jednotlivých vrstev VGG-16

Příloha G – Fotografie biometrického skeneru

PŘÍLOHA A – ARCHITEKTURA ALEXNET

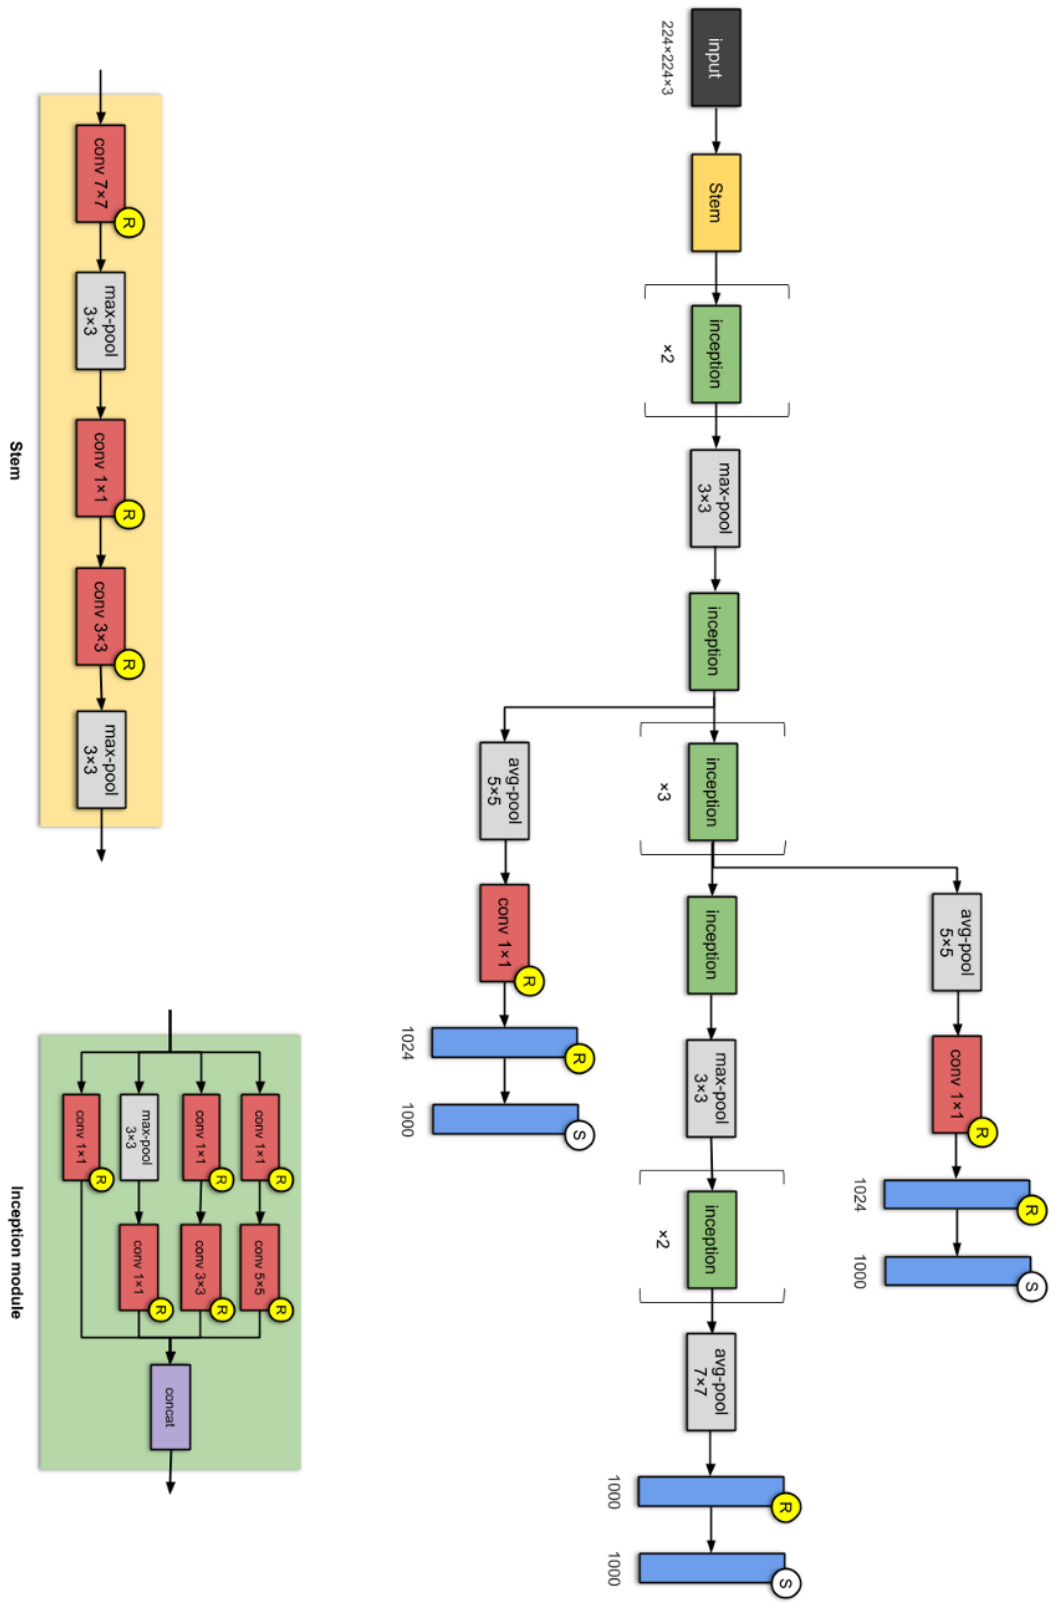


PŘÍLOHA B – PARAMETRY JEDNOTLIVÝCH VRSTEV

ALEXNET

ANALYSIS RESULT				
	Name	Type	Activations †	Learnables
1	data 227×227×3 images with 'zerocenter' normalization	Image Input	227×227×3	–
2	conv1 96 11×11×3 convolutions with stride [4 4] and padding [0 0 0]	Convolution	55×55×96	Weights 11×11×3×96 Bias 1×1×96
3	relu1 ReLU	ReLU	55×55×96	–
4	norm1 cross channel normalization with 5 channels per element	Cross Channel Normalization	55×55×96	–
5	pool1 3×3 max pooling with stride [2 2] and padding [0 0 0]	Max Pooling	27×27×96	–
6	conv2 2 groups of 128 5×5×48 convolutions with stride [1 1] and padding [2 2 2]	Grouped Convolution	27×27×256	Weights 5×5×48×128×2 Bias 1×1×128×2
7	relu2 ReLU	ReLU	27×27×256	–
8	norm2 cross channel normalization with 5 channels per element	Cross Channel Normalization	27×27×256	–
9	pool2 3×3 max pooling with stride [2 2] and padding [0 0 0]	Max Pooling	13×13×256	–
10	conv3 384 3×3×256 convolutions with stride [1 1] and padding [1 1 1]	Convolution	13×13×384	Weights 3×3×256×384 Bias 1×1×384
11	relu3 ReLU	ReLU	13×13×384	–
12	conv4 2 groups of 192 3×3×192 convolutions with stride [1 1] and padding [1 1 1]	Grouped Convolution	13×13×384	Weights 3×3×192×192×2 Bias 1×1×192×2
13	relu4 ReLU	ReLU	13×13×384	–
14	conv5 2 groups of 128 3×3×192 convolutions with stride [1 1] and padding [1 1 1]	Grouped Convolution	13×13×256	Weights 3×3×192×128×2 Bias 1×1×128×2
15	relu5 ReLU	ReLU	13×13×256	–
16	pool5 3×3 max pooling with stride [2 2] and padding [0 0 0]	Max Pooling	6×6×256	–
17	fc6 4096 fully connected layer	Fully Connected	1×1×4096	Weights 4096×9216 Bias 4096×1
18	relu6 ReLU	ReLU	1×1×4096	–
19	drop6 50% dropout	Dropout	1×1×4096	–
20	fc7 4096 fully connected layer	Fully Connected	1×1×4096	Weights 4096×4096 Bias 4096×1
21	relu7 ReLU	ReLU	1×1×4096	–
22	drop7 50% dropout	Dropout	1×1×4096	–
23	fc 50 fully connected layer	Fully Connected	1×1×50	Weights 50×4096 Bias 50×1
24	softmax softmax	Softmax	1×1×50	–
25	classoutput crossentropyex	Classification Output	1×1×50	–

PŘÍLOHA C – ARCHITEKTURA GOOGLNET



PŘÍLOHA D – PARAMETRY JEDNOTLIVÝCH VRSTEV

GOOGLNET


ANALYSIS RESULT				
	Name	Type	Activations	Learnables
1	data 224×224×3 images with 'zerocenter' normalization	Image Input	224×224×3	–
2	conv1-7x7_s2 64 7×7×3 convolutions with stride [2 2] and padding [3 3 3 3]	Convolution	112×112×64	Weights 7×7×3×64 Bias 1×1×64
3	conv1-relu_7x7 ReLU	ReLU	112×112×64	–
4	pool1-3x3_s2 3×3 max pooling with stride [2 2] and padding [0 1 0 1]	Max Pooling	56×56×64	–
5	pool1-norm1 cross channel normalization with 5 channels per element	Cross Channel Nor...	56×56×64	–
6	conv2-3x3_reduce 64 1×1×64 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	56×56×64	Weights 1×1×64×64 Bias 1×1×64
7	conv2-relu_3x3_reduce ReLU	ReLU	56×56×64	–
8	conv2-3x3 192 3×3×64 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	56×56×192	Weights 3×3×64×192 Bias 1×1×192
9	conv2-relu_3x3 ReLU	ReLU	56×56×192	–
10	conv2-norm2 cross channel normalization with 5 channels per element	Cross Channel Nor...	56×56×192	–
11	pool2-3x3_s2 3×3 max pooling with stride [2 2] and padding [0 1 0 1]	Max Pooling	28×28×192	–
12	inception_3a-1x1 64 1×1×192 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	28×28×64	Weights 1×1×192×64 Bias 1×1×64
13	inception_3a-relu_1x1 ReLU	ReLU	28×28×64	–
14	inception_3a-3x3_reduce 96 1×1×192 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	28×28×96	Weights 1×1×192×96 Bias 1×1×96
15	inception_3a-relu_3x3_reduce ReLU	ReLU	28×28×96	–
16	inception_3a-3x3 128 3×3×96 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	28×28×128	Weights 3×3×96×128 Bias 1×1×128
17	inception_3a-relu_3x3 ReLU	ReLU	28×28×128	–
18	inception_3a-5x5_reduce 16 1×1×192 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	28×28×16	Weights 1×1×192×16 Bias 1×1×16
19	inception_3a-relu_5x5_reduce ReLU	ReLU	28×28×16	–
20	inception_3a-5x5 32 5×5×16 convolutions with stride [1 1] and padding [2 2 2 2]	Convolution	28×28×32	Weights 5×5×16×32 Bias 1×1×32
21	inception_3a-relu_5x5 ReLU	ReLU	28×28×32	–
22	inception_3a-pool 3×3 max pooling with stride [1 1] and padding [1 1 1 1]	Max Pooling	28×28×192	–
23	inception_3a-pool_proj 32 1×1×192 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	28×28×32	Weights 1×1×192×32 Bias 1×1×32
24	inception_3a-relu_pool_proj ReLU	ReLU	28×28×32	–
25	inception_3a-output Depth concatenation of 4 inputs	Depth concatenation	28×28×256	–
26	inception_3b-1x1 128 1×1×256 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	28×28×128	Weights 1×1×256×128 Bias 1×1×128
27	inception_3b-relu_1x1 ReLU	ReLU	28×28×128	–
28	inception_3b-3x3_reduce 128 1×1×256 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	28×28×128	Weights 1×1×256×128 Bias 1×1×128
29	inception_3b-relu_3x3_reduce ReLU	ReLU	28×28×128	–
30	inception_3b-3x3 192 3×3×128 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	28×28×192	Weights 3×3×128×192 Bias 1×1×192
31	inception_3b-relu_3x3 ReLU	ReLU	28×28×192	–
32	inception_3b-5x5_reduce 32 1×1×256 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	28×28×32	Weights 1×1×256×32 Bias 1×1×32
33	inception_3b-relu_5x5_reduce ReLU	ReLU	28×28×32	–
34	inception_3b-5x5 96 5×5×32 convolutions with stride [1 1] and padding [2 2 2 2]	Convolution	28×28×96	Weights 5×5×32×96 Bias 1×1×96
35	inception_3b-relu_5x5 ReLU	ReLU	28×28×96	–
36	inception_3b-pool 3×3 max pooling with stride [1 1] and padding [1 1 1 1]	Max Pooling	28×28×256	–
37	inception_3b-pool_proj 64 1×1×256 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	28×28×64	Weights 1×1×256×64 Bias 1×1×64
38	inception_3b-relu_pool_proj ReLU	ReLU	28×28×64	–

39	inception_3b-output Depth concatenation of 4 inputs	Depth concatenation	28×28×480	-
40	pool3-3x3_s2 3×3 max pooling with stride [2 2] and padding [0 1 0 1]	Max Pooling	14×14×480	-
41	inception_4a-1x1 192 1×1×480 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×192	Weigh... 1×1×480×1... Bias 1×1×192
42	inception_4a-relu_1x1 ReLU	ReLU	14×14×192	-
43	inception_4a-3x3_reduce 96 1×1×480 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×96	Weights 1×1×480×96 Bias 1×1×96
44	inception_4a-relu_3x3_reduce ReLU	ReLU	14×14×96	-
45	inception_4a-3x3 208 3×3×96 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	14×14×208	Weights 3×3×96×208 Bias 1×1×208
46	inception_4a-relu_3x3 ReLU	ReLU	14×14×208	-
47	inception_4a-5x5_reduce 16 1×1×480 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×16	Weights 1×1×480×16 Bias 1×1×16
48	inception_4a-relu_5x5_reduce ReLU	ReLU	14×14×16	-
49	inception_4a-5x5 48 5×5×16 convolutions with stride [1 1] and padding [2 2 2 2]	Convolution	14×14×48	Weights 5×5×16×48 Bias 1×1×48
50	inception_4a-relu_5x5 ReLU	ReLU	14×14×48	-
51	inception_4a-pool 3×3 max pooling with stride [1 1] and padding [1 1 1 1]	Max Pooling	14×14×480	-
52	inception_4a-pool_proj 64 1×1×480 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×64	Weights 1×1×480×64 Bias 1×1×64
53	inception_4a-relu_pool_proj ReLU	ReLU	14×14×64	-
54	inception_4a-output Depth concatenation of 4 inputs	Depth concatenation	14×14×512	-
55	inception_4b-1x1 160 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×160	Weigh... 1×1×512×1... Bias 1×1×160
56	inception_4b-relu_1x1 ReLU	ReLU	14×14×160	-
57	inception_4b-3x3_reduce 112 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×112	Weigh... 1×1×512×1... Bias 1×1×112
58	inception_4b-relu_3x3_reduce ReLU	ReLU	14×14×112	-
59	inception_4b-3x3 224 3×3×112 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	14×14×224	Weigh... 3×3×112×2... Bias 1×1×224
60	inception_4b-relu_3x3 ReLU	ReLU	14×14×224	-
61	inception_4b-5x5_reduce 24 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×24	Weights 1×1×512×24 Bias 1×1×24
62	inception_4b-relu_5x5_reduce ReLU	ReLU	14×14×24	-
63	inception_4b-5x5 64 5×5×24 convolutions with stride [1 1] and padding [2 2 2 2]	Convolution	14×14×64	Weights 5×5×24×64 Bias 1×1×64
64	inception_4b-relu_5x5 ReLU	ReLU	14×14×64	-
65	inception_4b-pool 3×3 max pooling with stride [1 1] and padding [1 1 1 1]	Max Pooling	14×14×512	-
66	inception_4b-pool_proj 64 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×64	Weights 1×1×512×64 Bias 1×1×64
67	inception_4b-relu_pool_proj ReLU	ReLU	14×14×64	-
68	inception_4b-output Depth concatenation of 4 inputs	Depth concatenation	14×14×512	-
69	inception_4c-1x1 128 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×128	Weigh... 1×1×512×1... Bias 1×1×128
70	inception_4c-relu_1x1 ReLU	ReLU	14×14×128	-
71	inception_4c-3x3_reduce 128 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×128	Weigh... 1×1×512×1... Bias 1×1×128
72	inception_4c-relu_3x3_reduce ReLU	ReLU	14×14×128	-
73	inception_4c-3x3 256 3×3×128 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	14×14×256	Weigh... 3×3×128×2... Bias 1×1×256
74	inception_4c-relu_3x3 ReLU	ReLU	14×14×256	-
75	inception_4c-5x5_reduce 24 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×24	Weights 1×1×512×24 Bias 1×1×24
76	inception_4c-relu_5x5_reduce ReLU	ReLU	14×14×24	-
77	inception_4c-5x5 64 5×5×24 convolutions with stride [1 1] and padding [2 2 2 2]	Convolution	14×14×64	Weights 5×5×24×64 Bias 1×1×64
78	inception_4c-relu_5x5 ReLU	ReLU	14×14×64	-
79	inception_4c-pool 3×3 max pooling with stride [1 1] and padding [1 1 1 1]	Max Pooling	14×14×512	-
80	inception_4c-pool_proj 64 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×64	Weights 1×1×512×64 Bias 1×1×64
81	inception_4c-relu_pool_proj ReLU	ReLU	14×14×64	-
82	inception_4c-output Depth concatenation of 4 inputs	Depth concatenation	14×14×512	-

83	inception_4d-1x1 112 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×112	Weights Bias	1×1×512×1... 1×1×112
84	inception_4d-relu_1x1 ReLU	ReLU	14×14×112	-	-
85	inception_4d-3x3_reduce 144 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×144	Weights Bias	1×1×512×1... 1×1×144
86	inception_4d-relu_3x3_reduce ReLU	ReLU	14×14×144	-	-
87	inception_4d-3x3 288 3×3×144 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	14×14×288	Weights Bias	3×3×144×2... 1×1×288
88	inception_4d-relu_3x3 ReLU	ReLU	14×14×288	-	-
89	inception_4d-5x5_reduce 32 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×32	Weights Bias	1×1×512×32 1×1×32
90	inception_4d-relu_5x5_reduce ReLU	ReLU	14×14×32	-	-
91	inception_4d-5x5 64 5×5×32 convolutions with stride [1 1] and padding [2 2 2 2]	Convolution	14×14×64	Weights Bias	5×5×32×64 1×1×64
92	inception_4d-relu_5x5 ReLU	ReLU	14×14×64	-	-
93	inception_4d-pool 3×3 max pooling with stride [1 1] and padding [1 1 1 1]	Max Pooling	14×14×512	-	-
94	inception_4d-pool_proj 64 1×1×512 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×64	Weights Bias	1×1×512×64 1×1×64
95	inception_4d-relu_pool_proj ReLU	ReLU	14×14×64	-	-
96	inception_4d-output Depth concatenation of 4 inputs	Depth concatenation	14×14×528	-	-
97	inception_4e-1x1 256 1×1×528 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×256	Weights Bias	1×1×528×2... 1×1×256
98	inception_4e-relu_1x1 ReLU	ReLU	14×14×256	-	-
99	inception_4e-3x3_reduce 160 1×1×528 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×160	Weights Bias	1×1×528×1... 1×1×160
100	inception_4e-relu_3x3_reduce ReLU	ReLU	14×14×160	-	-
101	inception_4e-3x3 320 3×3×160 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	14×14×320	Weights Bias	3×3×160×3... 1×1×320
102	inception_4e-relu_3x3 ReLU	ReLU	14×14×320	-	-
103	inception_4e-5x5_reduce 32 1×1×528 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×32	Weights Bias	1×1×528×32 1×1×32
104	inception_4e-relu_5x5_reduce ReLU	ReLU	14×14×32	-	-
105	inception_4e-5x5 128 5×5×32 convolutions with stride [1 1] and padding [2 2 2 2]	Convolution	14×14×128	Weights Bias	5×5×32×128 1×1×128
106	inception_4e-relu_5x5 ReLU	ReLU	14×14×128	-	-
107	inception_4e-pool 3×3 max pooling with stride [1 1] and padding [1 1 1 1]	Max Pooling	14×14×528	-	-
108	inception_4e-pool_proj 128 1×1×528 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	14×14×128	Weights Bias	1×1×528×1... 1×1×128
109	inception_4e-relu_pool_proj ReLU	ReLU	14×14×128	-	-
110	inception_4e-output Depth concatenation of 4 inputs	Depth concatenation	14×14×832	-	-
111	pool4-3x3_s2 3×3 max pooling with stride [2 2] and padding [0 1 0 1]	Max Pooling	7×7×832	-	-
112	inception_5a-1x1 256 1×1×832 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	7×7×256	Weights Bias	1×1×832×2... 1×1×256
113	inception_5a-relu_1x1 ReLU	ReLU	7×7×256	-	-
114	inception_5a-3x3_reduce 160 1×1×832 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	7×7×160	Weights Bias	1×1×832×1... 1×1×160
115	inception_5a-relu_3x3_reduce ReLU	ReLU	7×7×160	-	-
116	inception_5a-3x3 320 3×3×160 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	7×7×320	Weights Bias	3×3×160×3... 1×1×320
117	inception_5a-relu_3x3 ReLU	ReLU	7×7×320	-	-
118	inception_5a-5x5_reduce 32 1×1×832 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	7×7×32	Weights Bias	1×1×832×32 1×1×32
119	inception_5a-relu_5x5_reduce ReLU	ReLU	7×7×32	-	-
120	inception_5a-5x5 128 5×5×32 convolutions with stride [1 1] and padding [2 2 2 2]	Convolution	7×7×128	Weights Bias	5×5×32×128 1×1×128
121	inception_5a-relu_5x5 ReLU	ReLU	7×7×128	-	-
122	inception_5a-pool 3×3 max pooling with stride [1 1] and padding [1 1 1 1]	Max Pooling	7×7×832	-	-
123	inception_5a-pool_proj 128 1×1×832 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	7×7×128	Weights Bias	1×1×832×1... 1×1×128
124	inception_5a-relu_pool_proj ReLU	ReLU	7×7×128	-	-
125	inception_5a-output Depth concatenation of 4 inputs	Depth concatenation	7×7×832	-	-
126	inception_5b-1x1 384 1×1×832 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	7×7×384	Weights Bias	1×1×832×3... 1×1×384

127	inception_5b-relu_1x1 ReLU	ReLU	7×7×384	-
128	inception_5b-3x3_reduce 192 1×1×832 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	7×7×192	Weights 1×1×832×1... Bias 1×1×192
129	inception_5b-relu_3x3_reduce ReLU	ReLU	7×7×192	-
130	inception_5b-3x3 384 3×3×192 convolutions with stride [1 1] and padding [1 1 1 1]	Convolution	7×7×384	Weights 3×3×192×3... Bias 1×1×384
131	inception_5b-relu_3x3 ReLU	ReLU	7×7×384	-
132	inception_5b-5x5_reduce 48 1×1×832 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	7×7×48	Weights 1×1×832×48 Bias 1×1×48
133	inception_5b-relu_5x5_reduce ReLU	ReLU	7×7×48	-
134	inception_5b-5x5 128 5×5×48 convolutions with stride [1 1] and padding [2 2 2 2]	Convolution	7×7×128	Weights 5×5×48×128 Bias 1×1×128
135	inception_5b-relu_5x5 ReLU	ReLU	7×7×128	-
136	inception_5b-pool 3×3 max pooling with stride [1 1] and padding [1 1 1 1]	Max Pooling	7×7×832	-
137	inception_5b-pool_proj 128 1×1×832 convolutions with stride [1 1] and padding [0 0 0 0]	Convolution	7×7×128	Weights 1×1×832×1... Bias 1×1×128
138	inception_5b-relu_pool_proj ReLU	ReLU	7×7×128	-
139	inception_5b-output Depth concatenation of 4 inputs	Depth concatenation	7×7×1024	-
140	pool5-7x7_s1 Global average pooling	Global Average Po...	1×1×1024	-
141	pool5-drop_7x7_s1 40% dropout	Dropout	1×1×1024	-
142	new_fc 50 fully connected layer	Fully Connected	1×1×50	Weights 50×1024 Bias 50×1
143	prob softmax	Softmax	1×1×50	-
144	new_classoutput crossentropyex	Classification Output	1×1×50	-

PŘÍLOHA E – ARCHITEKTURA VGG-16



PŘÍLOHA F – PARAMETRY JEDNOTLIVÝCH VRSTEV

VGG-16

ANALYSIS RESULT				
	Name	Type	Activations	Learnables
1	input 224×224×3 images with 'zerocenter' normalization	Image Input	224×224×3	-
2	conv1_1 64 3×3×3 convolutions with stride [1 1] and padding [1 1 1]	Convolution	224×224×64	Weights 3×3×3×64 Bias 1×1×64
3	relu1_1 ReLU	ReLU	224×224×64	-
4	conv1_2 64 3×3×64 convolutions with stride [1 1] and padding [1 1 1]	Convolution	224×224×64	Weights 3×3×64×64 Bias 1×1×64
5	relu1_2 ReLU	ReLU	224×224×64	-
6	pool1 2×2 max pooling with stride [2 2] and padding [0 0 0 0]	Max Pooling	112×112×64	-
7	conv2_1 128 3×3×64 convolutions with stride [1 1] and padding [1 1 1]	Convolution	112×112×128	Weights 3×3×64×128 Bias 1×1×128
8	relu2_1 ReLU	ReLU	112×112×128	-
9	conv2_2 128 3×3×128 convolutions with stride [1 1] and padding [1 1 1]	Convolution	112×112×128	Weights 3×3×128×128 Bias 1×1×128
10	relu2_2 ReLU	ReLU	112×112×128	-
11	pool2 2×2 max pooling with stride [2 2] and padding [0 0 0 0]	Max Pooling	56×56×128	-
12	conv3_1 256 3×3×128 convolutions with stride [1 1] and padding [1 1 1]	Convolution	56×56×256	Weights 3×3×128×256 Bias 1×1×256
13	relu3_1 ReLU	ReLU	56×56×256	-
14	conv3_2 256 3×3×256 convolutions with stride [1 1] and padding [1 1 1]	Convolution	56×56×256	Weights 3×3×256×256 Bias 1×1×256
15	relu3_2 ReLU	ReLU	56×56×256	-
16	conv3_3 256 3×3×256 convolutions with stride [1 1] and padding [1 1 1]	Convolution	56×56×256	Weights 3×3×256×256 Bias 1×1×256
17	relu3_3 ReLU	ReLU	56×56×256	-
18	pool3 2×2 max pooling with stride [2 2] and padding [0 0 0 0]	Max Pooling	28×28×256	-
19	conv4_1 512 3×3×256 convolutions with stride [1 1] and padding [1 1 1]	Convolution	28×28×512	Weights 3×3×256×512 Bias 1×1×512
20	relu4_1 ReLU	ReLU	28×28×512	-
21	conv4_2 512 3×3×512 convolutions with stride [1 1] and padding [1 1 1]	Convolution	28×28×512	Weights 3×3×512×512 Bias 1×1×512
22	relu4_2 ReLU	ReLU	28×28×512	-
23	conv4_3 512 3×3×512 convolutions with stride [1 1] and padding [1 1 1]	Convolution	28×28×512	Weights 3×3×512×512 Bias 1×1×512
24	relu4_3 ReLU	ReLU	28×28×512	-
25	pool4 2×2 max pooling with stride [2 2] and padding [0 0 0 0]	Max Pooling	14×14×512	-
26	conv5_1 512 3×3×512 convolutions with stride [1 1] and padding [1 1 1]	Convolution	14×14×512	Weights 3×3×512×512 Bias 1×1×512
27	relu5_1 ReLU	ReLU	14×14×512	-
28	conv5_2 512 3×3×512 convolutions with stride [1 1] and padding [1 1 1]	Convolution	14×14×512	Weights 3×3×512×512 Bias 1×1×512
29	relu5_2 ReLU	ReLU	14×14×512	-
30	conv5_3 512 3×3×512 convolutions with stride [1 1] and padding [1 1 1]	Convolution	14×14×512	Weights 3×3×512×512 Bias 1×1×512
31	relu5_3 ReLU	ReLU	14×14×512	-
32	pool5 2×2 max pooling with stride [2 2] and padding [0 0 0 0]	Max Pooling	7×7×512	-
33	fc6 4096 fully connected layer	Fully Connected	1×1×4096	Weights 4096×25088 Bias 4096×1
34	relu6 ReLU	ReLU	1×1×4096	-
35	drop6 50% dropout	Dropout	1×1×4096	-
36	fc7 4096 fully connected layer	Fully Connected	1×1×4096	Weights 4096×4096 Bias 4096×1
37	relu7 ReLU	ReLU	1×1×4096	-
38	drop7 50% dropout	Dropout	1×1×4096	-

39	fc8 1000 fully connected layer	Fully Connected	1×1×1000	Weights 1000×4096 Bias 1000×1
40	prob softmax	Softmax	1×1×1000	-
41	output crossentropyex with 'tench' and 999 other classes	Classification Output	1×1×1000	-

PŘÍLOHA G – FOTOGRAFIE BIOMETRICKÉHO SKENERU



