



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

**INTERAKTIVNÍ NÁSTROJ PRO BIKE FITTING VYUŽÍ-
VAJÍCÍ POČÍTAČOVÉ VIDĚNÍ**

INTERACTIVE TOOL FOR BIKE FITTING UTILIZING COMPUTER VISION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

MATEJ KOČMAN

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. VÍTĚZSLAV BERAN, Ph.D.

BRNO 2024

Zadání bakalářské práce



155110

Ústav: Ústav počítačové grafiky a multimédií (UPGM)
Student: **Kocman Matej**
Program: Informační technologie
Název: **Interaktivní nástroj pro bike fitting využívající počítačové vidění**
Kategorie: Počítačové vidění
Akademický rok: 2023/24

Zadání:

1. Seznamte se s problematikou rozpoznání pózy člověka a přesné lokalizace kloubů.
2. Prostudujte a popište problematiku "bike fitting".
3. Experimentujte s možnostmi využití počítačového vidění a interaktivních uživatelských rozhraní pro efektivní a uživatelsky přívětivé nastavení jízdního kola.
4. Integrujte vyvinuté algoritmy do řešení pro nastavení jízdního kola.
5. Testujte vyvíjené řešení s uživateli a iterativně je vylepšujte.
6. Vyhodnoťte vlastnosti vyvinutého řešení na dostatečném počtu uživatelů / cyklistů.
7. Zhodnoťte dosažené výsledky a navrhňte možnosti pokračování projektu; vytvořte plakátek a krátké video pro prezentování projektu.

Literatura:

- Elisa Păduraru, Fundamentals of Creating a Great UI/UX, Creative Tim, 2022
- Steve Krug: Rocket Surgery Made Easy: The Do-It-Yourself Guide to Finding and Fixing Usability, ISBN: 978-0321657299
- Richard Szeliski. *Computer Vision: Algorithms and Applications*, 2nd ed. ISBN: 978-3-030-34371-2, <https://doi.org/10.1007/978-3-030-34372-9>, 2022.
- Zhe Cao et al.: Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields, CVPR 2017
- Shih-En Wei et al.: Convolutional Pose Machines, CVPR 2016

Při obhajobě semestrální části projektu je požadováno:
body 1.-3, značné rozpracování bodu 4.

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

Vedoucí práce: **Beran Vítězslav, doc. Ing., Ph.D.**
Vedoucí ústavu: Černocký Jan, prof. Dr. Ing.
Datum zadání: 1.11.2023
Termín pro odevzdání: 9.5.2024
Datum schválení: 9.11.2023

Abstrakt

Bike fitting je nastavenie posedu na bicykli často pomocou analýzy videa za účelom zvýšenia komfortu, prevencie zranenia a optimalizácie výkonu. V tejto práci bolo cieľom vytvoriť prototyp aplikácie pre bike fitting, ktorý by nadväzoval na existujúce aplikácie svojho druhu a ponúkol funkčné riešenie na ich vybrané problémy.

Výsledná aplikácia ponúka funkcionality pre spresnenie detekcie pozície, zníženie počtu iterácií pozície pre optimálne nastavenie bicykla a nastavenie optimálnej pózy pre bicykel s obmedzenou možnosťou pre nastavenia.

Aplikácia bola testovaná na užívateľoch a prispela k dosiahnutiu ideálnej pozície už po niekoľkých iteráciách. Výsledná aplikácia je užitočným nástrojom pre domáci bike fitting a práca navrhuje spôsoby ako ju ďalej vylepšovať.

Abstract

Bike fitting is the adjustment of a cyclist's pose on the bike often with the help of video analysis with the aim of increasing comfort, preventing injury and performance optimisation. The goal of this thesis was to create a prototype application for bike fitting, which would follow up on existing applications of its kind and would offer a working solution for chosen problems.

The application offers functionality for increased keypoint detection accuracy, lowering the number of position iterations needed for optimal bike setup and optimal pose setup for a bike with limited setup options.

The application was tested on users and contributed towards reaching an ideal position after a few iterations already. The application is a useful tool for bike fitting at home and the thesis propositions ways of improving it further.

Klíčové slová

bike fit, bike fitting, nastavenie posedu, cyklistika, počítačové videnie, rozpoznanie pózy človeka, užívateľské rozhranie, aplikácia, návrh aplikácie, prototyp aplikácie

Keywords

bike fit, bike fitting, pose optimisation, cycling, computer vision, human pose estimation, user interface, application, app design, application prototype

Citácia

KOCMAN, Matej. *Interaktívni nástroj pro bike fitting využívající počítačové vidění*. Brno, 2024. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce doc. Ing. Vítězslav Beran, Ph.D.

Interaktivní nástroj pro bike fitting využívající počítačové vidění

Prehlásenie

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením pana doc. Ing. Vítězslava Berana, Ph.D. Uvedl jsem všechny literární prameny, publikace a další zdroje, ze kterých jsem čerpal.

.....
Matej Kocman
9. mája 2024

Podakovanie

Ďakujem svojemu vedúcemu, doc. Ing. Vítězslavovi Beranovi, Ph.D. za cenné rady a hlavne mnoho trpezlivosti pri vedení práce.

Obsah

1	Úvod	4
2	Problematika bike fittingu	5
2.1	Princípy bike fittingu	5
2.2	Profesionálny bike fitting	9
2.3	Prehľad bike fittingových aplikácií	10
3	Počítačové videnie pre detekciu pózy človeka	16
3.1	Základné znalosti a pojmy	16
3.2	Doladenie modelu	21
4	Trénovanie modelu pre detekciu kľúčových bodov	23
4.1	Tvorba datasetu	23
4.2	Výber modelu	24
4.3	Trénovanie a porovnanie	25
5	Návrh aplikácie	27
5.1	Ciele aplikácie	27
5.2	Návrh funkcionality a užívateľského rozhrania	28
6	Implementácia aplikácie	33
6.1	Použité technológie	33
6.2	Architektúra kódu	33
6.3	Implementácia, testovanie a iterovanie funkcionalít	34
7	Testovanie	47
7.1	Prvý test	47
7.2	Druhý test	48
7.3	Tretí test	49
7.4	Zhodnotenie	50
8	Záver	51
	Literatúra	52
A	Obsah priloženého pamäťového média	56

Zoznam obrázkov

2.1	Diagram častí cestého bicykla [30].	5
2.2	Zľava doprava - Osky pedálov rôznych dĺžok [18]. Možnosti nastavenia kufrov na pedáloch [22]. Žltou farbou naznačená podložka medzi kufrom a tretrou [18].	6
2.3	Riadidlá a brzdové páčky s bežným sklonom [18]. Kontaktná plocha na vrchu riadidiel je približne vodorovná.	6
2.4	Meranie KOPS [5]. Poloha kolena by mala byť nad oskou pedálu.	8
2.5	Všeobecné doporučené rozsahy uhlov prebrané z profesionálneho bike fittingového systému Retül [18].	8
2.6	Forma na meranie klenby chodidiel (vľavo) [43]. Prikrývka sedla merajúca tlak sedacích kostí (vpravo) [9].	10
2.7	Časť výpisu analýzy mobility cyklistu v aplikácii MyVeloFit [16].	11
2.8	Výpis odporúčaných zmien (vľavo) a časť výpisu analýzy pozície cyklistu (vpravo) v aplikácii MyVeloFit [39][16].	12
2.9	Pracovná plocha aplikácie Bike Fast Fit Elite [10].	13
2.10	Sekcia "Dashboard" v aplikácii Bike Fast Fit Elite [10].	14
2.11	Polia, ktoré zobrazujú namerané hodnoty v aplikácii Bike Fast Fit EZ [11].	15
3.1	Schéma regresie pomocou CNN v modeli DeepPose [42].	17
3.2	Schéma konvolúcie v CNN [8].	17
3.3	Heatmapy generované modelom Stacked Hourglass pre každý kľúčový bod [34].	18
3.4	Princípy algoritmov top-down a bottom-up. Prebrané z [35].	19
3.5	Príklady anotovaných snímok z datasetov (zľava doprava) COCO, MPII a Posetrack, prebrané z [19][7][6].	20
4.1	Príklady zozbieraných snímok vlastného datasetu.	24
4.2	Príklady zozbieraných snímok vlastného datasetu.	26
5.1	Znázornenie bodov, ktoré treba do aplikácie zadať pre potrebu merania KOPS	29
5.2	Znázornenie bodov, ktoré musia užívatelia zadať, aby aplikácia mala znalosť o vektoroch posunu sedlovky a hlavového zloženia	30
5.3	Návrh užívateľského rozhrania	32
6.1	Diagram architektúry MVVM. Prevzaté z [2]	34
6.2	Okná pre zadávanie informácií o pozícii po dokončení inferencie	35
6.3	Reprezentácia riešenia problému nájdenia nového bodu bedrového kĺbu. . .	36
6.4	Reprezentácia prvej časti riešenia problému nájdenia nového bodu pleca. . .	37
6.5	Reprezentácia druhej časti riešenia problému nájdenia nového bodu pleca. .	37
6.6	Užívateľské rozhranie aplikácie	40

7.1	Zobrazenie uhlov pozície užívateľa.	49
-----	---	----

Kapitola 1

Úvod

Bike fitting je proces nastavenia posedu na bicykli. Je dôležitý z hľadiska komfortu a prevencie zranenia, ako aj výkonu na bicykli. Do bike fittingu teoreticky spadá všetko od jednoduchej rady pre nastavenie výšky sedla podľa dĺžky vystrenej nohy až po testovanie polohy v aerodynamickom tuneli.

Vďaka nedávnej pandémie bol zaznamenaný nárast v počte amatérskych cyklistov. Títo cyklisti začínajú jazdiť na cestných bicykloch a častokrát zažívajú bolesti a diskomfort zo zle nastavenej pozície. Vďaka zvyšujúcim sa cenám v cyklistike plynúcich zo zníženej ponuky a zvýšeného dopytu vzniká potreba pre softwarový nástroj pre domáci bike fitting, ktorý by amatérskym cyklistom pomohol s nastavením posedu bez toho, aby museli platiť za drahý profesionálny bike fitting.

Táto práca je pokus vytvoriť funkčný prototyp bike fittingovej aplikácie, ktorá bude schopná výrazne pomôcť v procese domáceho bike fittingu. V kapitole 2 sú popísané metódy bike fittingu pomocou počítačového videnia a aktuálny stav domácich bike fittingových aplikácií. Kapitola 3 obsahuje vedomosti o počítačovom videní pre detekciu pózy človeka, ktoré potrebujeme pre vytrénovanie a použitie modelu pre detekciu a analýzu cyklistickej pozície. Kapitola 4 sa venuje samotnému trénovaniu modelu. V kapitole 5 je opísaný návrh aplikácie vrátane predstavy užívateľského rozhrania. Kapitola 6 obsahuje konkrétnu implementáciu jednotlivých komponent aplikácie a architektúru aplikácie. Kapitola 7 popisuje priebeh testovania na užívateľoch a jeho výsledky.

Kapitola 2

Problematika bike fittingu

Bike fitting je proces nastavenia posedu na bicykli. V kontexte vytvorenia aplikácie pre bike fitting je potrebné mať nasledujúce znalosti o bike fittingu.

Je potreba vedieť, aké rôzne zmeny je možné previesť na bicykli a cyklistovom vybavení tak, aby bola ovplyvnená jeho pozícia a aké metódy existujú na vybranie práve tých zmien, ktoré posed zlepšia.


Ďalej je vhodné sa pozrieť na bike fitting dostupný v cyklistických predajniach, ktorý teoreticky využíva tie najefektívnejšie metódy bike fittingu.

Nakoniec analýza existujúcich bike fittingových aplikácií pre domáce použitie poskytuje vzor, ako tieto efektívne metódy previesť do softwarovej formy použiteľnej doma.

2.1 Princípy bike fittingu

Informácie v tejto podkapitole sú prebrané primárne z [18].

V procese bike fittingu je cieľ zmeniť cyklistov posed na bicykli na ideálny. Na zmenu cyklistovho posedu je potreba previesť také zmeny na bicykli, ktoré nejakým spôsobom menia polohu kontaktných plôch cyklistu s bicyklom. Tieto kontaktné plochy sú tri a to sedlo, pedále a riadidlá s brzdovými páčkami.



Obr. 2.1: Diagram častí cestého bicykla [30].

Polohu týchto kontaktných plôch je možné meniť viacerými spôsobmi. Pre pedále je to dĺžka kľuky a dĺžka osky pedálu. Ďalej sem v prípade nášlapných pedálov patrí aj rozhranie medzi pedálom a treťou, kde sa dá meniť poloha kufrov, vložiť podložka medzi kufor trety a pedál, alebo priamo do trety.



Obr. 2.2: Zľava doprava - Osky pedálov rôznych dĺžok [18]. Možnosti nastavenia kufrov na pedáloch [22]. Žltou farbou naznačená podložka medzi kufrom a treťou [18].

Pri sedle sa mení samotné sedlo, kde sa jednotlivé kusy môžu líšiť tvarom, veľkosťou a materiálom. Pri nastavení sedla sa dá meniť jeho sklon, posun vpred a vzad po vodorovnej osi a posun sedlovky smerom hore a dole.

Riadidlá tiež prichádzajú v rôznych variantách, čo sa týka tvaru a veľkosti, kde pri veľkosti je najdôležitejším parametrom ich šírka. Pri nastavení polohy riadidiel je možné meniť polohu predstavca na hlavovom zložení smerom hore a dole. Je možné meniť aj samotný predstavec, ktorého veľkosť a sklon udáva polohu riadidiel. Tiež sa dá upraviť sklon riadidiel na predstavci a sklon resp. poloha brzdových páčiek, ktoré tiež tvoria kontaktnú plochu s cyklistom.



Obr. 2.3: Riadidlá a brzdové páčky s bežným sklonom [18]. Kontaktná plocha na vrchu riadidiel je približne vodorovná.

V užšom slova zmysle pod pojmom bike fitting rozumieme primárne zmene týchto dvanástich parametrov s cieľom zlepšiť cyklistovi posed. Ďalej je dôležité si ujasniť, ako určiť, či nejaká zmena posed zlepšila.

Evaluačné kritéria pri bike fittingu

V užšom slova zmysle pod pojmom bike fitting rozumieme primárne zmene týchto dvanástich parametrov s cieľom zlepšiť cyklistovi posed. Ďalej je dôležité si ujasniť, ako určiť, či nejaká zmena pozíciu naozaj vylepší.

Pri bike fittingu existujú dva hlavné piliere cieľov. Na jednej strane výkon, do ktorého spadá biomechanická efektivita pedálovania, tzv. „handling“, teda ako dobre sa bicykel ovláda a aerodynamika cyklistu. A druhým pilierom je komfort, kde je dôležitý subjektívny pocit cyklistu, bolesť ktorú potenciálne cíti a prevencia zranení.

Existuje veľa metód bike fittingu na určenie potrebných zmien podľa uvedených dvoch cieľov a je možné ich hierarchicky rozdeliť do niekoľko skupín podľa ich efektivity. Toto rozdelenie taktiež kopíruje ich historický vývoj.sed zlepšila.

Medzi dôležité metódy bike fittingu patria:

- Generické
- Individualizované
 - Statické
 - Dynamické

Generické metódy obsahujú isté pravidlá alebo formulky o tom, ako sa má bicykel nastaviť. Napríklad LeMondova metóda hovorí, že dĺžka vnútorného šva cyklistu vynásobená koeficientom 0,883 by mala odpovedať vzdialenosti medzi stredovým zložením a vrchom sedla. Takéto pravidlo síce funguje pre väčšinu cyklistov s typickými telami, nemusí byť ale vhodné pre cyklistov s netradičnými proporciami tela alebo extrémnymi dĺžkami končatín.

Individualizované metódy berú do úvahy celého cyklistu. A nie len celé telo, ale aj jeho polohu priamo na bicykli, kde cyklistova pozícia na bicykli je najlepšie analyzovaná pomocou uhlov v jeho kĺboch. Práve meranie uhlov v kĺboch je absolútnym základom pre dnešný bike fitting.

Pri meraní uhlov sa používa 6 hlavných kĺbov. Sú to kĺby zápästia, lakta, pleca, kolena, členku a bedrový kĺb. Uhly sa merajú z bočného pohľadu na cyklistu a to primárne v dvoch polohách – s pedálom v kolmej dolnej pozícii a kolmej hornej pozícii. Nemusia sa merať striktné len uhly kĺbov, veľmi užitočným je aj uhol chrbta. Meria sa tiež horizontálny rozdiel polohy kolena a polohy chodidla alebo pedálu. Ten sa meria ako vzdialenosť, nie uhol, a meria sa s pedálom vo vodorovnej polohe smerom dopredu. Toto meranie sa nazýva „Knee over pedal spindle“, alebo skrátene KOPS, demonštrované na obrázku 2.4.

Nech má cyklista akokoľvek nezvyčajné proporcie, analýza pozície podľa uhlov predpisuje pozíciu pre časti tela jednotlivo. A kvôli tomu, že pre každý uhol je rozpísaný istý rozsah optimálnych hodnôt, nie len konkrétna hodnota, je možné nastaviť vhodnú pozíciu aj napriek atypickým proporciám cyklistu alebo limitáciám nastavenia bicykla. Predpokladá sa, že ak uhol v kĺbe spadá do predpísaného rozsahu, pozícia je dostatočne dobrá, čo sa týka výkonu aj komfortu. Doporučené rozsahy uhlov sú na obrázku 2.5.

Ďalším dôležitým poznatkom o bike fittingu podľa uhlov je, že je relatívne jednoduché nastaviť posed s rôznymi prioritami. Všeobecne, čím nižšia pozícia na bicykli, tým viac



Obr. 2.4: Meranie KOPS [5]. Poloha kolena by mala byť nad oskou pedálu.

► RETŮL RECOMMENDED NORMAL RANGES					
MEASUREMENT NOTES	ROAD	MTB	TT	TRI	
Knee angle flexion	108°-112°	110°-115°	110°-115°	110°-115°	
Knee angle extension	35°-40°	35°-40°	37°-42°	37°-42°	
Back angle	on hoods for road 45°	50°	20°	25°	
Armpit angle to elbow	-	-	75°-80°	70°-75°	
Armpit angle to wrist	90°	75°-80°	-	-	
Elbow angle	150°-170°	150°-170°	90°-100°	90°-100°	
Forearm angle	-	-	varies	varies	

Ankling range	-	15°-30°	15°-30°	15°-30°	15°-30°
Ankle angle max (plantar flexion)	near top of pedal stroke	95°-105°	95°-105°	95°-105°	95°-105°
Ankle angle min (dorsi flexion)	near bottom of pedal stroke	70°-80°	70°-80°	70°-80°	70°-80°
Hip angle closed	look for bilateral differences	55°-65°	60°-80°	35°-45°	45°-55°
Hip angle open	look for crank length too	-	-	-	-
Knee forward of foot	-	(-10) - omm	(-20) -	(+50) -	(+50) -

Obr. 2.5: Všeobecné doporučené rozsahy uhlov prebrané z profesionálneho bike fittingového systému Retül [18].

bude cyklista aerodynamický a rýchlejší. Naopak vzpriamenejšia pozícia bude pre väčšinu cyklistov komfortnejšia. Nižšia alebo vzpriamenejšia pozícia sa dá nadefinovať rozdielnou sadou rozsahov optimálnych uhlov.

Nie je možné definitívne určiť, ktoré rozsahy uhlov sú ideálne. Vhodné rozsahy boli odhadnuté rokmi pozorovania, experimentovania a výskumu a záležia aj od mobility samotného cyklistu a priority daného fittingu [29].

Posledné rozdelenie na statické a dynamické metódy je veľmi dôležité. Pri statickej analýze sa meria cyklistova pozícia bez pohybu. Pri dynamickej analýze musí cyklista pedálovať voči odporu.

Najväčší dopad má táto zmena pravdepodobne na zhyb členku. Cyklisti majú prirodzene rôzne štýly pedálovania, ktoré sa nikdy neukážu pri statickej analýze. Zmena v zhybe členku mení uhol, ktorý sa nameria v kolennom kĺbe [21].

Taktiež sa cyklista pri dynamickom bike fittingu celkovo usadí na bicykel inak, ako pri statickom. Je pravdepodobné, že sa zmení presná poloha dotyku so sedlom, ako aj jednotlivé namerané uhly.

Je nevyhnutné poznať rôzne metódy bike fittingu a ich dôležitosť pri nastavení správneho posedu. Jednoznačne najkritickejšou metódou je dynamická analýza uhlov kĺbov cyklistu z bočného pohľadu a tvorí základ každého dobrého bike fittingu. Existujú však ďalšie využívané metódy, aj statické alebo generické, ktoré pomáhajú analyzovať posed cyklistu podrobnejšie. Najlepšie praktiky nastavenia posedu, vrátane týchto iných metód, je možné odporozorovať od profesionálnych bike fitterov. v sú na obrázku 2.5.

2.2 Profesionálny bike fitting

Aj keď sa detaily procedúr jednotlivých bike fitterov líšia, z dostupných zdrojov možno vyčítať bežný postup profesionálneho bike fittingu [36][14][41][33][43].

Postup profesionálneho bike fittingu:

1. Diskusia o zvykoch, cieľoch a problémoch cyklistu.
2. Statické meranie bicykla a cyklistu.
3. Nastavenie kufrov na tretrách, pridanie podložky.
4. Analýza tlaku na sedle a výber správneho sedla.
5. Meranie šírky pliec a riadidiel, výber riadidiel.
6. Dynamický bike fitting podľa uhlov meraných 3D systémom.

V prvotnej diskusii sa fitter dozvedá informácie o cyklistovi ako jeho ciele, čo očakáva a chce zlepšiť týmto bike fittingom, ako často a intenzívne zvykne bicyklovať, aké máva bolesti alebo problémy na bicykli. Tieto informácie umožnia vykonať bike fit na mieru tak, aby bol cyklista spokojný.

Statické merania sa týkajú najmä symetrickosti dolnej časti tela cyklistu. Premeriavajú sa dĺžky nôh pre potenciálnu potrebu vyrovnáť asymetriu podložkou chodidla, rotácia chodidiel pre potrebu kompenzácie rotáciou kufrov a prípadne aj zvolením dlhšej osky pedálu pre pohodlné pedálovanie a meria sa aj klenba chodidiel pre špeciálne podložky podporujúce chodidlá. Meria sa však aj flexibilita zadných stehenných svalov a bedrových ohýbačov pre určenie odporúčaného uhla v bokoch a kolene a vzdialenosť sedacích kostí pre určenie vhodne širokého sedla.

Tieto statické merania a korešpondujúce zmeny majú za úlohu vyrovnáť akékoľvek asymetrie v dolnej časti tela cyklistu. Tieto telesné asymetrie môžu bez korekcie viesť k najrôznejším bolestiam či už kolenách, bedrách, chodidlách, chrbte alebo krku. Bez odstránenia týchto asymetrií sa nemusí tieto bolesti podariť napraviť čisto len úpravou pozície na bicykli.



Obr. 2.6: Forma na meranie klenby chodidiel (vľavo) [43]. Prikrývka sedla merajúca tlak sedacích kostí (vpravo) [9].

Posledným takýmto meraním je šírka pliec. Riadidlá by mali byť proporčne široké ku pleciam, inak môže nastať bolesť v dlaniach, pleciach, krku alebo hornom chrbte.

Až po týchto všetkých meraniach a zmenách prichádza na rad analýza pozície pomocou 3D kamerového systému. Podľa doporučených uhlov a zistených poznatkov o cyklistovi sa cyklistov posed nastaví do optimálnej polohy. Bike fitter je schopný určiť zmeny, ktoré privedú cyklistu do správnej polohy s korektnými uhlami. Nastavuje sa poloha sedla a riadidiel po horizontálnej a vertikálnej osi z bočného pohľadu.

Predný a zadný pohľad môže odhaliť nadmerné kolísanie zo strany na stranu v bedrách a pleciach, alebo horizontálny pohyb kolena. Ak takéto problémy nastanú po statických meraniach a optimalizáciách, pravdepodobne to znamená zlú výšku sedla, ktorú by mala odhaliť analýza uhlov. Každopádne sú to extra dátové body na základe ktorých sa fitter môže rozhodovať a bike fitting personalizovať.

V profesionálnom bike fittingu vidíme oproti základnej dynamickej analýze podľa uhlov pridaný dôraz na statické merania pomáhajúce odhaliť asymetrie v cyklistovej póze a optimalizovať rozhranie medzi cyklistom a bicyklom vo všetkých troch kontaktných bodoch. Profesionálny bike fitter je schopný na základe skúseností a znalostí anatómie riešiť individuálne problémy cyklistu, ktoré môžu pretrvávať aj napriek tomu, že namerané uhly sú v norme.

2.3 Prehľad bike fittingových aplikácií

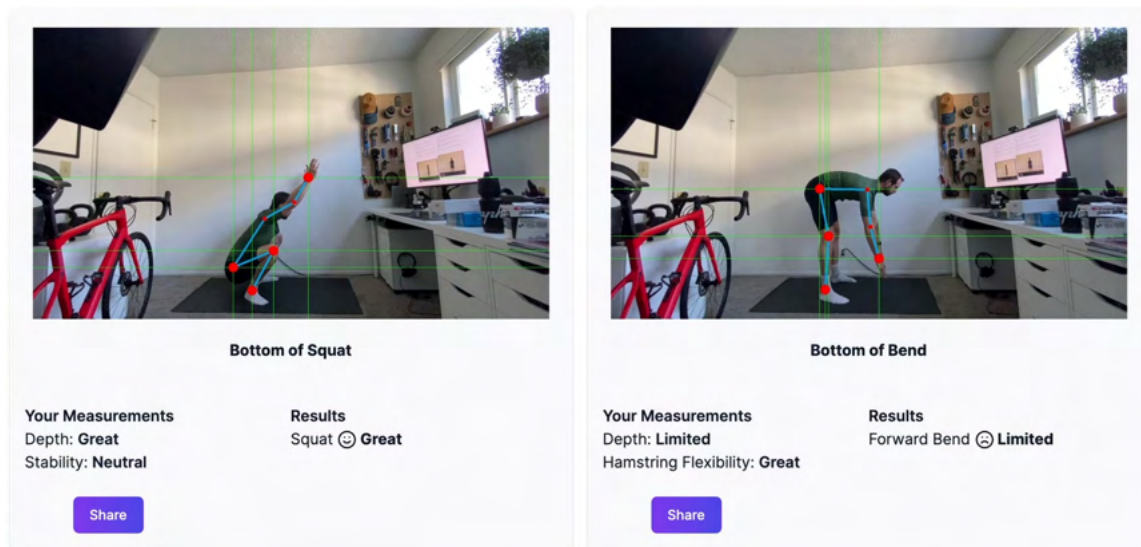
Pre vytvorenie úspešnej bike fittingovej aplikácie je potrebné sa pozrieť na už existujúce príklady. Cieľom je zistiť, aké majú nedostatky voči profesionálnemu bike fittingu a či existujú nejaké výhody. Na trhu sú dostupné primárne dve aplikácie a to webová aplikácia MyVeloFit a mobilná aplikácia pre iOS Bike Fast Fit [32][13].

MyVeloFit

Proces bike fittingu je popísaný na základe nasledujúcich zdrojov [13][27][38][16][39].

Proces aplikácie MyVeloFit začína vyplnením osobných údajov. Do aplikácie treba zadať cyklistovu výšku, váhu, vek a koľko rokov bicykluje. Potom nasleduje test mobility.

Test mobility je prevádzaný pomocou kamery smartfónu. Cyklista sa natočí podľa pokynov ako vykonáva isté cviky a aplikácia pomocou počítačového videnia a detekovania kľúčových bodov vypočíta cyklistovu mobilitu. Test je zobrazený na obrázku 2.7.



Obr. 2.7: Časť výpisu analýzy mobility cyklistu v aplikácii MyVeloFit [16].

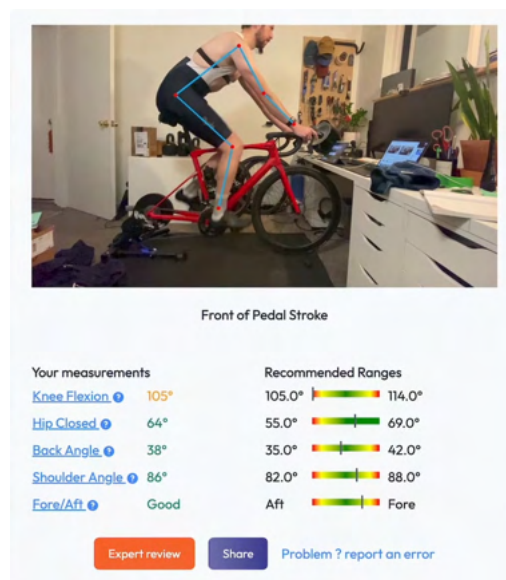
Cyklista vyberie o aký druh bicykla sa jedná, buď cestný, horský alebo časovkársky. Následne cyklista vyberie požadovaný cieľ pre daný bike fit spomedzi troch možností a to komfort, výkon a komfort, výkon. A nakoniec ostáva už len natočiť a nahrať do aplikácie video z bočného pohľadu, ktoré je spracované počítačovým videním pre detekciu kľúčových bodov cyklistu a aplikácia všetky tieto dáta spracuje a vyhodnotí a výsledky zobrazí.

Výpis obsahuje odporúčané zmeny spolu s nameranými uhlami. Odporúčané zmeny majú podobu inštrukcii pre posunutie riadidiel a sedla v horizontálnom a vertikálnom smere. Pri uhloch tu nájdeme aj rozdiel medzi horizontálnou polohou kolena a chodidla resp. pedálu, ktorý je ovplyvňovaný najmä prednozadnou pozíciou sedla a nazýva sa „Fore/Aft“. Aj keď táto metrika je vypočítaná ich proprietárnym algoritmom a nie tradičnou metódou, plní rovnáku rolu [24]. Nachádza sa tu aj snímok so všetkými pozíciami kľúčových bodov a odhadom ťažiska cyklistu a je možné si prehrať celé video s detekovanými kľúčovými bodmi. Výpis je na obrázku 2.8.

Cyklista dostane pokyn previesť doporučené zmeny a iteratívne opakovať tento proces od bodu natočenia videa, kým sa nedostane do pozície v ktorej mu software neponúkne žiadnu ďalšiu zmenu.

Táto aplikácia podobne ako profesionálny bike fitting využíva dynamickú analýzu uhlov z bočného pohľadu v troch hlavných polohách. Všetky zobrazené uhly a vzdialenosti sú známymi metrikami pre bike fitting a majú predpísané odporúčané rozsahy. Jedinou menšou záhadou je odhad ťažiska. Bežne sa zisťuje nepriamo, testom kde cyklista ostane v cyklistickej pozícii a len zdvihne ruky od riadidiel a vystrie ich smerom dozadu. Ak cyklista nedokáže túto pozíciu udržať, jeho ťažisko je príliš vpredu. Rola ťažiska v aplikácii tu nie je nikde popísaná.

Dobré stránky aplikácie sú, že využíva dynamický fitting na základe uhlov. Snaží sa pomocou zadania cieľa bike fittingu, typu bicykla a merania flexibility personalizovať bike fit pre potreby užívateľa, a to upravením doporučených uhlov. Napríklad pri cestnom bicykli s neohybným cyklistom a fitom pre komfort vygeneruje odporúčanie pre oveľa vzpriamenejší chrbát, a tým pádom aj menší uhol pleca, a pravdepodobne nižšiu polohu sedla čo znamená



Obr. 2.8: Výpis odporúčaných zmien (vľavo) a časť výpisu analýzy pozície cyklistu (vpravo) v aplikácii MyVeloFit [39][16].

menší kolenný uhol ako pri cestnom bicykli s agresívnym posedom a ohybným jazdcom, ktorý dostane extrémnejšiu pozíciu.

Spracovanie videa trvá krátko. Vizualizácia výsledkov je intuitívna a ľahko sa číta. Ak nie je užívateľ spokojný, môže navyše zaplatiť za posúdenie profilu jedným z profesionálnych bike fitterov, ktorý pre tento startup pracujú.

Nevýhodami sú, že je potrebné vykonať mnoho iterácií, kým sa dosiahne ideálna pozícia. Ďalej, akonáhle sa iteráciami dostane hodnota uhlu do odporúčaného rozsahu, algoritmus aplikácie považuje daný uhol za vyriešený [31]. Znamená to, že ak začiatková pozícia udáva uhol, ktorého hodnota je vyššia, ako jeho doporučený rozsah, šance sú, že výsledný uhol skončí okolo hornej hranice pre tento uhol. Ak udáva uhol nižší, tak naopak. Toto robí výsledky tejto aplikácie nedeterministické, ak cyklista začína v rozdielnych pozíciách. Aplikácia sa snaží nájsť dostatočne dobrú polohu, namiesto toho, aby sa snažila nájsť najlepšiu polohu.

Napriek tomu, že aplikácia zakomponováva osobné merania mobility, neodstraňuje asymetrie v nastavení cyklistu tak ako profesionálny bike fitting, čo môže viesť k nevyriešeným bolestiam na bicykli.

Poslednou a zdanlivo najväčšou nevýhodou je, že aplikácia dáva odporúčania, ktoré môžu vyžadovať zmenu komponentov. Najlepším príkladom je, keď aplikácia doporučí aby cyklista posunul pozíciu riadidiel dopredu alebo dozadu. Ak cyklista nemá špeciálny polohovateľný predstavec, čo je veľká väčšina cyklistov, tak nemá ako túto zmenu previesť bez toho, aby musel hneď kupovať novú súčiastku. A ak aplikácia vyhodnotí cez ďalšiu iteráciu, že by mal posunúť polohu riadidiel ešte viac, musel by teoreticky kupovať ďalšiu súčiastku. Aplikácia zdanlivo neberie ohľad na limitácie bicykla a cyklista by musel toto odporúčanie ignorovať a prevádzať len ostatné zmeny, kým sa dostane do dostatočne dobrej pozície s uhlami v odporúčaných rozsahoch. Toto ďalej zvyšuje počet potrebných iterácií.

Táto aplikácia celkovo vyzerá užitočne a spôsob zobrazenia výsledkov je veľmi príjemný. Je ľahká na používanie a jej proces je rýchly. Najväčšími problémami sú potreba veľkého

množstva iterácii a nedostatočné možnosti hľadania perfektnej pozície prispôsobenej na limitácie bicykla, alebo iné personalizované požiadavky.

Bike Fast Fit

Informácie o aplikácii boli zozbierané z [13][10][12][11][20].


Podobne ako predošlá aplikácia, Bike Fast Fit tiež využíva dynamický bike fitting pomocou kamery smartfónu, avšak z bočnej aj prednej polohy.

Na začiatok je potreba vytvoriť v aplikácii inštanciu pozície s údajmi ako názov a typ bicyklu. Medzi týmito údajmi je aj vzdialenosť medzi osami kolies a šírka riadidiel. Slúžia ako mierka pre bočný a predný pohľad.

Ďalej nasleduje natočenie videa. Aplikácia dáva užívateľovi inštrukcie ako nastaviť bicykel a kameru tak, aby bol záber kvalitný.

Detekovanie kľúčových bodov nie je implementované pomocou počítačového videnia. Užívateľ musí podľa inštrukcií nalepiť na kľúčové body tela farebné nálepky a potom po natočení videa musí kľúčové body v aplikácii označiť kliknutím na jednotlivé nálepky na video. Až potom si aplikácia uvedomí polohu kľúčových bodov a dokáže ju sledovať aj v ostatných snímkoch videa. Kvôli tomu, že sa jedná o mobilnú aplikáciu s limitovanými zdrojmi, aplikácia umožňuje nasnímať len 2,5 sekundové video.


V drahšej verzii aplikácie, Bike Fast Fit Elite, sa po spracovaní videa zobrazia kľúčové body s uhlami priamo na snímku. K uhlom máme dostupnú vizualizáciu doporučeného rozsahu a dokonca aj zobrazenie najvyššej a najnižšej nameranej hodnoty vo videu. V snímku sa dá odoberať a pridávať zobrazenie všetkých meraných uhlov a užívateľ má možnosť sa posúvať vo videu snímok za snímkom a sledovať zmeny. Aplikácia dokáže zistiť tri hlavné polohy bike fittingu a zobrazí snímok hociktorej z nich.



Obr. 2.9: Pracovná plocha aplikácie Bike Fast Fit Elite [10].

V sekcii „Dashboard“ sa zamkne pohľad na aktuálny snímok a odporúčané rozsahy uhlov sa zobrazia pod snímkom, podobne ako v predošlej aplikácii. Užívateľ má ďalej možnosť hýbať s kľúčovými bodmi kontaktných bodov (zápästie, bedro, členok) spôsobom „drag and drop“ a sledovať korešpondujúcu zmenu uhlov a pozícií ostatných kľúčových bodov.

Od užívateľa sa očakáva, že doporučené zmeny si odvodí z tohto experimentovania sám. Sekcia „Dashboard“ je na obrázku 2.10.



Obr. 2.10: Sekcia "Dashboard" v aplikácii Bike Fast Fit Elite [10].

Pozoruhodne, v lacnejšej verzii aplikácie - Bike Fast Fit EZ, aplikácia ponúka zistenie kľúčových bodov pomocou počítačového videnia bez potreby nálepiek. Tiež ponúka zaujímavú vizualizáciu odporúčaných rozsahov, kde kombinuje dva rozsahy, ktoré dokopy majú istú bike fittingovú sémantiku do 2D poľa a dokonca ponúka aj odporúčané zmeny. Tieto polia sú tri - výška sedla, prednozadná pozícia sedla (fore/aft) a typ/agresivita pozície, kde plochejší chrbát znamená agresívnejšia pozícia.

Pole výšky sedla je kombináciou rozsahov kolenného uhlu a členkového uhlu, pretože podľa aplikácie existuje výskum, ktorý potvrdzuje, že jazdci s vyšším členkovým uhlom potrebujú nižší kolenný uhol, a teda doporučené rozsahy týchto uhlov sú na sebe závislé.


Ďalším poľom je fore/aft, kde existuje relácia medzi vertikálnou polohou kolena voči pedálu a bedrovým uhlom, pretože čím viac posúvame sedlo dozadu, tým viac „zatvárame“ bedrový uhol, ktorý má svoj limit.

Posledným poľom je agresivita pozície, kde je relácia medzi uhlom chrbta a pleca. Tieto sú nastavované polohou riadidiel, kde čím viac posúvame riadidlá dopredu a dole, tým viac máme agresívnu pozíciu s menším uhlom chrbta, ktorá potrebuje vyšší uhol pleca a naopak.

Aplikácia ponúka aj analýzu pohľadu spredu. Na základe nálepiek na kolene a špičke nohy určí do akej miery sa pri pedálovaní hýbe koleno mimo vertikálnu os.

Aplikácia Bike Fast Fit má v porovnaní s MyVeloFit niekoľko dôležitých rozdielov. Voľba nálepiek, ktorá emuluje postupy profesionálnych bike fittingových systémov, je zaujímavá. Výhoda je, že ak užívateľ vie, ako lokalizovať kľúčové body sám, bude mať najpresnejšie meranie, aké je dostupné. Problém je, že to nemusí vedieť. Z toho pohľadu dáva zmysel rozdiel voľby pre základnú a pokročilú verziu aplikácie.

Obe aplikácie ponúkajú prehranie celého videa a zobrazenie troch bike fittingových pozícií, aj keď trochu inými spôsobmi. Dôležitým rozdielom je voľba rozsahov uhlov. Vo verzii Bike Fast Fit EZ, ktorá generuje doporučené zmeny, rozsahy uhlov nie sú modifikované meraním mobility. Ciele bike fittingu sú pokryté rovno v poli pre agresivitu pozície, ktoré



Obr. 2.11: Polia, ktoré zobrazujú namerané hodnoty v aplikácii Bike Fast Fit EZ [11].

je rozdelené na tri sekcie podľa cieľu cyklistu, teda generuje rozsahy uhlov chrbta a pleca pre všetky tri ciele naraz.

Skvelým prvkom v profesionálnej verzii je možnosť hýbať kľúčovými bodmi. Toto umožňuje do istej miery zistiť ideálnu pozíciu pre akúkoľvek zámienku, napríklad predošlá situácia, kde cyklista nemá dostupný predstavec inej dĺžky, alebo chce práveže zistiť, čo by sa stalo, keby si kúpil iný predstavec. Toto je veľká výhoda oproti MyVeloFit, kde užívateľ nemá šancu experimentovať a je odkázaný len na doporučenia aplikácie.

Ďalšou výhodou je, že hýbanie kľúčových bodov v profesionálnej verzii spolu so zobrazením predpokladaných uhlov v zobrazovacích poliach v základnej verzii znamená, že nech užívateľ používa akúkoľvek verziu aplikácie, vždy vidí predpokladané zmeny na pozícii, narozdiel od aplikácie MyVeloFit.

Prehľad dvoch hlavných aplikácií pre bike fitting poskytuje potrebné znalosti rôznych existujúcich prístupov k bike fittingu s pomocou aplikácie. Analýza ich výhod a nevýhod pomáha nájsť možné zmeny pre vytvorenie čo najlepšej aplikácie.

Kapitola 3

Počítačové videnie pre detekciu pózy človeka

V tejto kapitole sú popísané informácie potrebné k doladeniu predtrénovaného modelu pre odhad pózy v 2D pre potreby bike fittingu.

3.1 Základné znalosti a pojmy

Pre potrebu odhadu pózy človeka v 2D existuje historicky viacero prístupov. Medzi klasické prístupy odhadu pózy patria napríklad použitie tzv. *Pictorial Structures Model* alebo *Flexible Mixture-of Parts* [25]. Jednalo sa o modely, ktoré sa snažili matematicky vyjadriť a detekovať plochu častí ľudského tela a vzťahy medzi nimi. Tieto modely neboli veľmi presné v rôznorodých situáciách a chýbala im schopnosť generalizácie.

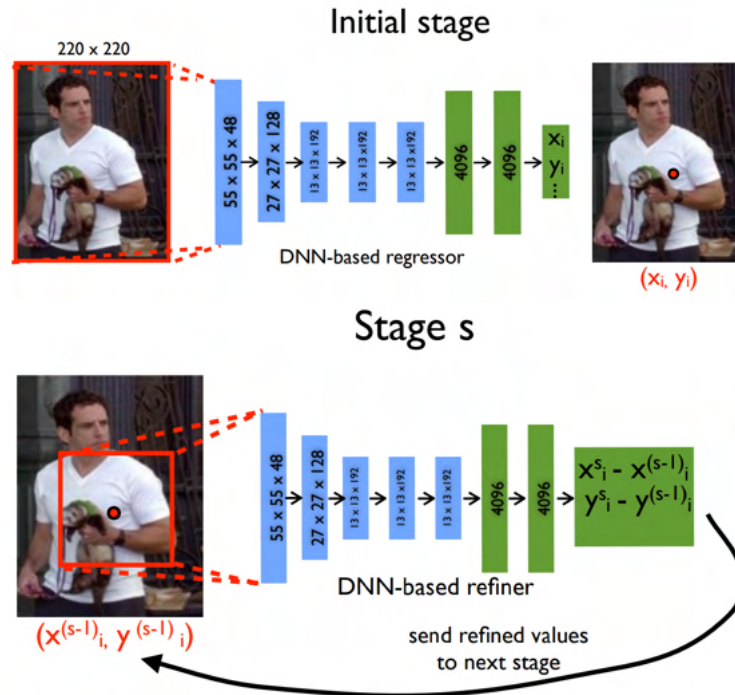
Tento stav zmenil model *DeepPose*, ktorý prvýkrát implementoval konvolučnú neurónovú sieť (CNN) pre detekciu pózy [42].

Konvolučné neurónové siete

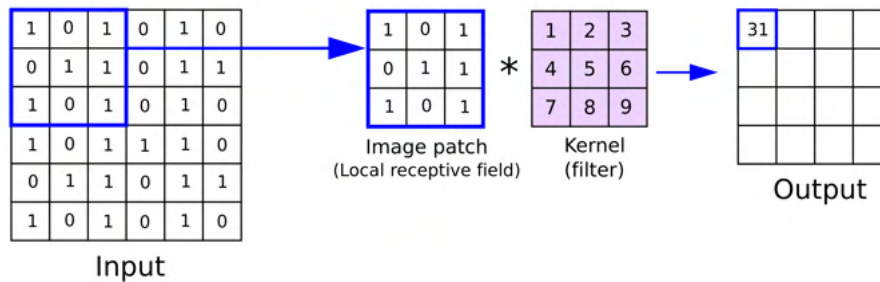
V modeli DeepPose sa problém detekcie pózy chápe ako problém regresie dát resp. pixelov snímky na koordináty kľúčových bodov detekovanej osoby. Táto regresia je dosiahnutá pomocou neurónovej siete, ktorá obsahuje konvolučné aj plne prepojené vrstvy. Po regresii sieťou sú však výsledky stále nepresné. Preto sú trénované aj paralelné siete, znázornené na obrázku 3.1, ktoré berú ako vstup jeden z predošle detekovaných bodov a oblasť snímky okolo daného bodu a pomocou ďalšej regresie sa dostanú na nové, presnejšie predikcie bodov. Prvotná sieť sa teda učí rozpoznávať všeobecné súvislosti ohľadom pózy v snímke, zatiaľ čo nasledujúce siete sa učia rozpoznávať detailnejšie súvislosti spojené s presnou lokalizáciou bodu.

Konvolučné siete, alebo v tomto prípade vrstvy siete, fungujú ako filtre, tiež nazývané kernely, znázornené na obrázku 3.2. Predstavujú sadu váh, ktorými sa pixely jednej časti pôvodnej snímky prenasobia a sčítajú na jednu hodnotu. Po spracovaní všetkých častí snímky vznikne mapa, ktorá môže odhaliť isté črty pôvodnej snímky. V konvolučnej sieti dokážu prvé vrstvy rozpoznávať len jednoduchšie črty, ale pokročilé vrstvy dokážu rozpoznávať aj komplikované prvky.

CNN umožňujú vytrénovať tieto filtre, aby dokázali rozpoznávať pokročilé prvky snímky, ako jednotlivé časti tela. Preto sú základom pre dnešné modely pre odhad pózy.



Obr. 3.1: Schéma regresie pomocou CNN v modeli DeepPose [42].



Obr. 3.2: Schéma konvolúcie v CNN [8].

Každá CNN je definovaná svojou architektúrou. Pod architektúrou rozumieme rozloženie vrstiev neurónov a ich prepojení. Architektúra danej siete je vždy prispôbená na konkrétnu úlohu. Pre odhad pózy existuje mnoho ďalších architektúr okrem DeepPose, napríklad Stacked Hourglass Network, HRNet, OpenPose, ResNet, MobileNet a iné.

Backbones a heads

Architektúru sietí možno ďalej rozdeliť na tzv. *backbones* a *heads*.

Backbone je prvotná časť siete, ktorá pomocou CNN extrahuje zo snímky vysokoúrovňové poznatky o črtách a súvislostiach v snímke, od hrán a tvarov až po komplexné informácie. Spomínané architektúry siete popisujú najmä túto časť siete.

Head je finálna časť siete, ktorá na základe naučených poznatkov backbone vytvorí finálne predikcie a produkuje output siete. Je možné na jeden backbone model vytrénovať

rôzne heads, ktoré na základe naučených poznatkov backbone generujú output s rôznymi počtami kľúčových bodov, alebo v inom formáte a môžu byť teda prispôbené na konkrétnu úlohu.

Dôležitým pokrokom v odhade pózy bolo použitie heads, ktoré nerobia regresiu ku konkrétnym súradniciam bodov, ale k tzv. *heatmaps*. Heatmap je pole hodnôt o veľkosti pôvodnej snímky, kde hodnota každého poľa indikuje pravdepodobnosť, že sa na tom mieste v snímke detekovaný bod nachádza. Heatmap je generovaná pre každý bod.



Obr. 3.3: Heatmapy generované modelom Stacked Hourglass pre každý kľúčový bod [34].

Výhodou tohto prístupu je lepšia presnosť detekcie najmä z komplikovaných snímok, kde sú napr. isté body zahalené, alebo viacerí ľudia v snímke sa prekrývajú. Nevýhodou je zvýšená komplexnosť siete, a tým pádom aj počítačová náročnosť tréningu.

Ďalšou výzvou pri použití heatmaps je kódovanie (encoding) zo súradníc kľúčových bodov do heatmaps a dekódovanie (decoding) z heatmaps na súradnice bodov.

Jednoduchým riešením pre kódovanie je Gaussova distribúcia hodnôt okolo skutočného bodu, kde rozptyl hodnôt musí byť prispôbený veľkosti objektu. Dekódovanie je robené matematicky, kde finálny bod môže byť jednoducho maximum z heatmapy, alebo pre skutočné využitie probabilistického charakteru heatmaps budú funkcie počítajúce výsledný bod zahŕňať aj ostatné hodnoty heatmapy.

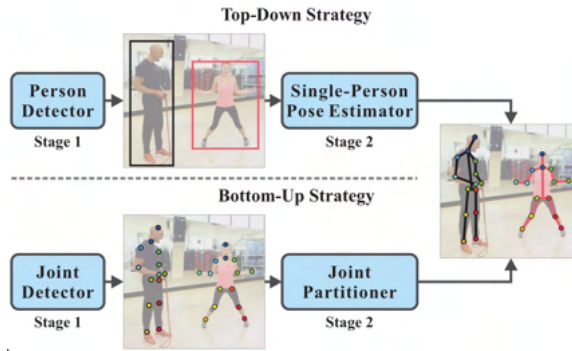
Algoritmy

Úlohou CNN pri odhade pózy je zo vstupnej snímky extrahovať črty rôznych častí tela a pomocou nich detekovať kľúčové body. Rôzne algoritmy, alebo metódy odhadu pózy, používajú CNN rôznym spôsobom, aby z úvodnej snímky dostali čo najpresnejšiu finálnu detekciu ľudí a ich modelov zostrojených z kľúčových bodov pospájaných do kostry. Algoritmy sa môžu od seba líšiť v technikách použitých na skoro každú časť modelu, ktorá bola opísaná, od spracovania a augmentácie vstupných snímok po rozdiel techník regresie hláv.

Pri odhade pózy viacerých ľudí v snímke sa algoritmy svojim prístupom rozdeľujú na dve hlavné kategórie.

Top-down algoritmy používajú najskôr model pre detekciu objektov, aby detekovali každého človeka v snímke. Výstupom tohto modelu sú tzv. *bounding boxy*, teda súradnice obdĺžnika, ktorý na snímke ohraničuje daného človeka. Ďalej sa použije druhý model, ktorý v rámci jednotlivých bounding boxov odhaduje kľúčové body a pozíciu jedného človeka. Tým pádom sa modeluje prístup algoritmov pre detekciu jedného človeka.

Bottom-up algoritmy detekujú v celej snímke potenciálne kľúčové body. Následne sa tieto body na základe rôznych techník rozdeľujú do skupín, kde každá skupina sú kľúčové body jedného človeka. Následne sa body spoja do kostry.



Obr. 3.4: Princípy algoritmov top-down a bottom-up. Prebrané z [35].

Dátové sady

Pre trénovanie CNN modelu pre počítačové videnie je potrebné mať veľké množstvo snímok s anotáciami obsahujúcimi pravdivé dáta, ktoré sa model snaží naučiť inferovať. Táto dvojica snímok a anotácií sa nazýva *dataset* a jeho kvalita výrazne ovplyvňuje výsledok trénovanie modelu.

Datasety sa môžu líšiť svojim zameraním. Okrem inej sady snímok majú datasety rozdiely aj v anotáciách. Pre 2D odhad pózy existuje viacero datasetov, z ktorých vyzdvihnem hlavne 3.

Dataset *COCO* sa skladá z vyše 330 000 rôznorodých snímok [28]. Napriek tomu, že bol dataset vytvorený primárne na úlohu detekcie a segmentácie objektov, je najpoužívanejším datasetom pre odhad pózy, pretože obsahuje vyše 200 000 anotovaných osôb. Anotácie pre odhad pózy obsahujú súradnice 17 bodov, 12 na tele a 5 na tvári, a ku súradniciam každého bodu aj príznak, či bod je na snímke viditeľný, zahalený, alebo vôbec neanotovaný. Ďalej anotácie hovoria, ktoré body sa majú spojiť aby vytvorili kostru.


Dataset *MPII* sa skladá zo snímok vybraných z YouTube videí a je priamo zameraný na odhad pózy [7]. Dataset obsahuje vyše 25 000 snímok s vyše 40 000 anotovanými osobami. Snímky boli vybrané tak, aby zahrňovali rôzne ľudské aktivity, vrátane cyklistiky. K anotovaným snímkam boli v datasete poskytnuté aj neanotované susedné snímky z videa. Anotácie sú tvorené 16 kľúčovými bodmi s podobnými dostupnými informáciami, ako dataset COCO.

Dataset *PoseTrack* je zameraný na odhad pózy viacerých osôb [6]. Je výnimočný tým, že sa skladá z anotovaných videí. Konkrétne 550 videí, ktoré obsahujú 66 374 snímok. Anotácie sú tvorené 15 kľúčovými bodmi. Dataset tiež obsahuje aj neanotované susediace snímky, ktoré majú byť využité aj pri vyhodnocovaní jednotlivých snímok.

Evaluačné metriky

Evaluačné metriky slúžia na vyjadrenie rozdielu medzi bodmi detekovanými modelom a anotáciami. Slúžia pre vyhodnotenie modelu na danom datasete. Evaluačné metriky používané na existujúcich datasetoch sa skladajú z jednoduchších vyhodnotení a konceptov za nimi. Metriky pre vyhodnocovanie kľúčových bodov, ktoré používa dataset COCO, sú založené na evaluačných metrikách používaných pre detekciu objektov.

Confidence score je pravdepodobnosť, ktorá definuje s akou istotou model vyhodnotil detekovaný objekt alebo kľúčový bod ako správne detekovaný. Vyššie hodnoty implikujú vyššiu istotou, že objekt bol správne detekovaný.



Obr. 3.5: Príklady anotovaných snímkov z datasetov (zľava doprava) COCO, MPII a Posetrack, prebrané z [19][7][6].

Metrika *Intersection over Union*, pomer prieniku a zjednotenia, tiež označovaná ako IoU, je definovaná pomocou predpokladaného ohraničenia (*predicted bounding box*) a skutočného ohraničenia (*ground-truth bounding box*) detekovaného objektu. Metrika IoU je definovaná ako

$$IoU = \frac{area(B_p \cap B_{gt})}{area(B_p \cup B_{gt})},$$

kde B_p je predpokladané ohraničenie a B_{gt} je skutočné ohraničenie detekcie [23].

Detekcia objektu sa vyhodnocuje na základe hodnôt jej Confidence Score a IoU ako pozitívna (objekt sa nachádza v ohraničení) alebo negatívna (objekt sa nenachádza v ohraničení) a pravá alebo nepravá. Confidence score sa porovnáva s prahom (*threshold*) a ak je vyššie než prah, detekcia je vyhodnotená ako pozitívna, inak negatívna. V prípade pozitívnej detekcie je s prahom porovnávané IoU. Ak je IoU vyššie než prah, detekcia je vyhodnotená ako pravá pozitívna (*true positive*), inak ako nepravá pozitívna (*false positive*), znázornené v tabuľke 3.1. Negatívne detekcie sa ďalej vyhodnocujú podľa toho, či skutočný objekt mal byť detekovaný (*false negative*) alebo nemal (*true negative*).

		Confidence Score	
		> <i>threshold</i>	< <i>threshold</i>
IoU	> <i>threshold</i>	true positive	negative
	< <i>threshold</i>	false positive	

Tabuľka 3.1: Vyhodnotenie detekcie na základe Confidence Score, IoU a threshold.

Tieto hodnoty sa používajú pre výpočet presnosti (*precision*) a vyvolania z pamäti (*recall*). Precision sa ráta ako podiel pravých pozitívnych detekcií a súčtu všetkých pozitívnych detekcií.

$$precision = \frac{TP}{TP + FP}$$

Recall je definovaný ako podiel pravých pozitívnych detekcií a všetkých, ktoré mali byť skutočne detekované ($TP + FN$).

$$recall = \frac{TP}{TP + FN}$$

Posúvaním prahu pre Confidence Score sa mení vzťah medzi precision a recall, a to modelujeme *precision-recall* krivkou. Túto krivku je možné použiť pri vyhodnotení správania detekcie objektov v závislosti na premenných prahoch.

Pre porovnávanie detektorov sa využíva kvantitatívna metrika *average precision* (skrátene *AP*), ktorá je založená na precision-recall krivke. Precision-recall krivka modeluje správanie na spojitom intervale prahov. Pre výpočet AP sa používa interpolovaná precision-recall krivka. Jeden z prístupov, ktorý počíta AP ako priemer hodnôt precision pre 11 hodnôt recall, definujeme ako

$$AP = \frac{1}{11}(p_i(r_0) + p_i(r_1) + \dots + p_i(r_{10}))$$

kde p_i značí precision pre interpolovanú krivku a $r_j \in (0.0, 0.1, \dots, 1.0)$. AP môžeme tiež definovať ako obsah pod interpolovanou precision-recall krivkou. Pri oboch prístupoch je výsledkom numerická hodnota, ktorá vyjadruje priemernú presnosť detektora.

Ďašia metrika používaná pre porovnávanie detektorov je *average recall* (skrátene *AR*). Táto metrika vychádza z *recall-IoU* krivky, ktorá modeluje vzťah medzi recall a IoU pre $\text{IoU} \in [0.5, 1.0]$. Metriku AR môžeme vypočítať ako 2-krát obsah pod *recall-IoU* krivkou.

$$AR = 2 \int_{0.5}^1 \text{recall}(o) do$$

Detekcia kľúčových bodov (*keypoint detection*) je inšpirovaná metrikami pre detekciu objektov. Miera podobnosti je pri detekovaní objektov definovaná metrikou IoU. Pri detekcií kľúčových bodov sa ako miera podobnosti používa metrika OKS (skrátene z anglického *object keypoint similarity*). Namiesto porovnávania detekovaného objektu so skutočným objektom sa porovnáva množina detekovaných kľúčových bodov s množinou skutočných (anotovaných) kľúčových bodov. Metrika OKS je definovaná nasledovne.

$$OKS = \frac{\sum_i [\exp(-\frac{d_i^2}{2s^2\kappa_i^2}) \delta(v_i > 0)]}{\sum_i [\delta(v_i > 0)]}$$

Metrika OKS na vyhodnotenie podobnosti nevyužíva prienik objektov (ako pri IoU), ale Euklidovskú vzdialenosť detekovaného a anotovaného bodu d_i . Táto metrika je analogická k metrike IoU a využíva sa pre výpočet AP a AR pri detekcií keypointov.

3.2 Doladenie modelu

Pri tréňovaní alebo ladení modelu je snaha zredukovať rozdiel medzi detekovanými bodmi a skutočnými bodmi. Rozdiel medzi nimi sa nazýva strata (*loss*) a je kalkulovaná cez stratovú funkciu (*loss function*), ktorá zahŕňa všetky parametre.

Cieľom tréňovania je minimalizovať stratovú funkciu. Parametre, ktoré rozhodujú o tom, ako bude prebiehať učenie parametrov v modeli, a teda ovplyvňujú výsledok tréňovania, sa nazývajú hyperparametre.

Hyperparametre tréňovania

V tejto sekcii bude vysvetlených niekoľko najdôležitejších hyperparametrov pre doladenie predtréňovaného modelu.

Optimizér

Cieľom optimizéra je minimalizovať stratovú funkciu pomocou algoritmov ako *gradient descent* spätnou úpravou parametrov v modeli [44]. Algoritmus gradient descent vypočíta gradient stratovej funkcie, ktorý hovorí, ktorým smerom funkcia rastie najviac. Algoritmus upraví parametre v opačnom smere. Vzorec pre vypočítanie kroku vyzerá nasledovne

$$w := w - \alpha * \frac{\partial L}{\partial w},$$

kde veľkosť úpravy parametru w je úmerná learning rate α a gradientu $\frac{\partial L}{\partial w}$.

Learning rate, ako vzorec napovedá, je hyperparameter určujúci magnitúdu úpravy parametrov pri tréovaní.

Gradient descent používa na výpočet gradientu výsledky celého datasetu [40]. Ak je dataset príliš veľký, môže sa použiť *stochastic gradient descent*. (SGD). Namiesto počítania gradientu použitím celého datasetu, SGD kalkuluje gradient (a prevádza zmenu parametrov) iba pre jednu náhodne zvolenú hodnotu datasetu. Mini-batch algoritmus je kompromis medzi týmito metódami, a využíva istú podmnožinu dátovej sady.

Batch size, teda počet vzoriek datasetu použitých na jednu iteráciu učenia gradient descent algoritmu, je hyperparameter [15]. Nižší batch size zvýši rýchlosť tréovania a zníži pamäťovú náročnosť algoritmu, ale obetuje trochu presnosti, kvôli náhodnosti výberu z datasetu a malému počtu vzoriek.

Nastavenie správneho learning rate pre SGD je náročné. Riziko príliš vysokej hodnoty je špatná konvergencia, príliš nízky learning rate spomaľuje učenie. Learning rate môže byť optimalizovaný cez *schedule*, ktorý určuje stratégiu postupného znižovania learning rate.

Optimizéry využívajú primárne SGD s rôznymi stratégiami pre optimalizáciu learning rates počas tréovania pre správnu konvergenciu.

Vzťah medzi batch size a learning rates ovplyvňuje charakteristiku tréovania. Stabilita a pomalé učenie veľkého batch size môže byť kompenzovaná vyšším learning rate, zatiaľ čo náhodnosť nižšieho batch size môže byť kontrolovaná pomalším learning rate.

Je dôležité vedieť, že volatilita spôsobená vyšším learning rate alebo menším batch size nie je čisto negatívna. Okrem vyššej rýchlosti môže volatilita pomôcť algoritmu sa vyslobodiť z istých lokálnych miním.

Tréovanie môže byť opakované tak, aby celý dataset prešiel modelom viackrát. Jeden prechod sieťou celého datasetu sa nazýva epocha a počet epoch je hyperparametrom. Vyšší počet epoch znamená väčšie prispôbenie parametrov modelu tréningom, avšak príliš veľa epoch môže viesť k *overfittingu*, kde model nedokáže naučené príznaky generalizovať na nové dáta, pretože naučené príznaky sú príliš konkrétne pre daný dataset.

Rozdelenie datasetu

Dôležitým hyperparametrom je rozdelenie dát do tréningovej, validačnej a testovacej sady [26]. Tréovacia sada prirodzene slúži na tréovanie modelu. Výsledky z tréovacej sady sú použité na zmenu parametrov modelu, ako bolo opísané vyššie.

Validačná sada bude periodicky vyhodnotená po tréovacej sade pre detekciu potenciálneho overfittingu. Na základe výsledkov z validačnej sady môžu byť iné hyperparametre modelu pozmenené, aby sa predišlo overfittingu.

Testovacia sada je na vyhodnotenie vytrénovaného modelu na nových dátach, ktoré model ešte nevidel.

Kapitola 4

Trénovanie modelu pre detekciu kľúčových bodov

Pre vytrénovanie modelu som na základe doporučenia zvolil knižnicu MMPose v0.28.1. V tejto kapitole budem často referovať rôzne časti jej dokumentácie [37]. Je to open-source knižnica pre odhad pózy, ktorá je súčasťou projektu OpenMMLab zameraného na počítačové videnie. OpenMMLab je založený na knižnici PyTorch [4].

Vytrénovanie modelu vyžaduje použitie špecifickej dátovej sady skladajúcej sa zo snímok podobných tým, ktoré budú užívatelia nahrávať do aplikácie. Po zvolení daného predtrénovaného modelu sa model doladí na tejto dátovej sade, aby bol schopný presne detekovať kľúčové body cyklistu v kĺboch, ktoré sú potrebné pre bike fitting.

4.1 Tvorba datasetu

Dôležitosť doladenia modelu spočíva v rozdieli medzi polohou bodu detekovaného predtrénovaným modelom a bodu, ktorý je skutočne hľadaný v procese bike fittingu. Existujúce modely sú totiž predtrénované na dátových sadách, ktoré síce definujú daných 6 kľúčových bodov, ktoré je potreba pre bike fitting, ale definujú ich v inej polohe. Najviac je toto možné vidieť na bode bedrového kĺbu. Doladenie modelu má za cieľ naučiť model detekovať body na správnom mieste.

Pre doladenie modelu neboli dostupné žiadne datasety snímok s cyklistickými pózami z bočného pohľadu, takže som musel vytvoriť celkom novú dátovú sadu. Ako zdroj snímok boli využité najmä videá z rôznych cyklistických pretekov dostupné na YouTube. Vybrané boli snímky z bočného pohľadu s pedálmi v rôznych polohách, vrátane troch polôh potrebných pre bike fitting. Vybrané boli tiež snímky, v ktorých sa nohy cyklistu opticky čiastočne prekrývajú, alebo snímky s inými vizuálnymi ťažkosťami, aby dotrénovaný model bol presný aj v týchto situáciách. Do dátovej sady boli vložené aj snímky z osobne nahraných videí.

Z každého vybraného úseku videa bolo vytvorených do 5 individuálnych snímok. Celkovo vytvorená dátová sada obsahuje 419 snímok so 110 rôznych úsekov. Dataset je v prílohe.

Aby sa zo snímok stal dataset, je k ním potreba vytvoriť anotácie. Formát anotácií je zvolený po vzore jedného z existujúcich datasetov, s ktorými pracuje MMPose. Konkrétne, pre potreby 2D detekcie ľudskej pózy dokáže MMPose spracovať snímky 7 rôznych formátov datasetov. V návode knižnice MMPose pre vytvorenie vlastného datasetu sa odporúča vytvoriť z dôvodu jednoduchosti anotácie vo formáte COCO.



Obr. 4.1: Príklady zozbieraných snímok vlastného datasetu.

Dôležitejším dôvodom pre výber formátu COCO je počet predtrénovaných modelov na danom datasete. Knihnica MMPose ponúka modely, ktoré sú predtrénované na rôznych kombináciách algoritmov, techník, datasetov, architektúr neurónových sietí. Práve dataset COCO je najpočetnejší vo všetkých týchto kombináciách. Inými slovami, najviac modelov je predtrénovaných na datasete COCO. Tým pádom všetky tieto modely bude možné vyhodnotiť na novovytvorenom datasete s formátom anotácií COCO a tak dostať evaluačné metriky pre ich porovnanie.

Anotácie vo formáte COCO boli vytvorené pomocou nástroja coco-annotator, exportované vo formáte JSON a dáta v súbore boli upravené, aby boli dodržané parametre definované v návode. [17]

4.2 Výber modelu

Výber predtrénovaného modelu knižnice MMPose závisí na vyššie spomínaných kombináciách parametrov. Musí sa vybrať taká kombinácia, ktorej model dokáže detekovať body pre bike fitting najpresnejšie.

Výber som začal som použitím demo skriptov pre inferenciu 2D pózy človeka s vizualizáciou výsledku. Ako vstup boli použité dve osobne nahrané videá pre bike fitting. Všetky výsledné demo videá sú v prílohe.

Na túto prvú experimentáciu boli vybrané modely predtrénované na datasete COCO. Cieľom bolo vyskúšať každý typ algoritmu - pre 2D pózy človeka sú to najmä top-down algoritmy Topdown Heatmap a DeepPose a bottom-up algoritmus Associative Embedding. Pre každý z týchto algoritmov bol vybraný najlepší možný model podľa výsledkov uvedených v dokumentácii, teda jedna konkrétna architektúra s prípadnými technikami tréovania.

Z experimentu bolo evidentné, že pri použití top-down algoritmov vznikol nežiadúci efekt pri detekovaní kľúčových bodov. Pri prehraní videa vyzerajú detekované body veľmi nestabilne. Zmeny v lokácii bodu sú zo snímky na snímku relatívne veľké. Každý bod vyzera, akoby osciluje, alebo sa „trasie“ okolo pravého detekovaného bodu. Táto priemerná pozícia bodu, teda istý stredový bod okolo ktorého detekovaný bod osciluje, vyzera byť pri najlepších modeloch stabilná a presná. Tento jav sa zdá byť aspoň čiastočne následkom detekovaného bounding boxu, ktorý je tiež pomerne nestabilný. Body detekované algoritmom Associative Embedding sú veľmi stabilné a nemajú tento jav.

Vzhľadom na to, že snímky boli anotované vo formáte COCO, bolo ďalej potrebné pomocou dostupného skriptu v knižnici vyhodnotiť tieto vybrané modely na novom datasete. Výsledky z testovania sú v tabuľke 4.1.

Dataset	Algorithm	Backbone	Technique	AP	AR	iterations
COCO	Associative Embedding	HigherHRNet-w48	UDP	0.806	0.854	1.4/s
COCO	DeepPose	ResNet-152	RLE	0.790	0.833	6.6/s
COCO	Topdown Heatmap	HRNet-w48	DarkPose	0.841	0.882	4.5/s

Tabuľka 4.1: Najlepšie modely knižnice MMPose vytrénované na datasete COCO vyhodnotenú na vlastnom datasete

Z dát vyplýva, že najlepší model pre algoritmus Topdown Heatmap detekuje body, ktoré naozaj oscilujú dostatočne málo a presne okolo anotovaných bodov, aby model dosiahol číselne najlepšie výsledky. Topdown algoritmy sa preukázali byť tiež oveľa rýchlejšie.

V druhom experimente som otestoval pomocou demo skriptu aj modely ostatných datasetov. Všetky modely okrem jedného detekovali problematický bod bedrového kĺbu na nepresnejšom mieste, ako modely datasetu COCO. Výnimkou boli modely datasetu MPII, pre ktorý boli dostupné len top-down algoritmy.

Ponúkali sa teda tri možnosti - top-down MPII model, top-down COCO model a bottom-up COCO model. Výhoda MPII modelu je, že bod bedrového kĺbu je detekovaný najbližšie k pravej polohe, ale oscilácia bodov medzi snímkami je ešte horšia, ako pri top-down COCO modeli. Výhoda top-down COCO modelu spočíva v lepšej evaluácii a rýchlosti oproti bottom-up modelu.


Zvolil som bottom-up COCO model napriek výhodám ostatných modelov, hlavne kvôli problému oscilácie. Tým, že je potreba v aplikácii merať uhly kĺbov, oscilácia troch susediacich bodov detekovanej kostry naraz násobí nepresnosť merania uhla medzi snímkami. Považujem výbornú stabilitu bottom-up modelov za najdôležitejšiu výhodu pre presnosť detekcie. Cieľom dotrénovania modelu bude hlavne upraviť polohu detekcie bodu bedrového kĺbu na správnejšiu polohu.

4.3 Trénovanie a porovnanie

Skripty knižnice MMPose potrebujú ako vstup pre potrebu akejkoľvek inferencie konfiguračný súbor. Zatiaľ v ňom bolo treba len zmeniť cestu k datasetu pri testovaní nového datasetu. Avšak v konfiguračných súboroch sa definuje veľa premenných, ktoré majú vplyv práve na trénovanie. Pre dotrénovanie modelu sú dôležité hyperparametre trénovania, ktoré treba upraviť aj podľa návodu v dokumentácii.

Najjednoduchším parametrom bol batch size, pretože veľkosť pamäte mi umožnila maximálne veľkosť 3. Learning rate som na základe návodu v dokumentácii zvolil $5e-4$, čo je nižšia hodnota, ako pri normálnom trénovaní. Počet epoch bol zvolený na základe časovej náročnosti. Zvolených 50 epoch totiž model trénoval približne 11 hodín. Podľa návodu som zvolil evaluáciu po každej epoche. Viacej parametrov nebolo treba meniť.

Výsledky trénovania vyzerali sľubne. Model dosiahol najvyššiu hodnotu AP v 26. epoche a aj podľa očného testu detekuje body na vyskúšaných videách presnejšie. Podarila sa mi spraviť chyba so sigma hodnotami, takže model začal tréning s neprirodzene vysokou aspoň nominálnou presnosťou, čo nenechalo veľa priestoru pre rast, takže graf vyzerá veľmi diskrétno.



Obr. 4.2: Príklady zozbieraných snímok vlastného datasetu.

Model najvyššej AP z 26. epochy a predtrénovaný model som ďalej vyhodnotil na testovacej sade. Doladený model dosiahol hodnoty $AP=0.936$ a $AR=0.957$, zatiaľ čo predtrénovaný model je na hodnotách $AP=0.830$ a $AR=0.863$.

Vzhľadom na dosiahnuté hodnoty a potvrdenie očným testom považujem dotrénovanie modelu za úspešné.

Kapitola 5

Návrh aplikácie

Pri tvorbe návrhu aplikácie som vychádzal z poznatkov o bike fittingu v kapitole 2. Na ich základe som najskôr vyčlenil ciele, ktoré musí aplikácia spĺňať. Následne som postupne navrhoval rôznu funkcionality aplikácie, vrátane použitia modelu vytrénovaného v kapitole 4, kým aplikácia dostatočne nespĺňala vytýčené ciele.

5.1 Ciele aplikácie

Pre vytvorenie úspešného prototypu aplikácie je potrebné vyčleniť ciele, ktoré má aplikácia splniť. V prvom rade je treba zdôrazniť, že v tejto práci nie je zámer vytvoriť aplikáciu s čo najlepším užívateľským rozhraním. Zamiera sa priamo na funkcionality a užívateľské rozhranie nebude optimalizované, pretože nie je priamym predmetom tejto práce.

Axiómom, na ktorom je celá funkcionality bike fittingových aplikácií založená, je že pozícia je lepšia, ak sa namerané hodnoty charakterizujúce pozíciu viacej približujú k odporúčaným hodnotám. Preto je hlavným cieľom aplikácie pre túto prácu pomôcť cyklistovi dosiahnuť čo najlepšiu takúto pozíciu, s čo najväčšou presnosťou, čo najrýchlejšie a pre čo najviac rôznych situácií, ako napríklad rôzna dostupnosť komponentov a možnosť prenastavenia, alebo rôzne osobné preferencie. Každý funkčný komponent aplikácie by mal pomáhať nejakým spôsobom k splneniu tohto cieľa.

Keďže tento prototyp aplikácie je kontinuuácia už existujúcich aplikácií svojho druhu popísaných v podkapitole 2.3, je vhodné pripomenúť ich najužitočnejšiu funkcionality, a to špecificky v kontexte zvoleného cieľa. Je potrebné implementovať túto funkcionality aj v novom prototypu.

Najužitočnejšie prvky existujúcich aplikácií:

- identifikovanie a zobrazenie snímok cyklistu v troch hlavných polohách pre bike fitting s pedálmi v správnej polohe
- generovanie kľúčových bodov z videa z bočného pohľadu pre dynamický bike fitting
 - počítačovým videním
 - pomocou nálepiek
- zobrazenie kľúčových bodov a kostry cyklistu na daných snímkach
- zobrazenie relevantných nameraných hodnôt a ich odporúčaných rozsahov

- možnosť hýbania kľúčovými bodmi s korešpondujúcou zmenou nameraných hodnôt
- generovanie doporučených zmien na bicykli

V tomto zozname významne chýba meranie mobility, ktoré bolo súčasťou aplikácie MyVeloFit a analýza cyklistu z predného pohľadu z aplikácie Bike Fast Fit.

Meranie mobility má za účel zmeniť odporúčané rozsahy uhlov tak, aby vyhovovali danému cyklistovi. Personalizované odporúčané rozsahy uhlov nebudú predmetom tejto implementácie. Cieľom bude vyšetrovať spôsoby, ako sa dostať do odporučených uhlov, nie zisťovať, ktoré to sú. Samozrejme, táto funkcionality je užitočná a môže byť predmetom ďalšej práce a iterácie tohto prototypu.

Analýza cyklistu z predného pohľadu je síce užitočná, ale nie je nutná. Ako bolo spomenuté v kapitole 2, správne nastavenie výšky sedla resp. správny uhol kolena by malo byť dostačujúce riešenie problému kolien, ktoré sa pri pedálovaní nehýbu kolmo hore a dole.

Ďalej je potreba si pripomenúť najväčšie nedostatky existujúcich aplikácií. Snaha ich vyriešiť prinesie nové nápady, ktoré nie sú implementované v existujúcich aplikáciách.

Najväčšie nedostatky existujúcich aplikácií:

- generácia doporučených zmien pre dostatočnú a nie ideálnu pozíciu
- generácia doporučených zmien neberie do úvahy limitácie nastavenia bicykla
- vysoký počet potrebných iterácií k dosiahnutiu dostatočnej pozície

Zoznamy najužitočnejších prvkov a najväčších nedostatkov bike fittingových aplikácií slúžia ako inšpirácia a podnet pre návrh a implementáciu jednotlivých komponentov nového prototypu aplikácie. Aplikácia by mala implementovať všetky prvky prvého zoznamu a riešiť do značnej miery problémy v druhom zozname.

5.2 Návrh funkcionality a užívateľského rozhrania

Táto sekcia je zameraná na generovanie návrhu rôznej funkcionality, ktorá spĺňa vytýčené ciele a rieši nájdené nedostatky. Návrh bude spísaný v poradí cieľov.

Identifikácia a zobrazenie snímok

Zobrazenie snímok bude hlavná časť užívateľského rozhrania. Vzhľadom na to, že bude implementované hýbanie kľúčovými bodmi, by mala snímka zaberáť čo najviac miesta, aby sa s bodmi dalo pohodlne pracovať. Preto som zvolil návrh, kde bude zobrazená jedna veľká snímka v strede užívateľského rozhrania s možnosťou jednoduchého prepínania troch vybraných snímok pozície.

Pre porovnanie jednotlivých pozícií na bicykli musí v aplikácii existovať ich zoznam. Každé nahrané video bude v aplikácii pridané do zoznamu ako nová pozícia a po výbere istej pozície zo zoznamu sa zobrazí v strede užívateľského rozhrania jej vybraná snímka. Nová pozícia v zozname môže byť tiež vytvorená skopírovaním už existujúcej pozície, aby užívateľ nemusel to isté video nahrávať dvakrát.

Pre výber snímok z videa bude použitý detekovaný bod článku. Je to bod, ktorý reprezentuje polohu pedálu. Skript pre inferenciu z videa bude musieť byť upravený, aby bol schopný vybrať a vrátiť snímky s pedálmi v správnej polohe.

Generovanie kľúčových bodov

Pre generovanie kľúčových bodov z videa bude slúžiť skript s doladeným modelom, avšak aplikácia by mala podporovať aj nálepky na cyklistovi. Pre tento účel a aj pre možnosť napravenia inferenciou nepresne detekovaných bodov som navrhol možnosť užívateľa manuálne zmeniť základnú polohu detekovaných bodov.

Táto funkcia bude fungovať podobne ako hýbanie kľúčovými bodmi z aplikácie Bike Fast Fit s tým rozdielom, že body budú od seba nezávislé. To znamená, že pri pohybe bodom sa zvyšok kostry nepohne. Tento individuálny posun detekovaných bodov umožní užívateľovi upresniť body získané inferenciou na ich pravú polohu, alebo polohu nálepiek. Istým spôsobom to bude pripomínať anotovanie snímok, ale priamo v aplikácii.

Po potvrdení zmien sa znovu prepočítajú doporučená na základe novej polohy bodov.

Zobrazenie kľúčových bodov, nameraných hodnôt a ich rozsahov

Na zobrazení kľúčových bodov nie je veľký priestor pre inováciu. Hlavné je body zobrazit výraznou farbou a dostatočne veľkým bodom a spojiť ich čiarami do kostry.

Pre zobrazenie nameraných hodnôt som zvolil spôsob aplikácie MyVeloFit. Obe existujúce aplikácie používajú slider pre zobrazenie doporučeného rozsahu a hodnotu v ňom ako reprezentáciu súčasnej hodnoty uhlu. Navyše je rozsah a súčasná hodnota vyjadrená aj číselne. V aplikácii MyVeloFit sú však slidery pod snímkom a zarovnané, čo je čitateľnejší spôsob oproti aplikácii Bike Fast Fit.

Pri zobrazení nameraných hodnôt existuje jeden problém, a to ako vypočítať horizontálnu polohu kolena voči pedálu, teda meranie KOPS. Toto meranie je jediný dôvod, prečo sa vôbec analyzuje pozícia s pedálmi vo vodorovnej polohe.

Bežný prístup pre dynamický bike fitting je porovnať horizontálnu polohu detekovaného kľúčového bodu kolena a chodidla v mieste dotyku s pedálom. Keďže sa v mojom modeli nedetekujú kľúčové body chodidla, navrhol som, nech si aplikácia od užívateľa vypýta polohu predku kolena a osky pedálu po každom nahraní videa do aplikácie. Toto je vlastne digitálna verzia tradičnej statickej metódy určenia tohto merania.



Obr. 5.1: Znáznornenie bodov, ktoré treba do aplikácie zadať pre potrebu merania KOPS

Nevýhoda tohto prístupu je, že užívateľ musí zadávať informácie navyše. Výhodou je, že sa už nepoužíva kľúčový bod kolena, ale naozajstná poloha predku kolena a nemusí sa dopočítavať odhadom, čo je žiadúce z hľadiska presnosti predikcie ideálnej pozície.

Možnosť hýbania kľúčovými bodmi

Táto funkcionálna je ekvivalentná tej z aplikácie Bike Fast Fit. Pri hýbaní kľúčovými bodmi treba hlavne dodržať fluidný pohyb kostry. Pri hýbaní kľúčového bodu musia byť zvyšné body dopyčítané tak, aby výsledný pohyb kostry odpovedal predvídanej zmene polohy.

Pre presnejšie hýbanie bodmi bude dobré, ak bude možné bod hýbať nie len spôsobom drag and drop, ale bude aj možné zvoliť bod kliknutím a označený bod hýbať pomocou kláves, napríklad šípkami. Toto platí aj pre funkcionálnu zmenu základnej polohy bodov.

Ďalej musí užívateľ vedieť určiť, o akú vzdialenosť posúva každý bod. Preto som navrhol zobrazenie zmeny polohy každého bodu v centimetroch oproti jeho pôvodnej pozícii. Toto zobrazenie bude niekde pri zobrazenej snímke, podobne ako slidery s hodnotami meraní. Užívateľ bude taktiež môcť pomocou tlačidla automaticky resetovať body do základnej pozície.

Kvôli predošle navrhutej funkcionálnu pre zmenu základnej polohy bodov som navrhol, aby toto bežné hýbanie bodmi bolo základným správaním a možnosť zmeny základnej polohy a pohyb bodmi s tým spojený bude umožnený tlačidlom.

Generovanie doporučených zmien

Pre generovanie ideálnych doporučených zmien, ktoré berú do úvahy limitácie nastavenia bicykla, bude musieť aplikácia vedieť informácie o nastaviteľnosti bicykla. Konkrétne je v aplikácii potreba vedieť o koľko centimetrov sa dajú posunúť riadidlá smerom hore a dole po hlavovom zložení, a o koľko sa dá posunúť sedlovka smerom hore a dole, a sedlo na sedlovke smerom dopredu a dozadu. Potom sa musia zistiť konkrétne vektory, po ktorých sa sedlo a riadidlá budú hýbať smerom hore a dole. Tieto informácie bude musieť ku každému videu zadať užívateľ, podobne ako informácie pre meranie KOPS.



Obr. 5.2: Znázornenie bodov, ktoré musia užívatelia zadať, aby aplikácia mala znalosť o vektoroch posunu sedlovky a hlavového zloženia

Pomocou týchto informácií bude aplikácia schopná pomocou algoritmu vytvoriť doporučenia pre zmenu pozície rešpektujúce limitácie bicykla. Algoritmus nájde takú polohu kostry, ktorá minimalizuje odchýlky meraní od ideálnych hodnôt na minimum vo všetkých troch snímkach pozície.

Tiež bude možné hýbať kľúčovými bodmi v smere týchto vektorov. To znamená, že ak užívateľ chce zistiť, ako sa jeho pozícia zmení, ak by napríklad zdvihol sedlovku o centimeter,

môže prepnúť hýbanie bodmi do tohto režimu, kde šípky hore a dole nebudú bod posúvať kolmo, ale po dráhe sedlovky resp. zadaného vektora.

Okrem algoritmu pre doporučenú pozíciu bude aplikácia obsahovať aj algoritmus pre ideálnu pozíciu. Algoritmus bude rovnaký až na to, že nebude brať ohľad na limitácie bicykla. Jednoducho dopočíta body tak, aby merania boli čo najbližšie k ideálnym hodnotám. Bude teda generovať najlepšiu možnú pozíciu pre daného cyklistu.

V užívateľskom rozhraní budú nielen zobrazené doporučené zmeny ako v aplikácii My-VeloFit, ale aj možnosť zmeniť polohu bodov na ideálnu alebo doporučenú pozíciu. Užívateľ bude mať šancu vidieť, aké sú predpokladané výsledné merania po vykonaní zmeny na bicykli.

Vidím potrebu oboch algoritmov v tom, aby užívateľ pochopil, do akej pozície sa ho snaží algoritmus pre počítanie doporučenej pozície dostať. Užívateľ môže zobraziť body podľa doporučených zmien a následne ideálne body a rozdiel medzi nimi ho informuje o tom, kde ho bicykel limituje. To mu môže potenciálne pomôcť rozhodnúť, akú inú súčastku má kúpiť, napríklad dlhší alebo kratší predstavec, sedlovku s iným odsadením a podobne.

Zmena nastaviteľnosti bicykla

V duchu umožniť ďalej užívateľovi čo najviac experimentovať s potenciálnymi pozíciami som navrhol komponent, v ktorom bude jednoduchý výpis nastaviteľnosti riadidiel a sedla. Jedná sa o informácie, ktoré užívateľ zadáva po nahratí videa. V tomto výpise môže užívateľ zmeniť hodnoty. Dôvod pre implementáciu tohto komponentu je rovnaký, ako pre možnosť kopírovania pozície v zozname. V prípade, že užívateľ chce zmeniť tieto hodnoty a nie je implementovaná táto funkcionálna, musí nahráť do aplikácie znovu to isté video a vyplniť všetky údaje po nahraní a zmeniť iba túto jednu vec.

Dôvod prečo by užívateľ chcel zmeniť údaje o nastaviteľnosti pozície je mnoho. Zmenšením alebo vynulovaním údajov o nastaviteľnosti môže podľa osobnej preferencie zafixovať istý kontaktný bod na mieste. Napríklad ak užívateľ nechce zistiť presný kompromis medzi meraniami, ktorý počíta algoritmus pre doporučenú pozíciu, ale chce mať hlavne spodnú časť tela v čo najlepšej polohe, pretože má problémy s kolenom. Skopíruje si svoju pozíciu do novej a po vzore vygenerovaných ideálnych bodov nastaví nový bod bedrového kĺbu na ideálnu pozíciu. Následne zmení nastaviteľnosť sedla na nulové hodnoty. Tým pádom zafixoval bod bedrového kĺbu do pozície, kde má optimálne nastavenú spodnú časť tela a algoritmus pre doporučenú pozíciu dopočíta najlepšiu možnú pozíciu vrchu tela.

Podobné situácie, kde užívateľ potrebuje experimentovať s pozíciou, pretože má individuálne požiadavky, dobre ilustrujú dôvod, prečo som navrhol a implementoval veľa týchto funkcionalít. Nie sú to len individuálne dôvody vymenované k jednotlivým komponentom vyššie, ale aj synergický efekt medzi nimi, kde užívateľ má šancu pomocou kombinácie týchto funkcionalít zistiť veľa poznatkov o svojej pozícii.

Ďalším príkladom je užívateľ, ktorý porovnaním doporučenej a ideálnej pozície zistí, že by mu pravdepodobne pomohol dlhší predstavec. Existujúcu pozíciu môže skopírovať a bod zápästia klávesnicou posunúť dopredu o vzdialenosť, ktorá je rozdielom dĺžok starého a potenciálneho nového predstavca. Zmení základné body na túto novú polohu a aplikácia vypočíta nové doporučené zmeny. Užívateľ môže porovnať novú doporučenú pozíciu so starou a rozhodnúť sa, či sa mu oplatí si kúpiť nový predstavec.

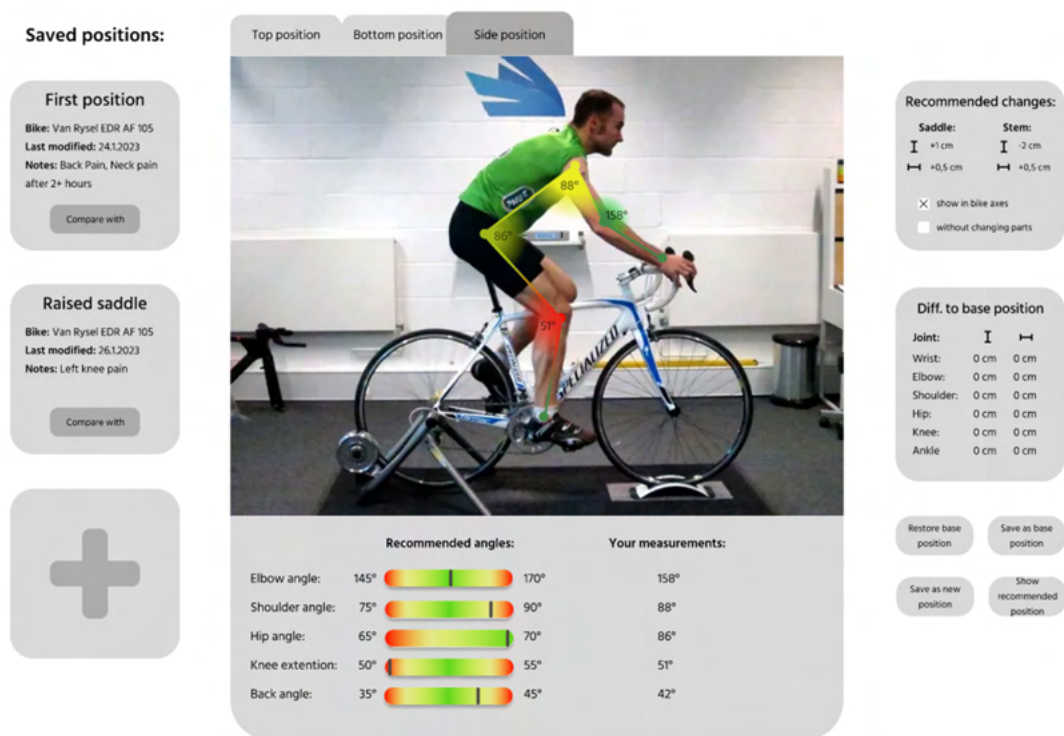
Pointa je, že bike fitting pomocou 2D videa z telefónu je nedokonalá metóda, ktorá má do seba zabudované nepresnosti. Aj keď aplikácia dovoľuje pre neznalých užívateľov jednoducho nahráť video, vyplniť potrebné údaje a dostať doporučenie pre svoj bicykel, umožňuje aj

pomocou všetkej funkcionality zistiť, aký dopad majú malé zmeny základnej pozície alebo dovolenej nastaviteľnosti na doporučené zmeny. Umožňuje vytvoriť rôzne situácie na základe jedného videa a experimentovať s následkami. Mojm presvedčením je, že to do istej miery mitiguje túto inherentnú nepresnosť, pretože užívateľ je schopný spraviť informovanejšie rozhodnutie ohľadom zmeny pozície, ktoré bude presnejšie.

A kvôli tomu, že cieľom bolo znížiť počet iterácií potrebných na nastavenie pozície a počítanie najlepšej možnej pozície, nie len dostatočne dobrej, mitigácia nepresností pri generovaní doporučených zmien je najdôležitejším faktorom. Pretože čím presnejšie sa určia potrebné zmeny pozície, tým je potreba menej iterácií a tým viac sa užívateľ dostane k skutočne najlepšej pozícii.

Výsledné užívateľské rozhranie

Užívateľské rozhranie, ktoré zakomponováva všetky navrhnuté funkcionality, môže vyzerat nasledovne.



Obr. 5.3: Návrh užívateľského rozhrania

Kapitola 6

Implementácia aplikácie

Implementácia aplikácie začína výberom technológií a na základe návrhu sa postupne implementujú, testujú a iterujú jednotlivé funkcionality.

6.1 Použité technológie

Pri voľbe technológii záleží na druhu aplikácie. Bike Fast Fit je mobilná aplikácia a MyVeloFit je webová aplikácia. Kvôli väčším možnostiam osobných počítačov oproti mobilným telefónom ako veľkosť obrazovky, prítomnosť myši a klávesnice a väčšej výpočtovej sile som sa rozhodol vytvoriť aplikáciu pre počítače. Vytvorenie desktopovej aplikácie je však jednoduchšie a plne postačujúce pre tento prototyp.

V implementácii aplikácie budeme používať funkcie z knižnice MMPose a teda prirodzenou voľbou pre programovací jazyk celej aplikácie je jazyk Python. Písanie v jazyku Python je rýchle, prehľadné a jazyk ponúka veľké množstvo knižníc, vďaka ktorým bude ľahšie implementovať všetkú funkcionality.

V jazyku Python sú implementované viaceré knižnice pre tvorbu užívateľských rozhraní. Mojou voľbou bola knižnica Kivy [3]. Aj keď je táto knižnica skôr zameraná na vývoj mobilných aplikácií, po vyskúšaní ďalších dvoch knižníc, a to PyQt a Tkinter, som bol presvedčený, že vývoj bude najlepší práve pomocou Kivy. Výhodami Kivy oproti alternatívam sú prekvapivo dobre vyzerajúce základné komponenty, deklaratívny jazyk KV pre tvorbu užívateľského rozhrania a rýchlo pochopiteľný a čitateľný kód.

Kvôli tomu, že sa nezameriavam na vzhľad aplikácie, sú dobre vyzerajúce komponenty značnou výhodou, keďže výsledná aplikácia nebude musieť vyzeráť nepekne. Deklaratívny jazyk pomáha ďalej oddeliť kód užívateľského rozhrania od funkcionality a zvyšuje čitateľnosť kódu.


K jazyku Python a knižniciam MMPose a Kivy sa ďalej počas implementácie pridali medzi použité technológie rôzne moduly štandardnej vstavanej knižnice jazyku Python a aj knižnica KivyGradient, vďaka ktorej bol vytvorený farebný prechod v slideroch všetkých zobrazených meraní [1].

6.2 Architektúra kódu

Deklaratívny jazyk KV využíva návrhový vzor Observer pre svoje Properties. Properties sú atribúty jednotlivých deklarovaných objektov. Ak sa bude v definícii prvej Property

vyskytovať druhá Property, tak prvá Property bude reagovať a aktualizuje sa pri zmene druhej Property.

Vďaka tejto vlastnosti Properties som sa rozhodol použiť architektúru MVVM. Ak bude objekt Viewmodel mať Properties, ktorých hodnoty sú dáta, ktoré View potrebuje na zostrojenie užívateľského rozhrania, tak objekty z deklarácie užívateľského rozhrania v jazyku KV môžu čítať tieto Properties, aby z nich získali potrebné dáta. Vďaka návrhovému vzoru Observer sa pri každej zmene hodnoty Properties vo Viewmodeli aktualizujú aj odoberané hodnoty vo View.



Obr. 6.1: Diagram architektúry MVVM. Prevzaté z [2]

6.3 Implementácia, testovanie a iterovanie funkcionalít

Pre zobrazenie snímok som ako spôsob prepínania snímok zvolil záložky na štýl internetových prehliadačov. Nad snímku sa nachádzajú tri záložky, jedna pre každú snímku. Po kliknutí na záložku sa zobrazí príslušná snímka v strede obrazovky.

Zoznam pozícií som implementoval ako sadu kartičiek na ľavej strane obrazovky, kde na každej je uvedený titul pozície, poznámky a dátum poslednej zmeny. Pri stlačení tlačidla „+“ na konci sady sa otvorí dialógové okno pre zadanie titulu a poznámok k novej pozícii. Po potvrdení výberu sa okno spýta užívateľa, či chce skopírovať existujúcu pozíciu, alebo vytvoriť novú z videa. Ak si zvolí video, aplikácia otvorí okno pre výber videa zo súborového systému. Po výbere videa prebehne inferencia pomocou skriptu a automaticky sa pridá nová pozícia do zoznamu.

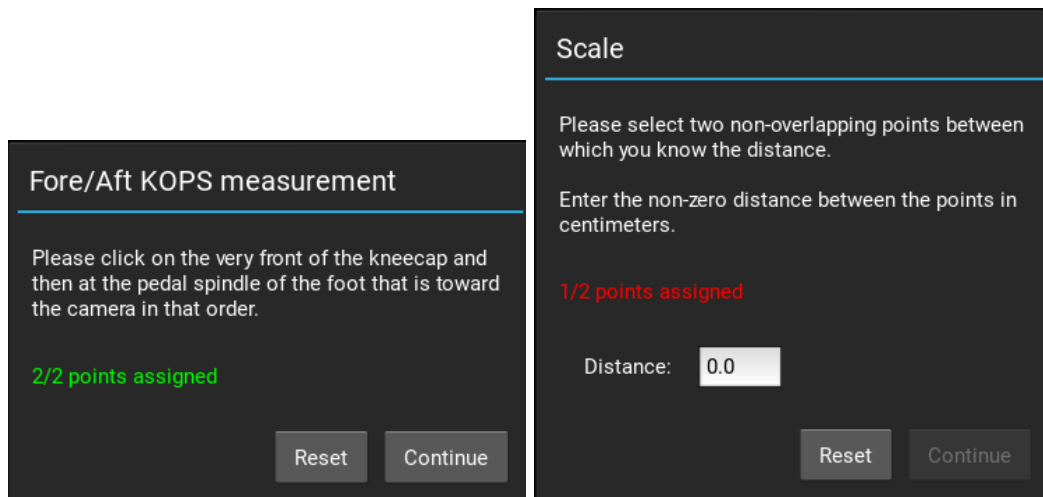
Kvôli časovej náročnosti inferencie som v skripte pre inferenciu implementoval počítanie zvyšného času inferencie. Z tejto informácie aplikácia vytvorí okno, ktoré užívateľa informuje o zvyšnom čase a umožňuje inferenciu zrušiť a tým aj zmazať novú pozíciu.

Skript som ďalej upravil tak, aby si pamätal vždy snímku a kľúčové body pre najprednejšiu, najvyššiu a najnižšiu pozíciu kľúčového bodu článku, ktorú zistil. Po ubehnutí inferencie skript vracia všetky tri snímky a sady súradníc kľúčových bodov.

Po inferencii sa zobrazí ďalšia séria dialógových okien, ktoré užívateľa prevedú zadávaním informácií k pozícii. Podľa návrhu sú to body predku kolena a osky pedálu pre meranie KOPS, vektory sedlovky a hlavového zloženia a možnosť posunu sedla a riadidiel resp. predstavca, na ktorom su riadidlá priprevnené.

Možné posunutie v centimetroch bude zadávané číselne v okne. Body pre meranie KOPS, ako aj body definujúce vektor sedlovky a hlavového zloženia budú zadávané kliknutím na správne miesto na zobrazenej snímke. Po kliknutí na snímku sa zobrazí bod, ktorým je možné hýbať. Ak je užívateľ spokojný s polohou bodov, svoju voľbu potvrdí v okne. Bodmi bude možno hýbať myšou spôsobom drag and drop ako aj označením a šípkami na klávesnici.

Aplikácia musí mať pre každé video mierku, teda pomer pixelov na centimeter, aby mohla zadanú možnosť posunu sedla a riadidiel spracovať. Táto informácia bude zadaná taktiež po inferencii pomocou dvoch bodov na snímke a uvedením vzdialenosti v centimetroch medzi nimi v okne.



Obr. 6.2: Okná pre zadávanie informácií o pozícii po dokončení inferencie

Doporučené rozsahy hodnôt meraní som zvolil najmä na základe všeobecných doporučení v literatúre, ale aj odpozorovaných hodnôt v existujúcich aplikáciach a v profesionálnych bike fittingoch. Rozsahy sú nastavené na komfortnú pozíciu, ktorá je vhodná pre najväčšie množstvo cyklistov.

Hýbanie kľúčovými bodmi

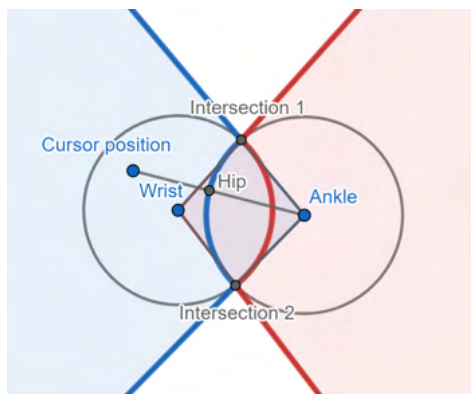
Pri normálnom hýbaní kľúčovými bodmi sa vytvorená kostra nemôže deformovať mimo pôvodné proporcie. Prakticky to znamená, že vzdialenosti medzi jednotlivými bodmi musia ostať konštantné. Je potreba navrhnúť správanie kostry pri pohybe kľúčových bodov, aby toto bolo dodržané.

Najprv som navrhol hýbanie s bodom zápästia a bedrového kĺbu, pretože tieto body reprezentujú kontaktné plochy cyklistu s bicyklom. Pri experimentovaní s pozíciou sa teda experimentuje s polohou týchto bodov.

Ak užívateľ hýbe bodom bedrového kĺbu, bod musí zostať dostatočne blízko k ostatným kontaktným bodom. Musí byť dostatočne blízko k bodu členku, aby sa zachovali proporcie nohy a dostatočne blízko k bodu zápästia, aby sa zachovali proporcie vrchnej časti tela. Matematicky sa dá tento problém vyjadriť pomocou kruhov, kde stredy kruhov sú susediace kontaktné body, a polomery sú vzdialenosti medzi bodom bedrového kĺbu a susediacimi kontaktnými bodmi postupne cez všetky body medzi nimi.

Vytvorené riešenie pre vypočítanie polohy bodu bedrového kĺbu je na obrázku 5.1. Priestor, v ktorom sa pohybuje bodom, som rozdelil do 3 častí, pre ktoré som implementoval rozdielne chovanie drag and drop.

Prvá časť je priestor, kde sa pretínajú oba kruhy. V tomto priestore musí zakaždým zostať bod bedrového kĺbu, aby kostra nebola deformovaná. Ak užívateľ ťahá bod cez tento priestor, poloha bodu bude rovnaká ako poloha kurzoru myši.



Obr. 6.3: Reprezentácia riešenia problému nájdenia nového bodu bedrového kĺbu.

Ak sa kurzor nachádza mimo prvú časť, musí sa z pozície kurzoru vypočítať pozícia bodu v prvej časti, a to konkrétne na jej obvode. Ďalšie pravidlo je, že ak sa kurzor potiahne na rozmedzie jednotlivých častí, metóda počítania výsledného bodu v oboch častiach musí dať rovnaký výsledok. Tým sa zaručí plynulý pohyb výsledného bodu, nech sa kurzor ťahá kamkoľvek.

Druhá časť sú na obrázku 5.1 zvyšné farebné časti priestoru okrem prvej časti. Pozíciu kurzoru dostaneme na obvod prvej časti pomocou úsečky do stredu protilahlého kruhu. Bod sa bude nachádzať na priesečníku daného kruhu a úsečky, ako je znázornené na obrázku.

Ak je kurzor v tretej časti, ktorou sú biele časti obrázka 5.1, bod skončí v bližšom z priesečníkov kruhov.


Po zmene kľúčového bodu bedra sa poloha zvyšných bodov dopočíta jednoducho. Medzi bodom bedrového kĺbu a bodom členku je len bod kolena, ktorý sa dopočíta tak, aby ostal rovnako ďaleko od oboch susediacich bodov, ako predtým. Medzi bodom bedrového kĺbu a bodom zápästia sú body pleca a lakťa. Algoritmus funguje takým spôsobom, aby zachoval laktový uhol, a tým pádom jediný voľný bod je plece, ktorého poloha sa dopočíta rovnakým postupom ako poloha kolena.

Dôvodom zachovania laktového uhla pri hýbaní kľúčových bodov je, že to nabližšie odpovedá tomu, ako by sa telo zachovalo pri takej zmene polohy. Laktový uhol býva medzi malými zmenami pozícií stabilný a nebude preto ani použitý v algoritme pre výpočet doporučených zmien. Nie je možné určiť iteratívnu zmenu polohy kontaktných bodov, po ktorej sa predvídateľne zmení uhol lakťa.

Pre hýbanie zápästia stačí jednoduchý algoritmus. Nový bod zápästia sa bude rovnať pozícii kurzora myši ak pri hýbaní s bodom kurzor neopustí kruh definovaný so stredom v bode bedrového kĺbu a polomerom ako súčet vzdialeností medzi bodom zápästia, bodom pleca a bodom bedrového kĺbu.

Ak kurzor kruh opustí, nový bod bude na priesečníku tohto kruhu a priamky od pozície kurzora do stredu kruhu. Uhol lakťa ostáva z rovnakého dôvodu ako predtým nezmenený. Pozícia bodov pleca a lakťa je dopočítaná rovnako ako pri pohybe bodu bedrového kĺbu.

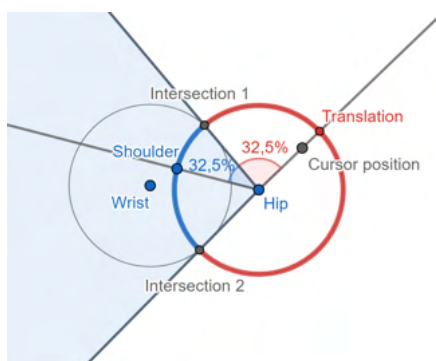
Rozhodol som sa pridať aj hýbanie bodom pleca. Dôvodom je, aby bolo možné nejak meniť uhol lakťa. Napriek tomu, že sa pri výpočte doporučených zmien tento uhol nebude používať, môže byť užitočné pre užívateľa chcieť zistiť výsledné uhly v iných pózach, ako napríklad bicyklovanie v stojci alebo v aerodynamicknej pozícii, kde bude potreba zmeniť uhol lakťa.



Obr. 6.4: Reprezentácia prvej časti riešenia problému nájdenia nového bodu pleca.

Pre bohyb pleca som musel zvoliť nasledovný algoritmus výpočtu novej pozície. Bod pleca je unikátny v tom, že medzi ním a najbližším kontaktným bodom, bodom bedrového kĺbu, sa nenachádzajú žiadne ďalšie body. Znamená to, že aby sa medzi týmito bodmi zachovala vzdialenosť, bod pleca sa bude musieť hýbať po kružnicovom oblúku. Ak je kurzor v oblasti vyznačenej na obrázku 5.2 modrou farbou, pozícia bude získaná podobne ako zápästie, teda priesečníkom s kruhom, avšak v prípade pleca to nastane aj keď je kurzor vnútri kruhu.

Ostáva problém s tým, ako dopočítať pozíciu bodu pleca, ak sa kurzor nachádza mimo modrej oblasti. Stále je potreba dodržať pravidlo, že na prelome týchto oblastí musia oba výpočty vrátiť tú istú pozíciu.



Obr. 6.5: Reprezentácia druhej časti riešenia problému nájdenia nového bodu pleca.

Navrhol som riešenie, kde sa aj mimo vyznačenej oblasti pozícia kurzora prepočíta na pozíciu na kružnicovom oblúku. Tentokrát sa jedná o vonkajší na obrázku 5.3 červený kružnicový oblúk. Ďalej sa vypočíta v percentách, ako ďaleko sa nachádza pozícia na červenom kružnicovom oblúku od jeho začiatku. Výsledný bod bude položený o rovnaké percento dĺžky modrého kružnicového oblúku od jeho začiatku. Toto riešenie dodrží aj podmienku o plynulom prechode.

Implementácia pohybu kľúčových bodov nie je dokonalá. Kostra sa deformuje, keď sa potiahne jeden z kontaktných bodov na pozíciu iného a medzi nimi je jeden voľný bod. Vzdialenosti medzi týmito bodmi a bodom medzi nimi nie sú rovnaké. To znamená, že v tejto polohe neexistuje validná kostra. Súčasnú riešenie je, že sa kostra deformuje natiahnutím jednej „kosti“. Hľadal som riešenie, kde aplikácia nepustí potiahnuť bodom do

takejto problematickej polohy, ale pri experimentovaní som nachádzal stále nové situácie, kde sa problém opakoval.

Algoritmy pre výpočet novej pozície

Algoritmus pre výpočet ideálnych kľúčových bodov je založený na princípe *hill climbing*. Snaží sa postupne iterovať bod zápastia a bedrového kĺbu, teda kontaktné body, ktorých zmena upraví pozíciu cyklistu. Do možných zmien kontaktných bodov patrí posun bodu hore, dole, vpravo, vľavo o veľkosti definovaného iteračného kroku. Iterovanie bodmi sa deje vo vnorenom cykle, kde vonkajší cyklus iteruje polohu zápastia a vnútorný iteruje polohu bedrového kĺbu.

Vo vnútornom cykle platí, že ak nový bod bedrového kĺbu pozíciu zlepší, zmena sa zachová a cyklus sa obnoví. Ak sa vyčerpajú všetky 4 možnosti bez zlepšenia pozície, iteračný krok sa zmenší na polovicu a cyklus sa opakuje. Toto sa deje, kým iteračný krok nedosiahne svoje minimum. Sémanticky sa jedná o hľadanie ideálneho bodu bedrového kĺbu pre daný bod zápastia.

Vonkajší cyklus pracuje skoro rovnako, ale pre bod zápastia. Rozdiel je, že pre každý posun zápastia sa najprv zavolá vnútorný cyklus, ktorý nájde najlepší možný bod bedrového kĺbu pre daný bod zápastia, až potom nastane vyhodnotenie.

Rozdiel medzi výpočtom ideálnych kľúčových bodov a doporučených je obmedzenie potenciálnych hodnôt kľúčových bodov zápastia a bedrového kĺbu. Na základe dát o možnom posune sedla a riadidiel, ktoré pri nahraní videa zadáva užívateľ, algoritmus vypočíta, či potenciálna zmena bodu spadá do povoleného rozmedzia. Ak nie je potenciálna zmena validná, algoritmus ju jednoducho preskočí a pokračuje ďalej.

Algoritmus 1 popisuje výpočty oboch nových pozícií.

Snažil som sa najskôr vytvoriť algoritmus, ktorý má zdieľaný iteračný krok pre oba body. To by znamenalo, že oba body sú na začiatku posúvané len veľkými krokmi, ktoré sa postupne sa znižujú. Tento prístup vedie k rýchlejšiemu algoritmu, ale pri testovaní riešenia som zistil, že evaluácia pozície má naprieč všetkými možnými bodmi zápastia a bedrového kĺbu lokálne minimum. Algoritmus, ktorý pre každý bod zápastia nájde najlepší možný bod bedrového kĺbu sa nezastavil v žiadnom lokálnom minime.

Ako evaluačnú metriku pozície používam súčet druhých mocnín odchýliek všetkých meraní. Ak má pozícia toto číslo menšie, považujem ju za lepšiu. V oboch algoritmoch, aj pre perfektné aj doporučené body, optimalizujem pre akýsi kompromis medzi všetkými meraniami. Hľadám pozíciu, ktorá bude mať v súčte čo najmenšie odchýlky meraní od ideálnych hodnôt, ale pomocou druhej mocniny dávam vyššiu váhu odchýlkam, ktoré sú ďalej od ideálnej hodnoty.

Testoval som aj iné evaluačné metriky, skúšal som súčet prvých mocnín (obyčajný súčet) aj tretích, alebo najvyššiu odchýlku zo všetkých meraní. Najlepšiu rovnováhu medzi minimalizovaním súčtu odchýliek a najvyššej odchýlky mala metrika súčtu druhých mocnín.

Zvyšná funkcionálnosť

Na pravej strane užívateľského rozhrania som podľa návrhu implementoval zobrazenie doporučených zmien, možnosť zmeny nastavitelnosti bicykla a tlačidlá pre rôzne funkcie.

Tlačidlá som rozdelil na dvoch skupín. V prvej sú tlačidlá z návrhu, ktoré menia kľúčové body. Sú to tlačidlá pre zobrazenie ideálnych bodov, doporučených bodov, reset bodov na základnú pozíciu, a tlačidlo pre zmenu základnej pozície bodov, ktoré pri kliknutí zapne mód s nezávislým hýbaním bodov, a pri ďalšom kliknutí sa body potvrdia a mód sa ukončí.

Algorithm 1 Všeobecný algoritmus pre výpočet novej pozície

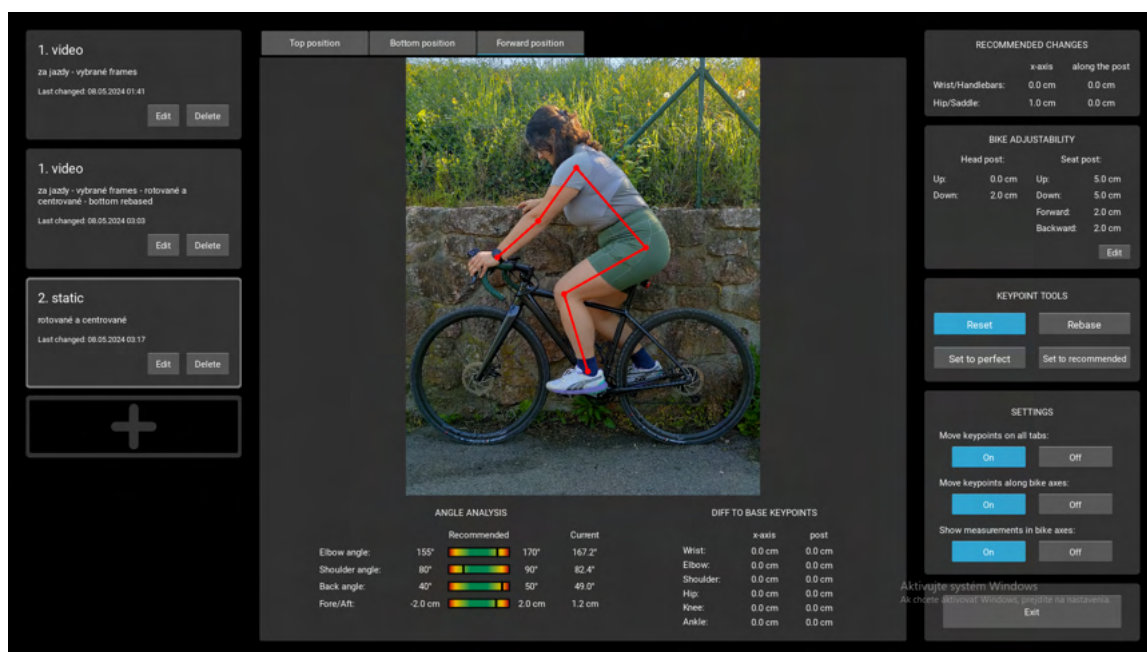
```
1: function GETNEWKEYPOINTS
2:    $iter \leftarrow$  keypoint iteration step
3:    $diffs \leftarrow$  keypoint iteration vectors  $\leftarrow [(0, iter), (0, -iter), (iter, 0), (-iter, 0)]$ 
4:
5:   while  $iter_{wrist} \geq$  minimum step do
6:     for  $diff_{wrist}$  in  $diffs_{wrist}$  do
7:
8:       if new wrist not viable then           # only for recommended keypoints
9:         continue
10:      end if
11:
12:      while  $iter_{hip} \geq$  minimum step do
13:        for  $diff_{hip}$  in  $diffs_{hip}$  do
14:
15:          if new hip not viable then       # only for recommended keypoints
16:            continue
17:          end if
18:
19:          EVALUATE_POSITION( $diff_{wrist}, diff_{hip}$ )
20:
21:          if new evaluation is better then
22:            KEEP_CHANGES( $diff_{hip}$ )
23:            break
24:          end if
25:          end for
26:          if better evaluation not found then
27:             $iter_{hip} /= 2$ 
28:          end if
29:        end while
30:
31:        EVALUATE_POSITION( $diff_{wrist}$ )
32:
33:        if new evaluation is better then
34:          KEEP_CHANGES( $diff_{wrist}$ )
35:          break
36:        else
37:          ROLLBACK_HIP_CHANGES()
38:        end if
39:      end for
40:      if better evaluation not found then
41:         $iter_{wrist} /= 2$ 
42:      end if
43:    end while
44: end function
```

Druhú skupinu som implementoval ako spínače, ktoré menia isté chovanie aplikácie na základe toho, či sú zapnuté alebo nie. Je tam spínač pre hýbanie bodmi po vektoroch sedlovky a hlavového zloženia z návrhu.

Ďalej som pridal spínač pre zobrazenie zmeny polohy bodov v týchto vektoroch. To znamená, že ak užívateľ hýbe bodom bedrového kĺbu po vektore sedlovky, môže si nechať zobraziť posun po tomto vektore.

Ako posledný som pridal spínač pre pohyb bodov všetkých troch snímkov naraz. Klasická situácia, kedy užívateľ väčšinou nemusí, ale môže chcieť pohnúť všetkými troma bodmi istého kĺbu je funkcionálna pre zmenu základnej polohy kľúčových bodov.

Výsledné užívateľské rozhranie aplikácie



Obr. 6.6: Užívateľské rozhranie aplikácie

Prvé testovanie rozptylu detekovaných uhlov

Navrhol a vykonal som jednoduchý test rozptylu detekovaných uhlov. Natočil som 100 sekúnd dlhé video bicyklovania z bočného pohľadu. Video som natrihal do 5 sekundových úsekov, ktoré som nahral do aplikácie. Výsledky sú v tabuľke. V nasledujúcich testoch budú vždy hodnoty odlišné od priemeru o aspoň 1 podfarbené žltou, aspoň 2 oranžovou a aspoň 3 červenou. Hodnoty uhlov sú v stupňoch. Pojem Fore/Aft je prebraný z aplikácie MyVeloFit, znamená výsledok merania KOPS zapísaný v centimetroch, kde kladné hodnoty znamenajú, že koleno je pred oskou pedálu, teda bližšie k predku bicykla.

Pozoruhodným javom je kontinuálne narastajúci uhol lakťa a pleca. Po analýze snímkov bolo jasné, že jav nastal kvôli pohybu riadidiel počas natáčania videa.

Ďalším významným javom je, že veľké množstvo nameraných bedrových uhlov vo vrchnej pozícii pedálu je ďaleko od priemernej hodnoty. Po analýze snímkov sa zdá, že príčinou je nekonzistentný výber snímkov. Vo veľkom počte snímkov nie je poloha pedálov presne zvislá.

Title	Top					Bottom					Side			
	elbow	shoulder	back	hip	knee	elbow	shoulder	back	hip	knee	elbow	shoulder	back	fore/aft
Test 1 - full	160,74	77,35	42,40	59,36	67,57	161,02	77,22	42,32	102,18	140,53	163,77	77,77	41,93	2,26
Test 1 - 1	161,75	77,22	43,03	63,31	65,94	160,24	77,47	41,81	101,29	140,12	162,43	78,32	42,65	2,03
Test 1 - 2	160,09	76,88	42,18	59,94	66,06	160,27	76,78	42,21	101,66	139,14	160,48	77,11	42,40	1,66
Test 1 - 3	161,04	77,26	42,29	61,33	65,70	160,52	76,88	42,11	100,40	138,55	160,58	78,33	41,25	2,22
Test 1 - 4	160,12	75,67	42,46	57,79	67,21	161,67	77,88	41,59	100,66	139,75	160,40	76,08	42,58	1,80
Test 1 - 5	160,93	76,40	42,57	59,39	66,42	162,69	77,00	42,54	100,47	138,43	160,71	78,16	41,27	2,18
Test 1 - 6	163,35	77,44	42,54	61,65	65,59	162,36	78,00	41,46	100,99	138,54	163,42	78,76	41,54	2,10
Test 1 - 7	164,02	77,72	42,70	58,79	65,16	163,78	78,60	41,59	99,88	138,97	163,87	79,11	41,63	1,68
Test 1 - 8	163,18	76,52	42,84	59,08	65,98	163,22	77,88	41,74	100,40	139,31	163,04	77,86	42,04	2,18
Test 1 - 9	162,99	77,58	42,04	57,46	66,08	162,19	76,93	42,12	102,14	139,25	162,68	77,86	42,16	1,93
Test 1 - 10	161,91	76,43	42,57	60,20	65,40	163,20	77,07	42,51	101,58	138,87	162,22	77,14	42,41	1,65
Test 1 - 11	162,44	77,25	42,05	58,17	65,84	162,07	76,18	42,27	101,75	137,21	163,06	78,01	41,89	2,08
Test 1 - 12	162,15	75,61	42,95	62,26	65,14	162,32	76,88	41,60	101,27	138,60	163,07	77,28	42,42	2,09
Test 1 - 13	163,39	76,48	43,07	61,84	65,59	163,33	77,14	42,11	101,82	139,65	163,45	78,18	41,89	1,91
Test 1 - 14	164,62	77,06	42,57	61,75	66,34	164,64	76,36	42,82	101,67	138,70	163,28	77,11	42,32	1,97
Test 1 - 15	163,92	77,43	41,95	60,92	64,96	163,25	76,45	42,03	101,32	140,08	164,12	77,00	42,59	1,97
Test 1 - 16	163,50	77,74	41,92	58,82	65,63	163,85	77,94	41,60	100,79	139,58	164,44	78,21	41,69	1,55
Test 1 - 17	163,35	77,40	42,58	60,01	65,55	163,72	76,65	42,53	102,17	138,53	164,38	77,88	42,19	1,78
Test 1 - 18	163,78	77,02	42,69	58,78	66,82	163,63	77,77	42,01	100,68	137,48	164,23	78,60	42,03	1,97
Test 1 - 19	164,19	78,69	41,66	59,96	65,59	163,63	78,27	41,76	100,64	138,29	163,56	78,67	41,51	1,52
Test 1 - 20	166,16	79,50	43,04	60,94	65,20	165,14	78,89	43,12	101,89	141,09	165,64	79,39	42,89	1,88
Average	162,74	77,17	42,48	60,08	65,89	162,70	77,34	42,09	101,22	139,08	162,99	77,94	42,06	1,92

Tabuľka 6.1: Tabuľka všetkých nameraných uhlov pozície získaných z 5 sekundových úsekov videa.

Toto môže byť spôsobené buď nedostatočným počtom snímok v 5 sekundovom videu, kde sa jednoducho nevyskytne snímka so správnou polohou pedálu, alebo špatnou metódou voľby snímky. Výber snímky podľa polohy kľúčového bodu členka môže byť pri cyklistoch s nie vodorovnou polohou chodidla chybný.

Preto som sa rozhodol test opakovať s 10 sekundovými intervalmi videa. Tým pádom nebude problém s nedostatkom snímok. Výsledky sú v tabuľke 6.2.

Title	Top					Bottom					Side			
	elbow	shoulder	back	hip	knee	elbow	shoulder	back	hip	knee	elbow	shoulder	back	fore/aft
Test 1 - full	160,74	77,35	42,40	59,36	67,57	161,02	77,22	42,32	102,18	140,53	163,77	77,77	41,93	2,26
Test 1 - 1 long	160,83	77,29	42,26	61,77	66,01	160,24	77,47	41,81	101,29	140,12	162,43	78,32	42,65	2,18
Test 1 - 2 long	161,04	77,26	42,29	61,33	65,70	161,67	78,00	41,46	100,35	139,56	160,40	76,22	42,44	1,95
Test 1 - 3 long	160,93	76,40	42,57	59,39	66,42	162,36	78,00	41,46	100,99	138,54	160,71	78,16	41,27	2,28
Test 1 - 4 long	164,02	77,72	42,70	59,05	65,43	163,22	78,02	41,60	100,38	139,42	163,04	77,88	42,03	2,52
Test 1 - 5 long	162,99	77,58	42,04	57,46	66,08	162,19	76,93	42,12	102,14	139,25	162,22	77,13	42,42	1,51
Test 1 - 6 long	161,94	75,35	43,21	62,32	64,93	162,02	75,76	42,41	101,86	138,34	162,84	77,28	42,42	2,41
Test 1 - 7 long	163,39	76,48	43,07	61,84	65,59	164,64	76,49	42,69	101,65	138,81	163,45	78,18	41,89	1,82
Test 1 - 8 long	163,92	77,43	41,95	60,92	64,96	163,25	76,45	42,03	101,32	140,08	164,17	78,17	41,69	2,26
Test 1 - 9 long	164,09	77,44	42,81	61,52	65,85	163,63	77,67	42,11	100,29	139,48	164,17	78,29	42,29	1,36
Test 1 - 10 long	165,65	79,11	43,16	61,26	65,24	165,14	79,30	42,71	101,45	140,88	164,13	78,14	42,16	0,94
Average	162,68	77,22	42,59	60,56	65,80	162,67	77,39	42,07	101,26	139,55	162,85	77,78	42,11	1,95

Tabuľka 6.2: Tabuľka všetkých uhlov pozície nameraných z 10 sekundových úsekov videa.

Vidno, že problém naďalej pretrváva a po analýze snímok je jasné, že sa jedná o druhý problém. Je potreba upraviť implementáciu výberu snímok.

Pre problém s pohybujúcimi sa rukami kvôli nestabilnej polohe existuje veľmi jednoduché riešenie. Stačí merať uhol pleca ako uhol medzi bedrovým kĺbom, plecóm a zápästím. Ja som zvolil v prvom riešení uhol medzi bedrovým kĺbom, plecóm a lakťom. Oba prístupy sú validné, avšak uhol k zápästiu nie je až tak ovplyvnený fluktuáciou pozície rúk. Po zmene počítania uhla som zmenil aj doporučený rozsah na vhodné hodnoty.

Čo sa týka špatného výberu snímok, v existujúcich aplikácie sa nájde jedna možnosť pre napravenie tohto problému. Aplikácia Bike Fast Fit podporuje prehranie videa po jednotlivých snímkach s manuálnym výberom snímky. Vytvoril som však mierne jednoduchšie

riešenie. Užívateľ bude môcť nahráť do aplikácie samotné vybrané snímky, namiesto celého videa. Snímky z videa môže vystrihnúť pomocou iného nástroja.

Navrhnutú zmenu som implementoval pridaním ďalšej možnosti pri tvorbe novej pozície. Dialógové okno sa spýta, či nová pozícia bude vytvorená z existujúcej, z videa, alebo z vybraných snímok. Podľa zvolenej možnosti je aj prispôbený výber zo súborového systému.

Druhé testovanie rozptylu detekovaných uhlov

Najprv som testoval nahranie snímok. Zobral som opäť pôvodné 5 sekundové úseky videa, z ktorých som vybral ideálnu snímku pre každú z troch polôh pedálov a nahrал ich do aplikácie. Výsledky sú v tabuľke 6.3.

Title	Top					Bottom					Side			
	elbow	shoulder	back	hip	knee	elbow	shoulder	back	hip	knee	elbow	shoulder	back	fore/aft
Test 2 - 1 frames	160,22	76,26	43,19	59,74	67,14	159,58	76,60	42,49	101,41	138,09	159,75	77,37	42,14	1,26
Test 2 - 2 frames	159,94	76,09	42,81	58,29	67,68	160,14	77,70	41,70	102,98	140,32	161,59	77,73	42,64	1,36
Test 2 - 3 frames	160,09	75,62	43,19	58,84	66,85	160,64	77,02	42,37	100,81	137,59	160,68	77,55	41,88	1,42
Test 2 - 4 frames	161,27	76,52	42,57	58,57	67,89	161,24	76,27	42,54	101,80	137,09	161,42	76,81	42,43	1,42
Test 2 - 5 frames	162,93	77,49	42,57	57,84	68,08	162,82	76,99	43,18	101,43	135,88	162,41	78,06	41,92	1,82
Test 2 - 6 frames	162,91	77,37	42,18	57,71	68,57	162,20	77,56	41,74	101,04	138,36	162,70	78,24	41,78	1,40
Test 2 - 7 frames	163,57	77,13	43,08	57,53	67,08	163,35	77,71	42,27	101,24	136,81	163,76	78,11	42,53	1,47
Test 2 - 8 frames	163,38	76,46	43,33	59,21	66,76	162,44	75,79	43,05	102,90	137,79	162,91	76,20	43,58	1,63
Test 2 - 9 frames	163,04	77,12	42,78	58,38	67,11	162,32	76,66	42,52	102,61	139,54	162,66	77,32	42,42	1,51
Test 2 - 10 frames	162,31	76,07	43,32	58,91	67,44	161,33	75,88	42,56	100,39	135,97	162,94	77,25	42,77	1,65
Test 2 - 11 frames	162,55	76,38	42,59	58,12	67,92	161,68	76,01	42,29	101,47	136,91	162,77	76,57	42,82	1,84
Test 2 - 12 frames	162,40	75,73	42,83	59,25	67,32	162,64	76,15	42,18	101,44	136,97	163,18	76,28	42,59	1,55
Test 2 - 13 frames	162,92	76,60	42,95	59,10	67,53	162,65	76,62	42,65	102,31	136,90	163,12	77,84	41,91	1,63
Test 2 - 14 frames	164,59	76,61	42,97	58,92	66,67	163,31	76,80	42,67	102,38	138,23	164,11	76,75	42,59	1,36
Test 2 - 15 frames	164,82	76,49	43,10	58,89	67,17	164,31	76,48	42,82	102,64	137,50	164,36	76,37	43,22	1,65
Test 2 - 16 frames	163,46	77,05	42,58	57,39	66,79	163,77	77,04	42,42	100,53	136,59	163,55	78,30	41,65	1,53
Test 2 - 17 frames	163,67	76,55	42,35	57,97	66,93	163,82	76,25	42,80	102,10	137,49	164,57	78,85	41,89	1,26
Test 2 - 18 frames	163,55	76,75	42,95	58,38	66,12	162,60	76,06	42,94	100,88	136,30	163,89	77,52	42,78	1,30
Test 2 - 19 frames	164,31	78,55	41,92	57,40	67,73	163,75	77,88	42,03	100,05	135,95	163,68	78,29	42,01	1,34
Test 2 - 20 frames	165,41	79,00	43,27	59,13	67,52	164,31	78,25	43,15	101,70	136,82	166,12	80,24	42,74	1,40
Average	162,87	76,79	42,83	58,48	67,31	162,44	76,79	42,52	101,61	137,35	163,01	77,58	42,41	1,49

Tabuľka 6.3: Tabuľka všetkých uhlov pozície nameraných z vybraných snímok 5 sekundových úsekov videa.

Rozptyl nameraných bedrových uhlov prakticky zmizol. Taktiež sa posunula priemerná hodnota v hornej polohe pedálu na približne 58 stupňov oproti pôvodným 60, čo indikuje, že naozaj bol problém s výberom mnoho snímok, čo skreslovalo aj priemerný uhol.

Ďalej som zmenil podľa predošlého popisu počítanie uhlu v pleci a testoval znovu. Výsledky sú v tabuľke 6.4.

Namerané uhly v pleci majú tiež menší rozptyl, avšak nie o veľa. Zmena definície uhla pleca samozrejme nezmenila rozptyl v uhle lakťa, ale uhol lakťa sa bežne ani v dynamickom bike fittingu priamo nenastavuje, takže rozptyl nepredstavuje problém.

Zmenšené rozptyly potvrdzujú, že vybrané zmeny sú užitočné. Zostávajúce rozptyly uhlov vyzerajú byť dôsledkom všeobecnej fluktuácie pozície na bicykli a zostávajúcich nepresností detekcie kľúčových bodov.

Tretie testovanie rozptylu detekovania uhlov

Ďalej som chcel otestovať zmenu rozptylov pri použití manuálnej zmeny základnej polohy kľúčových bodov. Pre otestovanie tejto funkcionality som pre každý 5 sekundový úsek manuálne zmenil kľúčové body vo všetkých troch snímkach. Výsledky sú v tabuľke 6.5.

Zdá sa, že manuálne upravenie kľúčových bodov nemení nejak rozptyl relevantných uhlov. Tento výsledok sa dal očakávať, pretože model, ktorý detekuje kľúčové body je vytrénovaný

Title	Top					Bottom					Side			
	elbow	shoulder	back	hip	knee	elbow	shoulder	back	hip	knee	elbow	shoulder	back	fore/aft
Test 2 - 1 frames	160,22	85,75	43,19	59,74	67,14	159,58	86,45	42,49	101,41	138,09	159,75	87,14	42,14	1,26
Test 2 - 2 frames	159,94	85,77	42,81	58,29	67,68	160,14	87,35	41,70	102,98	140,32	161,59	86,67	42,64	1,36
Test 2 - 3 frames	160,09	85,34	43,19	58,84	66,85	160,64	86,47	42,37	100,81	137,59	160,68	87,04	41,88	1,42
Test 2 - 4 frames	161,27	85,61	42,57	58,57	67,89	161,24	85,40	42,54	101,80	137,09	161,42	85,84	42,43	1,42
Test 2 - 5 frames	162,93	85,74	42,57	57,84	68,08	162,82	85,28	43,18	101,43	135,88	162,41	86,69	41,92	1,82
Test 2 - 6 frames	162,91	85,74	42,18	57,71	68,57	162,20	86,35	41,74	101,04	138,36	162,70	86,80	41,78	1,40
Test 2 - 7 frames	163,57	85,12	43,08	57,53	67,08	163,35	85,87	42,27	101,24	136,81	163,76	86,00	42,53	1,47
Test 2 - 8 frames	163,38	84,52	43,33	59,21	66,76	162,44	84,41	43,05	102,90	137,79	162,91	84,49	43,58	1,63
Test 2 - 9 frames	163,04	85,54	42,78	58,38	67,11	162,32	85,44	42,52	102,61	139,54	162,66	85,93	42,42	1,51
Test 2 - 10 frames	162,31	84,76	43,32	58,91	67,44	161,33	85,07	42,56	100,39	135,97	162,94	85,71	42,77	1,65
Test 2 - 11 frames	162,55	84,87	42,59	58,12	67,92	161,68	85,11	42,29	101,47	136,91	162,77	85,02	42,82	1,84
Test 2 - 12 frames	162,40	84,40	42,83	59,25	67,32	162,64	84,89	42,18	101,44	136,97	163,18	84,64	42,59	1,55
Test 2 - 13 frames	162,92	85,00	42,95	59,10	67,53	162,65	85,17	42,65	102,31	136,90	163,12	86,21	41,91	1,63
Test 2 - 14 frames	164,59	84,23	42,97	58,92	66,67	163,31	85,12	42,67	102,38	138,23	164,11	84,71	42,59	1,36
Test 2 - 15 frames	164,82	84,00	43,10	58,89	67,17	164,31	84,25	42,82	102,64	137,50	164,36	84,14	43,22	1,65
Test 2 - 16 frames	163,46	85,28	42,58	57,39	66,79	163,77	85,14	42,42	100,53	136,59	163,55	86,52	41,65	1,53
Test 2 - 17 frames	163,67	84,72	42,35	57,97	66,93	163,82	84,36	42,80	102,10	137,49	164,57	86,46	41,89	1,26
Test 2 - 18 frames	163,55	84,86	42,95	58,38	66,12	162,60	84,62	42,94	100,88	136,30	163,89	85,44	42,78	1,30
Test 2 - 19 frames	164,31	86,33	41,92	57,40	67,73	163,75	85,96	42,03	100,05	135,95	163,68	86,36	42,01	1,34
Test 2 - 20 frames	165,41	86,18	43,27	59,13	67,52	164,31	85,97	43,15	101,70	136,82	166,12	87,06	42,74	1,40
Average	162,87	85,19	42,83	58,48	67,31	162,44	85,43	42,52	101,61	137,35	163,01	85,94	42,41	1,49

Tabuľka 6.4: Tabuľka všetkých uhlov pozície nameraných z vybraných snímkov 5 sekundových úsekov videa po redefinícii uhla pleca.

Title	Top					Bottom					Side			
	elbow	shoulder	back	hip	knee	elbow	shoulder	back	hip	knee	elbow	shoulder	back	fore/aft
Test 3 - 1 rebase	160,34	84,74	44,03	62,12	68,67	159,82	85,71	43,08	101,02	137,10	159,97	86,22	42,89	1,26
Test 3 - 2 rebase	159,80	85,02	43,28	60,20	69,13	160,16	86,22	42,53	101,94	138,44	161,55	86,52	42,47	1,36
Test 3 - 3 rebase	160,72	84,29	44,28	61,78	68,69	161,24	85,16	43,71	100,67	136,11	161,28	85,76	43,18	1,42
Test 3 - 4 rebase	162,09	85,49	42,88	61,19	70,20	162,08	85,76	42,39	100,46	135,90	162,24	85,87	42,59	1,42
Test 3 - 5 rebase	163,63	84,19	44,19	61,38	70,00	162,85	83,80	44,48	102,47	135,62	163,13	85,32	43,36	1,82
Test 3 - 6 rebase	163,39	83,98	43,80	62,03	71,27	162,71	85,06	42,88	101,40	137,57	163,14	84,98	43,43	1,40
Test 3 - 7 rebase	164,12	84,86	43,39	60,84	70,07	163,92	84,98	43,22	101,45	136,08	164,29	85,67	42,90	1,47
Test 3 - 8 rebase	163,80	84,38	43,49	61,30	68,68	162,91	83,32	44,17	103,65	137,41	163,33	84,72	43,37	1,63
Test 3 - 9 rebase	163,21	85,51	42,63	61,30	70,20	162,53	84,43	43,35	103,67	139,77	162,64	85,69	42,38	1,51
Test 3 - 10 rebase	162,69	84,13	43,86	61,31	69,29	161,78	83,71	43,85	101,23	135,51	163,29	84,68	43,70	1,65
Test 3 - 11 rebase	163,13	83,24	44,19	62,33	70,52	162,31	83,79	43,59	102,20	136,34	162,73	84,50	43,09	1,84
Test 3 - 12 rebase	162,84	83,08	44,09	62,33	69,15	163,11	82,82	44,20	103,19	136,70	163,61	83,14	44,04	1,55
Test 3 - 13 rebase	162,94	83,67	44,02	62,76	70,12	162,68	83,78	43,78	102,97	136,42	163,12	84,67	43,19	1,63
Test 3 - 14 rebase	164,81	83,63	43,47	62,20	69,45	163,55	84,07	43,61	102,83	137,75	164,35	84,07	43,12	1,36
Test 3 - 15 rebase	165,57	83,25	43,97	62,47	69,87	165,08	82,73	44,47	104,07	137,28	165,11	82,81	44,67	1,65
Test 3 - 16 rebase	163,47	84,17	43,43	61,50	70,05	163,97	84,60	42,83	100,56	136,20	163,54	85,55	42,35	1,53
Test 3 - 17 rebase	163,72	83,63	43,21	61,31	69,41	163,87	83,75	43,18	100,99	136,00	164,51	85,45	42,63	1,26
Test 3 - 18 rebase	163,60	84,21	43,45	61,83	69,08	162,68	83,55	43,86	101,87	136,37	163,47	84,50	43,29	1,30
Test 3 - 19 rebase	164,26	84,65	43,33	61,59	70,50	163,74	84,39	43,33	101,15	135,76	163,65	85,16	42,95	1,34
Test 3 - 20 rebase	164,53	84,96	43,83	61,82	69,65	163,48	84,73	43,74	101,98	136,51	165,20	85,82	43,32	1,40
	163,13	84,25	43,64	61,68	69,70	162,72	84,32	43,51	101,99	136,74	163,21	85,05	43,15	1,49

Tabuľka 6.5: Tabuľka všetkých uhlov pozície nameraných z vybraných snímkov 5 sekundových úsekov videa s použitím funkcionality pre zmenu základnej polohy kľúčových bodov.

na dátových sadách, ktoré sú tiež len ručne anotované a tak bude mať porovnateľne veľký rozptyl.

Ako posledný test rozptylov uhlov som použil nálepky a natočil nové video. Pomocou zmeny základných bodov som zmenil polohy kľúčových bodov na pozície nálepiek. Výsledky sú v tabuľke 6.6.

Pozoruhodné sú rozdiely v priemerných nameraných uhloch medzi rôznymi metódami určenia kľúčových bodov. Priemerné namerané hodnoty sa líšia najmä v spodnej polohe pedálu v uhle kolena. Doporučené zmeny, ktoré aplikácia bude generovať, budú síce pravdepodobne generované s nízkym rozptylom, čo je môj cieľ, ale ich správnosť bude naďalej závislá od toho, ako presne budú lokalizované kľúčové body cyklistu. Môj pokus s nálepkami lo-

Title	Top					Bottom					Side			
	elbow	shoulder	back	hip	knee	elbow	shoulder	back	hip	knee	elbow	shoulder	back	fore/aft
Test 3 - 1 nalepky	168,20	86,93	41,90	60,25	69,11	168,37	85,41	43,01	97,36	130,68	168,63	86,48	42,34	1,19
Test 3 - 2 nalepky	168,59	86,65	41,78	60,10	69,87	168,56	86,15	42,50	97,98	131,75	168,38	85,96	42,48	1,19
Test 3 - 3 nalepky	169,43	86,72	41,70	60,33	70,08	168,92	86,06	42,59	98,76	133,77	169,23	86,02	42,45	0,79
Test 3 - 4 nalepky	169,45	86,35	41,68	61,03	69,52	169,81	85,15	42,68	99,96	133,41	169,87	85,86	42,28	0,83
Test 3 - 5 nalepky	170,03	86,67	41,61	59,93	70,34	169,68	85,27	42,67	99,51	132,23	169,55	85,93	42,39	0,78
Test 3 - 6 nalepky	171,43	87,02	41,54	59,82	70,71	169,90	85,06	42,77	99,16	132,07	170,00	85,77	42,47	1,32
Test 3 - 7 nalepky	170,53	86,31	41,71	61,05	70,77	169,97	84,91	42,84	99,21	132,86	170,36	85,93	42,45	0,95
Test 3 - 8 nalepky	169,87	86,48	41,80	60,79	70,57	170,13	85,10	43,00	99,42	132,63	170,03	86,00	42,49	1,12
Test 3 - 9 nalepky	170,39	86,53	41,78	61,19	70,24	170,43	84,54	42,99	99,31	133,53	170,56	85,71	42,62	1,00
Test 3 - 10 nalepky	170,88	86,30	41,88	60,84	69,50	170,60	85,02	43,14	99,69	132,51	170,56	85,91	42,65	1,04
Test 3 - 11 nalepky	170,68	86,12	41,72	61,10	70,43	171,00	84,60	43,12	98,87	132,39	170,92	86,42	42,32	0,95
Test 3 - 12 nalepky	171,94	87,61	40,81	59,23	70,88	173,04	86,03	41,82	98,42	134,18	172,54	86,59	41,61	0,57
Test 3 - 13 nalepky	171,38	87,00	41,58	60,59	69,95	171,59	85,72	42,79	97,58	131,50	170,79	87,17	41,97	0,68
Test 3 - 14 nalepky	172,42	87,20	41,57	60,23	69,85	171,97	85,64	42,81	100,21	134,66	172,06	85,97	42,40	0,91
Test 3 - 15 nalepky	172,29	86,62	41,53	61,26	69,42	171,89	85,09	42,69	98,74	132,13	172,28	86,23	42,04	0,95
Test 3 - 16 nalepky	172,20	87,08	41,53	60,42	70,18	171,80	85,44	42,91	100,33	134,85	172,21	86,03	42,36	1,02
Test 3 - 17 nalepky	170,71	87,45	41,12	60,46	70,50	172,34	85,16	42,67	98,61	132,20	172,27	86,03	42,20	1,00
Test 3 - 18 nalepky	170,88	87,39	41,17	60,27	70,23	170,77	85,35	42,79	97,10	131,29	171,34	86,90	41,79	0,98
Test 3 - 19 nalepky	171,36	87,07	41,60	60,83	70,14	171,47	85,50	42,71	98,54	132,10	170,82	86,48	42,11	0,87
Test 3 - 20 nalepky	171,69	86,75	41,73	60,22	69,64	171,77	85,49	42,72	98,09	131,30	172,13	86,44	42,59	1,15
	170,72	86,81	41,59	60,50	70,10	170,70	85,33	42,76	98,84	132,60	170,73	86,19	42,30	0,96

Tabuľka 6.6: Tabuľka všetkých uhlov pozície nameraných z vybraných snímok 5 sekundo- vých úsekov videa s použitím nálepiek a funkcionality pre zmenu základnej polohy kľúčových bodov.

kalizoval kľúčový bod bedra príliš nízko a kľúčový bod kolena príliš vpredu v porovnaní s počítačovým videním. To malo za následok zmenšenie nameraného uhlu kolena.

Nadalej pretrváva variabilita uhlu lakťa, ktorá ale netvorí problém. Všetky ostatné hodnoty uhlov vyzerajú byť veľmi konzistentné až na uhol kolena v spodnej polohe. Po analýze snímok vyzerá byť problém v prirodzenej fluktuácii pozície, ktorá by možno bola menšia, ak by bol použitý trenažér.

Preukázal som, že s priamym výberom korektných snímok, zmenou definície uhlu pleca a použitím nálepiek pre kľúčové body sa rozptyl meraní zmenšil. Funkcionalita pre spresnenie detekcie kľúčových bodov a korektných snímok je dostatočne efektívna, aby aj 5 sekundové video bolo reprezentatívnou vzorkou pozície.

Testovanie rozptylu generovaných pozícií

Ako pokračovanie predošlých testov rozptylu som otestoval aj rozptyl generovaných pozícií. Nízky rozptyl meraní, ktorý sa mi podarilo dosiahnuť predošlým testovaním a zmenami je hodnotný, len ak to vedie aj k nízkemu rozptylu generovaných pozícií.

Testoval som video s nálepkami, aj video bez. Výsledky sú v tabuľke 6.7 pre počítačové videnie a 6.8 pre nálepky. Hodnoty sú v centimetroch a hodnoty rozdielne od priemeru minimálne o 0,5cm sú žltou a o 1cm oranžovou.

Ak beriem do úvahy všetkých 80 dátových bodov, šanca že pri generovaní perfektných alebo doporučených bodov dostanem doporučené, ktoré sa aspoň v jednom kontaktnom bode líši od priemerných doporučených bodov o viac ako 1 cm je 7/80, teda 8,75%.

Pri detailnejšom pohľade na výsledky je jasné, že problémové výsledky sú pri generácii perfektných bodov z normálneho videa bez použitia nálepiek. V tomto vzorku dát sú 4 z 20 výsledkov doporučené, ktoré sa od priemerného líšia o viac ako 1 cm.

Po analýze snímok mi nie je úplne jasný dôvod tejto relatívnej nepresnosti. Môže byť, že kvôli menšiemu rozptylu uhlov natočených vo videu s použitím nálepiek, jednak vďaka nálepkám a pravdepodobne aj vďaka tomu, že sa mi darí lepšie držať tú istú pozíciu, sa znížil rozptyl vypočítaných pozícií. Vyšší rozptyl doporučených pozícií s použitím nálepiek

Title	Perfect						Recommended						
	Wrist diff			Hip diff			Wrist diff		Hip diff - x/y			Hip diff - x/post	
	x	y	to avg	x	y	to avg	x	y	x	y	to avg	x	post
Test 4 - 1	-1,46	3,41	0,96	-0,67	1,23	0,23	0	0	0,57	0,88	0,25	0,80	0,90
Test 4 - 2	-1,99	3,18	1,48	-1,21	0,55	0,84	0	0	-0,48	0,02	1,43	-0,5	0
Test 4 - 3	-1,35	3,88	0,54	-0,79	1,36	0,10	0	0	0,59	0,98	0,18	0,9	1,0
Test 4 - 4	-0,88	4,27	0,08	-0,79	1,31	0,10	0	0	0,58	1,17	0,15	0,9	1,2
Test 4 - 5	-1,64	4,09	0,72	-1,24	1,45	0,38	0	0	0,53	1,42	0,33	0,9	1,5
Test 4 - 6	-1,60	4,08	0,69	-1,07	0,86	0,50	0	0	0,17	0,67	0,52	0,4	0,7
Test 4 - 7	-0,77	4,28	0,16	-0,70	1,54	0,28	0	0	0,64	1,25	0,24	1,0	1,3
Test 4 - 8	-0,32	3,91	0,67	-1,05	1,30	0,17	0	0	0,10	1,11	0,34	0,4	1,2
Test 4 - 9	-1,37	3,57	0,78	-1,21	0,81	0,62	0	0	0,18	0,77	0,43	0,4	0,8
Test 4 - 10	-0,77	4,18	0,16	-0,92	1,60	0,27	0	0	0,50	1,47	0,37	0,9	1,5
Test 4 - 11	-0,98	4,51	0,30	-1,40	1,22	0,52	0	0	0,17	1,12	0,28	0,5	1,2
Test 4 - 12	-0,18	5,00	1,08	-0,88	1,41	0,08	0	0	0,53	1,16	0,10	0,9	1,2
Test 4 - 13	-1,15	4,41	0,30	-1,08	1,35	0,20	0	0	0,48	1,13	0,04	0,8	1,2
Test 4 - 14	-0,14	4,47	0,83	-0,76	1,27	0,14	0	0	0,63	1,25	0,23	1,0	1,3
Test 4 - 15	-0,09	4,51	0,89	-1,12	1,27	0,25	0	0	0,06	0,99	0,40	0,3	1,0
Test 4 - 16	-0,95	4,97	0,76	-0,76	1,61	0,31	0	0	0,81	1,28	0,40	1,2	1,3
Test 4 - 17	-0,42	4,71	0,71	-0,53	1,45	0,37	0	0	0,80	1,05	0,35	1,1	1,1
Test 4 - 18	0,09	4,74	1,14	-0,24	1,91	0,86	0	0	0,50	1,55	0,45	0,9	1,6
Test 4 - 19	-0,94	4,97	0,76	-0,50	1,66	0,51	0	0	1,09	1,53	0,77	1,5	1,6
Test 4 - 20	-1,60	3,08	1,32	-0,73	1,45	0,19	0	0	0,52	1,28	0,19	0,9	1,3
Average	-0,93	4,21	0,00	-0,88	1,33	0,00	0,00	0,00	0,45	1,10	0,00	0,76	1,15

Tabuľka 6.7: Rozptyl generovaných perfektných a doporučených pozícií bodov zápästia a bedrového kĺbu z vybraných snímkov z 5 sekundových úsekov videa.

Title	Perfect						Recommended						
	Wrist diff			Hip diff			Wrist diff		Hip diff - x/y			Hip diff - x/post	
	x	y	to avg pt	x	y	to avg pt	x	y	x	y	to avg pt	x	post
Test 4 - 1	-0,10	5,67	0,24	0,44	2,99	0,70	0,00	0,00	-0,59	2,72	0,71	0,20	2,80
Test 4 - 2	-0,35	5,55	0,29	0,23	2,53	0,26	0,00	0,00	-0,40	2,38	0,33	0,3	2,5
Test 4 - 3	-0,18	5,05	0,40	0,45	2,05	0,28	0,00	0,00	0,41	2,03	0,58	1,0	2,1
Test 4 - 4	0,37	5,57	0,47	0,53	2,23	0,20	0,00	0,00	0,23	2,07	0,39	0,8	2,2
Test 4 - 5	0,44	5,69	0,58	0,77	2,43	0,45	0,00	0,00	-0,98	2,04	0,84	-0,4	2,1
Test 4 - 6	-0,55	5,38	0,48	-0,16	2,20	0,51	0,00	0,00	-0,85	2,04	0,71	-0,3	2,1
Test 4 - 7	0,21	5,37	0,29	0,25	2,09	0,24	0,00	0,00	0,03	2,04	0,22	0,6	2,1
Test 4 - 8	-0,17	5,11	0,34	0,04	2,13	0,36	0,00	0,00	-0,35	2,04	0,24	0,2	2,1
Test 4 - 9	0,09	5,15	0,33	0,08	1,98	0,42	0,00	0,00	0,33	2,04	0,49	0,9	2,1
Test 4 - 10	0,24	5,34	0,33	0,35	2,42	0,12	0,00	0,00	0,29	2,37	0,48	1,0	2,5
Test 4 - 11	0,34	5,41	0,42	0,35	2,29	0,01	0,00	0,00	-0,71	2,04	0,58	-0,1	2,1
Test 4 - 12	-0,44	5,71	0,46	0,48	1,82	0,50	0,00	0,00	-1,18	1,38	1,29	-0,8	1,4
Test 4 - 13	0,34	5,64	0,46	1,09	2,79	0,88	0,00	0,00	0,08	2,55	0,45	0,8	2,7
Test 4 - 14	-0,67	4,67	0,97	0,04	1,77	0,61	0,00	0,00	0,49	1,77	0,75	1,0	1,8
Test 4 - 15	0,26	5,97	0,64	0,51	2,57	0,32	0,00	0,00	0,28	2,46	0,52	1,0	2,6
Test 4 - 16	-0,77	4,57	1,11	-0,19	1,62	0,87	0,00	0,00	0,43	1,70	0,75	0,9	1,8
Test 4 - 17	-0,31	5,70	0,35	0,27	2,31	0,08	0,00	0,00	-0,88	2,04	0,74	-0,3	2,1
Test 4 - 18	-0,11	5,89	0,45	0,54	2,66	0,41	0,00	0,00	0,05	2,55	0,43	0,8	2,6
Test 4 - 19	-0,03	5,49	0,08	0,56	2,47	0,27	0,00	0,00	0,16	2,38	0,37	0,8	2,5
Test 4 - 20	-0,15	5,74	0,31	0,31	2,70	0,40	0,00	0,00	0,19	2,67	0,61	1,0	2,8
Average	-0,08	5,43	0,00	0,35	2,30	0,00	0,00	0,00	-0,15	2,16	0,00	0,47	2,25

Tabuľka 6.8: Rozptyl generovaných perfektných a doporučených pozícií bodov zápästia a bedrového kĺbu z vybraných snímkov z 5 sekundových úsekov videa. Pre úpravu polohy kľúčových bodov boli použité nálepky a funkcionality pre zmenu základnej polohy kľúčových bodov.

môže byť dôsledok doporučenia väčšieho pohybu bodu bedrového kĺbu. Veľkosť zmeny musí korelovať s veľkosťou rozptylu.

Nemyslím si, že vyšší rozptyl perfektných bodov je veľkým problémom. Perfektné body stále nesú svoj význam toho, aby ukázali kam sa všeobecne daná pozícia má dostať. Kým sú doporučené zmeny generované s dostatočne nízkym rozptylom, je možné efektívne použiť aj krátke videá s priamym výberom snímok bez použitia nálepiek na to, aby sa za niekoľko iterácií užívateľ dostal do doporučenej pozície.

Kapitola 7

Testovanie

Testovanie aplikácie som previedol jednoducho tak, že som sa snažil naplno využiť všetkú funkcionálnosť, aby som dostal užívateľa do čo najlepšej pozície. Tiež som sa snažil predpovedať možné zmeny komponentov, ktoré by užívateľovi zlepšili pozíciu.

Kvôli nedostupnosti trénažera sú merania skreslené a menej presné, ale to aj umožňuje aplikácii dokázať svoju užitočnosť aj v nepriaznivých podmienkach.

7.1 Prvý test

V prvom rade som riadne otestoval svoju vlastnú pozíciu. Motiváciou boli hlavne opakujúce sa bolesti pri dlhších jazdách kvôli špatne vybranej veľkosti bicykla. Video som nahral opretý o stenu so spadnutou reťazou, bicyklovaním „na sucho“. Vo videu mám mierne nešťastné oblečenie, ktoré robí modelu malé problémy presne lokalizovať body. Tu sa ukázala byť vhodná funkcionálnosť pre zmenu základnej polohy bodov, pomocou ktorej som pozmenil jednotlivé body. Výsledná zmena uhlov bola v prípade uhla pleca a chrbta až 2 stupne.

Hlavnou črtou mojej pozície je, že vďaka malému rozmeru bicykla na moju výšku sú riadidlá príliš nízko a ďaleko. Poloha sedla má oveľa väčšiu nastaviteľnosť a aj to mi umožnilo mať sedlo prekvapivo dobre nastavené. Rozdiel medzi mojím bodom bedrového kĺbu a toho z ideálnej pozície je len 1,2 cm posun dozadu. V mojej pozícii sú uhly spodného tela v norme.

Uhol pleca je ale príliš veľký a uhol chrbta zase príliš malý. Táto kombinácia napovedá, že riadidlá sú príliš ďaleko a musím sa k nim príliš zohíňať. Ideálnym bodom zápästia je oproti môjmu nameranému až o 3,6 cm bližšie horizontálne a 3,9cm vyššie vertikálne. Spolu s posunutím ideálneho sedla je verdikt jasný. Aplikácia sa ma snaží dostať do oveľa vzpriamenejšej pozície, kde sa nemusím za riadidlami natahovať, čo je krásne vidno pri použití zobrazenia oboch sád bodov.

Kvôli limitáciám bicykla sa riadidlá nedajú posunúť ani bližšie, ani vyššie. Algoritmus vypočítal doporučenú pozíciu, v ktorej mám posunúť sedlo dokonca viac dopredu o 1,3 cm a o 0,4 cm vyššie, napriek tomu, že ideálne sedlo by bolo vzadšie. Algoritmus sa snaží teda posunúť sedlo trochu dopredu, keďže nemôže posunúť riadidlá bližšie, pre benefit uhla chrbta a pleca a hlavne na úkor merania Fore/Aft.

Sedlo som posunul podľa doporučení. Predpokladané uhly po zmene a namerané uhly po zmene sú v tabuľke 7.1.

Výsledky po zmene sú zaujímavé. Meranie Fore/Aft bolo kompletne napravené tým, že som tentokrát mal chodidlo vodorovne a nie sklonené dole, čo je dobrým ponaučením, že merania sú presnejšie pri pedáľovaní s odporom. Uhol pleca sa posunul skoro presne

	top					bottom					side			
	elbow	shoulder	back	hip	knee	elbow	shoulder	back	hip	knee	elbow	shoulder	back	fore/aft
Prediction	160.9°	87.9°	40.5°	61.0°	69.9°	159.8°	86.6°	41.1°	108.8°	142.0°	160.4°	87.8°	40.6°	2.1cm
Actual	165.9°	87.5°	43.1°	61.2°	70.2°	164.3°	87.5°	42.6°	103.7°	143.0°	165.8°	88.5°	41.8°	0.6cm

Tabuľka 7.1: Caption

podľa očakávaní, zatiaľ čo uhol chrbta sa napravil až nad očakávania. Uhol chrbta je trochu klamlivý, pretože sa zdá, že v novej pozícii viacej zaoblujem chrbát. Je to indikácia, že zmena dostala pozíciu na limit a je otázne, či sa napriek priaznivej zmene meraní len nespôsobil ďalší problém. Je veľmi možné, že takáto pozícia by pri dlhšej jazde spôsobila bolesti dolného chrbta.

Úspechom je fakt, že ďalšia doporučená zmena je pod 0,5 centimetra v oboch smeroch a teda produkuje zanedbateľné vylepšenia. Ideálne body produkované z tejto novej pozície sú skreslené novým uhlom chrbta a nedokážu predpokladať, že chrbát je nadmieru prehnutý.

Z týchto všetkých informácií možno vyčítať, že kompenzácia nízkych uhlov pleca a chrbta sa pravdepodobne nedá vykompenzovať posunutím vpred, pretože aj na to je bicykel príliš malý a pozícia sa ďalej degraduje. Znamená to, že pôvodná pozícia bola pravdepodobne veľmi blízko najlepšiemu možnému meraniu, záležiac od bolestí spôsobených novou pozíciou.

Jediná možná zmena komponentov je kratší predstavec. Snažil som sa pomocou hýbania bodov, funkcie pre zmenu základnej polohy bodov a algoritmu pre doporučenú pozíciu zistiť potenciálnu najlepšíu pozíciu, keby mám o 2 cm kratší predstavec. Výsledná pozícia má najmä nižší uhol pleca, čo by určite pomohlo v rámci meraní a mohlo pomôcť aj v rámci bolesti. Avšak ďaleko najlepším riešením by bola kúpa nového bicykla.

7.2 Druhý test

Predmetov druhého testu bola Lenka. Amatérska cyklistka, ktorá si chcela skontrolovať pozíciu na jej čisto novom bicykli. Pri bicyklovaní nezvykne mať bolesti, až na občasné problémy so sedlom. S Lenkou sa konal bike fitting vonku, takže sme sa snažili natočiť video za jazdy, kde som natáčal Lenku s môjho vlastného bicykla.

Ako kompenzáciu pre nepresnosť tejto metódy som zvolil výber snímok do aplikácie namiesto nahrania videa. Každopádne aj vybrané snímky boli snímané z príliš odlišných uhlov a variácia medzi meraniami bola veľká. Rozhodol som sa snímky rotovať a orezať tak, aby bicykel bol centrováný a vodorovný so spodnou hranou snímky. Tieto snímky už mali výpovednú hodnotu.

Zistili sme, že Lenkina pozícia je nastavená na veľmi komfortnú jazdu. Uhol chrbta bol nameraný na približne 46° a uhol pleca na 82°. To značí veľmi vzpriamenú a pohodlnú pozíciu. Najvýznamnejší bol uhol kolena s pedálom v dolnej pozícii, ktorý mal až 154°, ďaleko za odporúčaný rozsah.

Bolo teda jasné, že sedlo musí byť prenastavené nižšie. Doporučená pozícia by vyžadoval posunutie sedla nielen dole, ale aj dozadu, spolu s posunom riadidiel dole. Algoritmus sa snaží udržať uhol chrbta okolo 45° a natiahnúť uhol pleca na 85°, avšak toto je pre Lenku nežiadúce. Nie je dôvod, prečo jednoduché posunutie sedla dole by nebolo lepšou variantou. Uhol pleca by sa ďalej znížil a uhol chrbta zvýšil a uhol kolena by sa napravil. Pozícia by bola jednoznačne komfortnejšia, čo je hlavným cieľom.

Aby túto skutočnosť odzrkadlil aj algoritmus, zmenil som v zdrojovom kóde ideálny uhol pleca na 80° a ideálny uhol chrbta na 47°. Za týchto podmienok algoritmus odporučal

posun sedla o 1,7cm kolmo dole, alebo 1,8 cm dole po sedlovke a 0,6 cm dozadu. Lenka sa však obávala posunu sedla dozadu, kvôli natiiahnutiu pozície, a tak sme sa dohodli na konzervatívnejšej zmene, a to 1,5 cm zníženie sedla. Predpokladané merania a namerané merania po vykonaní zmeny pozície sú v tabuľke 7.2.

	top					bottom					side			
	elbow	shoulder	back	hip	knee	elbow	shoulder	back	hip	knee	elbow	shoulder	back	fore/aft
Prediction	169.5°	81.4°	46.9°	67.9°	65.3°	168.4°	80.2°	47.8°	112.2°	146.0°	169.5°	80.5°	48.1°	1.3cm
Actual	166.7°	84.7°	47.0°	68.8°	66.7°	166.8°	80.4°	49.8°	114.6°	145.1°	167.2°	82.4°	49.0°	1.2cm

Tabuľka 7.2: Caption

Kvôli časovej tiesni sme znovu netočili video, vyberali a modifikovali snímky. Jednoducho sme urobili statickú analýzu pomocou troch staticky vytvorených snímok s pedálmi v správnej polohe. Napriek tomu sú predpokladané a detekované uhly kolena a meranie Fore/Aft veľmi podobné. To znamená, že zmena pozície priniesla presne žiadané zmeny meraní. Uhly chrbta a pleca sú naďalej vo veľmi komfortných hodnotách.

Jediné riziko ostalo vo zväčšenej hodnote Fore/Aft, ktorá by bola napravená posunom sedla dozadu, ktorý algoritmus odporúčal, ale nebol vykonaný.

7.3 Tretí test

Tretí test bol s ďalším amatérskym cyklistom, Matejom. Na začiatok som zvolil rovnaký postup, ako pri predošlom teste, teda video za jazdy s výberom, rotovaním a centrovaním snímok. Zistil som, že rotovanie snímok zhoršuje kvalitu snímku natoľko, že model má problém presne detekovať body. Preto som musel použiť zmenu základných bodov a v podstate správne anotovať snímky.

Matej je cyklista s agresívnejším posedom, s uhlom pleca okolo 82° a uhlom chrbta okolo 40°. Subjektívne však považuje svoju pozíciu za komfortnú. Musel však predtým vymeniť predstavca za kratší, ináč sa cítil príliš natiahnutý. Problémovým rozmerom v Matejovej pozícii sú malý uhol kolena v dolnej pozícii pedálu a vysoká hodnota Fore/Aft.



Obr. 7.1: Zobrazenie uhlov pozície užívateľa.

Algoritmus odporúča dať sedlo o 1cm vyššie a dozadu. Táto zmena natiahne uhol kolena a posunie koleno dozadu, čím napravi obe merania. Po vyskúšaní posunu dozadu aj vyššie sme zistili, že oba posuny vyvolávajú diskomfort. V podstate prinášajú pre Mateja ten istý problém ako dlhší predstavca.

Tým pádom sme pre Mateja nenašli žiadne zlepšenie pozície. Jediné zlepšenie by bolo podobné prvému testu, teda vyššie umiestnené riadidlá, čo ale nedovoľuje bicykel. Test sme teda ukončili s rovnakou pozíciou, s akou sme začali.

7.4 Zhodnotenie

Najdôležitejšie kladné poznatky získané testovaním:

- napriek nedokonalým podmienkam sa preukázala dobrá schopnosť aplikácie predvídať zmeny meraní na základe prenastavenia bicykla
- v týchto podmienkach je schopnosť aplikácie prijať snímky namiesto videa veľmi užitočná, rovnako ako schopnosť zmeny základných bodov
- možnosť hýbať bodmi po vektoroch sedlovky a hlavového zloženia je veľmi užitočná pri experimentovaní s pozíciami
- aplikácia umožňuje ľahko porovnávať jednotlivé pozície, či už predošlú s aktuálnou, alebo aktuálnu s predikciou
- algoritmus pre ideálnu pozíciu je užitočný pre rozhodovanie o zmenách, ak sú rozsahy uhlov v súlade s preferenciami užívateľa

Na základe testovania navrhujem nasledujúce možné zlepšenia, ktoré riešia zistené problémy a môžu byť predmetom ďalšej práce:

- integrácia spracovania vstupného videa do automatického procesu - aplikácia môže snímok vyrovnáť, orezať a centrováť
- presnejší a rýchlejší model pre detekciu kľúčových bodov
- robustnejšie algoritmy počítajúce výsledné pozície - riešenie problému lokálnych miním, počítanie z vyššieho množstva vstupných dát

Kapitola 8

Záver

V práci bolo cieľom vytvoriť novú aplikáciu pre bike fitting, ktorá vychádza z existujúcich príkladov, integruje ich najlepšie črty a rieši ich najväčšie nedostatky. Bike fittingové aplikácie používajú počítačové videnie na detekciu kľúčových bodov cyklistu, na základe ktorých vyhodnocujú pozíciu a doporučujú zmeny nastavenia bicykla.

V rámci tvorby aplikácie bolo treba dotrénovať existujúci model pre odhad pózy človeka pre špecifickú potrebu bike fittingu. Pre dotrénovanie modelu bol vytvorený dataset so snímkami, ktoré v sebe majú cyklistov v podobných polohách, ako pri bike fittingu. S pomocou datasetu sa dotrénoval model, ktorý presnejšie odhaduje polohu kľúčových bodov tak, ako je potreba pre bike fitting.

Hlavným bodom návrhu aplikácie bol cieľ pomôcť cyklistovi dosiahnuť ideálnu pozíciu za čo najmenší počet iterácií. Ideálna pozícia z pohľadu bike fittingových aplikácií znamená dostať merania definujúce posed čo najbližšie k ideálnym hodnotám. Inováciou aplikácie je, že zisťuje od užívateľa limitácie nastavenia jeho bicykla, čo znamená, že aplikácia môže vytvárať doporučenia priamo pre daný bicykel, alebo pre rôzne iné scenáre, ako dostupnosť rôznych komponent.

Aplikácia generuje doporučené polohy cyklistu na základe algoritmov, ale umožňuje užívateľovi experimentovať s pozíciami sám. Kopírovanie pozícií, hýbanie kľúčovými bodmi a sledovanie meniacich sa metrik ponúka nástroje, ktorými sa k riešeniu rôznych situácií môže užívateľ dopracovať sám.

Testovaním aplikácie sa zistilo, že implementované funkcionality pomáhajú dosiahnuť lepšie pozície aj napriek nedokonalým podmienkam testovania. Aplikácia dokáže relatívne presne predpovedať zmenu meraní, ktoré hodnotia pozíciu a doporučiť kladnú zmenu.

Slabé stránky aplikácie, a možnosti pre vylepšenie, sú hlavne potreba kvalitných vstupných dát, kde zatiaľ spadá zodpovednosť na užívateľa. Veľa úkonov pre skvalitnenie dát sa dá do aplikácie integrovať. Prediktívne algoritmy sú zatiaľ jednoduché a ich zdokonalenie by vedelo ešte zlepšiť prediktívnu schopnosť aplikácie.

Literatúra

- [1] *KivyGradient* [online]. 2021 [cit. 2024-03-15]. Dostupné z: <https://pypi.org/project/KivyGradient/>.
- [2] *Model-View-ViewModel - .NET* [online]. 2022 [cit. 2024-03-15]. Dostupné z: <https://learn.microsoft.com/en-us/dotnet/architecture/maui/mvvm>.
- [3] *Welcome to Kivy* [online]. 2023 [cit. 2024-04-27]. Dostupné z: <https://kivy.org/doc/stable/>.
- [4] *PyTorch* [online]. 2024 [cit. 2024-03-15]. Dostupné z: <https://pytorch.org/>.
- [5] AGUR, L. Fore Aft Saddle Position. *I Love Bicycling* [online]. 15. mája 2014 [cit. 2024-04-27]. Dostupné z: <https://ilovebicycling.com/fore-aft-saddle-position/>.
- [6] ANDRILUKA, M., IQBAL, U., MILAN, A., INSAFUTDINOV, E., PISHCHULIN, L. et al. PoseTrack: A Benchmark for Human Pose Estimation and Tracking. *CoRR*. 2017, abs/1710.10000. Dostupné z: <http://arxiv.org/abs/1710.10000>.
- [7] ANDRILUKA, M., PISHCHULIN, L., GEHLER, P. a SCHIELE, B. 2D Human Pose Estimation: New Benchmark and State of the Art Analysis. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 2014.
- [8] ANTONIADIS, P. Neural Networks: Difference Between Conv and FC Layers. *Baeldung on Computer Science* [online]. 14. júla 2022. Revidované 18. 3. 2024 [cit. 2024-05-01]. Dostupné z: <https://www.baeldung.com/cs/neural-networks-conv-fc-layers>.
- [9] BENSON, C. Review: Pressure map saddle fitting to join the GebioMized Secret Saddle Club. *Bikerumor* [online]. 6. februára 2020 [cit. 2024-03-15]. Dostupné z: <https://bikerumor.com/review-pressure-map-saddle-fitting-to-join-the-gebiomized-secret-saddle-club/>.
- [10] BIKE FAST FIT. Bike Fast Fit Elite - Basic Fitting Process. *YouTube* [online]. 19. apríla 2019 [cit. 2024-03-15]. Dostupné z: https://www.youtube.com/watch?v=SA-XR961XXs&ab_channel=BikeFastFit.
- [11] BIKE FAST FIT. Set Your Bicycle Seat Height. *YouTube* [online]. 23. septembra 2021 [cit. 2024-03-15]. Dostupné z: https://www.youtube.com/watch?v=kzaFomrEaI8&ab_channel=BikeFastFit.
- [12] BIKE FAST FIT. Bike Fitting with Bike Fast Fit EZ. *YouTube* [online]. 17. novembra 2022 [cit. 2024-03-15]. Dostupné z: https://www.youtube.com/watch?v=iw7dqs8TFtg&ab_channel=BikeFastFit.

- [13] BIKE FAST FIT. *Bike Fast Fit - Video Bike Fitting iOS Apps* [online]. 2023 [cit. 2024-03-15]. Dostupné z: <https://bikefastfit.com/>.
- [14] BIKE RADAR. How Much Difference Can A Bike Fit Make? *YouTube* [online]. 2. marca 2018 [cit. 2024-03-15]. Dostupné z: https://www.youtube.com/watch?v=05yfJgGSz60&ab_channel=BikeRadar.
- [15] BILOGUR, A. *Full batch, mini-batch, and online learning* [online]. 2018 [cit. 2024-04-27]. Dostupné z: <https://www.kaggle.com/code/residentmario/full-batch-mini-batch-and-online-learning/notebook>.
- [16] BOYER, M. My Perfect Bike Fit at Home Using MyVeloFit. *YouTube* [online]. 4. marca 2022 [cit. 2024-03-15]. Dostupné z: https://www.youtube.com/watch?v=4XFLZT907Hk&t=120s&ab_channel=MitchBoyer.
- [17] BROOKS, J. *COCO Annotator* [<https://github.com/jsbroks/coco-annotator/>]. 2019.
- [18] BURT, P. *Bike Fit 2nd edition: Optimise Your Bike Position for High Performance and Injury Avoidance*. 2. vyd. Bloomsbury Sport, apríl 2022. ISBN 978-1-4729-9018-1.
- [19] COCO. *COCO - Common Objects in Context* [online]. 2024 [cit. 2024-03-15]. Dostupné z: <https://cocodataset.org/#keypoints-2020>.
- [20] DESILETS, W. Bike Fit For \$10 - Bike Fast Fit Elite. *YouTube* [online]. 16. júna 2020 [cit. 2024-03-15]. Dostupné z: https://www.youtube.com/watch?v=yVGHpqH-b04&ab_channel=WayneDesilets.
- [21] FONDA, B., SARABON, N. a LI, F.-X. Validity and reliability of different kinematics methods used for bike fitting. *Journal of Sports Sciences*. Routledge. 2014, zv. 32, č. 10, s. 940–946. DOI: 10.1080/02640414.2013.868919. Dostupné z: <https://doi.org/10.1080/02640414.2013.868919>.
- [22] GOULDING, J. Cycling Cleat Positioning 101. *MyVeloFit* [online]. 28. októbra 2021 [cit. 2024-04-27]. Dostupné z: <https://www.myvelofit.com/fit-academy/cycling-cleat-positioning-101>.
- [23] GUANGYU, Z. *An Introduction to Evaluation Metrics for Object Detection* [online]. 16. decembra 2018 [cit. 2024-04-27]. Dostupné z: <https://blog.zenggyu.com/posts/en/2018-12-16-an-introduction-to-evaluation-metrics-for-object-detection/>.
- [24] JARJOUR, J. What to expect during your online bike fit. *MyVeloFit* [online]. 1. februára 2021 [cit. 2024-03-15]. Dostupné z: <https://www.myvelofit.com/fit-academy/what-to-expect-during-your-online-bike-fit>.
- [25] JOSYULA, R. a OSTADABBAS, S. A Review on Human Pose Estimation. *CoRR*. 2021, abs/2110.06877. Dostupné z: <https://arxiv.org/abs/2110.06877>.
- [26] KHANNA, S. *A Comprehensive Guide to Train-Test-Validation Split in 2024* [online]. 2024 [cit. 2024-04-27]. Dostupné z: <https://www.analyticsvidhya.com/blog/2023/11/train-test-validation-split/>.

- [27] LACKE, S. Reviewed: MyVeloFit Remote Bike-Fitting App. *Triathlete* [online]. 17. februára 2022 [cit. 2024-03-15]. Dostupné z: <https://www.triathlete.com/gear/bike/my-velo-fit-review/>.
- [28] LIN, T., MAIRE, M., BELONGIE, S. J., BOURDEV, L. D., GIRSHICK, R. B. et al. Microsoft COCO: Common Objects in Context. *CoRR*. 2014, abs/1405.0312. Dostupné z: <http://arxiv.org/abs/1405.0312>.
- [29] MILLOUR, G., VELÁSQUEZ, A. T. a DOMINGUE, F. A literature overview of modern biomechanical-based technologies for bike-fitting professionals and coaches. *International Journal of Sports Science & Coaching*. 2023, zv. 18, č. 1, s. 292–303. DOI: 10.1177/17479541221123960. Dostupné z: https://www.researchgate.net/publication/364780793_A_literature_overview_of_modern_biomechanical-based_technologies_for_bike-fitting_professionals_and_coaches.
- [30] MONDRAKER. *Užívateľská príručka*. Mondraker. Dostupné z: http://www.mondraker.cz/data_20/soubory/4.pdf.
- [31] MYVELOFIT. Frequently Asked Questions. *MyVeloFit* [online]. 2023 [cit. 2024-03-15]. Dostupné z: <https://www.myvelofit.com/faq>.
- [32] MYVELOFIT. *MyVeloFit: The World's First AI Powered Online Bike Fit* [online]. 2023 [cit. 2024-03-15]. Dostupné z: <https://www.myvelofit.com/>.
- [33] NAESEN, B. My First Professional Bike Fit EVER - Retül Bike Fit. *YouTube* [online]. 13. júna 2023 [cit. 2024-03-15]. Dostupné z: https://www.youtube.com/watch?v=el2agzm1w10&ab_channel=BenjiNaesen.
- [34] NEWELL, A., YANG, K. a DENG, J. Stacked Hourglass Networks for Human Pose Estimation. *CoRR*. 2016, abs/1603.06937. Dostupné z: <http://arxiv.org/abs/1603.06937>.
- [35] NIE, X., ZHANG, J., YAN, S. a FENG, J. Single-Stage Multi-Person Pose Machines. *CoRR*. 2019, abs/1908.09220. Dostupné z: <http://arxiv.org/abs/1908.09220>.
- [36] NORMAN, P. Bike fits explained: what is a bike fit and should you get one? *BikeRadar* [online]. 25. marca 2023 [cit. 2024-03-15]. Dostupné z: <https://www.bikeradar.com/advice/sizing-and-fit/bike-fit-explained-what-is-a-bike-fit-and-should-you-get-one/>.
- [37] OPENMMLAB. *Welcome to MMPose's documentation!* [online]. 2021 [cit. 2024-03-15]. Dostupné z: <https://mmpose.readthedocs.io/en/0.x/>.
- [38] OUIMET, C. Let's Get AS FAST AS POSSIBLE... on a BUDGET! AI-Powered Bike Fitting : MyVeloFit. *YouTube* [online]. 19. februára 2022 [cit. 2024-03-15]. Dostupné z: https://www.youtube.com/watch?v=UmZAFvdUwzM&ab_channel=CharlesOuimet.
- [39] PATH LESS PEDALED. Pro Bike Fit with Just Your Phone? GAMECHANGER. *YouTube* [online]. 11. novembra 2021 [cit. 2024-03-15]. Dostupné z: https://www.youtube.com/watch?v=2NWQoybfv-A&t=57s&ab_channel=PathLessPedaled.
- [40] RUDER, S. An overview of gradient descent optimization algorithms. *CoRR*. 2016, abs/1609.04747. Dostupné z: <http://arxiv.org/abs/1609.04747>.

- [41] THE PRO'S CLOSET. How to Improve Your Bike Fit: Benefits of Retül. *YouTube* [online]. 20. marca 2020 [cit. 2024-03-15]. Dostupné z: https://www.youtube.com/watch?v=YqnZTgfoZzQ&ab_channel=ThePro%27sCloset.
- [42] TOSHEV, A. a SZEGEDY, C. DeepPose: Human Pose Estimation via Deep Neural Networks. *2014 IEEE Conference on Computer Vision and Pattern Recognition*. 2013, s. 1653–1660. Dostupné z: <https://api.semanticscholar.org/CorpusID:206592152>.
- [43] VELO INSIGHT. Bike Fitting. *Velo Insight* [online]. 2021 [cit. 2024-03-15]. Dostupné z: <https://veloinsight.co.uk/bike-fitting/>.
- [44] YAMASHITA, R., NISHIO, M., DO, R. a TOGASHI, K. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*. Jún 2018, zv. 9. DOI: 10.1007/s13244-018-0639-9.

Príloha A

Obsah priloženého pamäťového média

src/ – priečinok so zdrojovými súbormi aplikácie

appdata/ – záloha dát z testovania, uložené snímky a bike fit dáta

inferences/ – inferencie vlastných videí z testovaných modelov

dataset/ – vlastný dataset

thesis/ – priečinok obsahujúci zdrojový kód tejto technickej správy

xkocma07.pdf – PDF súbor obsahujúci túto technickú správu

video.mp4 – obsahuje video demonštrujúce aplikáciu

plagat.pdf – obsahuje plagát zhotovený k aplikácií