



**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA INFORMAČNÍCH TECHNOLOGIÍ**

FACULTY OF INFORMATION TECHNOLOGY

**ÚSTAV INTELIGENTNÍCH SYSTÉMŮ**

DEPARTMENT OF INTELLIGENT SYSTEMS

**ANALÝZA VÝVOJA TVÁRE NA ZÁKLADĚ ANTROPO-  
METRICKÝCH VLASTNOSTÍ**

ANALYSIS OF FACIAL DEVELOPMENT BASED ON ANTHROPOMETRIC PROPERTIES

**BAKALÁŘSKÁ PRÁCE**

BACHELOR'S THESIS

**AUTOR PRÁCE**

AUTHOR

**DÁVID ORAVEC**

**VEDOUcí PRÁCE**

SUPERVISOR

**Ing. TOMÁŠ GOLDMANN**

BRNO 2022

## Zadání bakalářské práce



Student: **Oravec Dávid**  
Program: Informační technologie  
Název: **Analýza vývoje obličeje na základě antropometrických vlastností**  
**Analysis of Facial Development Based on Anthropometric Properties**  
Kategorie: Umělá inteligence

### Zadání:

1. Seznamte s problematikou antropometrie lidského obličeje a zjistěte, jak se liší lidský obličej mezi významnými haploskupinami.
2. Seznamte se s algoritmy pro detekci významných bodů ve snímku obličeje. Především se zaměřte na algoritmy, které dokáží detekovat antropometrické body.
3. Navrhněte algoritmus, který v sadě snímků provede detekci antropometrických bodů obličeje a provede analýzu vývoje daného obličeje v čase.
4. Navržené řešení implementujte v programovacím jazyce Python a vytvořte k němu jednoduché uživatelské prostředí.
5. Proveďte experimenty zaměřené na určení změny poměrů antropometrických bodů v průběhu času. Výsledky diskutujte a navrhněte další rozšíření.

### Literatura:

- DAVIS, Josh P.; VALENTINE, Tim; DAVIS, Robert E. Computer assisted photo-anthropometric analyses of full-face and profile facial images. *Forensic science international*, 2010, 200.1-3: 165-176.
- DHALIWAL, Jasbir, et al. Facial Anthropometric Measurements and Photographs-An Interdisciplinary Study. *IEEE Access*, 2020, 8: 181998-182013.

Pro udělení zápočtu za první semestr je požadováno:

- Body 1 a 2.

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

Vedoucí práce: **Goldmann Tomáš, Ing.**  
Vedoucí ústavu: Hanáček Petr, doc. Dr. Ing.  
Datum zadání: 1. listopadu 2021  
Datum odevzdání: 11. května 2022  
Datum schválení: 3. listopadu 2021

## Abstrakt

Táto bakalárska práca sa zaoberá problematikou antropometrie ľudskej tváre, antropometrickými bodmi, ktoré slúžia na stanovenie presných vzdialeností a vzájomných pomerov, ktoré určujú rôzne indexy. Naše telo poznamenáva starnutie čo spôsobuje, že sa pozície antropometrických bodov vyvíjajú. Cieľom tejto práce je určiť antropometrické body z fotografie, na ktorej je ľudská tvár a analyzovať danú tvár ako sa vyvíja v čase. Na detekciu bodov bol natrénovaný model a z detekovaných bodov sa vybrali len tie, ktoré sa využijú na určenie rôznych indexov. Indexy sa použijú na určenie vývoja tváre v čase. Na základe experimentov pozorujeme, ako sa tvár mužov a žien plynutím času postupne mení.

## Abstract

This bachelor thesis deals with anthropometry of human face, anthropometric landmarks, which are used to determine the distances and various relations between them. Our body is aging and consequently the position of anthropometric points is changing. The aim of this work is to determine anthropometric landmarks from photo of the human face and then to analyze the given face and how it develops over time. The model for facial landmark detection was trained and selected points which will be used to determine facial indices were chosen. Indices are used to find out how the face is evolving over time. Based on experiments we observe how the faces of men and women are changing over time.

## Klíčové slová

antropometrické body, vývoj tváre, detekcia tváre, body na tvári, analýza tváre

## Keywords

anthropometric points, facial development, facial detection, facial points, facial analysis

## Citácia

ORAVEC, Dávid. *Analýza vývoja tváre na základe antropometrických vlastností*. Brno, 2022. Bakalárska práca. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Tomáš Goldmann

# Analýza vývoja tváre na základe antropometrických vlastností

## Prehlásenie

Prehlasujem, že som túto bakalársku prácu vypracoval samostatne pod vedením pána Ing. Tomáša Goldmanna. Uviedol som všetky literárne pramene, publikácie a ďalšie zdroje, z ktorých som čerpal.

.....  
Dávid Oravec  
11. mája 2022

## Podakovanie

Chcel by som sa poďakovať môjmu vedúcemu práce pánovi Ing. Tomášovi Goldmannovi za navrhnutie témy a nasmerovanie vypracovania.

# Obsah

<b>1</b>	<b>Úvod</b>	<b>2</b>
<b>2</b>	<b>Antropometria a jej využitie</b>	<b>4</b>
2.1	Antropometrické body na tvári . . . . .	6
2.2	Antropometrické vzdialenosti medzi bodmi . . . . .	7
2.3	Indexy tváre . . . . .	8
2.4	Rozdelenie obyvateľstva na haploskupiny podľa antropometrických údajov . . . . .	9
2.5	Rozdiely tváre medzi rôznymi haploskupinami . . . . .	10
2.6	Zmeny tváre v čase . . . . .	10
<b>3</b>	<b>Metódy detekcie</b>	<b>12</b>
3.1	Staršie prístupy . . . . .	12
3.2	Neurónové siete . . . . .	13
3.2.1	Konvolučné neurónové siete . . . . .	16
3.3	Neurónové siete pre detekciu tváre a antropometrických bodov na tvári . . . . .	16
3.3.1	YOLO . . . . .	16
3.3.2	VGG-NET . . . . .	17
3.3.3	MTCNN . . . . .	17
3.3.4	ASMNet . . . . .	17
3.3.5	Deep Convolution Network Cascade . . . . .	18
<b>4</b>	<b>Návrh algoritmu</b>	<b>19</b>
4.1	Model na detekciu tváre a antropometrických bodov . . . . .	19
4.1.1	RESNET . . . . .	19
4.1.2	Natrénovanie modelu . . . . .	20
4.2	Analýza tváre . . . . .	22
4.3	Použité technológie . . . . .	23
4.3.1	Tensorflow . . . . .	23
4.3.2	Numpy . . . . .	24
4.3.3	Matplotlib . . . . .	24
4.3.4	Pandas . . . . .	24
<b>5</b>	<b>Experimenty</b>	<b>25</b>
5.1	Diskusia . . . . .	28
<b>6</b>	<b>Záver</b>	<b>30</b>
	<b>Literatúra</b>	<b>32</b>

# Kapitola 1

## Úvod

Antropometria je každodennou súčasťou človeka. Stretávame sa s ňou už pri narodení dieťaťa, kedy ho odvážia, aby zistili jeho pôrodnú váhu, ktorú následne sledujú, aby bábätko nezačalo prudko chudnúť. Tak ako u novorodenca, tak aj všetci ostatní zisťujú svoju váhu, dokonca niektorí ľudia váhu sledujú každý jeden deň. V období vývinu dieťaťa sa pomerne často sleduje aj výška dieťaťa častokrát až dokedy prestane rásť. Antropometrické miery môžeme využiť aj v každodennom živote pri kúpe oblečenia, topánok, pri upevňovaní zrkadla na stenu, kde je dôležitá výška, pri výbere okuliarov, kde rozhoduje šírka tváre a vzdialenosť očí.

Ďalšími poznatkami, čo je to antropometria a ako sa dá využiť, čím sa zaoberá sa pozrieme v kapitole 2, ktorá sa rozdeľuje na šesť podkapitol. V týchto podkapitolách podrobnejšie sa popíše, aké poznáme antropometrické body na tvári, kde sa nachádzajú, aké sú medzi nimi vzťahy, rozoberieme si pojmy ako symetria a asymetria tváre, ktoré sú dôležitou súčasťou antropometrického merania. Popíšeme si konkrétne indexy tváre, ktoré získame vypočítaním so vzdialenosti antropometrických bodov, rozdelíme obyvateľstvo na jednotlivé rasy a ich charakteristické črty. Ďalej spomenieme ako sa tvár vyvíja a mení následkom času a samotného starnutia.

Pomocou informačných technológií je možné z obrazu získať rôzne informácie, ako sú jednotlivé objekty v obraze, ich pozíciu poprípade aj o aký objekt sa jedná. Takýmto spôsobom vieme získať aj ľudí a rôzne časti ľudského tela. Určenie kde sa tvár nachádza a na nej aj určenie charakteristických bodov je dôležitou časťou pre rozpoznanie tváre, sledovanie tváre.

V kapitole 3 a v jej podkapitolách sa pozrieme na to, aké prístupy sa využívajú na detekciu ľudskej tváre zo snímku a následne akým spôsobom môžeme detekovať body na ľudskej tvári. Popíšeme aké prístupy sa používajú a ako fungujú. V tejto kapitole sa budeme zaoberať fungovaním neurónových sietí so zameraním sa na konvolučné neurónové siete, pretože tieto siete sú veľkou súčasťou pri spracovaní obrazu.

V kapitole 4 sa budeme venovať návrhu algoritmu, čo podrobnejšie rozoberieme v jednotlivých podkapitolách. Návrh algoritmu využijeme na detekciu tváre a detekciu bodov na tvári. Ďalej rozpíšeme akým spôsobom sme vybrali antropometrické body, ktoré následne použijeme na získanie potrebných vzdialeností a výpočet pomerov antropometrických bodov.

V poslednej kapitole urobíme experimenty ako sa vyvíjajú pomery antropometrických bodov mužov a žien, chlapcov a dievčat v čase v rôznych rokoch života. Zamyslíme sa nad zisteniami a popíšeme výsledky experimentov.

V závere práce navrhujeme spôsoby na rozšírenie alebo vylepšenie výsledkov analýzy, navrhujeme rozšírenie experimentov jednotlivých haploskupín.

## Kapitola 2

# Antropometria a jej využitie

Antropometria [12] je vedný odbor zaoberajúci sa meraním ľudského tela a jeho častí. Delí sa na dve časti somatometriu a osteometriu.[14] Somatometria sa zaoberá meraním živého človeka. Osteometria sa zaoberá meraním kostí. Na základe skúmania človeka sa určili antropometrické body, pričom antropometrický bod [11] je presne definovaný bod na ľudskom tele, ktorý zodpovedá rovnomennému bodu na kostre premietnutému na povrch tela. Tieto body slúžia na stanovenie presných antropometrických vzdialeností a rôznych vzájomných pomerov. Medzi základné rozmery v klinickej antropometrii využívajúce antropometrické body [10] sú:

- telesná výška, ktorá sa meria z plochy, na ktorej meraná osoba stojí až po antropometrický bod vertex, čo je bod na temene lebky ležiaci najvyššie,
- výška v sede je meraná od plochy, na ktorej meraná osoba sedí až po antropometrický bod vertex,
- biakromiálna šírka ramien využitím antropometrických bodov acromiale, čo je najvzdialenejší bod na vonkajšom konci lopatky vo vzpriamenej polohe s pripaženou hornou končatinou,
- šírka panvy meraná pomocou bodov iliocristale, čo sú body najviac vystupujúce na bedrovom hrebenu,
- dĺžka dolných končatín využívajúca bod iliospianle anterior, čo je bod na hornom prednom bedrovom tíni,
- dĺžka horných končatín využívajúca antropometrický bod acromiale a daktylion, bod na konci prstu, pri pripažení leží najnižšie a na meranie dĺžky hornej končatiny sa využíva daktylion na treťom prste,
- rozpätie rúk sa meria pomocou daktylionov tretieho prstu pri rozpažených rukách,
- dĺžka chodidla sa meria pomocou 2 bodov - pternion (antropometrický bod ležiaci najviac vzadu na päte) a akropodion (antropometrický bod ležiaci na špičke najviac vpredu, buď na prvom alebo druhom prste).

Ďalšími rozmermi sú telesná hmotnosť, obvod brucha, obvod ruky, obvod predlaktia, obvod stehna, obvod lýtky.

Na antropometrické merania sa používajú predpísané postupy, ktoré určujú ako správne využívať pomôcky na meranie. Na rôzne merania sa používajú konkrétne pomôcky ako sú



pásový meter, ktorý sa využíva na meranie obvodu pása, váha na meranie telesnej hmotnosti, antropometer, dlhá dutá kovová tyč so stupnicou, kde je posúvadlo s vyznačenou ryskou na odčítanie veľkosti, ktorá sa využíva na merania výškových rozmerov ako je výška ľudského tela, ale využije sa aj na odmeranie dĺžky horných a dolných končatín, torakometer je posuvné meradlo využívané na meranie kratších vzdialeností, pelvimeter je veľké kružidlo s polooblúkovými ramenami a stupnicou využívajúci sa na meranie panvy, dynamometer je prístroj na meranie sily, kefalometer dotykové meradlo s dvomi ramenami polooblúkovitého tvaru využívajúce sa na meranie rozmerov hlavy, tváre. [15].

Pre získanie objektívnych údajov z merania jednotlivých bodov alebo vzdialeností sa vytvorili štandardizované metodiky [10] merania. Pre meranie výškových rozmerov sa meraná osoba postaví vzpriamene chrbtom k stene, ktorej sa dotýka pätami, zadkom a lopatkami pozerajúca sa priamo pred seba. Pri meraní dĺžkových, šírkových a hĺbkových rozmerov zisťujeme priamu vzdialenosť medzi oboma antropometrickými bodmi prechádzaním ramenami meracej pomôcky v mieste, kde sa dané antropometrické body nachádzajú. Výsledná meraná hodnota je najvyššia odčítaná z meracej pomôcky pri prechádzaní v okolí daných antropometrických bodov. Na meranie obvodových rozmerov sa využíva pásový alebo krajčírsky meter. Meranie obvodu hrudníka sa líši od pohlavia. Pri mužoch pásový meter prechádza tesne nad prsnými bradavkami a pri ženách prechádza antropometrickým bodom mesosternale, čo je bod na prednej strane hrudníka v mieste spojenia svalu a štvrtého rebra v strede hrudnej kosti a vzadu prechádza pri oboch pohlaviach tesne pod dolným uhlom lopatiek. Pri meraní hrudníka si musíme dať pozor na to, aby hrudník nebol v nádychovej alebo výdychovej polohe, čo môžeme dosiahnuť, že meranej osobe položíme otázku a v čase odpovede meriame.

Namerané hodnoty sa využívajú na definovanie a vypočítanie rôznych indexov. Indexy sú relatívne čísla vyjadrujúce proporcie tela a vzťahy jednotlivých rozmerov k iným. Index [16, 15] určujúci dĺžku trupu určuje výška v sede k výške celého tela, index na určenie dĺžky hornej alebo dolnej končatiny je pomer dĺžky danej končatiny k výške tela. Jedným z najznámejších indexov je Body-Mass Index(BMI), ktorý slúži ako jednoduchý ukazovateľ miery obezity jedinca. Je to však iba orientačný údaj pretože obezita [9] je zvýšené nahromadenie tuku, avšak BMI nám nič nehovorí o podiele tukovej a svalovej zložky.

S pomocou týchto antropometrických mier vieme zistiť a identifikovať rôzne zdravotné problémy ako sú obezita, gigantizmus alebo nanizmus. Pre človeka je veľmi užitočné niektoré z týchto mier poznať, aby sme si vedeli správne vybrať napríklad veľkosť oblečenia alebo veľkosť topánok. Hmotnosť človeka je podstatná miera, keďže niektoré zariadenia a produkty sú vyrobené s váhovým limitom ako napríklad stoličky, sedačky, postele alebo trampolíny. Ľudskú antropometriu teda využívame aj v priemysle pri dizajne a výrobe produktov tak, aby sa ľuďom dobre používali a boli prispôsobené na ľudské telo, čím môžu byť produkty ako myši k počítaču, sedačky do áut, prilby, topánky, rôzne pomôcky pre zlepšenie pozície tela počas používania produktov.

Na základe určenia antropometrických bodov vieme pomocou informačných technológií automaticky rozpoznávať, analyzovať, rekonštruovať, vytvárať fotorealistické snímky alebo aj 3D modely. Významným využitím antropometrických bodov na tvári je rozpoznávanie a detekcia tváre v kriminalistike alebo rekonštrukcia vinníka na základe opisu, pri biometrii na verifikáciu, na automatické zisťovanie emócie na základe mimiky alebo vytvorenia predpokladaného výzoru o niekoľko rokov. Sledovanie antropometrických bodov pomocou kamier sme využili aj v zábavnom priemysle na vytvorenie rôznych zábavných filtrov vo fotografických aplikáciách v smartfónoch, ktoré nám menia veľkosti očí, pridávajú mihalnice, fúzy, odstraňujú vlasy, vrásky alebo prefarbujú oči a pery. Pre zábavu využívame aj


detekciu rôznych pohybov, ktoré využívame na vyvolanie nejakej akcie v počítači napríklad pomocou X-box Kinect, s ktorým vieme ovládať hernú konzolu pomocou pohybov ruky pred obrazovkou alebo na základe konkrétnych pohybov hráme hru, na to určenú bez nutnosti držania nejakého ovládača, ale len čisto našim telom pred obrazovkou.

## 2.1 Antropometrické body na tvári

Tvár je jednou z prvých častí tela, ktorú si na človeku všimneme. Keď sa s niekým rozprávame, naša pozornosť sa upriami na jeho tvár. Tá je našim hlavným objektom vnímania. Udržujeme zrakový kontakt, sledujeme jeho mimiku tváre, ktorá nám častokrát napovie, čo naozaj cíti počas nášho rozhovoru. Môžeme si ďalej všimnúť farbu a tvar očí, krivosť a veľkosť nosa, veľkosť, tvar a farbu úst, veľkosť uší, či odstávajú, vysoké alebo nízke čelo, samotný tvar tváre ako gulatosť, súmernosť, hranatosť, či farbu pleti.

Na tvári sa nachádza niekoľko antropometrických bodov, ktoré sa využívajú na charakteristiku vlastností tváre [22, 21, 40]. Pozície niektorých antropometrických bodov sú vyobrazené na obrázku 2.1.

- Oko má 5 antropometrických bodov - vnútorné oko (endocanthion), vonkajšie oko (exocanthion), horné viečko (palpebrale superius), dolné viečko (palpebrale inferius), zrenica (pupilla).
- Obočie má 4 antropometrické body - vonkajšie obočie (frontotemporale), vnútorné obočie, základ obočia (orbitale superius), vrch obočia (superciliare).
- Na ústach sa nachádza 5 bodov - kútiky úst (2x cheilion), stred hornej pery (labiale superius), stred dolnej pery (labiale inferius), stred zavretých úst (stomion).
- Na nosovej časti sa nachádza 7 antropometrických bodov - stredný bod nazofrontálneho stehu (nasion), body, kde sa stretávajú maxiloanteriorálne a nasoanteriorálne stehy (2x maxillofrontale), najviac bočný obrys nosa (2x alare), základ nosa (subnasale), špička nosa (pronasale).
- Ďalšie antropometrické body na tvári sú výčnelok medzi obočím (glabella), najvzdialenejší body od stredu na lícnej kosti (2x zygion), body na uhle dolnej čelusti (2x gonion), najnižší stredný bod na dolnej čeluste (gnathion), najvyššie ležajúci predný stredný bod brady (pogonion), stred čela na vlasovej línii (trichion).



Obr. 2.1: Antropometrické body na tvári [25, 13] ex - vonkajšie oko (exocanthian), en - vnútorné oko (endocanthian), zy - najvzdialenejší bod od stredu na lícnej kosti (zygion), al - vonkajší bod nosnej oblasti (alare), ch - vonkajší bod úst (cheilion), go - bod na uhle dolnej čelusti (gonion), gn - najnižší stredný bod na dolnej čelusti (gnathion), sn - základ nosa (subnasale), tr - stred čela na vlasovej línii (trichion), n - bod ležiaci na mediálnej rovine nosa, najhlbší bod koreňa nosa (nasion).

## 2.2 Antropometrické vzdialenosti medzi bodmi

Na základe určenia jednotlivých antropometrických bodov z 2.1 získavame rôzne vzdialenosti na ďalšie spracovanie. Dôležité vzdialenosti sú medzikártálna šírka (en-en), biokulárna šírka (ex-ex), šírka oka (ex-en, en-ex), vzdialenosť medzi zrenicami, šírka tváre (zy-zy), morfológická šírka nosa (al-al), šírka nosového koreňa, šírka mandibuly (go-go), šírka úst (ch-ch), výška čela (tr-n), výška hlavy (gn-v), fyziognomická výška tváre (tr-gn), morfológická výška tváre (n-gn), spodná výška tváre (sn-gn), predná horná výška tváre (n-sn) [25, 40].

Niektoré body sa nachádzajú na tvárovej strednej línii [36]. Túto línii vytvorí spojenie dvoch bodov, ktorými sú glabella a stredný bod hornej pery. Ak je tvár symetrická táto čiara sa spojí aj s bodmi ako sú špička nosa, najnižším stredným bodom na dolnej čelusti, stredom dolnej pery a taktiež so stredom čela na vlasovej línii. Táto línii je v strede medzi stredmi zreničiek pravého a ľavého oka. Pod symetriou si predstavíme niečo, čo je dokonale súmerné a pravidelné. Môžeme naozaj povedať, že existuje dokonalá symetrická tvár? Ľudia sa snažia dosiahnuť symetriu svojej tváre, pretože sa symetrická tvár považuje za oveľa atraktívnejšiu, i keď to možno nie je tak. Podvedome vnímame, že symetrické črty tváre sú akýmsi symbolom dobrého zdravia. Vo všeobecnosti sa hovorí, že ľudia so symetrickou tvárou sa považujú za nositeľov "lepších génov". Nežijeme v dokonalom svete a preto každý z nás má určitý stupeň asymetrie tváre, ktorý môže byť u niekoho viac viditeľný ako u druhého. Asymetriu tváre môže spôsobiť aj len maličký detail na tvári ako krivý kútik úst pri úsmeve. Genetika zohráva veľkú úlohu pri asymetrii tváre. Buď sa s asymetriou tváre narodíme alebo počas života môžeme dosiahnuť asymetriu kvôli určitým faktorom

ako napríklad zranenie, choroba, životný štýl, či len samotné starnutie. Tým ako človeku pribúdajú roky, tak sa aj asymetria tváre mení.

Príkladom zmeny asymetrie tváre spôsobenou časom je dominancia pravej časti tváre, ktorá sa vyskytovala vo veku 12 rokov u dievčat, ale u chlapcov až vo veku 16 rokov. [35]

Vďaka antropometrickému meraniu tváre dokážu lekári diagnostikovať kraniofaciálne anomálie, čo sú určité abnormality, ktoré sú už vrodené. Príkladom najčastejšie vrodenej abnormality tváre je rázštep pery a podnebia. Antropometrické merania sa používajú aj na nastavenie štandardov pre plánovanie tvárovej rekonštrukcie po vážnom zranení. [23]

## 2.3 Indexy tváre

Na základe antropometrických vzdialeností medzi bodmi sa vytvorili rôzne metrické vlastnosti nazývané aj indexy [39], ktoré sa využívajú na klasifikáciu jednotlivých črt do troch tried či sú dané črty úzke, stredné alebo široké, nízke, stredné alebo vysoké, tenké, stredné alebo hrubé, krátke, stredné alebo dlhé.

- Index veľkosti čela sa udáva ako  $\frac{100 \times \text{výšky čela}}{\text{výška hlavy}}$ .
- Tvárový index je  $\frac{100 \times \text{morfologická výška tváre}}{\text{šírka tváre}}$ .
- Medzikartálny index sa počíta ako  $\frac{100 \times \text{medzikartálna šírka}}{\text{vzdialenosť biokulárnej šírky}}$ .
- Nos má taktiež index definovaný ako  $\frac{100 \times \text{morfologická šírka nosa}}{\text{morfologická výška tváre}}$ .
- Nasofaciálny index je  $\frac{100 \times \text{predná horná výška tváre}}{\text{morfologická výška tváre}}$ .
- Index nosno-tvárovej šírky definuje  $\frac{100 \times \text{šírka nosa}}{\text{šírka tváre}}$ .
- Index pery je  $\frac{100 \times \text{výška úst}}{\text{šírka úst}}$ .
- Index hrúbky hornej a dolnej pery je definovaný ako  $\frac{100 \times \text{výška danej pery}}{\text{výška úst}}$ .
- Index šírky úst je  $\frac{100 \times \text{šírka úst}}{\text{biokulárna šírka}}$ .
- Index vertikálnej výšky úst sa vypočíta  $\frac{100 \times \text{výška úst}}{\text{morfologická výška tvár}}$ .
- Index veľkosti brady je definovaný  $\frac{100 \times \text{vzdialenosť stredu dolnej pery(li) a najnižšiemu bodu na dolnej čelusti(gn)}}{\text{morfologická výška tvár}}$ .

Jednotlivé indexy sú rozdelené na 3 rozsahy, ktoré rozdeľujú jednotlivé črty tváre do tried. Použité rozsahy a ako sa k nim dospelo popisuje M. M. Roelofse vo svojej práci [38].

Čelo sa považuje za nízke, ak index veľkosti čela je menší ako 21,9, stredné, ak je v rozmedzí 22-28 a vysoké nad 28,1.

Tvárový index menší ako 78,9 klasifikuje tvár ako krátku, ale širokú, medzi 79 až 92,9 ako strednú a nad 93 ako dlhú, ale úzku.

Vzdialenosť očí klasifikuje medzikartálny index, ktorý určuje, že oči sú blízko seba, ak je jeho hodnota menšia ako 36,9, v normálnej vzdialenosti, ak sa hodnota pohybuje medzi 37 až 46 a oči sú ďaleko od seba keď hodnota medzikartálneho indexu je väčšia ako 46,1.

Nos je krátky, ak nasofaciálny index dosahuje hodnoty menšie ako 37,9 normálny, keď jeho hodnoty sú v rozmedzí 38-46 no a dlhý, ak jeho hodnota prevyšuje 46,1. Šírku nosa

klasifikuje index nosno-tvárovej šírky, ktorý určí, že je nos úzky pokiaľ jeho hodnota neprevyšuje 31,9, normálnej šírky je vtedy, keď dosahuje hodnôt medzi 32 až 36 a nos je široký akonáhle index dosiahne, poprípade presiahne hodnotu 46,1.

Index pery určuje ako hrubé sú ústa. Za tenké ústa sa považujú vtedy, keď index pery je menší ako 34,9, ústa normálnej hrúbky sú ak index dosahuje hodnotu medzi 35 a 44,9 a za hrubé pery sa považuje ak je index pery aspoň 45. Výšku úst klasifikuje index vertikálnej výšky úst, ktorý ak je menší ako 15,9, tak sa ústa považujú ako tenké, pri dosiahnutí hodnôt 16 až 22 sú ústa stredné a nad 22,1 sa považujú za hrubé. Index hornej pery určuje ako veľmi je zastúpená horná pera k výške úst a považuje sa za tenkú ak nepresahuje 31,9, za strednú kedy dosahuje hodnotu 32 až 44 a za hrubú, ak je jeho hodnota väčšia ako 44,1. Index dolnej pery podobne ako index hornej pery určuje jej zastúpenie voči výške úst. Dolná pera je tenká, ak jej index je menší ako 51,9, stredná pri rozmedzí 52 a 62 a hrubá pri hodnote indexu, ktorá dosahuje alebo presahuje hodnotu 62,1. Úzke ústa sú klasifikované keď hodnota indexu šírky úst je maximálne 54,9, stredné ústa sú vtedy, keď index má hodnoty medzi 55 a 66 a pri hodnotách indexu dosahujúcich alebo vyšších ako 66,1 sa ústa považujú za široké.

Poslednou klasifikáciou je veľkosť brady, ktorú určuje index veľkosti brady a brada je normálna pri hodnotách indexu v rozmedzí 20 až 29, krátka pri indexe o hodnote 19,9 a menšej, a za dlhú bradu sa považuje, ak index je buď rovný 29,1 alebo väčší.

index	nížší, užší, tenší	stredný	vyšší, širší, hrubší
veľkosti čela	$\leq 21,9$	22-28	$\geq 28,1$
tvárový	$\leq 78,9$	79-92,9	$\geq 93$
medzikartálny	$\leq 36,9$	37-46	$\geq 46,1$
nosový	$\leq 54,9$	55-99,9	$\geq 100$
nasofaciálny	$\leq 37,9$	38-36	$\geq 36,1$
nosno-tvárovej šírky	$\leq 31,9$	32-36	$\geq 36,1$
pery	$\leq 34,9$	35-44,9	$\geq 45$
vertikálnej výšky úst	$\leq 15,9$	16-22	$\geq 22,1$
hornej pery	$\leq 31,9$	32-44	$\geq 44,1$
dolnej pery	$\leq 51,9$	52-62	$\geq 62,1$
šírky úst	$\leq 54,9$	55-66	$\geq 66,1$
veľkosť brady	$\leq 19,9$	20-29	$\geq 29,1$

Tabuľka 2.1: klasifikácia indexov

## 2.4 Rozdelenie obyvateľstva na haploskupiny podľa antropometrických údajov

Na našom kontinente, ale i celkovo vo svete je obrovské množstvo ľudí. Každý jedinec je iný a odlišný na základe rôznych znakov. S každým človekom, s ktorým sa stretne počas nášho života sa vzájomne odlišujeme, a tým sme každý jedinečný. Už v histórii sa ľudstvo delilo do rôznych skupín podľa telesných znakov. S týmto delením sa ako prvý zaoberal francúzsky výskumník F. Bernier, ktorý v roku 1684 klasifikoval a rozdelil obyvateľstvo do niekoľkých skupín na základe farby pleti a vlasov, tvaru nosa, očí, telesnej výšky a tváre. Vytvoril tak štyri skupiny:

- Európania a západný Aziati

- Černosi
- Východný Aziati
- Laponci

Pri vzniku ďalších delení sa rozdelili ľudia do rás. Každá rasa má svoje charakteristické črty, ktorými sa od inej líši. Tieto rozdiely sa najčastejšie prejavujú vo farbe pokožky, tvare vlasov a v črtách na tvári ako je tvar očí, pier, nosa a profil tváre. J. J. Roginskij viac špecifikoval a rozdelil ľudí do rás. Ľudské rasy rozlíšil podľa tvárových podôb a geografického výskytu. Vznikli tri veľké skupiny ako ekvatoriálna, eurázijská a ázijsko-americká, v ktorých popísal farbu pleti, vlasov, očí, šírku nosa a tváre, výšku čela a orbity.

Prvou z týchto skupín je Ekvatoriálna alebo Afroamerická rasa, pre ktorú je charakteristická tmavá farba pleti, očí a vlasov. Tvar vlasov je vlnitý až kučeravý. Nos je nízky až stredný, ale široký. Pery sú hrubé a nadmerne vyčnievajúce dopredu. Výška čela a šírka tváre je malá až stredná a výška orbity je nízka až stredná.

Pre Eurázijskú alebo Europoidnú rasu je farba pleti svetlá až jemne tmavá. Vlasy sú rovné prípadne vlnité rôznej farby. Pery sú tenké a stredne veľké. Nos je vysoký a úzky. Výška čela a šírka tváre je malá až stredná. Výška orbity je stredná.

Poslednou treťou skupinou je ázijsko-americká alebo mongoloidná rasa, pre ktorú je typické, že má podobnú farbu pleti ako pri europoidnej rase, no dosť často prechádza až do nažltlého odtieňu pleti. Farba vlasov a očí je tmavá ako pri Afroameričanoch. Vlasy majú rovné a pevné. Nos je nízky až stredný, len u Indiánov je vysoký. Pery sú stredné až hrubé a podobne vyčnievajúce ako pri Ekvatoriálnej rase. Výška čela a šírka tváre je stredná až veľká, výška orbity je veľká. [26]

## 2.5 Rozdiely tváre medzi rôznymi haploskupinami

Každá rasa je odlišná buď veľkými alebo malými, až nepatrnými rozdielmi, ktoré si dokážeme všimnúť voľným okom. Vzdialenosti antropometrických bodov sa medzi jednotlivými rasami líšia, čo môžeme vidieť už aj pri Roginskijovom rozdelení 2.4. Ďalší výskum [23] nám ukazuje, že v priemere Európania, stredný východ a severná Amerika majú väčšiu výšku tváre ako Afroameričania a Ázijci. Mongoloidná rasa má vzdialenosť medzi očami väčšiu. Najširší nos a najširšie ústa majú Afroameričania, no napriek tomu majú najužšiu tvár.

Dominantnou črtou ázijskej tváre [28] je väčšia vzdialenosť medzi bodmi vnútorného oka v závislosti od vzdialenosti medzi horným a dolným viečkom otvoreného oka. Výšku oka majú Ázijci od 8 mm do 10 mm, pričom kaukazská populácia má priemernú výšku oka 10,3mm. Čo sa týka šírky oka pri mongoloidnej rase sa pohybuje v rozmedzí 27 mm až 30 mm a pri kaukazskej populácii v priemere 27,2 mm.

Zaujímavou črtou tváre je nos, kedy priemernú výšku nosa majú Ázijci a Európania 60 mm a Afroameričania 57 mm, ale zase šírku nosa majú 37,6 mm, pričom europoidná rasa má 32,8 mm a ázijská má 33,7 mm, takže Európania majú na základe tabuľky 2.1 v primere úzky nos a Afroameričania a Ázijci majú nos stredný.

## 2.6 Zmeny tváre v čase

Človek sa dennodenne mení a vyvíja. Naše telo poznamenáva čas a starnutie, ktoré prichádza a prejaví sa na vzhľade a stavbe celého tela. Najčastejšie známky vývoja a zmien pri plynutí

času vidíme na ľudskej tvári. Na základe publikácie [33], ktorá sa zaoberá modelovaním vývoja tváre detí a mladistvých od 7 do 17 rokov v Českej Republike sa najväčší vývoj tváre zaznamenal v období puberty. Zaujímavosťou je, že zmena prebieha inak pri dievčatách a chlapcoch.

Pri dievčatách najväčší vývoj tváre je v rozmedzí v 7 až 14 rokov. Zvýrazňuje sa špička nosa, brada a obočie a predlžuje sa čelo a spodná časť tváre. Medzi 14. a 16. rokom vzrastie oblasť pod očami a po 16. roku vývoj prakticky zastane.

Pri chlapcoch je vývoj najväčší v rozmedzí 11-14 rokov, kedy sa mení čelo, nos a brada. Po 14. roku vývoj tváre sa spomalí, ale stále pretrváva aj do 17. roku. Po 16. roku sa zaznamenali len malé zmeny v oblasti nosa a brady.

Najväčšie zmeny v tvári nastali v oblasti čela, nosa a čeluste v oboch pohlaviach. Pred pubertou muži zvyknú mať väčšiu tvár ako ženy v rovnakom veku. Napriek tomu, že medzi pohlaviami vo vývoji tváre sú rozdiely štúdia [33] predpokladá, že obe pohlavia majú podobný starnúci vzor.

Iná štúdia [46] zaoberajúca sa vývojom tváre v Hong Kongu zaznamenala taktiež zväčšenie čela a aj indexu veľkosti brady pri oboch pohlaviach. Špička nosa sa zvýraznila pri oboch pohlaviach, ale bola výraznejšia pri mužoch.

Ženám z Hong Kongu sa počas vývoja tváre predĺžila výška očí viac ako mužom. Výška medzi nosom a hornou perou sa výraznejšie zvýšila pri ženách. Čo sa týka úst, tak šírka úst sa zmenila u žien, ale pri mužoch nie.

## Kapitola 3

# Metódy detekcie

V tejto kapitole sa pozrieme na metódy detekcie objektov a zameriame sa na detekciu ľudskej tváre, detekciu bodov určujúcich tvar tváre a tvárových orgánov. Určenie charakteristických bodov na tvári je kritická časť pre spracovanie týchto údajov v aplikáciách na rozpoznanie tváre, sledovanie tváre, detekcia pohľadu, zistenie výrazov alebo mimiky tváre. Najskôr sa musíme pozrieť na detekciu regiónu tváre zo snímku, či sa na danom snímku vôbec ľudská tvár nachádza, aby sme mohli na nej detekovať body, ktoré potom využijeme na ďalšie spracovanie a analýzu. Na detekciu objektov a bodov sa využívajú staršie prístupy, ktoré využívajú štatistické modely alebo novšie prístupy využívajúce hlboké učenie pomocou neurónových sietí.

### 3.1 Staršie prístupy

Na detekciu tváre napríklad v digitálnych kamerách a fotoaparátoch sa využíva algoritmus Viola-Jones pre jeho výbornú prácu v reálnom čase. Tento algoritmus bol motivovaný hlavne detekciou tváre, ale môže byť natrénovaný aj na detekciu iných objektov.

Algoritmus Viola-Jones [45] využíva prístup rozdielu intenzít danej oblasti obrazu. Využíva Haarove príznaky, ktoré hovoria o tmavších a svetlejších oblastiach. Napríklad oblasť očí je tmavšia ako oblasť líc. Každá jedna časť sa počíta sčítaním a odčítaním intenzít na základe haarových príznakov, čo spôsobuje redundantné výpočty. Na zabránenie nadbytočných výpočtov a zefektívnenie celého procesu získania výsledku sa využilo vypočítanie integračného obrázku, ktorý obsahuje súčet intenzít tak, že na súradnici  $x$ ,  $y$  sa nachádza súčet intenzít všetkých pixelov naľavo a hore od danej súradnice obrázku. Natrénujú sa príznaky od najviac všeobecného, až po špecifické a detekuje sa tvár, až po tom ako všetky príznaky sú prítomné.

Medzi staršie metódy detekcie antropometrických bodov na tvári patria Active Appearance Model (AAM), Active Shape Model (ASM) a Constrained Local Model (CLM). Všetky metódy patria medzi štatistické modely detekcie tvaru objektov.

AAM [18, 34] je nelineárny parametrický model, ktorý sa trénuje na základe označenia konkrétnych bodov na tréningových snímkoch. Následne sa lokalita týchto bodov použije na definovanie tvaru tváre. Na základe tohto modelu dostaneme štartovací odhad a pomocou upravovania parametrov modelu urobíme rekonštrukciu, kde sa snažíme minimalizovať rozdiel medzi rekonštrukciou a pôvodným obrazom. Tento optimalizačný problém sa rieši iteratívnou metódou, kedy sa vždy vypočíta, aká veľká je chyba novej predikcie. Ak je veľ-



kosť chyby menšia ako aktuálna, tak sa príjme, inak sa vyskúša modifikovaný parameter predikcie.

Model ASM [19] sa taktiež trénuje pomocou označenej množiny bodov na obrázkoch. Tento model pri tréňovaní musí zarovnať tvary zo všetkých obrázkov a následne vypočítať priemerný tvar. Už sa len určí predvolená rotácia, veľkosť a pozícia. Na základe určeného stredného tvaru sa znovu zarovnávajú tréňovacie tvary a tento proces sa opakuje pokiaľ nastáva významná zmena. Týmto procesom sa získa model, ktorý následne sa využíva na detekciu tvarov pomocou transformácie daných bodov.

CLM [20] je podobný Active Appearance modelu, ale využíva lokálne vzory vlastností. Tréňovacia oblasť je vzorkovaná okolo každého bodu a oblasti sú prevzorkované na stálu veľkosť. Tieto oblasti sú následne spojené do jedného vektora, ktorý sa využije na vytvorenie lineárneho modelu s následným vytvorením spojeného modelu. Tento model vyhľadáva body pomocou prvotného určenia bodov a následného generovania oblastí od týchto bodov, vypočítania odpovede každej oblasti za pomoci normalizovanej korelácie, pričom predikuje nové pozície bodov a upravuje parametre až dokiaľ nenastáva významná zmena v detekovaných bodoch.

Moderné prístupy využívajú neurónové siete na detekciu objektov a bodov na tvári a preto sa na ne bližšie pozrieme v nasledujúcej časti.

## 3.2 Neurónové siete

Neurónová sieť je skupina algoritmov založená na vzore fungovania ľudského mozgu. Skladá sa z prepojených uzlov, ktoré sú podobné neurónom v mozgu. Každý neurón má svoj vstup, výstup a má priradenú váhu, ktorá určuje dôležitosť daného vstupu. Všetky vstupy do neurónu sú vynásobené natréňovanými váhami a spočítané do výsledku. Výsledok je posunutý aktivačnej funkciou, ktorá určí výsledný výstup. Výstup následne predá ďalšej vrstve alebo ho priradí na finálny výstup z neurónovej siete.

Poznáme viaceré aktivačné funkcie, ktoré môžu byť buď lineárne alebo nelineárne. Lineárna aktivačná funkcia častokrát známa aj ako funkcia identity  $f(x) = x$  nijako nemení výstup neurónu a jej pridaním na všetky uzly zachová lineárnu kombináciu vstupov s jednotlivými váhami. Pri využití nelineárnych aktivačných funkcií sa zovšeobecňuje rôznorodosť dát a odlišujú sa výstupy.

Nelineárnymi aktivačnými funkciami sú[1]:

- ReLU (Rectified Linear Unit)

Najpoužívanejšia aktivačná funkcia a jej úlohou je ponechať kladné hodnoty a záporné premeniť na nulu. Takže je to spojenie dvoch lineárnych funkcií, pričom jedna je v množine záporných čísiel a druhá v množine v kladných čísiel.

$$f(x) = \max(x, 0), f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$$

- Sigmoid

Funkcia, ktorá vráti hodnoty v obore (0,1), takže je vhodná na určenie pravdepodobnosti výstupu pri klasifikačných problémoch.

$$f(x) = \frac{1}{1 + e^{-x}}$$

- Tanh

Funkcia symetrická v nule v obore hodnôt  $(-1,1)$ . Je podobný sigmoide, akurát vysoko záporné hodnoty budú označené ako záporné, hodnoty blízko nuly k nule a kladné hodnoty ako kladné. Funkcia sa využíva hlavne pri klasifikácii dvoch tried.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Keďže neurónové siete sa trénujú, musíme zistiť ako sú presné. Na určenie tejto presnosti sa využívajú stratové funkcie, ktoré nám povedia ako sa líšia predikované hodnoty oproti reálnym hodnotám, ktoré sme chceli skutočne nájsť. Medzi stratové funkcie patria napríklad[3]:

- MAE

Mean absolute error alebo stredná absolútna chyba je stredná hodnota súčtu veľkosti chýb medzi skutočnosťou a predpoveďou modelu. Absolútna chyba je odolnejšia voči vzdialenejším hodnotám.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i^{skuto} - y_i^{pred}|$$

- MSE

Mean squared error alebo stredná kvadratická chyba je stredná hodnota súčtu štvorcovou rozdielov medzi skutočnosťou a hodnotou získanou z modelu. Používa sa keď chceme aby väčšie chyby boli viac potrestané, mali väčší dopad na nepresnosť modelu ako menšie chyby.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i^{skuto} - y_i^{pred})^2$$

- MBE

Mean bias error alebo stredná vychýlená chyba je priemer súčtu chýb a berie do úvahy aj smer, ktorý môže spôsobiť vzájomné vyrušenie. Je málo využívaný, ale môže určiť či model má pozitívnu alebo negatívnu odchýlku.

$$MBE = \frac{1}{n} \sum_{i=1}^n (y_i^{skuto} - y_i^{pred})$$

Toto sú najpoužívanejšie stratové funkcie používané na tréning neurónových sietí. Existujú aj špeciálne klasifikačné stratové funkcie používané pri učení neurónových sietí na predpoveď tried objektov ako je krížová entropia, ktorá využíva logaritmus a tým zvyšuje hodnotu straty pri vysokej percentuálnej nezhode medzi predikciou a realitou.

Učenie neurónovej siete [5] spočíva v minimalizovaní hodnoty stratovej funkcie zmenou váh a prahov pri každom neuróne. Na minimalizovanie straty sa využívajú optimalizačné algoritmy, ktoré s využitím učiaceho sa kroku chcú nájsť globálne minimum. Učiaci krok v optimalizačnom algoritme sa nastavuje, a v niektorých algoritmoch sa môže meniť jeho hodnota aj počas tréningu. Medzi optimalizačné algoritmy [6], ktoré sa využívajú pri neurónových sieťach patrí zostupný prechod, stochastický zostupný prechod, momentum,

Adagrad, AdaDelta, Adam. Adam [32] je efektívny a časovo nenáročný algoritmus vhodný na veľký počet dát a parametrov.

Neurónová sieť sa naučí hodnoty všetkých parametrov siete pomocou dostatočného množstva tréningových dát, ako nájsť riešenie daného problému a vhodne zvolenou optimalizačnou a stratovou funkciou na daný problém. Sieť následne určuje výstup s určitou presnosťou, ktorú vieme získať z validačnej množiny dát. Validácia množina dát je množina, z ktorých sa neurónová sieť neučí, iba validuje model, či dokáže a s akou presnosťou riešiť problém aj na neznámych dátach.

Na to, aby sme vedeli správne navrhnuť neurónovú sieť potrebujeme najskôr pochopiť s čím pracujeme. Čo je náš vstup a čo by malo byť výstupom. Dobrým spôsobom je vizualizácia dát, pozrieme si, čo dávame na vstup, a čo by malo byť na výstupe. Tým lepšie pochopíme dáta a môžeme sa vrhnúť na ich spracovanie. Dáta na vstupe a výstupe často predstavujú nečíselné údaje a preto ich najskôr potrebujeme premeniť na číselnú podobu, pretože neurónová sieť vie pracovať len s číslami a s rôznymi matematickými funkciami. Neurónovú sieť vieme využiť na akýkoľvek problém, pokiaľ vieme správne transformovať vstup a výstup na číselnú reprezentáciu. Natrénovaná neurónová sieť vie riešiť len ten problém, na ktorý bola tréningovaná na základe tréningových dát, takže úspešnosť a presnosť potom záleží od kvality a dostatku tréningových dát, navrhnutého modelu, dĺžky tréningovania a použitých tréningových parametrov.

Návrh modelu neurónovej siete spočíva v experimentovaní. Mali by sme začať buď existujúcim modelom, ktorý rieši podobný problém ako je ten náš alebo začať s veľmi jednoduchým návrhom a postupne ho upravovať. Existujúci model si upravíme na základe našich potrieb ako sú veľkosť vstupu, veľkosť výstupu, poprípade pridanie alebo odstránenie ďalších vrstiev v modeli. Pri vytváraní úplne nového modelu môžeme postupne zvyšovať komplexnosť pridávaním ďalších vrstiev, menením počtu parametrov, pridávaním aktivačných funkcií. Pri návrhu modelu sa pozeráme ako náš model rieši náš problém, akú má presnosť a úspešnosť, ktorú môžeme zvýšiť rôznymi spôsobmi ako sú zväčšenie množiny tréningových dát, zvýšenie počtu vrstiev neurónovej siete, normalizácia vstupných dát alebo aj dĺžkou tréningovania. Pri dĺžke tréningovania si treba dať pozor na pretrénovanie. Aby sme sa vyhli pretrénovaniu siete využívame zväčšenie rôznorodosti tréningovej množiny alebo zmenenie komplexnosti modelu. Komplexnosť modelu môžeme zmeniť zmenou počtu vrstiev, počtu parametrov, náhodnej manipulácie vstupných dát, pričom cieľom je zvýšiť všeobecnosť modelu a redukovať nadmernú presnosť v tréningových dátach.

Neurónové siete sa rozdeľujú na 3 typy [2]:

- dopredné neurónové siete,
- konvolučné neurónové siete,
- rekurentné neurónové siete.

Dopredné neurónové siete sú najzákladnejšími neurónovými sieťami. Spracovávajú vstupy iba smerom dopredu a nevytvárajú cyklus. Využívajú sa na textové, tabuľkové alebo obrázkové dáta. Rekurentné neurónové siete sa od dopredných líšia tým, že obsahujú cyklus a povoluju aby predchádzajúci výstup bol použitý znova ako vstup. Využívajú sa na časové dáta, textové alebo audio dáta. Konvolučné neurónové siete sa využívajú na spracovanie obrazu a preto sa im budem viac venovať.

### 3.2.1 Konvolučné neurónové siete

V konvolučnej neurónovej sieti [8, 4] sú dôležitým prvkom konvolučné vrstvy, ktoré obsahujú filtre. Filtre sú určené na získanie informácií o obraze. Hodnoty filtrov sú predmetom učenia neurónovej siete, ktoré vyťahujú informácie zo vstupu. Základnou operáciou je konvolúcia, čo je súčet vynásobených vstupných hodnôt o veľkosti filtra s hodnotami filtra a vznikne jedna výsledná hodnota pre danú veľkosť filtra. Filter sa následne posunie a znova sa vykoná konvolúcia, čo sa opakuje až dokiaľ sa nespracuje celý vstup. Filter má určenú veľkosť, čo je jedným z nastavovaných parametrov v konvolučnej vrstve. Ďalším parametrom je aj posun alebo krok filtra, o koľko a ktorým smerom sa posunie, aby spracoval celý vstup. Pri aplikácii filtra nastáva problém pri hraniciach, kedy neexistuje hodnota suseda. Na riešenie neexistujúcich hodnôt na hraniciach sa používa niekoľko prístupov, ktoré sú tiež predmetom nastavenia konvolučnej vrstvy. Neexistujúce hodnoty, ktoré sú za hranicou obrazu vyplníme buď nulami alebo zduplikujeme hodnoty od suseda. Taktiež môžeme hraničné body vynechať, čo zapríčiniť redukciu výstupu.

V konvolučnej vrstve sa môže nachádzať niekoľko filtrov, pričom každý z filtrov vyprodukuje príznakovú mapu, čo je výstup po aplikácii daného filtra. Každá zostrojená príznaková mapa je vstupom aktivačnej funkcie a najviac využívaná aktivačná funkcia v konvolučných vrstvách je ReLU. Po konvolučnej vrstve môže nasledovať tzv. pooling, čo je prevzorkovanie vstupných hodnôt do menšej mapy. Zoberie sa okno nejakej veľkosti a v rámci toho okna sa buď vyberie maximálna hodnota alebo priemerná hodnota v danom okne zo vstupnej príznakovej mapy. Počas tejto operácie stratíme nejaké informácie, čo zvýši efektivitu výpočtu, zredukuje zložitosť obrazu a podporí, aby neurónová sieť viac zovšeobecnila vstupné dáta, a tak mala lepšiu presnosť.

Poslednou vrstvou je plne prepojená vrstva, ktorá nám skombinuje príznaky, prevedie klasifikáciu alebo vytvorí výstup. Jedným zo spôsobov prevedenia klasifikácie [4] je využitie aktivačnej funkcie softmax, ktorá nám vráti pravdepodobnosť, že sa daný objekt nachádza na obrázku.

## 3.3 Neurónové siete pre detekciu tváre a antropometrických bodov na tvári

Popularizáciou hlbokého učenia a počítačového videnia vzniklo viacero modelov na detekciu objektov. Za pomoci detekcie objektov vieme sledovať v kamere daný objekt automaticky a využiť to na automatické ostrenie, autonómne autá sa dokážu vyhnúť havárii a podobne. V rámci detekcie objektov môžeme detekovať aj ľudskú tvár a potom tvár využiť na ďalšie spracovanie, ako je detekcia antropometrických bodov na tvári, ktoré môžu byť využité na rozpoznanie tváre, ale môžu byť využité aj na zábavu ako sú rôzne zábavné aplikácie


### 3.3.1 YOLO

Algoritmus využívajúci neurónove siete je You Only Look Once model alebo YOLO. YOLO [37] je model na detekciu rôznych objektov, či sú prítomné na obraze a ak áno, kde sa nachádzajú. Funguje s využitím konvolučných neurónových sietí, ktoré detekujú v jednom obraze viacero objektov. Vstup sa rozdelí na štvorcovú mriežku a každá bunka mriežky odhadne niekoľko ohraničujúcich obdĺžnikov a vypočíta pravdepodobnosti objektov, ktoré sa v danom ohraničení nachádzajú. Daná bunka potom vráti pozíciu stredu objektu, šírku a výšku objektu. V prípade kedy detekuje jeden objekt viacerými ohraničeniami počíta

prienik nad zjednotením (IoU - intersection over union) alebo Jaccard index, čo je pomer medzi obsahom počítaného ohraničenia a obsahom zjednotených ohraničení. Najvyššie IoU sa považuje za výsledné ohraničenie, a tak sa eliminujú nepotrebné ohraničenia, ktoré neboli až tak presné. Výsledkom sú jednotlivé ohraničenia, ktoré detekujú dané objekty na snímku aj s pravdepodobnosťou o aký objekt sa jedná.

### 3.3.2 VGG-NET

VGG-NET [7, 41] je ďalším algoritmom na detekciu rôznych objektov s využitím hlbkej konvolučnej neurónovej siete. Používa sa na detekciu veľkého množstva individuálnych objektov ako sú zvieratá, ľudia, kancelárske potreby. Na obrázku 3.1 je vyzobrazená architektúra siete. Využíva 16 váhových vrstiev, ako sú konvolučné vrstvy alebo plneprepojené vrstvy, pričom na vstupe je obrázok s veľkosťou 224 px x 224 px a všetkými tromi kanálmi RGB. Každým jedným poolingom sa zredukuje rozlíšenie štvornásobne, pretože využíva okno 2 x 2 s posunom o 2 x 2 pixelov. Na základe veľkého množstva vrstiev v sieti zlepšuje presnosť klasifikácie. Nevýhodou tohto algoritmu je veľmi zdĺhavé tréningovanie a veľkosť natrénovanej siete. Pri natrénovaní na dáta ImageNet, ktorá obsahuje až 14 miliónov obrázkov, dokáže klasifikovať až 1000 rôznych objektov s presnosťou 92,7%.



Obr. 3.1: Architektúra VGG-16 [7] (upravené)

### 3.3.3 MTCNN

MTCNN alebo Multi-Task Cascaded Convolutional Neural Network [48] je algoritmus, ktorý detekuje na obrázku nie len tvár, ale aj oči, nos a ústa. Algoritmus pozostáva z troch štádií pričom v každom štádiu je jedna konvolučná sieť. Prvým štádiom je detekcia všetkých možných ohraničení, ktoré pravdepodobne obsahujú tvár. Konvolučná neurónová sieť využívaná v prvom štádiu sa volá P-Net a je zložená z 5 konvolučných vrstiev. Druhým štádiom je využitie R-Net, čo je ďalšia konvolučná neurónová sieť, ktorá odfiltruje nesprávne ohraničenia tváří a vyberie už výsledné ohraničenie tváre. R-Net využíva 3 konvolučné vrstvy a 3 plne prepojené vrstvy. V treťom štádiu sa využije tretia konvolučná neurónová sieť nazvaná O-Net, ktorá obsahuje 4 konvolučné vrstvy a 4 plne prepojené vrstvy. O-Net vráti detekované ohraničenia tváří, ako veľmi si je istá každou tvárou a ešte navyše vráti aj 5 spresňujúcich bodov na tvári, ktoré určujú oči, špičku nosa a kútiky úst.

### 3.3.4 ASMNet

ASMNet [24] je algoritmus využívajúci konvolučné neurónové siete, ktorý detekuje antropometrické body na tvári a zároveň aj to, ako je daná tvár otočená. Používa svoju vlastnú stratovú funkciu z názvom ASM-Loss. ASM-Loss využíva porovnanie predikovaných bodov

s bodmi generovanými pomocou ASM. Hlavnou stratovou funkciou je MSE. Postupne sa znižuje váha ASM-Loss a využíva sa len MSE aby sa neurónová sieť viac sústredila na originálne body. Trénovanie s využitím ASM-Loss vedie k zvýšeniu presnosti algoritmu. Výhodou tohto algoritmu je, že je malý, rýchly a aj napriek tomu dostatočne presný.

### 3.3.5 Deep Convolution Network Cascade

Algoritmus [43] využíva tri úrovne konvolučných neurónových sietí. Už pri prvej úrovni robí celkom presné predikcie aj pri veľmi náročných obrázkoch, ako sú rôzne uhly tváre, zlé svetelné podmienky, alebo aj deformácie spôsobené mimikou tváre. Na tejto úrovni si dovoľí detekciu bodov s vyššou mierou nepresnosti, pretože ďalšie 2 úrovne slúžia na získanie väčšej presnosti. Tieto úrovne si berú na spracovanie len oblasť okolo predikovaného bodu z predchádzajúcej úrovne a na výstup vrátia novú predpoveď.

V prvej úrovni využíva 3 konvolučné neurónové siete, ktoré na vstup dostanú oblasť tváre. Prvá konvolučná neurónová sieť detekuje 5 bodov, ktorými sú stredy očí, špička nosa a kútiky úst. Druhá konvolučná neurónová sieť detekuje len oči a nos a tretia konvolučná neurónová sieť detekuje kútiky úst a špičku nosa. Predpovede všetkých troch konvolučných neurónových sietí sú priemerované a detekovaný bod sa predá ďalšej úrovni. Všetky tri konvolučné neurónové siete majú rovnakú štruktúru, ktorá spočíva v 4 konvolučných vrstvách, medzi ktoré sú vložené 3 max-poolingové vrstvy a zakončujú to dve plneprepojené vrstvy.

V druhej a tretej úrovni sa nachádza až 10 konvolučných neurónových sietí, pretože pre každý bod sú vytvorené až dve konvolučné siete. Každá konvolučná neurónová sieť v týchto úrovniach dostane bod z predchádzajúcej úrovne a rozdielne veľkosti okolia bodu. Všetky konvolučné neurónové siete v týchto úrovniach majú rovnakú štruktúru a sú plytšie ako v prvej úrovni. Obsahujú len 2 konvolučné vrstvy spolu s 2 max-poolingovými vrstvami a zakončujú to dve plne prepojené vrstvy. Každá neurónová sieť vráti 2 čísla, ktoré určujú x-ovú a y-ovú súradnicu detekovaného bodu.

## Kapitola 4

# Návrh algoritmu

Cieľom navrhnutého programu je detekovať antropometrické body na tvári a následne urobiť analýzu tváre s použitím rôznych indexov v sade obrázkov, kde je tvár vyobrazená v rôznych rokoch života. Výstupom programu budú grafy vývoja pomerov rôznych vzdialeností medzi detekovanými antropometrickými bodmi v čase a ilustrácia detekovaných bodov na obrázkoch.

Pre analýzu tváre najskôr potrebujem získať tvár zo snímku. Túto tvár získame pomocou tvárového detektoru Multi-task Cascaded Convolutional Networks (MTCNN) 3.3.3, ktorý nám vráti región tváre a 5 základných antropometrických bodov, ktoré sa nevyužijú. Tvár sa predspracuje, tak ako sa predspracovávali vstupné tréningové dáta, aby model dostal dáta, na ktoré bol trénovaný. Tento model vráti 68 bodov na tvári. Počas samotnej analýzy nebudem pracovať so všetkými bodmi, pretože na analýzu budem potrebovať iba body, ktoré sú popísané v časti 2. V tejto chvíli je snímok s tvárou pripravený na analýzu, kde sa spočíta vzdialenosť konkrétnych bodov, ktoré si určím na základe bodov z 2.1.

### 4.1 Model na detekciu tváre a antropometrických bodov

Na určenie antropometrických bodov sa využije neurónová sieť. Túto sieť treba navrhnuť a následne natrénovať pomocou tréningových dát. Tréningové dáta predstavujú konkrétne snímky tváre a určené body na nich, ktoré sa považujú za čistú pravdu. Ako počiatočný model som použil residuálnu neurónovú sieť alebo RESNET, ktorú využíva viacero štúdií[42, 30, 47] ako základ pre detekciu bodov na tvári.

#### 4.1.1 RESNET

RESNET je model hlbkej neurónovej siete vytvorený na klasifikáciu objektov v obrázkoch. Využitím residuálnych blokov v sieti získame presnosť modelu so zvyšujúcim sa počtom vrstiev v sieti. Bez použitia týchto blokov sa zvyšuje tréningová chyba s pribúdajúcim počtom vrstiev.

Residuálny blok je sčítanie vstupu residuálneho bloku a výstupu naukladaných konvolučných vrstiev v tomto bloku. Tento blok sa delí na dva v závislosti od hĺbky siete. Základný blok obsahuje dve konvolučné vrstvy s jadrom o veľkosti  $3 \times 3$ , posunom o  $1 \times 1$  a počtom filtrov v závislosti, ktorú etapu a ktorý blok popisujeme. Počiatočný počet filtrov je 64 a každou etapou sa zvyšuje dvojnásobne. Obsahuje dávkovú normalizáciu a aktivačnú funkciu ReLU. Aby sa zamedzilo zmenšeniu vstupu, tak sa použije nulová výplň na hraniciach vstupu o veľkosti 1. Tento základný blok sa používa v sieti Resnet-18 a Resnet-34, pričom

číslo za názvom znamená počet vrstiev. Druhý typ bloku nazývaný bottleneck blok sa líši od základného tak, že obsahuje o jednu konvolučnú vrstvu viac a vrstvy majú zmenené parametre. Prvá a posledná konvolučná vrstva v bottleneck bloku má jadro o veľkosti 1 x 1 a stredná 3 x 3. Počet filtrov je taktiež závislý v akej etape sa nachádzame, ale posledná konvolučná vrstva obsahuje štvornásobok počtu filtrov ako predchádzajúce dve.

Poslednou vrstvou je plne prepojená vrstva obsahujúca počet výstupov. Ešte pred plne prepojenou vrstvou nastáva globálny pooling priemerom, ktorý urobí priemer z každej príznakovej mapy vytvorenej z predchádzajúcej vrstvy o počte filtrov. Globálny pooling zredukuje celú mapu na jedno číslo, pričom klasický pooling nám iba zmenší vstup, ale ponechá dimenzie. Keďže RESNET bol navrhnutý na klasifikačný problém, tak výsledkom je výstup z aktivačnej funkcie softmax, ktorá nám vráti pravdepodobnosti, aký objekt sa na obrázku nachádza.

### 4.1.2 Natrénovanie modelu

Pre natrénovanie modelu na detekciu antropometrických bodov som využil Resnet-50, pretože sa pomerne rýchlo trénoval a mohol som opakovane trénovať a skúšať rôzne parametre, ako učiaci sa krok, normalizácia dát, počet epochov a menenie náhodných transformácií trénovacích dát. Resnet bol primárne navrhnutý na klasifikáciu rôznych objektov. Aby som Resnet mohol využiť na detekciu bodov musel som upraviť vstup a výstup modelu, aby na vstupe očakával dáta, ktoré mu poskytnem a na výstupe mi dal pozície bodov a nie pravdepodobnosť, či sa na obrázku nachádza nejaký objekt.

Vstup je nastavený tak, aby prijímal dáta čiernobieleho obrázku o veľkosti 224 px x 224 px. Pre zvýšenie efektivity trénovania sa nastavilo predspracovanie vstupu. Toto predspracovanie obsahuje transformáciu na čiernobiely obrázok, normalizáciu dát do mierky od -1 do 1, zväčšenie alebo zmenšenie na veľkosť 224 px x 224 px. Pre trénovanie modelu dataset prejde náhodnou transformáciou, pretože potrebujem zvýšiť rôznorodosť dát aby model vedel detekovať body nezávisle na otočení hlavy, popřípade kvality fotografie. Náhodná transformácia obsahuje náhodnú rotáciu obrázkov a náhodné zmenenie intenzít jednotlivých pixelov obrázka.

Výstup modelu je upravený zrušením aktivačnej funkcie softmax, pretože nepotrebujeme pravdepodobnosť, čo sa tam vyskytuje, ale konkrétne pozície, kde sa dané body nachádzajú. Nastavenie výstupnej plne prepojenej vrstvy je urobené tak, aby počet výstupných hodnôt nebol 1000, ale len 136, pretože chcem detekovať 68 bodov na tvári a každý bod má x-ovú a y-ovú pozíciu na obrázku.

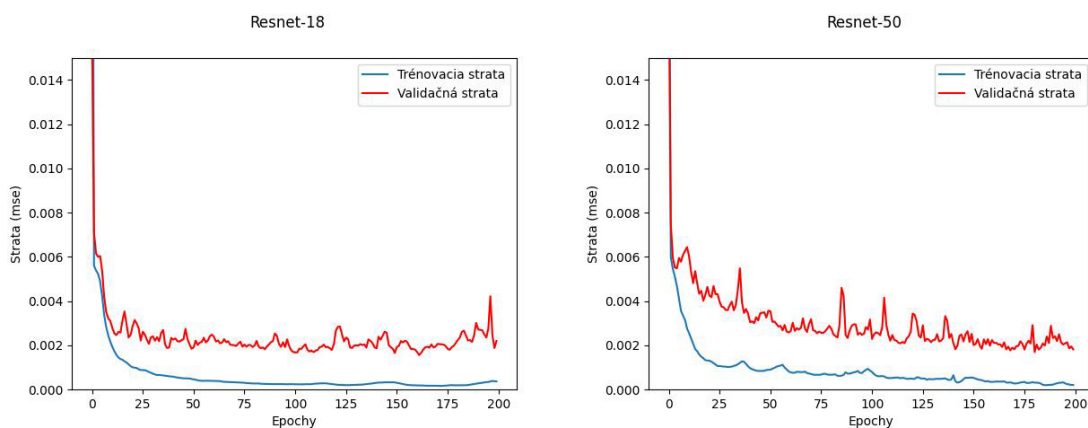
Na natrénovanie som použil oficiálny Dlib dataset obsahujúci 6666 obrázkov ľudí s označenými pozíciami bodov na tvári. Každý obrázok má určenú pozíciu tváre a 68 pozícií bodov na tvári. Dataset je rozdelený na trénovaciu a testovaciu množinu. Trénovacia množina sa použije na natrénovanie modelu a testovaciu množinu využijem na validáciu modelu počas trénovania, aby som vedel ako je model úspešný v detekcii pri neznámych dátach. Načítanie dát z datasetu spočíva v získaní obrázku, pozícií tváre a bodov, pričom všetky tieto dáta sa spracujú pre každý obrázok, kde vyberieme len úsek tváre a pozície bodov transformujeme do relatívnych hodnôt a posunieme ich k nule. Aby sme zvýšili variabilitu dát, tak tieto body spolu s obrázkom sa trochu pootočia o náhodný uhol v rozmedzí  $-20^\circ$  až  $20^\circ$ .

Na natrénovanie modelu je vytvorený trénovací skript, ktorý je určený na spustenie trénovania neurónovej siete s rôznymi parametrami ako sú počet epoch pomocou argumentu `-e [počet]`, učiaci sa krok definovaním argumentu `-lr [desiatinné číslo]`, zložka, z ktorej majú brať trénovacie a validačné dáta určená argumentom `--dataset_dir [cesta k datasetu]`,




zložku, do ktorej sa má uložiť natrénovaný model definuje argument `--model_dir [cesta]`. Ak sa má na konci zobrazíť graf učenia, tak využijeme argument `-shg`, prípadne vie zobrazíť len graf na základe uloženého súboru z predchádzajúceho učenia, ktorý získa z argumentu `--show_history_file [cesta k uloženému súboru]`. Tento trénovací skript som spúšťal v prostredí spoločnosti Kaggle<sup>1</sup>, ktorá poskytuje zadarmo niekoľko hodín využitia ich hardwaru na spustenie rôznych aplikácií v programovacom jazyku Python. Takto som si mohol skúšať trénovanie modelu s rôznymi parametrami, keďže na mojom počítači by som čakal aj niekoľko dní na natréovanie jedného modelu.

Model využitý na detekciu a následnú analýzu bol trénovaný na 200 epoch pričom v každom epochu sa dávkovalo 64 obrázkov. Využitá stratová funkcia bola mse a graf vývoja trénovacej a validačnej straty môžeme vidieť na obrázku č. 4.1, kde vidíme aká strata bola v danom epochu trénovania pre oba modeli Resnet-18 a Resnet-50. Môžeme si všimnúť, že pre model Resnet-50 validačná strata lepšie konverguje v závere trénovania ako pri Resnet-18, kde sa zdá, že začína validačná strata stúpať. Keď si pozrieme porovnanie predikcie na obrázku č. 4.2 môžeme si všimnúť, že model Resnet-50 dosahuje lepšiu presnosť a preto ho využijem pri ďalšej analýze.



Obr. 4.1: Grafy strát (MSE) počas učenia modelov Resnet-18 a Resnet-50


<sup>1</sup><https://www.kaggle.com/>



Obr. 4.2: Porovnanie detekcie bodov medzi referenčnými bodmi a detekovanými bodmi pomocou Resnet-18 a Resnet-50

## 4.2 Analýza tváre

Pre analýzu tváre podľa antropometrických bodov sú dôležité vzdialenosti medzi jednotlivými bodmi. Každý detekovaný bod má určité číslo, ktoré vieme získať jednoduchým zobrazením bodov s daným číslom pri bode. Na základe antropometrie 2.1 si poznačíme dôležité body, ktoré sa budú pri analýze využívať. Na obrázku č.4.3 môžeme vidieť všetkých 68 bodov s číslami a každé číslo reprezentuje číslo daného bodu. Vyznačíme si všetky potrebné čísla detekovaných bodov, s ktorými budeme ďalej pracovať.



Obr. 4.3: Detekované body na tvári pomocou modelu Resnet-50 a vybrané body, ktoré sú použité na detekciu

Medzi vybrané spadajú body definujúce pravé oko a majú číslo 42 (vnútorné oko - endocanthian) a 45 (vonkajšie oko - exocanthian). Pre ľavé oko sú to body 39 (vnútorné oko - endocanthian) a 36 (vonkajšie oko - exocanthian). Bod nasion má číslo 27. Vonkajšie body nosnej oblasti (alare) majú čísla 31 a 35. Antropometrický bod základu nosa (subnasale) sa nachádza pod číslom 33. Pravý kútik úst má číslo 54 a ľavý kútik úst číslo 48. Stred hornej

pery 51 a stred dolnej pery 57. Body gonion na uhle dolnej čelusti majú čísla 4 a 12. Body zygion sa nachádzajú pod číslom 1 a 15. Antropometrický bod gnasion má číslo 8.

Na základe vybraných bodov analýza spočíva v spočítaní a získaní medzikartálnej šírky, biokulárnej šírky, šírky očí, šírky tváre, šírky mandibuly, šírky úst, morfolologickej výšky tváre, spodnej výšky tváre, výšky úst, výšky nosa a následného počítania tvárového indexu, medzikartálneho indexu, indexu nosno-tvárovej šírky, indexu pery, indexu šírky úst, indexu výšky úst a indexu veľkosti brady.

Analýzu tváre robí hlavný skript, ktorý pomocou argumentov sa môže veľmi jednoducho modifikovať, napríklad využitím iného natrénovaného modelu z Tensorflowu, ktorý by mal mať prispôbený vstup aj výstup na základe tréningového skriptu, aby analýza vedela modelu predprípraviť vstupné dáta a využiť výstupné dáta z modelu. Ďalšie modifikácie určujú aké obrázky skript bude analyzovať, či zobrazí výstup alebo ho iba uloží. Argumenty pre spustenie a modifikáciu sú `--model_dir [zložka obsahujúca model]`, ktorý určí použitý model na detekciu bodov, `--images_dir [zložka obsahujúca obrázky určené na analýzu]`, `--experiments [názov]`, spustí experimenty a ukáže grafy vypočítaných indexov v analyzovaných obrázkoch, `--show_points`, ktorý zobrazí očíslované detekované body a vybrané body určené na analýzu, `--model_example`, čo ukáže rozdiely detekcie medzi modelom Resnet-18, Resnet-50 a referenčnými bodmi, `--show_results` zobrazí výsledky na obrazovku, bez použitia výsledky len uloží do zložky "results". Pri použití argumentu `--plot_lines` spolu s `--experiments` zobrazí predpoklad vývoja indexov každej analyzovanej osoby samostatne. Ak sa tento argument nepoužije, tak sa znázorní súhrnný predpoklad vývoja daného indexu.

Každý obrázok môže mať inú výšku, šírku, takže konkrétne vzdialenosti medzi bodmi využijem len na výpočet pomerov medzi nimi. Vzdialenosť dvoch bodov v rovine získam pomocou:

$$f(p1, p2) = \sqrt{(p1_x - p2_x)^2 + (p1_y - p2_y)^2}$$

Výpočtom vzdialenosti dvoch bodov získam hodnoty potrebné na výpočet jednotlivých indexov. Získané indexy využijem na vykreslenie grafov, ktoré mi ukážu vývoj jednotlivých metrických v čase na základe daných obrázkov.

Obrázky program získa zo zložky, v ktorej každý obrázok bude pomenovaný podľa vzoru *menoAvek.JPG*, čím program bude vedieť aký obrázok určuje akého človeka v akom veku. Obrázky spracuje podľa názvu a zoskupí ich podľa rovnakých mien. Následne pre každé meno vie vykonať analýzu tváre v čase, kde vyobrazí body na analyzovaných obrázkoch a následne vytvorí graf ku každej metrike v závislosti na veku.

## 4.3 Použitie technológií

Celý program je napísaný v programovacom jazyku Python verzie 3.9.

### 4.3.1 Tensorflow

Tensorflow [17] je kompletná open-source platforma na strojové učenie. Obsahuje všetky potrebné nástroje na výskum, ale aj vývoj aplikácií, ktoré sú poháňané strojovým učením a umelou inteligenciou. Súčasťou tensorflowu je aj Keras, čo je aplikačné rozhranie obsahujúce všetko potrebné pre hlboké učenie neurónových sietí ako sú vrstvy, optimalizátori, stratové a aktivačné funkcie, metriky. Výhodou tensorflowu je, že pracuje automaticky na grafickej karte, ak je dostupná a nie je potrebná žiadna ďalšia réžia. Základom je Tensor, čo je pole čísel, avšak dokáže pracovať aj na grafickej karte.

### 4.3.2 Numpy

Numpy [29] je knižnica implementujúca efektívnu prácu s poliami v pythone. Numpy poskytuje rôzne matematické funkcie a efektívnu prácu s číslami.

### 4.3.3 Matplotlib

Matplotlib [31] je knižnica na vytváranie vizualizácií v pythone. Knižnicu využívam na zobrazenie a upravenie grafov a obrázkov na prezentáciu výsledkov experimentov.

### 4.3.4 Pandas

Pandas [44] je knižnica určená na dátovú analýzu a manipuláciu s dátami. Implementuje nástroje na načítavanie a ukladanie dátových súborov, rýchlu a efektívnu prácu s dátami.

## Kapitola 5

# Experimenty

Experimenty zamerané na analýzu tváre boli urobené na množine vybraných fotografií z datasetu FG-Net [27], z ktorého sme zobrali snímky a mennú konvenciu obrázkov. V tomto datasete sa nachádzajú snímky jednotlivých ľudí v rôznych rokoch ich života. Z datasetu využijeme vzorky jednotlivých ľudí na experimenty a zistenie ako sa menia pomery antropometrických bodov v čase. Vzorky obrázkov rozdelíme podľa veku do 19 rokov a nad 19 rokov a podľa pohlavia.

Experimenty na zistenie zmeny pomerov som rozdelil podľa veku na deti a dospelých a podľa pohlavia na mužov a ženy. V každom experimente sa nachádza 5 ľudí v rôznom veku svojho života. Pre každého človeka sa prevedie analýza a získajú sa hodnoty indexov, z ktorých sa následne urobí graf. Všetkými vypočítanými indexmi preložíme krivku pomocou lineárnej regresie, ktorá nám určí akým spôsobom sa indexy vyvíjajú.

Prvým experimentom bolo analyzovanie ako sa vyvíjajú jednotlivé pomery pri mužoch do 19 rokov. Na obrázku 5.1 vidíme, že na základe tvárového indexu, mužom sa predlžuje a zužuje tvár. Index veľkosti brady, medzikartálny index a index nosno-tvárovej šírky, index šírky úst nevykazuje výraznú tendenciu zmeny. Index pery a index výšky úst pre mužov do 19 rokov mierne klesá. Nasofaciálny index sa postupom času mierne zväčšuje.

Druhým experimentom bolo skúmanie vývinu pomerov antropometrických bodov pre ženy vo veku do 19 rokov, ktoré je znázornené na obrázku 5.2. Tvárový index, index veľkosti brady, medzikartálny index, nasofaciálny index, index nosno-tvárovej šírky veľmi mierne narastajú v čase, pričom index šírky úst narastá s oveľa väčším prírastkom. Index pery a index výšky úst mierne klesajú.

Tretím experimentom bolo analyzovanie vývoja indexov mužov vo veku nad 19 rokov, ktoré je zobrazené na obrázku 5.3, kde si môžeme všimnúť, že všetky indexy časom sa zväčšujú až na medzikartálny a nasofaciálny. Medzikartálny index zostáva takmer nezmenený a nasofaciálny index časom klesá.

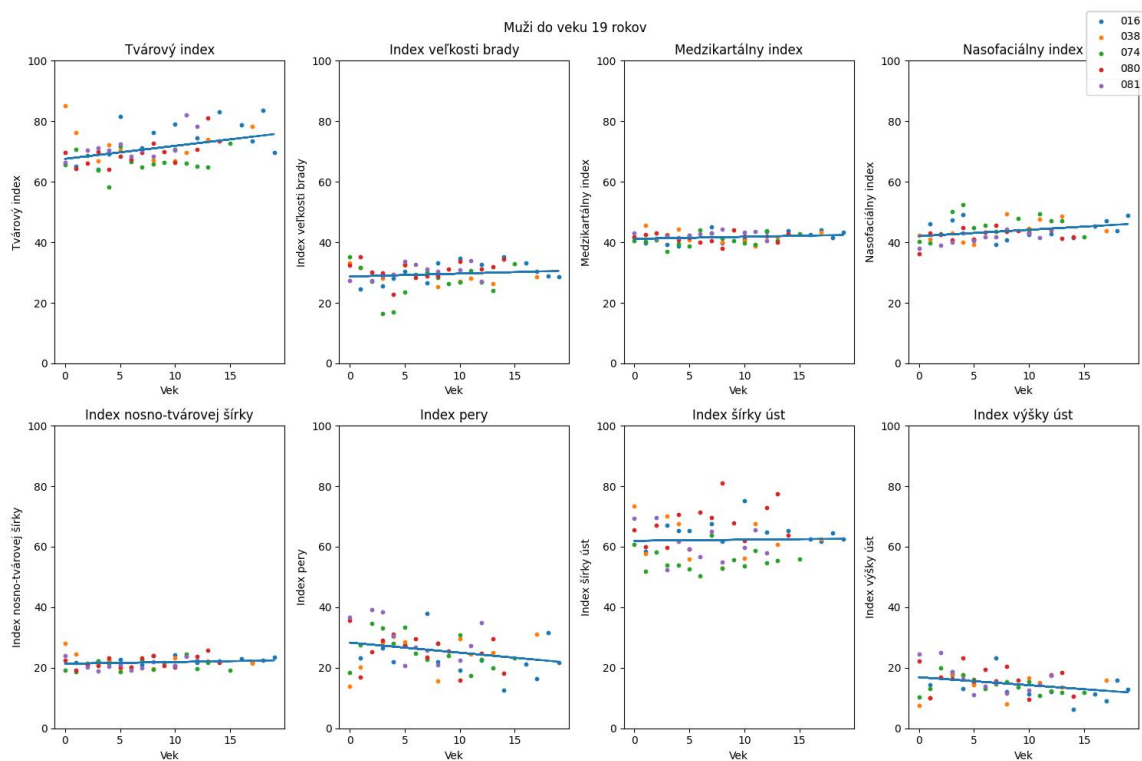
Štvrtým experimentom bolo zistenie vývoja hodnôt indexov žien vo veku nad 19 rokov. Hodnoty indexov sú znázornené na obrázku 5.4. Medzikartálny index zostáva takmer nezmenený v čase a nasofaciálny index časom mierne klesá. Ostatné indexy v čase rastú.

Na základe prevedených experimentov si môžeme všimnúť podobnosti medzi ženami a mužmi. Výsledky žien do veku 19 rokov sa od mužov do veku 19 rokov líšia v tvárovom indexe. Index šírky úst, kde tvárový index sa postupom času zvyšuje, tak ako pri mužoch, ale s menším prírastkom a zase index šírky úst rastie s väčším prírastkom. Pri veku nad 19 rokov je zmena antropometrických pomerov rozdielna, napríklad pri indexe veľkosti brady, kde môžeme vidieť ako pri mužoch rastie, ale pri ženách sa takmer nemení. Ostatné indexy majú pri ženách len menší prírastok, ale hodnota indexov stúpa. V oboch kategóriách

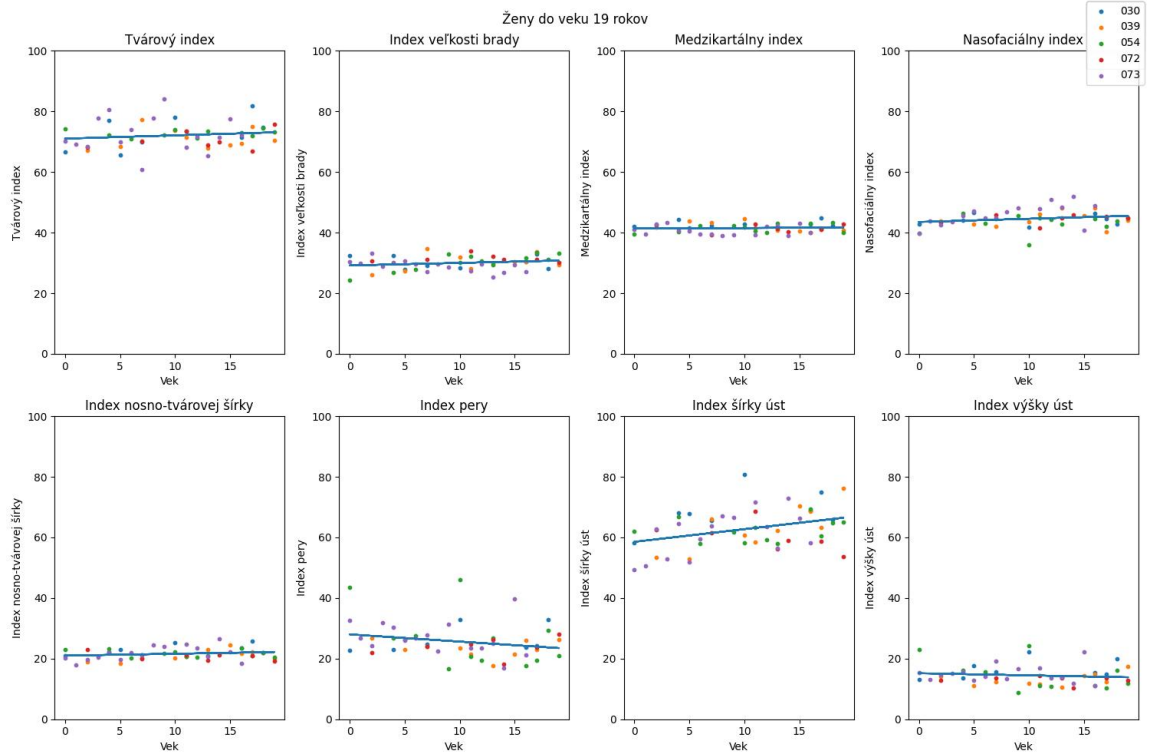
do veku 19 rokov a vo veku nad 19 rokov ženy aj muži majú podobnú zmenu pomerov antropometrických bodov. Týmto sme potvrdili, že obe pohlavia majú podobný starnúci vzor ako predpokladá štúdia, z ktorej som popisoval zmeny medzi pohlaviami v časti 2.6.

Keď sa pozrieme na jednotlivé pohlavia, tak si môžeme všimnúť, že pri mužoch do veku 19 rokov klesá hodnota indexu pery, ale pri veku nad 19 rokov zase stúpa až sa dostáva k pôvodným hodnotám. Index šírky úst sa výrazne nemení, ale v dospelosti narastá. Index výšky úst v mladosti mierne klesá a zase v dospelosti mierne narastá. Nasofaciálny index najskôr narastá a postupom času zase klesá. Index veľkosti brady mierne narastá v čase. Index nosno-tvárovej šírky v mladosti sa výrazne nemení, ale v dospelosti postupom času sa mierne zväčšuje. Tvárový index narastá počas celej doby života.

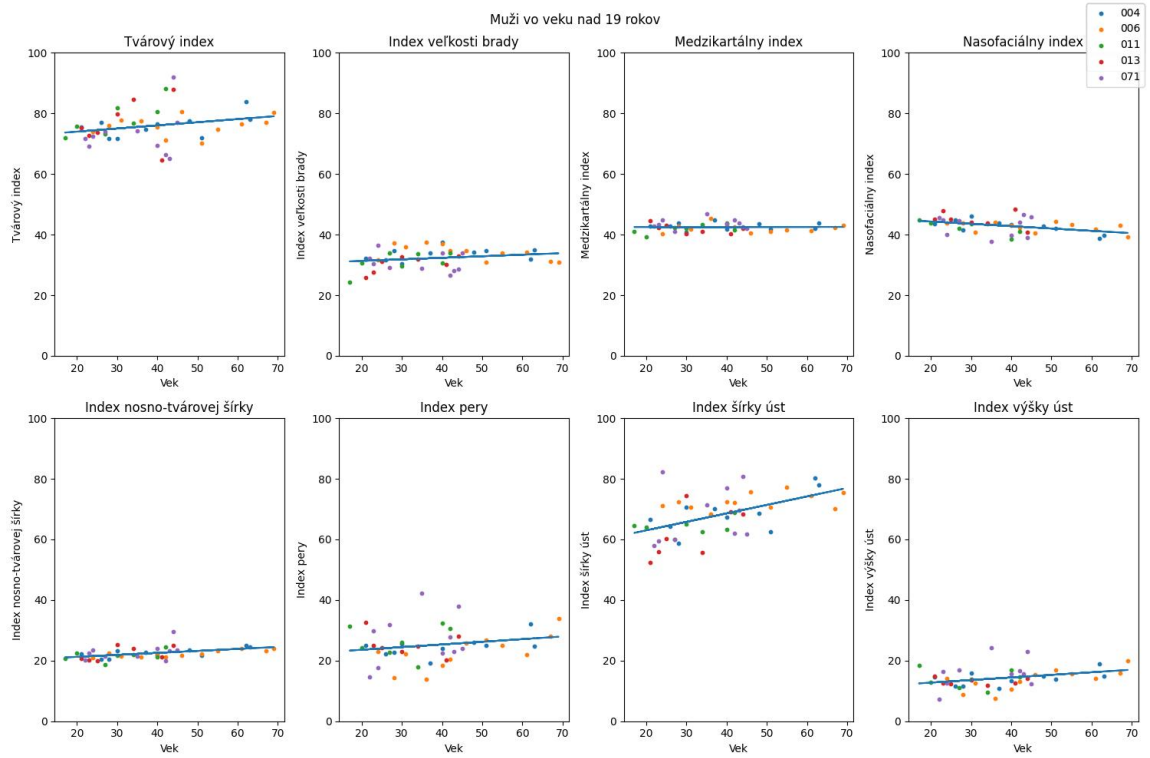
Pri ženách index šírky úst rastie stále. Index výšky úst do 19.roku mierne klesá a potom sa už významne nevyvíja. Nasofaciálny index narastá v mladosti a v dospelosti postupne klesá. Tvárový index zvyšuje svoju hodnotu v čase. Index pery najskôr klesá a v dospelosti sa nepatrne zvyšuje. Index veľkosti brady pri ženách veľmi nepatrne rastie a v dospelosti sa ďalej nevyvíja.



Obr. 5.1: indexy mužov do veku 19 rokov

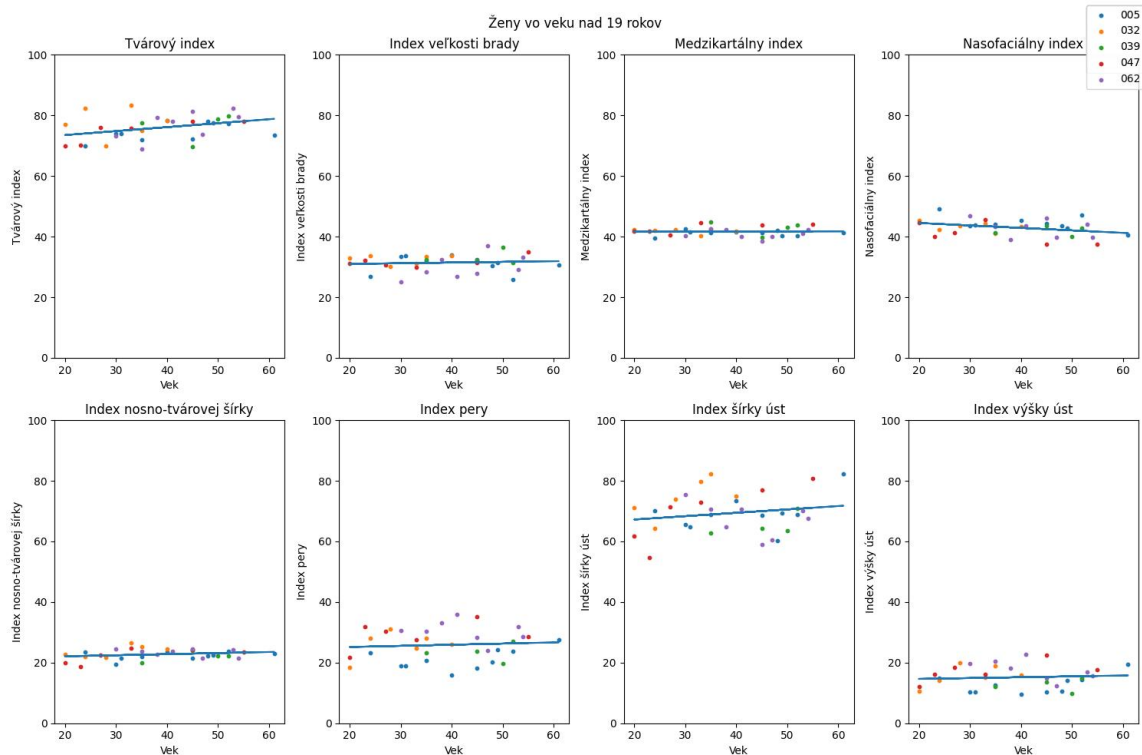


Obr. 5.2: indexy žien do veku 19 rokov



Obr. 5.3: indexy mužov vo veku nad 19 rokov





Obr. 5.4: indexy žien vo veku nad 19 rokov

## 5.1 Diskusia

Na základe prevedených experimentov si môžeme všimnúť, že sa nám pomerne s veľkou odchýlkou menia merané indexy v čase. Táto odchýlka môže byť spôsobená dvomi faktormi. Prvým sú fotografie, ktoré nemajú správne natočenie hlavy, kde môže dochádzať k skresleniu dĺžok, pretože nemáme dodatočnú informáciu o hĺbke daného bodu alebo fotografie kde sa nenachádza neutrálny výraz v tvári. Druhým faktorom je nepresnosť detekcie bodov na tvári použitým algoritmom. Kombináciou týchto dvoch problémov nastanú veľké odchýlky v meraní a znepresňujú finálnu analýzu.

Meranie antropometrických bodov pomocou fotografií nie je metodikou správneho merania. Každá fotografia obsahuje rôzne natočenie tváre do strany alebo predklonenie poprípadne zaklonenie hlavy. Aby sme meranie pomocou fotografií upresnili, všetky fotografie by mali byť vyhotovené za rovnakých podmienok a rovnakým postupom. V metodike merania máme presne určené ako postupovať pri meraní. Rovnako by sme mali použiť definované postupy pri zhotovovaní analyzovaných fotografií. Dôležitou súčasťou pri vyhotovení by mala byť pozícia fotoaparátu a pozícia tváre. Fotoaparát by mal byť na statíve vo výške tváre tak, aby nos bol vo výške stredu objektívu. Využívať by sa mal objektív, ktorý veľmi nedeformuje snímok. Odporúčané pre tento účel sú portrétové objektívy. Dôležitou súčasťou je určite aj to, že fotografovaná tvár by mala byť otočená priamo na fotoaparát aby nedochádzalo k perspektívnemu skresleniu, hlavne pri predklone a záklone hlavy, poprípadne pootočení hlavy do strany. Pootočenie v rovine snímania nepredstavuje problém, keďže body sa posúvajú len v rámci danej roviny a nie je potrebná dodatočná informácia hĺbky. Dobrým spôsobom je štandardizovaná metodika [10] postavenia človeka vzpriamene chrbtom k stene.



Ak už máme dostatočne kvalitné fotografie na prevedenie merania potom je dôležitou súčasťou kvalitná detekcia bodov. Detekciu bodov môžeme vylepšovať pridávaním ďalších neurónových sietí, ktoré by spresňovali detekované pozície bodov na úkor rýchlosti alebo použitie iných modelov neurónových sietí, ktoré by mohli byť presnejšie.

Rozšírením analýzy by mohlo byť využitie fotografií tváre z profilu, kde by sme vedeli sledovať aj ďalšie vlastnosti tváre ako sú dĺžka hlavy, kraniofaciálna výška, dĺžka ucha. Pri rozšírení bude potrebné rozšíriť dataset na detekciu bodov, ktorý bude mať označené body aj na fotografiách z profilu. Pre fotografie tváre by sa do datasetu mohol pridať ďalší bod trichion, ktorý by sa mohol využiť na zistenie výšky čela a fyziognomickej výšky tváre, keďže aktuálne datasety obsahujú síce 68 bodov, ale len v spodnej časti tváre a úplne vynechávajú čelo.

Analýza by sa mohla rozšíriť aj o experimenty rôznych haploskupín alebo rás, kde je problémom získanie obrázkov jednotlivých ľudí rôznych haploskupín v rôznych rokoch ich života. Pomocou týchto experimentov by sme vedeli porovnávať nie len ženy a mužov, ale aj rozdiely medzi jednotlivými rasami ako sa menia antropometrické pomery v čase medzi rôznymi rasami a aj obomi pohlaviami.

# Kapitola 6

## Záver

Cieľom práce bolo preštudovať literatúru, ktorá sa zaoberá antropometriou ľudskej tváre, zistiť ako sa líši ľudská tvár medzi rôznymi skupinami obyvateľstva, zoznámiť sa s rôznymi algoritmi na detekciu bodov z obrázku, na ktorej sa nachádza tvár a navrhnúť algoritmus, ktorý urobí detekciu antropometrických bodov a následne spočíta jednotlivé indexy a urobí analýzu tváre v čase.

Práca je rozdelená na štyri časti, medzi ktoré patrí zoznámenie sa s vedným odborom antropometriou a algoritmi na detekciu tváre a jednotlivých bodov na tvári, návrh algoritmu na detekciu a analýzu tváří zo sady obrázkov, prevedenie experimentov rôznych skupín snímok ľudí.

V prvej časti sme sa zaoberali významom a využitím antropometrie, vymenovali sme si aké antropometrické body sa nachádzajú na ľudskej tvári a kde sa vyskytujú. Zistili sme, že na meranie sa používajú predpísané postupy, metódy a rôzne pomôcky, aby boli namerané údaje objektívne. Odmeraním určitých antropometrických bodov získame vzdialenosti, ktoré môžu byť využité v dizajne a výrobe rôznych produktov. Popísali sme o rozdieloch medzi rôznymi haploskupinami a ako sa tvár mužov, žien, chlapcov a dievčat vyvíja v čase. Oboznámili sme sa o klasifikácii rôznych tvárových súčastí, ktorú určujú rôzne tvárové indexy.

V druhej časti sme zistili, že existujú štatistické modely na detekciu antropometrických bodov, metódy detekcie objektov, detekcie ľudskej tváre, kde sa využívajú hlavne metódy hlbokého učenia neurónových sietí. Dozvedeli sme sa ako neurónové siete fungujú, ako sa delia, s akými dátami vedia pracovať, a čo všetko potrebujú pre ich použitie, ako navrhnúť vlastnú neurónovú sieť. Zistili sme aké modely neurónových sietí sa používajú na detekciu objektov, tváre a bodov na tvári.

V tretej časti sme pri návrhu algoritmu na detekciu bodov využili existujúcu neurónovú sieť Resnet, ktorú sme si upravili podľa potrieb, aby vedela detekovať body na tvári. Z detekovaných bodov sme vybrali tie, ktoré sa využijú na analýzu tváre. Po detekovaní sme vypočítali vzdialenosti medzi bodmi a následne pomery jednotlivých vzdialeností podľa určených indexov.

V poslednej štvrtej časti sme sa venovali experimentom, ktorých cieľom bolo zistiť ako sa menia indexy v čase. Urobili sme štyri experimenty rozdelené podľa veku do 19 rokov, od 19 rokov a podľa pohlavia. V kategórii do 19 rokov nastal významnejší nárast v hodnote indexu šírky úst pri ženách a zase výraznejší nárast v tvárovom indexe nastal pri mužoch. V kategórii nad 19 rokov sú nárasty podobné pri oboch pohlaviach, líšia sa len vo veľkosti, o koľko sa daný index zvýšil. Na základe experimentov sme si všimli pomerne veľké odchýlky

medzi jednotlivými obrázkami tváří, ktoré môžu byť spôsobené buď chybnými obrázkami, kedy je tvár natočená alebo nepresnosťou detekcie jednotlivých antropometrických bodov.

# Literatúra

- [1] *Activation Functions in Neural Networks* [online]. Towards Data Science [cit. 2022-04-19]. Dostupné z: <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>.
- [2] *CNN vs. RNN vs. ANN – Analyzing 3 Types of Neural Networks in Deep Learning* [online]. Analytics Vidhya. Dostupné z: <https://www.analyticsvidhya.com/blog/2020/02/cnn-vs-rnn-vs-mlp-analyzing-3-types-of-neural-networks-in-deep-learning/>.
- [3] *Common Loss functions in machine learning* [online]. Towards Data Science [cit. 2022-04-19]. Dostupné z: <https://towardsdatascience.com/common-loss-functions-in-machine-learning-46af0ffc4d23>.
- [4] *Convolutional Neural Networks* [online]. IBM [cit. 2022-01-26]. Dostupné z: <https://www.ibm.com/cloud/learn/convolutional-neural-networks>.
- [5] *Neural Networks* [online]. IBM [cit. 2022-01-26]. Dostupné z: <https://www.ibm.com/cloud/learn/neural-networks>.
- [6] *Various Optimization Algorithms For Training Neural Network* [online]. Towards Data Science [cit. 2022-04-19]. Dostupné z: <https://towardsdatascience.com/optimizers-for-training-neural-network-59450d71caf6>.
- [7] *VGG16 – Convolutional Network for Classification and Detection* [online]. NeuroHive [cit. 2022-01-27]. Dostupné z: <https://neurohive.io/en/popular-networks/vgg16/>.
- [8] *Úvod do konvolučných neurónových sietí* [online]. Umelá Inteligencia [cit. 2022-01-26]. Dostupné z: <https://umelainteligencia.sk/uvod-do-konvolucnych-neuronovych-sieti/>.
- [9] *Obezita – etiopatogeneze, diagnostika a léčba* [online]. Solen Bratislava, Interní medicína pro praxi, 2004 [cit. 2022-04-24]. Dostupné z: <https://www.internimedicina.cz/pdfs/int/2004/09/04.pdf>.
- [10] *Antropometrický instrumentář a metodika měření antropometrických parametrů*. Vydavatelství Univerzity Palackého, 2013 [cit. 2022-05-01]. ISBN 978-80-244-3613-5.
- [11] *Antropometrický bod* [online]. Encyclopaedia Beliana, 2016 [cit. 2021-12-25]. ISBN 978-80-89524-30-3. Dostupné z: <https://beliana.sav.sk/heslo/antropometricky-bod>.
- [12] *Antropometria* [online]. 2019 [cit. 2021-12-24]. Dostupné z: <https://zona.fmed.uniba.sk/uploads/media/Antropometria.pdf>.

- [13] *Antropometrické body* [online]. 2019 [cit. 2021-12-25]. Dostupné z: [https://is.muni.cz/el/sci/jaro2018/Bi6121/um/Antropometricke\\_body\\_3.pdf](https://is.muni.cz/el/sci/jaro2018/Bi6121/um/Antropometricke_body_3.pdf).
- [14] *Antropometrie* [online]. 2019 [cit. 2021-12-24]. Dostupné z: [https://is.muni.cz/el/sci/jaro2019/Bi6121/um/Antropometrie\\_1.pdf](https://is.muni.cz/el/sci/jaro2019/Bi6121/um/Antropometrie_1.pdf).
- [15] *Somatometrie* [online]. 2019 [cit. 2021-12-24]. Dostupné z: <https://is.muni.cz/el/sci/jaro2019/Bi6121/um/Somatometrie.pdf>.
- [16] *Indexy tělesných rozměrů* [online]. 2021 [cit. 2022-05-02]. Dostupné z: [https://is.muni.cz/el/sci/jaro2021/Bi5120c/um/07\\_Indexy\\_telesnych\\_rozmeru.pdf](https://is.muni.cz/el/sci/jaro2021/Bi5120c/um/07_Indexy_telesnych_rozmeru.pdf).
- [17] ABADI, M., AGARWAL, A., BARHAM, P., BREVDO, E., CHEN, Z. et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. Software available from tensorflow.org. Dostupné z: <https://www.tensorflow.org/>.
- [18] COOTES, T. F., EDWARDS, G. J. a TAYLOR, C. J. Active appearance models. In: BURKHARDT, H. a NEUMANN, B., ed. *Computer Vision — ECCV'98*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1998, s. 484–498. ISBN 978-3-540-69235-5.
- [19] COOTES, T. F. An Introduction to Active Shape Models. In.: 2000.
- [20] CRISTINACCE, D. a COOTES, T. Feature Detection and Tracking with Constrained Local Models. In: *BMVC*. 2006.
- [21] DAVIS, J., VALENTINE, T. a DAVIS, R. Computer assisted photo-anthropometric analyses of full-face and profile facial images. *Forensic science international*. Júl 2010, zv. 200, s. 165–176. DOI: 10.1016/j.forsciint.2010.04.012.
- [22] DEUTSCH, C., SHELL, A., FRANCIS, R. a BIRD, B. The Farkas System of Craniofacial Anthropometry: Methodology and Normative Databases. In.: Január 2012, s. 561–573. DOI: 10.1007/978-1-4419-1788-1\_29. ISBN 978-1-4419-1787-4.
- [23] DHALIWAL, J., WAGNER, J., LEONG, S. L. a LIM, C. H. Facial Anthropometric Measurements and Photographs — An Interdisciplinary Study. *IEEE Access*. 2020, zv. 8, s. 181998–182013. DOI: 10.1109/ACCESS.2020.3028694.
- [24] FARD, A. P., ABDOLLAHI, H. a MAHOOR, M. ASMNet: A Lightweight Deep Neural Network for Face Alignment and Pose Estimation. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*. June 2021, s. 1521–1530.
- [25] FARKAS, L., KATIC, M., FORREST, C., ALT, K., BAGIC, I. et al. International Anthropometric Study of Facial Morphology in Various Ethnic Groups/Races. *The Journal of craniofacial surgery*. August 2005, zv. 16, s. 615–46. DOI: 10.1097/01.scs.0000171847.58031.9e.
- [26] FETTER, V. *Antropologie: vysokoškolská příručka*. Praha: Academia, 1967. 498-509 s. Dostupné z: <https://ndk.cz/uuid/uuid:c2047ef0-b66a-11e3-9d7d-005056827e51>.
- [27] FU, Y., HOSPEDALES, T. M., XIANG, T., XIONG, J., GONG, S. et al. Robust Subjective Visual Property Prediction from Crowdsourced Pairwise Labels. In: *IEEE TPAMI*. 2016.

- [28] GAO, Y., NIDDAM, J., NOEL, W., HERSANT, B. a MENINGAUD, J. Comparison of aesthetic facial criteria between Caucasian and East Asian female populations: An esthetic surgeon's perspective. *Asian Journal of Surgery*. 2018, zv. 41, č. 1, s. 4–11. DOI: <https://doi.org/10.1016/j.asjsur.2016.07.007>. ISSN 1015-9584. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1015958416301798>.
- [29] HARRIS, C. R., MILLMAN, K. J., WALT, S. J. van der, GOMMERS, R., VIRTANEN, P. et al. Array programming with NumPy. *Nature*. Springer Science and Business Media LLC. september 2020, zv. 585, č. 7825, s. 357–362. DOI: 10.1038/s41586-020-2649-2. Dostupné z: <https://doi.org/10.1038/s41586-020-2649-2>.
- [30] HOANG, V.-T., HUANG, D.-S. a JO, K.-H. 3D Facial Landmarks Detection for Intelligent Video Systems. *IEEE Transactions on Industrial Informatics*. Január 2020, PP, s. 1–1. DOI: 10.1109/TII.2020.2966513.
- [31] HUNTER, J. D. Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*. IEEE COMPUTER SOC. 2007, zv. 9, č. 3, s. 90–95. DOI: 10.1109/MCSE.2007.55.
- [32] KINGMA, D. P. a BA, J. *Adam: A Method for Stochastic Optimization*. arXiv, 2014. DOI: 10.48550/ARXIV.1412.6980. Dostupné z: <https://arxiv.org/abs/1412.6980>.
- [33] KOUDELOVÁ, J., HOFFMANNOVÁ, E., DUPEJ, J. a VELEMÍNSKÁ, J. Simulation of facial growth based on longitudinal data: Age progression and age regression between 7 and 17 years of age using 3D surface data. *PLOS ONE*. Public Library of Science. Február 2019, zv. 14, č. 2, s. 1–16. DOI: 10.1371/journal.pone.0212618. Dostupné z: <https://doi.org/10.1371/journal.pone.0212618>.
- [34] MATTHEWS, I. a BAKER, S. Active Appearance Models Revisited. *International Journal of Computer Vision*. Marec 2004, zv. 60. DOI: 10.1023/B:VISI.0000029666.37597.d3.
- [35] MELNIK, A. K. A cephalometric study of mandibular asymmetry in a longitudinally followed sample of growing children. *American Journal of Orthodontics and Dentofacial Orthopedics*. 1992, zv. 101, č. 4, s. 355–366. DOI: [https://doi.org/10.1016/S0889-5406\(05\)80329-4](https://doi.org/10.1016/S0889-5406(05)80329-4). ISSN 0889-5406. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0889540605803294>.
- [36] OZDEMIR, S. The Concept of Anthropometric Facial Asymmetry. In:. Január 2012, s. 625–639. DOI: 10.1007/978-1-4419-1788-1\_33.
- [37] REDMON, J., DIVVALA, S., GIRSHICK, R. a FARHADI, A. *You Only Look Once: Unified, Real-Time Object Detection*. 2016.
- [38] ROELOFSE, M. M. An analysis of the metrical and morphological features of South African black males for the purpose of facial identification. In:. 2006.
- [39] ROELOFSE, M., STEYN, M. a BECKER, P. Photo identification: Facial metrical and morphological features in South African males. *Forensic Science International*. 2008, zv. 177, č. 2, s. 168–175. DOI: <https://doi.org/10.1016/j.forsciint.2007.12.003>. ISSN 0379-0738. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0379073807008614>.

- [40] SFORZA, C., LAINO, A., GRANDI, G., TARTAGLIA, G. a FERRARIO, V. Anthropometry of Facial Beauty. In: . Január 2012, s. 593–609. DOI: 10.1007/978-1-4419-1788-1\_31. ISBN 978-1-4419-1787-4.
- [41] SIMONYAN, K. a ZISSERMAN, A. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. 2015.
- [42] SONG, Y., QIAO, X., IWAMOTO, Y., CHEN, Y.-W. a CHEN, Y. An Efficient Deep Learning Based Coarse-to-Fine Cephalometric Landmark Detection Method. *IEICE Transactions on Information and Systems*. 2021, E104.D, č. 8, s. 1359–1366. DOI: 10.1587/transinf.2021EDP7001.
- [43] SUN, Y., WANG, X. a TANG, X. Deep Convolutional Network Cascade for Facial Point Detection. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 2013.
- [44] TEAM, T. pandas development. *Pandas-dev/pandas: Pandas*. Zenodo, február 2020. DOI: 10.5281/zenodo.3509134. Dostupné z: <https://doi.org/10.5281/zenodo.3509134>.
- [45] VIOLA, P. a JONES, M. Robust Real-Time Object Detection. In: . Január 2001, sv. 57.
- [46] WEN, Y. F., WONG, H. M. a MCGRATH, C. P. A longitudinal study of facial growth of Southern Chinese in Hong Kong: Comprehensive photogrammetric analyses. *PLOS ONE*. Public Library of Science. Október 2017, zv. 12, č. 10, s. 1–33. DOI: 10.1371/journal.pone.0186598. Dostupné z: <https://doi.org/10.1371/journal.pone.0186598>.
- [47] YAN, Y., DUFFNER, S., PHUTANE, P., BERTHELIER, A., NATUREL, X. et al. Fine-grained facial landmark detection exploiting intermediate feature representations. *Computer Vision and Image Understanding*. 2020, zv. 200, s. 103036. DOI: <https://doi.org/10.1016/j.cviu.2020.103036>. ISSN 1077-3142. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1077314220300886>.
- [48] ZHANG, K., ZHANG, Z., LI, Z. a QIAO, Y. Joint Face Detection and Alignment using Multi-task Cascaded Convolutional Networks. *CoRR*. 2016, abs/1604.02878. Dostupné z: <http://arxiv.org/abs/1604.02878>.