

UNIVERZITA KOMENSKÉHO V BRATISLAVE  
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

# VYHLÁDÁVANIE V DATABÁZE ĽUDÍ REPREZENTOVANÝCH KOSTROU

Diplomová práca

2017

Bc. Michal Sejč

UNIVERZITA KOMENSKÉHO V BRATISLAVE  
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

**VYHĽADÁVANIE V DATABÁZE ĽUDÍ REPREZENTOVANÝCH KOSTROU**

Diplomová práca

Študijný program: Aplikovaná informatika  
Študijný obor: 2511 Aplikovaná informatika  
Školiace pracovisko: Katedra Aplikovanej Informatiky  
Školiteľ: Mgr. Andrej Mihálik, PhD.

Bratislava, 2017

Bc. Michal Sejč



Univerzita Komenského v Bratislave  
Fakulta matematiky, fyziky a informatiky

---

## ZADANIE ZÁVEREČNEJ PRÁCE

**Meno a priezvisko študenta:** Bc. Michal Sejč  
**Študijný program:** aplikovaná informatika (Jednoodborové štúdium, magisterský II. st., denná forma)  
**Študijný odbor:** 9.2.9. aplikovaná informatika  
**Typ záverečnej práce:** diplomová  
**Jazyk záverečnej práce:** slovenský  
**Sekundárny jazyk:** anglický

**Názov:** Vyhľadávanie v databáze ľudí reprezentovaných kostrou.  
*Database searching of people represented by the skeleton.*

**Cieľ:** Cieľom práce je navrhnúť algoritmus vyhľadávania ľudí zosnímaných bezpečnostnou kamerou na základe zrekonštruovanej kostry a jej pohybu.

**Vedúci:** Mgr. Andrej Mihálik, PhD.  
**Katedra:** FMFI.KAI - Katedra aplikovanej informatiky  
**Vedúci katedry:** prof. Ing. Igor Farkaš, Dr.  
**Dátum zadania:** 12.10.2015

**Dátum schválenia:** 26.10.2015

prof. RNDr. Roman Ďurikovič, PhD.  
garant študijného programu

  
študent

  
vedúci práce

Čestne prehlasujem, že som túto diplomovú prácu  
vypracoval samostatne s použitím citovaných zdrojov.

Bratislava, 2017

.....

Bc. Michal Sejč

# Pod'akovanie

Predovšetkým by som chcel poďakovať môjmu školiteľovi Mgr. Andrejovi Mihálikovi, PhD. za jeho neoceniteľnú pomoc a usmerňovanie počas práce na tejto problematike. Ďalej by som chcel poďakovať profesorovi RNDr. Romanovi Ďurikovičovi, PhD. a kolegom z YACGS semináru za cenné rady ohľadom návrhu a implementácie tejto metódy. Nakoniec by som sa chcel poďakovať svojej rodine a priateľom za ich podporu počas môjho štúdia.

# Abstrakt

Cieľom našej práce bolo správne identifikovať osobu na základe chôdze. Pri práci používame dáta získané metódou snímania pohybu. Z týchto dát následne extrahujeme chôdzu. Zo samotnej chôdze vypočítavame parametre, ktoré by mohli byť významné pri identifikácií. Tieto parametre ďalej analyzujeme a vyberáme tie, ktoré sú najrelevantnejšie. Následne vytvárame novú metódu, ktorá kombinuje overené techniky s novo zistenými poznatkami. Nakoniec správnosť našej metódy overujeme.

Kľúčové slová: ľudská chôdza, biometria, indetifikácia ľudí, vyhľadávanie v databáze

# Abstract

The main aim of the presented thesis is to rightly identify a person based on his or her gait. The thesis is based on data obtained by the motion capture method. The gait information is subsequently extracted therefrom. The parameters significant for identification are calculated from the walking itself afterwards. The stated parameters are throughoutly analysed and the most relevant ones are chosen for the creation of the new method which combines verified techniques and the new obtained data. At the end, the rightness of our method is verified.

Keywords: human gait, biometrics, human identification, database search

# Obsah

<b>1</b>	<b>Úvod</b>	<b>1</b>
<b>2</b>	<b>Analýza ľudskej chôdze</b>	<b>3</b>
2.1	Snímanie pohybu . . . . .	3
2.2	Štruktúra MoCap dát . . . . .	4
2.3	Model kostry . . . . .	7
2.4	Reprezentácia chôdze . . . . .	9
2.5	Parametre chôdze . . . . .	11
2.5.1	Fyziologické parametre . . . . .	11
2.5.2	Pohybové parametre . . . . .	13
2.5.3	Časovo závislé parametre . . . . .	19
2.6	Porovnanie hodnôt . . . . .	26
2.6.1	Porovnanie fyziologických a pohybových parametrov	27
2.6.2	Porovnanie časovo závislých parametrov . . . . .	28

<i>OBSAH</i>	ix
2.7 Analýza parametrov . . . . .	31
2.7.1 Analýza fyziologických a pohybových parametrov . . . . .	31
2.7.2 Analýza časovo závislých parametrov . . . . .	36
<b>3 Implementácia</b>	<b>41</b>
3.1 Návrh systému . . . . .	41
3.1.1 Syntaktický analyzátor . . . . .	42
3.1.2 Filter chôdze . . . . .	42
3.1.3 Prehrávač . . . . .	44
3.1.4 Deskriptor . . . . .	45
3.1.5 Analyzátor chôdze . . . . .	46
3.1.6 Porovnanie . . . . .	47
3.2 Návrh databázy . . . . .	48
<b>4 Validácia</b>	<b>50</b>
<b>5 Záver</b>	<b>53</b>

# Kapitola 1

## Úvod

V dnešnom svete plnom kriminality je správna a rýchla identifikácia osôb z pohľadu bezpečnosti kľúčovým prvkom. Každý z nás je totiž jedinečný. Naša osobnosť, rodina, bankové konto, účet na facebooku, náš život. To všetko vytvára identitu každého z nás. Tá však v dnešnom svete nemusí byť v bezpečí. Najčastejším spôsobom zisťovania identity býva preukázanie sa dokladom totožnosti. V horších prípadoch je postačujúce len heslo prípadne pin. Všetky tieto kľúče k našej identite môžu byť ukradnuté, prípadne sfaľované. Je teda potrebné zamerať sa na unikátne vlastnosti každého z nás, ktoré nie je možné nijako napodobniť, stratiť, prípadne zabudnúť. Jedná sa o identifikáciu, kde kľúčom je sám človek.

Táto forma identifikácie sa nazýva biometria. Ide o súbor vlastností a príznakov, ktoré sú jedinečné pre každého z nás. Medzi takéto vlastnosti patrí napríklad odtlačok prsta, očná dúhovka, DNA, hlas, vlastnoručný podpis, tvár, mapa žíl na dlani alebo prstoch, spôsob chôdze atď. Každá z týchto vlastností je len veľmi ťažko napodobiteľná, dokonca v niektorých prípadoch je to priam nemožné. Väčšina z týchto metód si však vyžaduje čas, špeciálnu technológiu alebo spoluprácu s danou osobou. Napríklad snímanie odtlačkov, skenovanie dúhovky alebo vytváranie podpisu. Ideálnym prípadom by bolo správne iden-

tifikovať osobu v reálnom čase pri bežnej činnosti, ako je napríklad chôdza s použitím bežných technológií akými sú napríklad kamery. V našej práci sa zameriavame práve na identifikáciu ľudí na základe ich chôdze.

Chôdza každého z nás je jedinečná ako potvrdil experiment [1], ktorý bol vykonaný v 70-tych rokoch minulého storočia. Experimentu sa zúčastnilo 14 sledovaných subjektov, 7 mužov a 7 žien s približne rovnakou výškou a váhou. Sledované subjekty mali oblečené čierne oblečenie, aby ich nebolo možné identifikovať prostredníctvom tváre alebo vzhľadu. Na oblečení mali rozmiestnené reflexné pásy, ktoré umožňovali vidieť iba pohyb. V podstate bolo možné z pohľadu pozorovateľov vidieť iba pohybujúce sa svetlé body v tme. Úlohou pozorovateľov a zároveň aj cieľom experimentu bolo určiť pohlavie osoby iba na základe pohybu týchto bodov. Experiment ukázal, že je možné identifikovať pohlavie s presnosťou takmer 70%. Úspešnosť pri určovaní identity sa však pohybovala iba okolo 51%. Experiment však potvrdil, že čím dlhšie pozorovatelia sledovali chôdzu, tým šanca na správnu identifikáciu rástla.

Ako sa však neskôr ukázalo, osobu je možné identifikovať s oveľa väčšou presnosťou na základe použitia vybraných príznakov. Výskum z roku 2014 ukázal, že je možné dosiahnuť až 96% úspešnosť [2]. V tejto práci používali najmä fyziologické premenné chôdze, ako napríklad výška osoby a dĺžka končatín. V našej metóde sme sa rozhodli využiť niektoré z týchto overených parametrov chôdze. Pokúsili sme sa ich rozšíriť, čím sme chceli dosiahnuť vyššiu presnosť identifikácie.

# Kapitola 2

## Analýza ľudskej chôdze

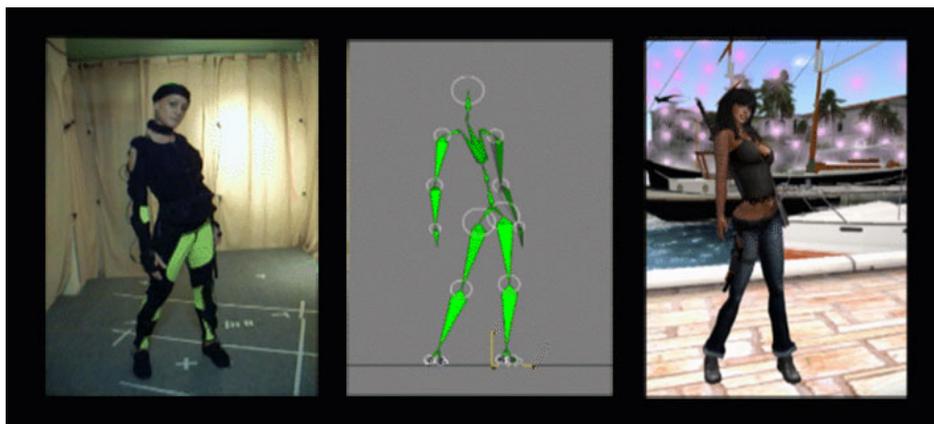
### 2.1 Snímanie pohybu

Snímanie pohybu alebo inými slovami motion capture je proces, ktorého úlohou je zaznamenávať pohyb objektov, osôb, prípadne zvierat. Výsledkom tejto metódy sú dáta reprezentujúce pohyb, ktoré majú využitie v rôznych odvetviach počítačovej grafiky.

Na získanie dát je potrebná scéna, v ktorej sa nachádza snímaný objekt. V našom prípade je objektom ľudský herec. Ďalej je potrebné, aby bol tento herec oblečený v špeciálnom obleku, ktorý má na svojom povrchu umiestnené reflexné body. Tieto body sú ľahko identifikovateľné pomocou počítača. Celá scéna je následne snímaná viacerými kamerami z rôznych uhlov. Každá z kamier vytvára snímky v rovnakých časových intervaloch. Najčastejšie sa používa 30 snímok za sekundu. Z týchto snímok je následne možné zistiť polohu reflexných bodov v priestore pre konkrétny čas.

Polohy bodov sa následne aplikujú na virtuálnu kostru, kde jeden bod na obleku herca prislúcha jednému kĺbu na kostre, ako môžeme vidieť na obrázku

2.1. Výsledkom je kostra, ktorá sa vo virtuálnom svete pohybuje rovnako ako herec na scéne. Pridaním 3D modelu na kostru sa dá následne vytvoriť počítačová animácia, v ktorej už nebude potrebné pohyby ručne animovať. V našej metóde však budeme používať iba samotnú kostru, ktorá bude reprezentovať chôdzu konkrétnej osoby.



Obr. 2.1: Priebeh metódy snímania pohybu [21].

Na výskum a testovanie našej metódy sme potrebovali dáta, ktoré by reprezentovali chôdzu ľudí. Našli sme mnoho online knižníc, ktoré ponúkajú rôzne motion capture dáta. Vo väčšine prípadov sa však nejednalo o dáta chôdze, ale o beh, lezenie, chytanie lopty atď. Vybrali sme si 2 knižnice [7] [11], ktoré ponúkali takmer 200 vhodných záznamov chôdze rôznych ľudí. Tieto záznamy sme neskôr spracovali a použili.

## 2.2 Štruktúra MoCap dát

Existuje veľa spôsobov ako reprezentovať dáta získané snímaním pohybu. Najčastejšie sa však ukladajú v *ASCII* formáte v podobe textu. Tento text je následne možné čítať a zostaviť z neho nasnímaný pohyb. Spôsobov kódovania pohybu do textu je hneď niekoľko. Každý zo spôsobov má svoj

špecifický formát. Najčastejšie používané formáty sú *amc/asf*, *c3d*, *tvd*, *bvh* a *txt*. Líšia sa v spôsobe akým dáta ukladajú. My sme si vybrali súbory vo formáte *bvh* (biovision hierarchy) [15].

Súbor s týmto formátom obsahuje okrem dát pohybu aj údaje o štruktúre a veľkosti kostry, ktoré sú pre našu metódu kľúčové. Súbor je rozdelený na 2 hlavné sekcie. Prvá z nich sa nazýva hierarchická, pretože sa v nej opisuje kostra, ktorá má hierarchickú štruktúru. Časť tejto sekcie môžeme vidieť v ukážke 2.1.

```
1 HIERARCHY
2 ROOT Hips
3 {
4   OFFSET 34.0413 97.9226 25.1906
5   CHANNELS 6 Xposition Yposition Zposition Zrotation Xrotation
6     Yrotation
7   JOINT ToSpine
8     {
9       OFFSET 0.0105055 10 1
10      CHANNELS 3 Zrotation Xrotation Yrotation
11      JOINT Spine
12        {
13          OFFSET 0 12 1.60637
14          CHANNELS 3 Zrotation Xrotation Yrotation
15          JOINT Neck
16            {
17              ...
18            }
19          }
20 }
```

Výpis 2.1: Ukážka hierarchickej sekcie *bvh* súboru.

Súbor sa začína slovom *HIERARCHY*. To znamená začiatok hierarchickej sekcie. V druhom riadku je slovo *ROOT*, ktoré označuje koreňový vrchol, respektíve koreňový kĺb celej hierarchie. Nasledujúce slovo v tomto riadku

súboru je názov kĺbu. V našom prípade hips, teda bedrá. Ak začneme postupovať ďalej, narazíme na slovo *OFFSET*. Za ním nasledujú 3 čísla, ktoré predstavujú, o koľko je tento vrchol vzdialený od svojho predka v smere  $X$ ,  $Y$  a  $Z$ . Vieme teda zistiť dĺžku danej kosti. Keďže sa však jedná o koreň, ktorý nemá predka, počíta sa tento posun od počiatku globálneho súradnicového systému. V našom prípade to znamená, že koreň sa nachádza presne v strede sústavy, teda nie je nikam posunutý.

Slovo *CHANNELS* znamená, že za ním bude nasledovať počet kanálov, ktoré využíva tento vrchol. Za číslom, ktoré vyjadruje ich počet sa nachádza aj zoznam daných kanálov. Tieto kanály slúžia na výpočet priestorovej pozície daného kĺbu. Môžeme sa z nich dozvedieť, že koreň obsahuje 3 kanály, ktoré popisujú jeho pozíciu pomocou súradníc  $X$ ,  $Y$  a  $Z$  a ďalšie 3 kanály, ktoré určujú jeho rotáciu vzhľadom na predka. Keďže koreň predka nemá tieto rotačné údaje, znamenajú rotáciu okolo vlastnej osi. Čiže smer, ktorým bude koreň a následne aj celá kostra natočená. Hodnoty týchto kanálov sa načítavajú z pohybovej sekcie z ukážky 2.2, ktorú si neskôr popíšeme.

Po deklarácií kanálov nasleduje slovo *JOINT*. To reprezentuje nový kĺb, ktorý je potomkom vrcholu z predošlej úrovne, čiže koreňa. Všetky ostatné slová a hodnoty sa správajú rovnako ako pri koreňovom vrchole. S tým rozdielom, že tieto údaje budú znamenať posun a rotáciu vzhľadom na svojho predka. Hierarchia vrcholov je v súbore zadaná zátvorkami a odsadením textu. Odsadenie textu nie je nutnou podmienkou, ale niektoré z profesionálnych softvérov ho vyžadujú. Syntaktický analyzátor, ktorý sme implementovali vyžadoval iba správne rozmiestnené zátvorky.

```
1 MOTION
2 Frames: 91
3 Frame Time: 0.0333333
4 10.6596 99.3375 16.8111 0.444372 -4.42636 -2.22279 0 0 0 ...
5 10.6581 99.3561 16.8106 0.388866 -4.34177 -2.20058 0 0 0 ...
6 ...
```

Výpis 2.2: Ukážka pohybovej sekcie bvh súboru.

Z hierarchickej sekcie dokážeme pomocou offsetov a informácií o hierarchii, zostaviť celú kostru, ktorú si detailnejšie popíšeme v sekcii 2.3. Okrem kostry však potrebujeme ešte údaje o pohybe. Tie sú uložené v pohybovej sekcii súboru, ktorá nasleduje hneď za sekciou hierarchickou.

Začína sa slovom *MOTION* a popisuje pohyb danej kostry. Slovo *Frames* označuje, koľko jednotlivých snímok sa v súbore nachádza. *FrameTime* je číslo, ktoré označuje čas trvania jedného snímku. V našom prípade to je 33 milisekúnd, čo predstavuje rýchlosť 30 snímok za sekundu.

V nasledujúcom riadku sa už nachádzajú samotné dáta pohybu. Každý riadok popisuje jeden snímok. Tieto dáta sú hodnoty, ktoré vstupujú do kanálov z hierarchickej sekcie. Ak si zoberieme koreňový vrchol, vidíme, že má 6 kanálov. Konkrétne *Xposition*, *Yposition*, *Zposition*, *Zrotation*, *Xrotation* a *Yrotation*. Prvé číslo v riadku bude predstavovať súradnicu *X* koreňa, druhé číslo súradnicu *Y* atď. Prvých 6 čísel bude teda určených iba pre koreň. Ostatné vrcholy majú iba 3 rotačné kanály takže každé ďalšie 3 čísla budú predstavovať hodnoty pre nasledujúci hierarchický vrchol.

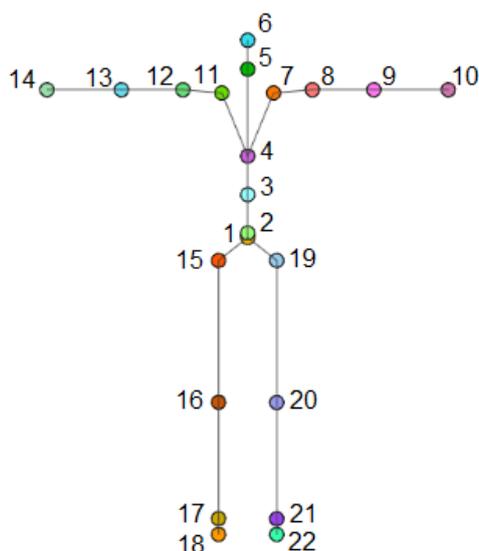
## 2.3 Model kostry

V predošlej sekcii sme si popísali štruktúru súboru, ktorý používame ako vstup pre našu metódu. Tieto dáta je však potrebné správne načítať pre ďalšie použitie.

Prvým krokom je zostavenie kostry z hierarchickej sekcie vstupného súboru. Z tejto sekcie dokážeme zostaviť kostru v základnej polohe, teda bez pohybu. Kostru si môžeme predstaviť ako graf, kde vrcholy predstavujú kĺby a hrany predstavujú kosti. Pozícia koreňa je pevne daná. Potomkovia mali definovaný iba posun vzhľadom na predka. Čiže pozíciu každého z potomkov bolo možné vypočítať ako súčet posunu s pozíciou priameho predka.

Týmto spôsobom sme vedeli zostaviť kostru, ktorá obsahovala informácie o priestorovej polohe kĺbov. Na túto kostru už bolo možné aplikovať dáta z pohybovej sekcie vstupného súboru, ktoré reprezentovali pohyb. O nich si povieme viac v sekcii 2.4.

Zatiaľ však máme iba kostru v základnej polohe. Štruktúra kostry môže byť pre každý vstupný súbor iná. Dataset ktorý sme použili však obsahoval kostry, ktorých štruktúru môžeme vidieť na obrázku 2.2. Celý systém sme navrhli tak, aby vedel spracovať kostru tohto typu. Použitá kostra je zložená zo 17 kĺbov a 5 koncových bodov, takže v súčte pozostáva z 22 hierarchicky usporiadaných bodov. Tieto body budeme označovať ako  $P_i$ , kde  $i \in \langle 1, 22 \rangle$ .



Obr. 2.2: Model kostry.  $P_1$ -bedrá (stred),  $P_2$ -kostrč,  $P_3$ -dolný chrbát,  $P_4$ -horný chrbát,  $P_5$ -krk,  $P_6$ -hlava,  $P_7$ -ľavé rameno,  $P_8$ -ľavá ruka,  $P_9$ -ľavý lakeť,  $P_{10}$ -ľavá dľaň,  $P_{11}$ -pravé rameno,  $P_{12}$ -pravá ruka,  $P_{13}$ -pravý lakeť,  $P_{14}$ -pravá dľaň,  $P_{15}$ -pravý bedrový kĺb,  $P_{16}$ -pravé koleno,  $P_{17}$ -pravá päta,  $P_{18}$ -pravá špička,  $P_{19}$ -ľavý bedrový kĺb,  $P_{20}$ -ľavé koleno,  $P_{21}$ -ľavá päta,  $P_{22}$ -ľavá špička.

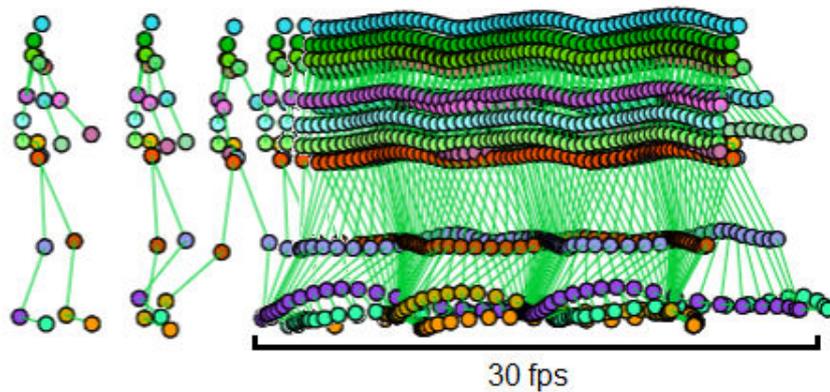
Koreňom celej hierarchie je bod  $P_1$  označený číslom 1. Jeho potomkovia sú kĺby s číslom 2, 15 a 19, teda body  $P_2$ ,  $P_{15}$  a  $P_{19}$ . Podobným spôsobom je

usporiadaná celá kostra. Hierarchia v tomto prípade slúži na správnu reprezentáciu rotácií. Rotácia každého vrcholu sa prejaví na všetkých jeho potomkoch. V prípade, že pridáme rotáciu na koreňový vrchol, táto rotácia sa prejaví rekurzívne na všetkých jeho potomkoch. Cíže celá postava sa otočí o daný uhol po danej osi. Pridaním rotácie pre každý z kĺbov, vieme kostru vytvárať do ľubovoľnej pózy.

## 2.4 Reprezentácia chôdze

V predchádzajúcej sekcii sme si popísali štruktúru kostry, ktorú budeme používať. Pre našu metódu však potrebujeme okrem statickej pózy aj pohyb. Ten je súčasťou zdrojového súboru, ale je potrebné ho správne aplikovať.

Každý z kĺbov je možné rotovať okolo svojho hierarchického predka po všetkých troch osiach. Takže pomocou rotácií, ktorých hodnoty sa nachádzajú v pohybovej sekcii vstupného súboru, dokážeme vytvárať jednotlivé pózy tejto kostry. Týmito pózami vieme následne reprezentovať aj samotnú chôdzu. Na reprezentáciu chôdze nám stačí niekoľko po sebe idúcich póz, ako môžeme vidieť na obrázku 2.3. Jedna takáto póza sa taktiež nazýva snímok. Optimálne množstvo pre reprezentáciu normálnej chôdze je 30 snímok za 1 sekundu (30 fps). Pri reprezentácií rýchlejšieho pohybu ako napríklad behu by bolo potrebné použiť aspoň 60 snímok za sekundu, aby bol pohyb plynulý. Pri chôdzi nám ich však stačilo 30.



Obr. 2.3: Sekvencia reprezentovanej chôdze.

Na zostavenie každej z póz celej sekvencie potrebujeme kostru v základnej polohe, ktorú zostavíme pomocou offsetov jednotlivých kĺbov. Na všetky kĺby tejto kostry následne aplikujeme dáta z pohybovej sekcie *bvh* súboru. V tejto sekcii sa nachádza popis pohybu pre každý snímok zvlášť. Pre koreň je okrem rotácie zadaná aj pozícia. To znamená, že tento údaj bude udávať globálnu polohu celej kostry v priestore pre každý snímok zvlášť.

Pre každý z kĺbov máme zadanú rotáciu pre všetky tri osi  $XYZ$ . Toto číslo je vyjadrené v stupňoch a určuje, o koľko sa daný kĺb otočí okolo svojho predka. Táto rotácia sa prejaví aj na všetkých potomkoch rotovaného kĺbu. Ak napríklad otočíme koreň, spolu s ním sa otočí celá kostra. Ak otočíme ramenný kĺb, pohne sa celá ruka.

Poradie v akom sa rotácie aplikujú je dôležité pre správnu interpretáciu pózy. Toto poradie je striktné zadané pomocou hierarchie kĺbov. Rotácie sa teda začnú aplikovať postupne so začiatkom v koreňovom kĺbe. Podľa špecifikácie formátu *bvh* sa však rotácia okolo koreňa musí preskočiť a vykonať ako posledná. Táto posledná rotácia už iba natočí kostru do správneho smeru.

Poradie osí okolo ktorých kĺby rotujeme je tiež veľmi dôležité. Toto poradie je zadané v zdrojovom súbore. Konkrétne ako *Zrotation*, *Xrotation* a

*Yrotation* v ukážke 2.1. To znamená, že najskôr musíme kĺb rotovať okolo osi  $Z$ , potom okolo osi  $X$  a nakoniec okolo osi  $Y$ . Pre dosiahnutie správneho výsledku však musíme rotačné matice aplikovať v opačnom poradí. To isté platí aj v prípade použitia kvaternionov. Rotácie je teda potrebné skladať odzadu, teda najskôr sa vykonáva rotácia okolo osi  $Y$ , potom okolo  $X$  a nakoniec okolo osi  $Z$ .

## 2.5 Parametre chôdze

My ľudia dokážeme častokrát identifikovať známu osobu v diaľke alebo pri zlom svetle, iba na základe toho ako sa pohybuje. Chôdza každého človeka totiž obsahuje množstvo charakteristických črt, ktoré sú pre danú osobu jedinečné. Niektorí kráča rýchlejšie, niektorí dvíha nohy vyššie a niektorí zase príliš pohybuje rukami alebo sa viac nakláňa do strán. Podobných príznakov by sme vedeli nájsť nespočetne veľa. Z celej tejto množiny príznakov sme niektoré vybrali a rozdelili ich na tri kategórie. Fyziologické, pohybové a časovo závislé. Medzi fyziologické patrí napríklad výška osoby. Tá je stále konštantná. Za pohybové môžeme považovať napríklad dĺžku kroku. Táto dĺžka nemusí byť nutne rovnaká pri každom kroku a môže sa jemne líšiť. Poslednou kategóriou sú časovo závislé parametre. Medzi ne patrí napríklad zrýchlenie, ktoré sa počíta pre každý časový okamih. V tejto kapitole si všetky tieto príznaky alebo inak povedané parametre detailne popíšeme.

### 2.5.1 Fyziologické parametre

Fyziologické parametre sú pre jednu osobu rovnaké v každom časovom okamihu pohybu. Na ich výpočet nie je dokonca ani potrebné, aby sa subjekt prechádzal. Dajú sa vypočítať z jedného ľubovoľného snímku. V našej metóde sme použili 5 fyziologických parametrov. Medzi ne patrí výška trupu, dĺžka

ľavej a pravej ruky, dĺžka ľavej a pravej nohy. Pri výpočte týchto parametrov sa používajú vzdialenosti medzi kĺbmi. Každý z kĺbov je reprezentovaný ako bod  $P$  v trojrozmernom priestore, definovaný súradnicami  $(x, y, z)$ . Takže vzdialenosť  $D$  medzi dvoma kĺbmi sa vypočíta ako euklidovská vzdialenosť týchto dvoch bodov podľa rovnice 2.1. Výsledná hodnota bude súčet vzdialeností medzi každými dvoma susediacimi kĺbmi z danej postupnosti. Jednotlivé parametre predstavujúce dĺžky telesných partií  $L$ , tak vypočítame pomocou rovnice 2.2.

$$D(P_1, P_2) = \sqrt{(P_{1x} - P_{2x})^2 + (P_{1y} - P_{2y})^2 + (P_{1z} - P_{2z})^2}, \quad (2.1)$$

$$L_w = \sum_{i \in w} D(P_{w_i}, P_{w_{i+1}}), \quad (2.2)$$

kde  $w$  predstavuje množinu kĺbov reprezentujúcich danú partiu. Indexy kĺbov z týchto množín nájdeme popísané v tabuľke 2.1. Tieto vzdialenosti sme počítali pre každý snímok zvlášť. Výsledná hodnota bola priemerom hodnôt zo všetkých snímkov, aby sa tak minimalizovali drobné nepresnosti, spôsobené počítačovou aritmetikou.

Označenie	Parameter	$w$
$\gamma$	Výška trupu	{6, 5, 4, 3, 2, 1}
$\alpha_P$	Dĺžka pravej ruky	{12, 13, 14}
$\alpha_L$	Dĺžka ľavej ruky	{8, 9, 10}
$\beta_P$	Dĺžka pravej nohy	{15, 16, 17}
$\beta_L$	Dĺžka ľavej nohy	{19, 20, 21}

Tabuľka 2.1: Postupnosti kĺbov.

## 2.5.2 Pohybové parametre

Pohybové parametre zahŕňajú atribúty, ktoré sa môžu pri každom kroku chôdze meniť. Patrí sem napríklad rýchlosť chôdze, dĺžka kroku atď. Celkom sme skúmali až 30 parametrov, ktoré by mohli byť pri identifikácii relevantné. Ukázalo sa však, že väčšina z nich je závislá od priestorovej polohy kostry. Takéto parametre sme preto vylúčili. Nakoniec nám zostalo 10 parametrov, ktoré sme ďalej podrobili analýze. Zoznam parametrov je uvedený v tabuľke 2.2.

Označenie	Parameter
$v$	Rýchlosť chôdze
$\delta_L$	Dĺžka kroku ľavou nohou
$\delta_P$	Dĺžka kroku pravou nohou
$\kappa$	Šírka kroku
$\sigma_{P_6,x}^2$	Variancia hlavy po x-ovej osi
$\sigma_{P_6,y}^2$	Variancia hlavy po y-ovej osi
$\sigma_{P_{20},y}^2$	Variancia ľavého kolena po y-ovej osi
$\sigma_{P_{16},y}^2$	Variancia pravého kolena po y-ovej osi
$\sigma_{P_7,x}^2$	Variancia ľavého ramena po x-ovej osi
$\sigma_{P_{11},x}^2$	Variancia pravého ramena po x-ovej osi

Tabuľka 2.2: Zoznam pohybových parametrov.

Pohybové parametre nie sú stabilné tak ako parametre fyziologické. Pre jednu osobu sa môžu pri každom kroku meniť. Na ich výpočet nám už nebude stačiť iba jediný snímok ako pri fyziologických parametroch. V tomto prípade budeme potrebovať niekoľko, po sebe idúcich snímok, ktoré zachytávajú minimálne 2 kroky z celej chôdze. 2 kroky znamenajú to, že sa ľavá aj pravá noha dotkne zeme 2x, aby bolo možné vypočítať dĺžku kroku. Počet snímok, ktorý by tieto 2 kroky zachytával, nie je možné jednoznačne určiť. Závisí to od počtu snímok za sekundu a rýchlosti snímanej chôdze.

## Rýchlosť chôdze

Rýchlosť chôdze je číselná hodnota udávajúca dĺžku dráhy, ktorú osoba prejde za stanovený čas. Konkrétne je to vzdialenosť, ktorú urazí bod  $P_1$  (obr. 2.2). Potrebovali sme si však zvoliť vhodný časový krok. Vzhľadom na to, že vstupné dáta obsahujú pre jednu sekundu vždy celočíselný počet snímok (30, 60, ...), bola jedna sekunda najvhodnejšia voľba.

Zo vstupných dát sme vedeli, koľko snímok sa nachádza v jednej sekunde. Pri našich pokusoch to bolo vždy 30. Nemusí to však byť pravidlom. Na základe toho sme si z celej sekvencie chôdze mohli vyselektovať každý tridsiaty. Z každých dvoch vyselektovaných, po sebe idúcich snímok sme vypočítali, o koľko sa bod  $P_1$  pohol. Tieto vzdialenosti udávali dĺžku dráhy, ktorú osoba prešla za každú sekundu trvania chôdze. Aj napriek tomu, že rýchlosť chôdze by mala byť teoreticky konštantná, neboli všetky tieto hodnoty rovnaké. V jednej sekunde totiž mohla sledovaná osoba mierne zrýchliť alebo naopak spomaliť. Pokúsili sme sa použiť aritmetický priemer týchto dát, ktorý sa však ukázal ako nesprávna voľba. V niektorých prípadoch začala sledovaná osoba ku koncu chôdze spomaľovať, čo spôsobovalo skreslenie výsledkov. Výslednú rýchlosť sme určili ako medián zo získaných dát.

## Dĺžka kroku

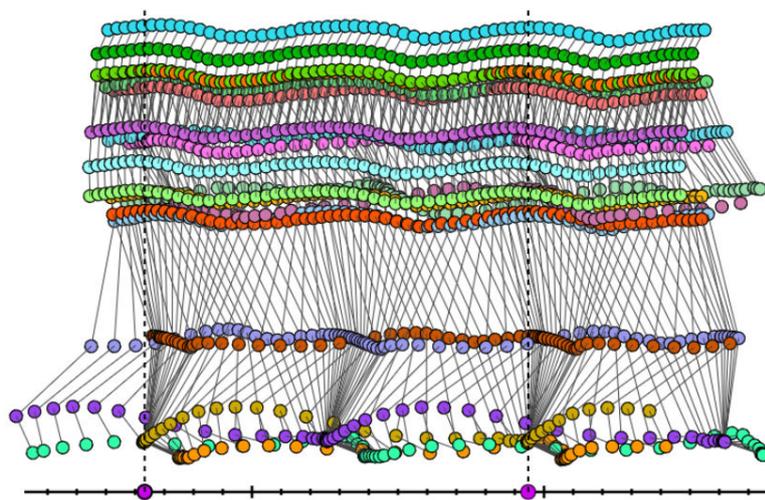
Pri našich experimentoch sme využívali dva parametre pre dĺžku kroku. Jeden pre ľavú a druhý pre pravú nohu. Ukázalo sa totiž, že človek nemusí robiť rovnako dlhé kroky pre každú z dolných končatín. Dĺžku kroku sme počítali ako vzdialenosť dvoch bodov, v ktorých sa päta rovnakej nohy dotkla zeme. Tieto body sú znázornené na obrázku 2.4. Obrázok ukazuje dotyky ľavej nohy s podlahou.

Na výpočet vzdialenosti sme najskôr potrebovali detegovať body v ktorých

sa noha dotkla zeme. Podlaha však nebola nijako definovaná. Mohla sa nachádzať v ľubovoľnej výške vzhľadom na súradnicový systém. Použití výškové súradnice na detekciu dotyku s podlahou, nebolo možné.

Pri chôdzi však dochádza k striedavému pohybu nôh. Napríklad pravá noha sa pohybuje, zatiaľ čo ľavá stojí na mieste a svoju polohu nemení. Ľavá sa začne pohybovať, až keď sa pravou dotkneme podlahy. Čiže v momente dotyku nohy s podlahou, sa jej poloha nemení. To znamená, že poloha tejto nohy je v niekoľko, po sebe idúcich snímkach rovnaká. Z obrázku 2.4 môžeme vidieť, že v hľadaných miestach je hustota bodov reprezentujúcich pätu vyššia.

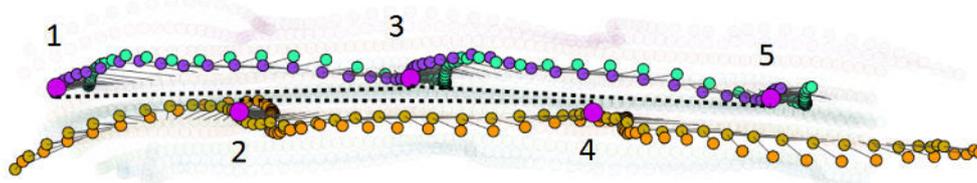
Miesta v ktorých bola táto hustota najvyššia, predstavovali body, v ktorých sa noha dotkla zeme. Týmto spôsobom sme dostali niekoľko, po sebe idúcich bodov, ktoré predstavovali dotyk nohy s podlahou. Následne sme vypočítali vzdialenosti medzi nimi. Táto vzdialenosť bola hľadaná dĺžka kroku. K výpočtu sme však vždy potrebovali sekvenciu chôdze v ktorej by osoba vykonala minimálne dva kroky. Pre jednu osobu sa dĺžka krokov počas chôdze mohla mierne líšiť. Výslednú hodnotu sme dostali ako medián z vypočítaných dát. Platí však, že čím je záznam chôdze dlhší, tým sú výsledky presnejšie.



Obr. 2.4: Dĺžka kroku ľavej nohy.

### Šírka krokov

Tento parameter určuje, aká je vzdialenosť piat od seba pri chôdzi. Pre výpočet tejto hodnoty sme potrebovali taktiež detekovať body, v ktorých sa nohy dotýkali zeme. Tieto body sme získali rovnakým spôsobom ako v pri výpočte dĺžky kroku. Získané body sme následne premietli na podlahu, teda na rovinu  $XZ$ . Vzhľadom na to sme začali, uvažovať o týchto bodoch v 2D. Pohľad na túto rovinu je zobrazený na obrázku 2.5. Hľadané body sú znázornené fialovou farbou s označením 1 až 5.



Obr. 2.5: Šírka kroku - pohľad z hora.

Na výpočet šírky sú potrebné minimálne 3 po sebe idúce body. Pri hľadaní presnej hodnoty sme však vyskúšali dva rôzne spôsoby. Prvým z nich bolo jednoducho pospájať každý tretí bod a vytvoriť tak priamky, ktoré by prechádzali bodmi  $\{1,3\}$ ,  $\{2,4\}$  a  $\{3,5\}$ . Od týchto priamok sme následne vypočítali vzdialenosť k bodu, ktorý sme preskočili. Čiže vzdialenosť bodu 2 od priamky, ktorá prechádzala bodmi  $\{1,3\}$  atď. Týmto spôsobom sme však získali hodnoty s veľkým rozptylom. Znamenalo to, že tento prístup nebol príliš dobrý, pretože sme potrebovali získať dáta, ktorých rozptyl by bol medzi jednotlivými krokmi čo najmenší.

Zvolili sme preto použitie lineárnej regresie [9]. Pomocou nej sme pre každé tri po sebe idúce body našli priamku, ktorá tieto body najlepšie vystihovala. Takto nájdené priamky sú čiastočne načrtnuté na obrázku 2.5 čiarkovanou čiarou. Následne sme vypočítali vzdialenosti týchto priamok od prostredného

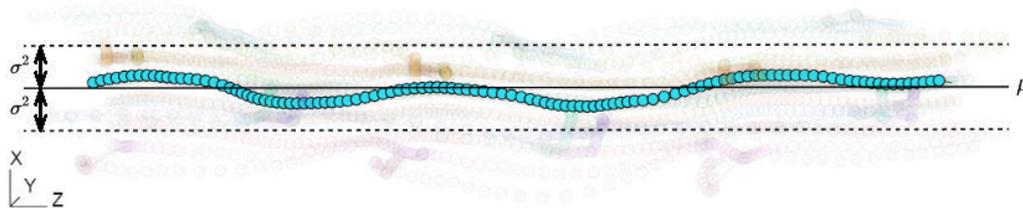
z bodov, ktoré boli použité pri určení priamky lineárnou regresiou. Čiže pre priamku vypočítanú z bodov  $\{1,2,3\}$ , sme hľadali vzdialenosť od bodu 2. Týmto spôsobom sme taktiež získali dáta, ktoré mali určitý rozptyl, ktorý bol spôsobený tým, že sledovaná osoba sa neprechádzala po dokonale rovnej trajektórii, ale občas zamierila do strán a následne pohyb vyrovnala. Tieto občasné extrémny by pri priemerovaní hodnôt mohli spôsobovať značnú mieru skreslenia, a preto sme opäť použili medián z vypočítaných dát.

### Variancia

Variancia alebo inými slovami rozptyl udáva veľkosť rozmedzia, v ktorom sa nachádzajú sledované hodnoty. Označuje sa ako  $\sigma^2$  a je možné ju vypočítať podľa vzorca 2.3.

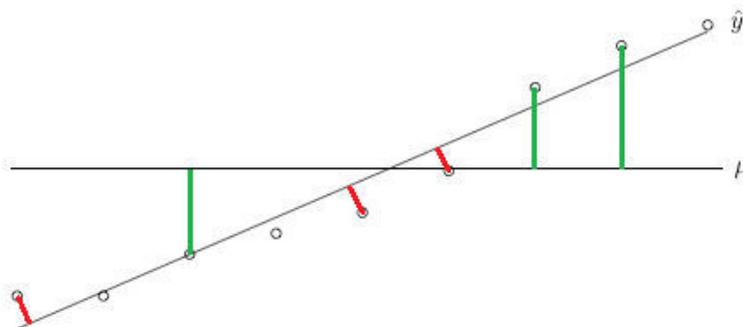
$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2, \quad (2.3)$$

kde  $N$  je počet bodov a  $\mu$  je stredná hodnota. Je to v podstate priemer druhých mocnín vzdialeností hodnôt od ich priemernej hodnoty  $\mu$ . Na obrázku 2.6 môžeme vidieť pohľad z hora na chôdzu osoby. Farebné body predstavujú pohyb hlavy po osi  $X$ . Plná čiara označená ako  $\mu$ , predstavuje strednú hodnotu resp. priemer súradníc  $X$  týchto bodov. Variancia  $\sigma^2$  je reprezentovaná čiarkovanou čiarou a predstavuje rozmedzie v akom sa body nachádzajú, respektíve druhú mocninu tohto rozmedzia.



Obr. 2.6: Variancia hlavy po osi X.

Tento spôsob výpočtu variance by bol správny iba v prípade, že by sledovaná osoba kráčala vždy v smere osi  $Z$ . Ak si predstavíme, že by sa osoba pohybovala rovnakým spôsobom, ale v smere osi  $X$ , rozptyl by bol obrovský, pričom chôdza by zostala nezmenená. Riešením bolo počítať varianciu ako strednú kvadratickú odchýlku  $MSE$  [8], ktorá predstavuje odhadovanú hodnotu variance. Rozdiel bol v tom, že strednú hodnotu sme už nepočítali ako obyčajný priemer, ale tento raz sme využili lineárnu regresiu [9]. Jej výsledkom bola priamka, ktorá predstavovala strednú hodnotu našich bodov. Rozdiel je vidieť na obrázku 2.7.

Obr. 2.7: Lineárna regresia  $\hat{y}$  a stredná hodnota  $\mu$ .

Je vidieť, že priamka  $\hat{y}$  vystihuje zadané body oveľa lepšie ako priemer  $\mu$ . Pomocou tejto priamky sme už vedeli vypočítať veľkosť strednej kvadratickej odchýlky  $MSE$  pomocou vzorca 2.4.

$$MSE = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N - 2}, \quad (2.4)$$

kde  $N$  je počet bodov,  $y_i$  je  $y$  súradnica  $i$ -teho bodu a  $\hat{y}_i$  je stredná hodnota v bode  $i$  vypočítaná ako priamka  $\hat{y}_i = \beta_0 + \beta_1 x_i$ .  $\beta_0$  a  $\beta_1$  sú koeficienty získané lineárnou regresiou. Tento spôsob sa ukázal ako najpresnejšia voľba pri odhade veľkosti variancie, a preto sme sa ho rozhodli použiť na výpočet všetkých variancií uvedených v tabuľke 2.2.

### 2.5.3 Časovo závislé parametre

$a_{P_6}$	zrýchlenie hlavy	$\omega_v$	rotácia ramien vertikálna
$a_{P_1}$	zrýchlenie bedier	$\omega_h$	rotácia ramien horizont.
$a_{P_9}$	zrýchlenie ľavého lakťa	$d_{P_{10,14}}$	vzdialenosť dlaní
$a_{P_{13}}$	zrýchlenie pravého lakťa	$d_{P_{9,13}}$	vzdialenosť lakťov
$a_{P_{10}}$	zrýchlenie ľavej dlane	$d_{P_{16,20}}$	vzdialenosť kolien
$a_{P_{14}}$	zrýchlenie pravej dlane	$d_{P_{17,21}}$	vzdialenosť piat
$a_{P_{20}}$	zrýchlenie ľavého kolena	$d_{P_{18,22}}$	vzdialenosť špičiek
$a_{P_{16}}$	zrýchlenie pravého kolena	$\varphi_n$	náklon hlavy voči krku
$a_{P_{21}}$	zrýchlenie ľavej päty	$\varphi_\gamma$	náklon trupu
$a_{P_{17}}$	zrýchlenie pravej päty	$\varphi_{\alpha_L}$	ohyb ľavej ruky
$a_{P_{22}}$	zrýchlenie ľavej špičky	$\varphi_{\alpha_P}$	ohyb pravej ruky
$a_{P_{18}}$	zrýchlenie pravej špičky	$\varphi_{\beta_L}$	ohyb ľavej nohy
		$\varphi_{\beta_P}$	ohyb pravej nohy

Tabuľka 2.3: Zoznam časovo závislých parametrov.

V tejto sekcii si popíšeme parametre, ktoré sú závislé od času. Nebude sa už jednať o jednorozmerné hodnoty, ako to bolo pri fyziologických alebo pohybových parametroch, ale o postupnosť hodnôt v závislosti od času.

Parametrov, ktoré sa menia v závislosti od času, by sa dalo nájst mnoho. My

sme sa však rozhodli skúmať zrýchlenie kĺbov, rotácie ramien, ohyb a vzdialenosti končatín. Kompletný prehľad skúmaných parametrov je popísaný v tabuľke 2.3.

### Zrýchlenie

Ako už názov napovedá, skúmali sme zrýchlenie rôznych kĺbov v čase. Výsledkom bol signál, ktorý ukazoval, zmenu magnitúdy zrýchlenia v závislosti na čase. Magnitúdu zrýchlenia sme najskôr počítali z kĺbov, dvoch tesne po sebe idúcich snímok. Tieto výsledky sa však ukázali ako nepresné, nakoľko obsahovali veľké skreslenie. Výpočet sme upravili tak, aby sa nepoužívali dva, tesne po sebe idúce snímky, ale aby sa vždy jeden preskočil a do výpočtu sa použil iba každý druhý snímok. Výsledné hodnoty zrýchlenia  $a$  sme vypočítali podľa vzorca 2.5. Pre výpočet zrýchlenia sme potrebovali poznať rýchlosti  $v_1$  a  $v_2$ , ktoré sme vypočítali pomocou vzorca 2.6.

$$a = \frac{v_2 - v_1}{t_2 - t_1}, \quad (2.5)$$

$$v = \frac{D(P_2, P_1)}{t_2 - t_1}, \quad (2.6)$$

kde  $P_1$  a  $P_2$  sú body reprezentujúce pozície kĺbu v časoch  $t_1$  a  $t_2$ .  $v_1$  a  $v_2$  sú rýchlosti v časoch  $t_1$  a  $t_2$ .  $D$  je funkcia pre výpočet vzdialenosti dvoch bodov.

Týmto spôsobom sme vypočítali magnitúdy zrýchlenia v čase. Výsledné hodnoty sme zakreslili do grafu, kde os  $x$  predstavuje čas a os  $y$  veľkosť zrýchlenia. Tento graf môžeme vidieť na obrázku 2.8.



Obr. 2.8: Zrýchlenie bedrového kĺbu - pôvodný signál.

Ako môžeme z grafu vidieť, tento signál nemá hladký priebeh. Je mierne zašumený. Je to spôsobené tým, že záznam chôdze pozostáva iba z 30 snímkov za sekundu. Ak by sme mali záznam chôdze s hustejším vzorkovaním, signál by bol hladší. Použili sme trojuhelníkovú vyhladzovaciu funkciu [16], ktorá na vyhladenie signálu používa vážený priemer okolitých hodnôt. Tieto vyhladené hodnoty boli vypočítané podľa vzorca 2.7.

$$X_i = \frac{Y_{i-2} + 2Y_{i-1} + 3Y_i + 2Y_{i+1} + Y_{i+2}}{9}, \quad (2.7)$$

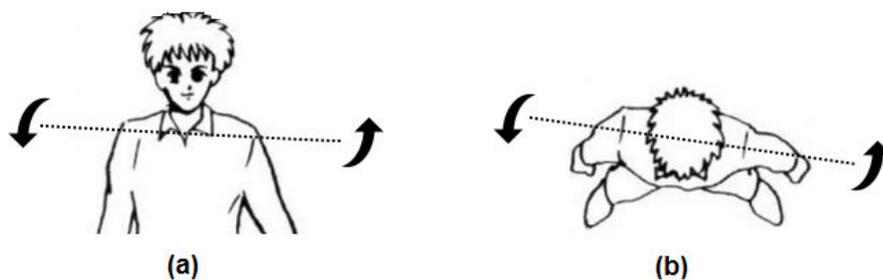
kde  $Y$  predstavuje vstupný a  $X$  výstupný signál. Po použití tejto vyhladzovacej funkcie sme dostali signál, ktorý môžeme vidieť na obrázku 2.9.



Obr. 2.9: Zrýchlenie bedrového kĺbu - vyhladený signál.

### Rotácie ramien

Ďalším parametrom, ktorý sme skúmali bola rotácia ramien. Ak si predstavíme kráčajúcu osobu, môžeme si všimnúť, že mierne pohybuje ramenami. Jedno rameno sa pohybuje smerom nahor, zatiaľ čo druhé klesá. Jedno sa pohybuje vpred a druhé naopak vzad. Toto sú dva základné pohyby, ktoré vykonávame ramenami, počas toho ako kráčame. Ak by sme si predstavili priamku, prechádzajúcu oboma ramenami, menila by svoj uhol vzhľadom k podlahe a rovnako aj k ľubovoľnej vertikálnej rovine. Preto sme tieto pohyby nazvali ako horizontálna a vertikálna rotácia ramien. Ilustráciu týchto pohybov je možné vidieť na obrázku 2.10.



Obr. 2.10: Horizontálna (a) a vertikálna (b) rotácia ramien [20].

Na výpočet sme použili body  $P_8$  a  $P_{12}$  (obr 2.2). Z týchto bodov sme vypočítali smerový vektor  $\vec{v} = (v_1, v_2, v_3)$  podľa vzorca 2.8.

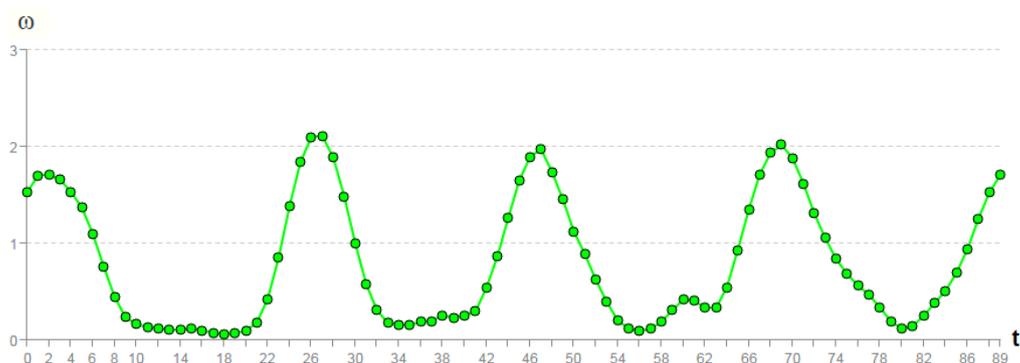
$$\vec{v} = (P_{12,x} - P_{8,x}, P_{12,y} - P_{8,y}, P_{12,z} - P_{8,z}), \quad (2.8)$$

kde  $P_{i,x}$ ,  $P_{i,y}$  a  $P_{i,z}$  predstavujú súradnice  $x, y, z$  bodu  $P_i$ ,  $i \in \{12, 8\}$ . Následne sme vypočítali kosínus uhla, ktorý zvieral tento vektor s podlahou (vzorec 2.9) a kosínus uhla, ktorý zvieral s jednou z vertikálnych rovín (vzorec 2.10).

$$\omega_h = |\vec{n}_h| \cdot |\vec{v}|, \quad (2.9)$$

$$\omega_v = |\vec{n}_v| \cdot |\vec{v}|, \quad (2.10)$$

kde vektor  $\vec{n}_h$  pri výpočte horizontálnej rotácie predstavoval normálový vektor podlahy  $(0, 1, 0)$ . Pri vertikálnej rotácii predstavoval vektor  $\vec{n}_v$  normálový vektor roviny  $YX$ , čiže  $(0, 0, 1)$ . Zmenu kosínov uhlov medzi jednotlivými snímkami sme zakreslili do grafu, ktorý môžeme vidieť na obrázku 2.11. Signál je taktiež vyhladený trojuholníkovou vyhladzovacou funkciou [16].

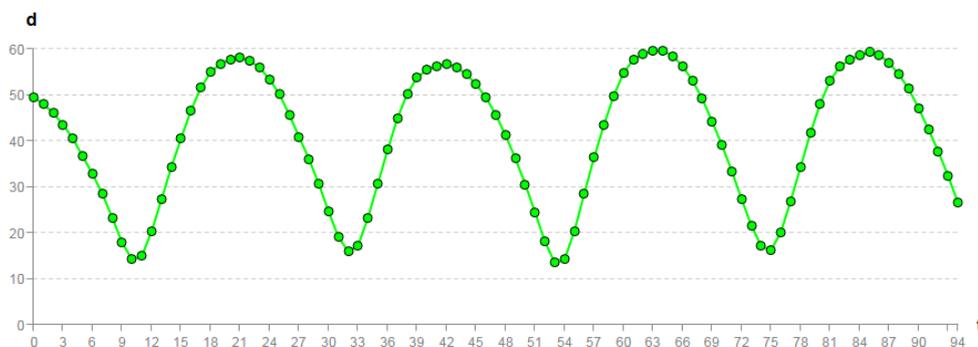


Obr. 2.11: Veľkosť vertikálnej rotácie ramien.

## Vzdialenosti

Ak sa pozrieme na kráčajúcu osobu a zahľadíme sa na jej ľavú a pravú dľaň, môžeme si všimnúť, že sa istú dobu k sebe približujú a po chvíli sa začnú opäť vzdalovať. Ich vzdialenosť sa mení. Rozhodli sme sa preskúmať, či by táto zmena vzdialeností nemohla byť pre isté osoby charakteristickou vlastnosťou. Pri skúmaní sme sa zamerali na zmenu vzdialeností dlaní, lakt'ov, kolien a chodidiel. Pri chodidlách sme navyše skúmali pätu aj špičku. Takže celkovo sme získali až 5 parametrov.

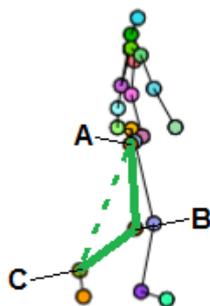
Jednotlivé kĺby su definované ako body v priestore. Ich vzdialenosť sa rovnala euklidovskej vzdialenosti týchto dvoch bodov. Túto vzdialenosť sme vypočítali pre dané kĺby v každom snímku. Výsledné hodnoty sme zakreslili do grafu s príslušným časom snímku. Graf zobrazujúci vzdialenosti piat môžeme vidieť na obrázku 2.12. Kde os  $y$  predstavuje hodnotu vzdialenosti a os  $x$  čas vyjadrený počtom snímok. Tento signál neobsahuje takmer žiadny šum a nebolo potrebné ho filtrovať.



Obr. 2.12: Vzdialenosť piat

## Náklon a ohyb

Každý z nás počas chôdze zohýba ruky, nohy, pohybuje hlavou alebo sa nakláňa do strán. Otázne bolo, či to každý z nás nerobí vlastným, špecifickým spôsobom. Rozhodli sme sa preskúmať a analyzovať tieto atribúty. Jednalo sa o ohyb rúk, nôh, o náklon krku a celého tela.

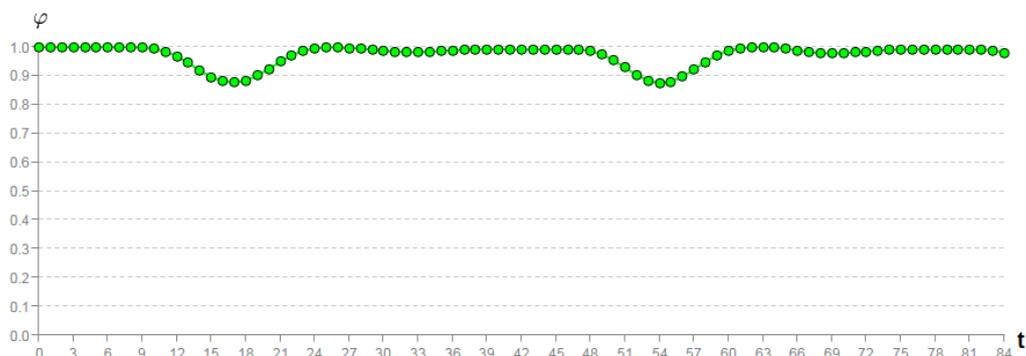


Obr. 2.13: Ohyb nohy.

Ruka aj noha obsahuje v našom prípade práve tri kĺby. Označme si tieto kĺby ako  $A$ ,  $B$  a  $C$ . Pre lepšiu predstavu pozri obrázok 2.13. Výsledný ohyb sme vypočítali ako pomer dĺžky končatiny k vzdialenosti medzi bodmi  $A$  a  $C$ . Napríklad ohyb pravej nohy bol vypočítaný podľa vzorca 2.11.

$$\varphi_{\beta_P} = \beta_P / D(P_{15}, P_{17}), \quad (2.11)$$

kde  $\beta_P$  je dĺžka pravej nohy a  $D(P_{15}, P_{17})$  je vzdialenosť medzi bodmi  $P_{15}$  a  $P_{17}$ . Tento výpočet sme aplikovali na každý snímok. Výsledkom je graf, ktorý môžeme vidieť na obrázku 2.14, kde os  $y$  predstavuje pomer vzdialeností  $\varphi_{\beta_P}$  a os  $x$  čas vyjadrený počtom snímkov.



Obr. 2.14: Ohyb pravej nohy.

Náklon celého tela bol vypočítaný tak, že sme pre každý snímok premietli bodom  $P_1$  priamku kolmú na podlahu. Od tejto priamky sme následne vypočítali vzdialenosť k bodu  $P_6$  (obr. 2.2). Uvedeným spôsobom sme zistili, pohyb hlavy vzhľadom na ťažisko tela. Výsledný graf však skôr pripomínal zmes náhodných hodnôt ako periodický signál. Z toho dôvodu sme signál považovali za nerelevantný. Rovnako ako pri náklone hlavy voči krku. S tým rozdielom, že v tomto prípade priamka kolmá na podlahu, prechádzala bodom  $P_5$ .

## 2.6 Porovnávanie hodnôt

V predošlej sekcii sme si popísali všetky parametre, ktoré sme pri našom výskume použili. Cieľom výskumu bolo zistiť, ktoré z nich sú relevantné pri identifikácii a ktoré naopak nie. Ešte pred tým, ako sme sa pustili do ich analýzy, potrebovali sme navrhnuť spôsob, akým s týmito parametrami pracovať a ako ich porovnávať. Vzhľadom na rôzne typy parametrov, sme museli použiť pre každý typ inú metódu. Metódu sme vyskúšali hneď niekoľko, z ktorých sme vybrali tú najlepšiu.

### 2.6.1 Porovnávanie fyziologických a pohybových parametrov

Najskôr sme sa zamerali iba na porovnávanie fyziologických parametrov. Fyziologické parametre pozostávajú z piatich číselných hodnôt. Tvoria v podstate vektor, ktorý si môžeme predstaviť ako  $\vec{u} = (\gamma, \alpha_P, \alpha_L, \beta_P, \beta_L)$ .

Pokúsili sme nájsť zhodu pomocou skalárneho súčinu [6] dvoch takýchto vektorov. Výsledkom by bola hodnota na intervale  $\langle -1, 1 \rangle$ , kde 1 by predstavovala zhodu 100% a -1 by znamenala zhodu 0%. Problémom však bolo, že sa oba vektory museli najskôr normalizovať, aby mali jednotkovú dĺžku, čo zapríčinilo stratu informácií o veľkosti osoby. Zachovali sa iba informácie o telesných proporciách, presnejšie o pomeroch dĺžok končatín. Výsledná informácia by bola dostačujúca pre zisťovanie veku danej osoby. Telesné proporcie sa totiž do 25 roku života menia [3]. Od 25 roku sú pomery medzi jednotlivými proporciami až na malé odchýlky približne rovnaké.

Táto metóda bola nepoužiteľná. Ďalej sme vyskúšali zhodu počítat' ako veľkosť relatívnej chyby zvlášť pre každý parameter. Relatívnu chybu sme vypočítali podľa vzorca 2.12.

$$E = \left| \frac{\bar{X} - X}{X} \right| \cdot 100, \quad (2.12)$$

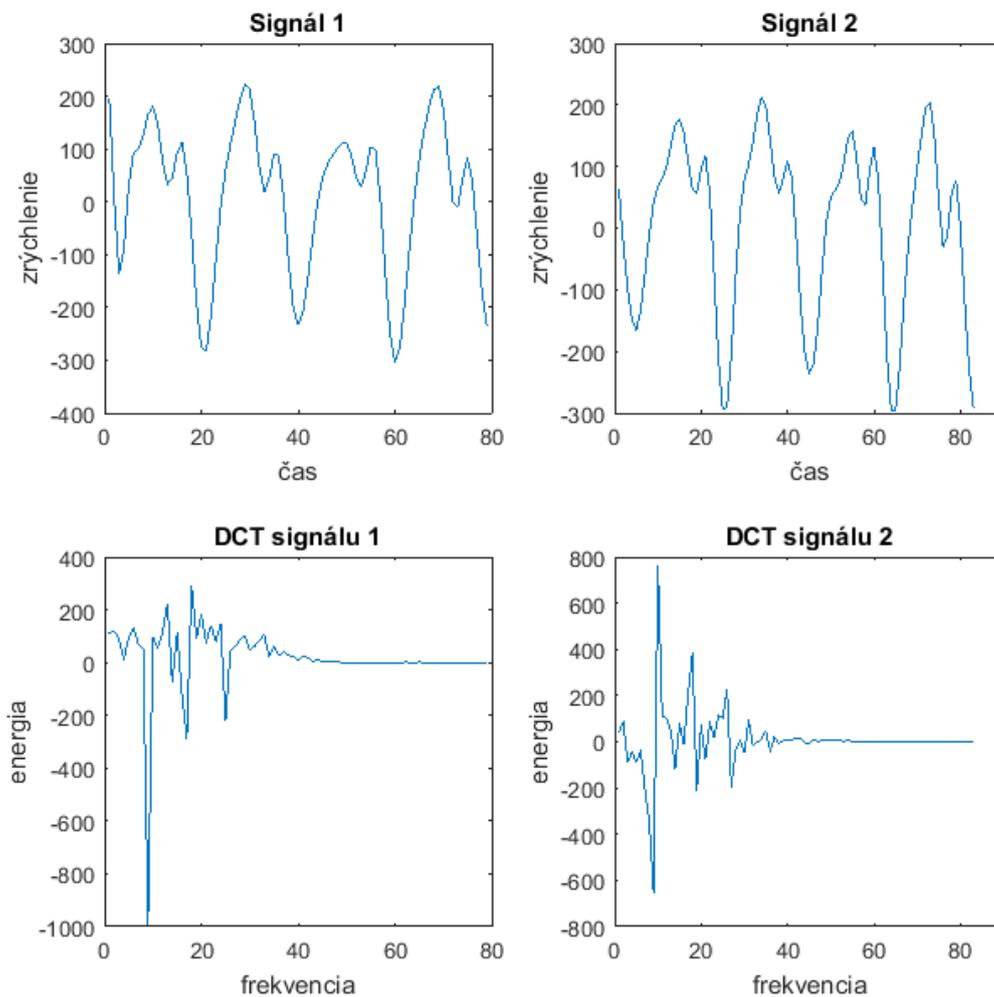
kde  $\bar{X}$  je hľadaná hodnota a  $X$  je skutočná hodnota. Týmto spôsobom sme získali percentuálnu odchýlku v porovnávaných dátach. Rovnaký postup porovnávaní sme následne aplikovali aj na pohybové parametre. Výsledná percentuálna zhoda medzi dvoma porovnávanými osobami bola vypočítaná aritmetickým priemerom relatívnych chýb fyziologických a pohybových parametrov.

### 2.6.2 Porovnávanie časovo závislých parametrov

Zatiaľ čo pri fyziologických a pohybových parametroch sme hľadali podobnosť v číselných hodnotách, pri časovo závislých parametroch sme museli nájsť zhodu medzi dvoma signálmi. Vyskúšali sme hneď niekoľko možností. Prvou z nich bolo použitie koeficientov vypočítaných pomocou diskkrétnej kosínusovej transformácie (DCT) [4]. Výsledkom tejto transformácie boli koeficienty, ktoré predstavovali frekvenčné zastúpenie jednotlivých zložiek vstupného signálu. Inými slovami signál pozostávajúci zo série číselných hodnôt  $(a_0, a_1, \dots, a_{n-1})$ , bol transformovaný na sériu koeficientov  $(w_0, w_1, \dots, w_{n-1})$  frekvenčnej domény. Výhodou tejto transformácie je, že hlavné frekvenčné zložky daného signálu môžu byť koncentrované iba v niekoľkých frekvenčných koeficientoch, ktoré sa nachádzajú na začiatku postupnosti. To znamená, že väčšina koeficientov bude nulová alebo veľmi malá a tým pádom ju môžeme zanedbať, čím zredukujeme množstvo dát potrebných na popísanie daného signálu. Tieto koeficienty sme vypočítali podľa vzorca 2.13.

$$w_k = \sum_{t=0}^{n-1} a_t \cos\left[\frac{\pi}{n}\left(t + \frac{1}{2}\right)\right], k = 0, \dots, n-1, \quad (2.13)$$

kde  $a$  je vstupný signál a  $n$  je počet vzoriek vstupného signálu. Dva podobné signály by mali mať porovnateľné koeficienty. Vyskúšali sme tento postup aplikovať na 2 signály, ktoré sú veľmi podobné. Jednalo sa o dva signály reprezentujúce zrýchlenie bedier  $a_{P_1}$ . Oba patrili rovnakej osobe a mali by byť takmer totožné. Z obrázku 2.15 môžeme vidieť podobnosť medzi signálmi 1 a 2. Ak si však všimneme grafy, ktoré reprezentujú vypočítané kosínusové koeficienty, vidíme, že sa patrične líšia. To znamená, že pre nájdenie podobnosti sú nevyhovujúce. Uvedený spôsob porovnávania signálov sa ukázal ako nesprávny.



Obr. 2.15: Diskrétna kosínusova transformácia signálov zrýchlenia bedier.

Okrem diskkrétnej kosínusovej transformácie sme vyskúšali aj fourierovu transformáciu [5], ktorá skončila s podobným výsledkom. Rozhodli sme sa vyskúšať krížovú koreláciu (cross correlation) [17]. Je to metóda na zisťovanie korelácie, inými slovami podobnosti medzi dvoma signálmi. Vstupom pre túto metódu sú 2 rôzne signály, ktorých podobnosť chceme zmerať. Výstupom je reálne číslo na intervale  $\langle -1,1 \rangle$ . Ak si predstavíme 2 signály, pričom jeden lineárne klesá a druhý naopak lineárne rastie, znamená to, že je medzi nimi záporná

korelácia a výsledok bude bližšie k číslu  $-1$ . Takýto výsledok v podstate vyjadruje, že jeden zo signálov je inverzný k tomu druhému. Ak si však predstavíme 2 signály, ktoré rovnakým tempom rastú, znamená to, že je medzi nimi silná kladná korelácia a výsledok sa bude pohybovať v blízkosti 1. Nula reprezentuje, že medzi signálmi nie je korelácia žiadna.

Z obrázku 2.15 si môžeme všimnúť, že vstupné signály sú časovo mierne posunuté. Tento nepatrný posun by mohol spôsobiť skreslenie výsledkov korelácie. Časový posun medzi signálmi sme kompenzovali umelým posúvaním signálu. Inými slovami, zobrali sme signál 1 a posunuli ho o jeden časový krok vpred. S týmto posunom sme vypočítali veľkosť korelácie. Následne sme tento signál posunuli o ďalší časový krok a opäť vypočítali veľkosť korelácie, atď. Ako výsledok sme potom vybrali najväčšiu vypočítanú zhodu. Túto koreláciu sme počítali podľa vzorca 2.14.

$$r(d) = \frac{\sum_{i=0}^{n-1} [(x_i - \bar{x})(y_{i-d} - \bar{y})]}{\sqrt{\sum_{i=0}^{n-1} (x_i - \bar{x})^2} \sqrt{\sum_{i=0}^{n-1} (y_{i-d} - \bar{y})^2}}, \quad (2.14)$$

kde  $x$  a  $y$  sú porovnávané signály a  $n$  je počet vzoriek kratšieho z nich. Písmenom  $d$  je označený časový posun signálu. V našom prípade  $d \in \langle -50, 50 \rangle$ . Premenné  $\bar{x}$  a  $\bar{y}$  sú stredné hodnoty signálov  $x$  a  $y$ . V prípade, že signály nemajú rovnakú dĺžku, časť ktorá zostane neprekrytá sa do výpočtu nezapočíta. Niektoré prístupy uvádzajú doplniť chýbajúcu dĺžku signálu nulami, ale ukázalo sa, že to znižuje presnosť výsledku. To isté platí aj pri časovom posune signálu. Korelácia sa počíta iba z prekrývajúcich sa častí oboch signálov. Touto metódou sa nám podarilo vypočítať, že zhoda signálov z obrázku 2.15 je takmer 90%. Pre porovnávanie zhody signálov sme preto zvolili metódu krížovej korelácie.

## 2.7 Analýza parametrov

V predošlých dvoch sekciách sme si detailne popísali všetky parametre, o ktorých sme si mysleli, že by mohli predstavovať charakteristické črty jednotlivých osôb a aj spôsob, akým sme ich porovnávali. Tieto parametre sme následne skúmali a analyzovali, čím sme zisťovali ich relevantnosť pri jednoznačnom určovaní identity. Spôsobov a možností na skúmanie týchto parametrov je hneď niekoľko. My si popíšeme tie, ktoré sme použili a pomocou ktorých sme dosiahli žiadany výsledok.

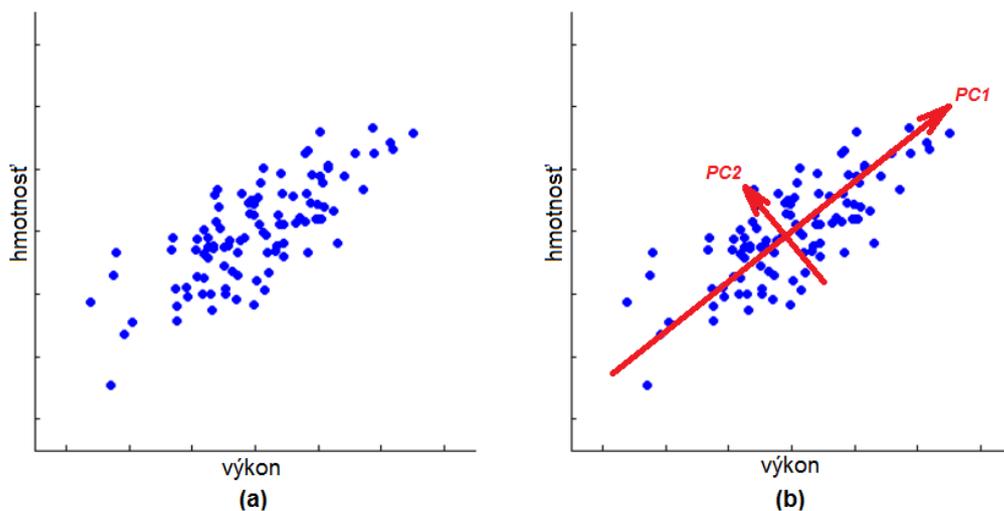
V našej práci sme pracovali s dvoma skupinami parametrov. Do prvej z nich patrili jednočíselné hodnoty, teda fyziologické a pohybové parametre. Druhá skupina obsahovala parametre časovo závislé, ktoré sme si mohli predstaviť ako diskkrétne signály. Nemohli sme teda použiť rovnakú metódu na analýzu oboch skupín. Pre každú zo skupín sme použili inú metódu na analyzovanie relevantnosti parametrov. Na základe týchto analýz sme z každej zo skupín vybrali parametre, ktoré sa ukázali ako najviac rozhodujúce.

Pri analýze sme mali k dispozícii viacero záznamov chôdze od každého subjektu. Z toho dôvodu sme sa rozhodli, najskôr hľadať také parametre, ktoré sú podobné pre rôzne záznamy chôdze rovnakého subjektu. Teda parametre, ktoré by boli typické pre danú osobu. Začali sme preto hľadať hodnoty s najmenším možným rozptylom.

### 2.7.1 Analýza fyziologických a pohybových parametrov

Prvým krokom bolo určiť dôležité parametre spomedzi skupiny jednočíselných hodnôt. Hľadali sme také hodnoty, ktoré by boli pre všetky záznamy chôdze jedného subjektu podobné. Na tento účel sme využili metódu *PCA* [10].

Táto metóda slúži na nájdenie veľkostí jednotlivých rozptylov dát. Môžeme si to vysvetliť na jednoduchom príklade. Predstavme si ľubovoľné dáta v dvojrozmernom priestore. Môžeme použiť napríklad výkon a hmotnosť automobilov. Tieto dáta si zakreslíme do grafu, ktorý je vidieť na obrázku 2.16 (a).



Obr. 2.16: Ukážka princípu PCA metódy.

Každý bod predstavuje jeden konkrétny automobil. Chceme však zistiť, ktorý z týchto dvoch parametrov je pre jednotlivé automobily viac charakteristický. Teda parameter, podľa ktorého by bolo možné jednoduchšie identifikovať daný automobil. Ak by totiž mali všetky autá rovnakú hmotnosť a rozdielny by bol iba výkon, nevedeli by sme na základe hmotnosti jednotlivé autá rozoznať. Potrebujeme preto zistiť, ktorý z týchto dvoch parametrov sa medzi jednotlivými autami najviac odlišuje.

Ak sa pozrieme na graf (a) obrázku 2.16, môžeme si všimnúť, že dáta vytvárajú akýsi zhluk. Nás však budú zaujímať rozmery tohto zhluku, ktoré vieme vypočítať práve pomocou *PCA* metódy. Pre každú dimenziu vieme vypočítať os, ktorá by najlepšie vystihovala naše dáta. Všetky tieto osi sú na seba navzájom kolmé. V našom prípade budú dve a môžeme ich vidieť na grafe

(b) obrázku 2.16, označené ako  $PC1$  a  $PC2$ .

Tieto osi nám určujú nový priestor pre naše dáta. Môžeme si ich predstaviť ako novú os  $x$  a  $y$ . Nevieme však, ktorá os nového priestoru predstavuje ktorý parameter. Zistíme to tak, že si vypočítame, o koľko sa nové osi líšia od tých starých. Čiže, ak je os  $PC1$  bližšie k pôvodnej osi  $x$ , predstavujúcej výkon ako k osi  $y$ , môžeme povedať, že rozptyl dát tejto osi tvorí práve výkon. Ak by však obe nové osi boli od tých starých vzdialené rovnako, tento spôsob priradenia by nefungoval a museli by sme použiť inú metódu. V našom prípade sa však taká situácia nevyskytla.

Z obrázku taktiež môžeme vidieť, že os  $PC1$  je väčšia ako  $PC2$ . To znamená, že os  $PC1$  je dominantná a tieto dáta majú väčší rozptyl. V našom príklade to bude znamenať, že autá sa od seba odlišujú viac vo výkone ako v hmotnosti.

Tento princíp sme aplikovali na určenie relevantnosti jednotlivých parametrov pri identifikácii ľudí. Čím význačnejšia os, tým relevantnejší parameter. V našom prípade sme však mali 10 záznamov chôdze od rovnakej osoby. Takže sme hľadali naopak tie parametre, ktoré mali osi čo najmenšie. Chceli sme nájsť také parametre, ktoré by boli pre túto jednu osobu spomedzi rôznych záznamov chôdze rovnaké.

Celkovo sme skúmali 15 parametrov. Takže náš novo vzniknutý priestor  $b$  mal mať 15 dimenzií. Prvým krokom bolo vypočítanie stredných hodnôt pre každý z parametrov. Následne sme vypočítali kovarianciu každého parametra s každým podľa vzťahu 2.15. Potom sme z týchto kovarinácií vytvorili kovariančnú maticu  $C$  podľa vzťahu 2.16.

$$\text{cov}(X, Y) = \frac{\sum_{i=0}^{n-1} (X_i - \bar{X})(Y_i - \bar{Y})}{n - 1} \quad (2.15)$$

$$C = \begin{pmatrix} cov(X_1, X_1) & cov(X_1, X_2) & \dots & cov(X_1, X_n) \\ cov(X_2, X_1) & cov(X_2, X_2) & \dots & cov(X_2, X_n) \\ \vdots & \vdots & \ddots & \vdots \\ cov(X_n, X_1) & cov(X_n, X_2) & \dots & cov(X_n, X_n) \end{pmatrix}, \quad (2.16)$$

kde  $X$  a  $Y$  predstavujú jednotlivé parametre chôdze a  $\bar{X}$  a  $\bar{Y}$  sú ich stredné hodnoty. Týmto spôsobom sme získali maticu s rozmerom 15x15.

Následne sme potrebovali vypočítať vlastné čísla a vlastné vektory tejto matice. Vlastné vektory by predstavovali novovzniknuté osi a k nim prislúchajúce vlastné čísla by predstavovali, ako sú tieto osi významné. To by znamenalo, že čím väčšie je vlastné číslo, tým je na danej osi väčší rozptyl dát. Nás však v tomto prípade zaujímal rozptyl najmenší.

Problémom však bolo, že fyziologické parametre boli pri všetkých 10 záznamoch chôdze rovnaké. To spôsobilo, že sa v kovariančnej matici vyskytlo 5 nulových riadkov. Tým pádom nebolo možné vypočítať vlastné čísla a ani vlastné vektory, pretože riadky v matici boli lineárne závislé. Rozhodli sme sa, fyziologické parametre z analýzy vynechať a ich relevantnosť určiť až pri testovaní.

Pokračovali sme v analýze iba na základe pohybových parametrov. Rozmer našej kovariančnej matice sa zmenšil na 10x10. Pre výpočet vlastných čísel a vlastných vektorov sme použili funkciu z Matlabu  $[V, D] = eig(D)$  [18], kde  $D$  je diagonálna matica obsahujúca vlastné čísla a  $V$  je matica obsahujúca príslušné vlastné vektory. Maticu  $D$ , ktorú sme dostali, môžeme vidieť na obrázku 2.17.

-0.0000	0	0	0	0	0	0	0	0	0
0	0.0005	0	0	0	0	0	0	0	0
0	0	0.0070	0	0	0	0	0	0	0
0	0	0	0.0621	0	0	0	0	0	0
0	0	0	0	0.1336	0	0	0	0	0
0	0	0	0	0	1.1904	0	0	0	0
0	0	0	0	0	0	3.0513	0	0	0
0	0	0	0	0	0	0	8.0575	0	0
0	0	0	0	0	0	0	0	45.8126	0
0	0	0	0	0	0	0	0	0	109.3433

Obr. 2.17: Diagonálna matica reprezentujúca vypočítané vlastné čísla.

Na základe tejto matice sme sa rozhodli vybrať 3 parametre s najmenším rozptylom. Teda tie, ktorých vlastné číslo bolo menšie ako 0,01. Zostávalo iba zistiť, ku ktorým osiam tieto vlastné čísla patria. Zistili sme to spôsobom, že sme pomocou skalárneho súčinu vypočítali uhol, ktorý zvierali tieto 3 vlastné vektory s pôvodnými súradnicovými osami. Tie ktorých uhol k pôvodným osiam bol najmenší, boli vybrané.

K piatim fyziologickým parametrom sme spomedzi pohybových parametrov na základe tejto analýzy vybrali tri, ktoré mali najmenší rozptyl hodnôt. Boli to varianca hlavy a oboch kolien pozdĺž osi  $y$ . Z celkového počtu 5 fyziologických a 10 pohybových parametrov sme vybrali 8, ktoré môžeme vidieť v tabuľke 2.4.

Označenie	Parameter
$\gamma$	Výška trupu
$\alpha_P$	Dĺžka pravej ruky
$\alpha_L$	Dĺžka ľavej ruky
$\beta_P$	Dĺžka pravej nohy
$\beta_L$	Dĺžka ľavej nohy
$\sigma_{P_6,y}^2$	Variancia hlavy po y-ovej osi
$\sigma_{P_{20},y}^2$	Variancia ľavého kolena po y-ovej osi
$\sigma_{P_{16},y}^2$	Variancia pravého kolena po y-ovej osi

Tabuľka 2.4: Výsledok analýzy fyziologických a pohybových parametrov.

### 2.7.2 Analýza časovo závislých parametrov

Pri analýze časovo závislých parametrov sme mali rovnako, ako aj v predošlom prípade 10 záznamov chôdzi rovnakej osoby. Z každého z týchto záznamov sme si vypočítali všetkých 25 parametrov, uvedených v tabuľke 2.3. Cieľom analýzy bolo zistiť, ktoré z týchto parametrov by sa dali použiť na jednoznačnú identifikáciu osoby. Keďže sme mali k dispozícii záznamy chôdze iba od jednej osoby, úlohou bolo zistiť, ktorý z parametrov je vo všetkých záznamoch rovnaký, prípadne veľmi podobný.

Jednotlivé parametre sme medzi sebou porovnávali pomocou krížovej korelácie, ktorú sme spomínali v predošlej kapitole. Pomocou nej sme vedeli vypočítať zhodu medzi dvoma signálmi. Táto zhoda sa dá vyjadriť číselnou hodnotou na intervale  $\langle -1, 1 \rangle$ , kde 1 predstavuje zhodu 100%.

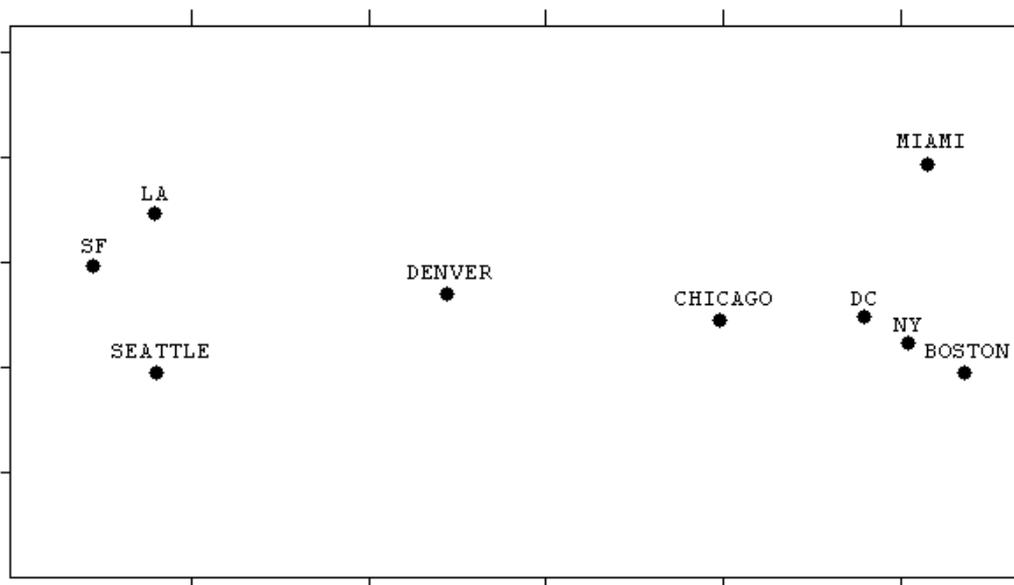
Následne sme pre každý z parametrov dokázali vytvoriť maticu 10x10, kde sme na základe konkrétneho parametra porovnali každý záznam chôdze s každým. Každá z týchto matíc bola symetrická, pretože zhoda medzi záznamom 1 a záznamom 2 musí byť rovnaká ako zhoda medzi záznamom 2 a záznamom 1. Diagonála obsahovala vždy jednotky, nakoľko sa jednalo o porovnávanie dvoch rovnakých záznamov. Celkovo sme dostali 25 takýchto matíc a naším cieľom bolo nájsť tie, v ktorých sa mimo diagonálne prvky čo najviac približovali k jednotke.

Na daný účel sme použili metódu *MDS* [12], ktorá by nám pomohla tieto matice vyselektovať. Princíp metódy si najskôr ukážeme na zjednodušenom príklade. Predstavme si maticu, ktorá obsahuje vzdušné vzdialenosti medzi mestami v USA [13] (obrázok 2.18).

		1	2	3	4	5	6	7	8	9
		BOST	NY	DC	MIAM	CHIC	SEAT	SF	LA	DENV
1	BOSTON	0	206	429	1504	963	2976	3095	2979	1949
2	NY	206	0	233	1308	802	2815	2934	2786	1771
3	DC	429	233	0	1075	671	2684	2799	2631	1616
4	MIAMI	1504	1308	1075	0	1329	3273	3053	2687	2037
5	CHICAGO	963	802	671	1329	0	2013	2142	2054	996
6	SEATTLE	2976	2815	2684	3273	2013	0	808	1131	1307
7	SF	3095	2934	2799	3053	2142	808	0	379	1235
8	LA	2979	2786	2631	2687	2054	1131	379	0	1059
9	DENVER	1949	1771	1616	2037	996	1307	1235	1059	0

Obr. 2.18: Matica vzdialeností medzi mestami v USA. [13]

Takto zadaná matica by predstavovala vstup pre *MDS* metódu. Výstupom uvedenej metódy je  $p$  - rozmerný priestor, v ktorom sú rozmiestnené mestá na základe ich vzájomných vzdialeností. V tomto konkrétnom prípade bude mať vzniknutý nový priestor práve dve dimenzie. Výsledkom bude v podstate mapa, ktorú môžeme vidieť na obrázku 2.19.



Obr. 2.19: Mapa miest v USA vytvorená pomocou MDS metódy. [13]

Z obrázka môžeme vidieť, že poloha miest sa oproti ich skutočnej lokalite na mape líši. Mestá sú presne naopak. Miami a Los Angeles by mali byť na juhu, zatiaľ čo Boston a Seattle na severe. Cieľom tejto metódy však nie je zistenie skutočnej polohy na mape, ale správne určenie ich vzájomnej polohy. Z toho vyplýva, že celý priestor môžeme ľubovoľne rotovať a vzdialenosti medzi mestami sa nezmenia.

Čo nás však zaujíma najviac, je rozptyl týchto miest na mape. Ak si predstavíme, že  $Y$  je matica, ktorá obsahuje pozície miest získané použitím *MDS* metódy, tak  $B = YY^T$  je grammova matica [14]. Táto matica je proporčne rovnaká ako kovariančná matica, použitá pri *PCA* metóde. To znamená, že vlastné čísla tejto matice budú určovať význam novovzniknutého priestoru.

Z našich vstupných matíc rozdielnosti, sme však potrebovali vybrať tie s najnižším rozptylom dát. To znamenalo, že rozmer novovzniknutého priestoru by mal byť malý. Na výpočet sme použili funkciu z Matlabu  $[Y, e] = \text{cmdscale}(D)$ , kde  $e$  bol vektor obsahujúci vlastné čísla grammovej matice  $B = YY^T$ .  $D$  je vstupná matica rozdielnosti a  $Y$  je matica obsahujúca súradnice bodov v novom priestore. Novovzniknutý priestor bol  $p$  - dimenzionálny. Dimenzia priestoru pre nás však nebola zaujímavá. Zaujímal nás iba rozmer. Čím bola veľkosť menšia, tým bol parameter chôdze relevantnejší.

Na základe vypočítaných veľkostí vlastných čísel z vektora  $e$ , sme vstupné parametre zoradili podľa veľkosti. Prvé vlastné číslo bolo vždy najväčšie a predstavovalo dominantnú os nového priestoru. Tabuľka 2.5 obsahuje parametre zoradené na základe veľkosti vlastných čísel od najmenšieho po najväčšie.

	Označenie	Parameter	$e_1$
1	$a_{P_{20}}$	Zrýchlenie ľavého kolena	0.0586
2	$\varphi_{\beta_P}$	Ohyb pravej nohy	0.0600
3	$d_{P_{18,22}}$	Vzdialenosť špičiek	0.0617
4	$a_{P_{22}}$	Zrýchlenie ľavej špičky	0.0651
5	$d_{P_{17,21}}$	Vzdialenosť piat	0.0658
6	$a_{P_{17}}$	Zrýchlenie pravej päty	0.0706
7	$a_{P_{18}}$	Zrýchlenie pravej špičky	0.0733
8	$\varphi_{\beta_L}$	Ohyb ľavej nohy	0.0805
9	$d_{P_{16,20}}$	Vzdialenosť kolien	0.0831
10	$a_{P_{21}}$	Zrýchlenie ľavej päty	0.0836
11	$a_{P_1}$	Zrýchlenie Bedier	0.1077
12	$a_{P_6}$	Zrýchlenie hlavy	0.1114
13	$a_{P_{13}}$	Zrýchlenie pravého lakťa	0.1147
14	$a_{P_{16}}$	Zrýchlenie pravého kolena	0.1156
15	$a_{P_9}$	Zrýchlenie ľavého lakťa	0.1385
16	$a_{P_{14}}$	Zrýchlenie pravej dlane	0.1399
17	$a_{P_{10}}$	Zrýchlenie ľavej dlane	0.1426
18	$d_{P_{9,13}}$	Vzdialenosť lakt'ov	0.1809
19	$\varphi_\gamma$	Náklon trupu	0.2010
20	$d_{P_{10,14}}$	Vzdialenosť dlaní	0.2036
21	$\varphi_{\alpha_P}$	Ohyb pravej ruky	0.3648
22	$\omega_h$	Rotácia ramien horizontálna	0.3923
23	$\varphi_{\alpha_L}$	Ohyb ľavej ruky	0.3935
24	$\omega_v$	Rotácia ramien vertikálna	0.4794
25	$\varphi_n$	Náklon hlavy voči krku	0.5272

Tabuľka 2.5: Časovo závislé parametre zoradené podľa relevantnosti.

Na základe tejto analýzy sme vedeli vybrať parametre, ktoré sú spomedzi mnohých záznamov chôdze jednej osoby, čo najviac podobné. Rozhodli sme

sa vybrať tie, ktorých príslušná hodnota  $e_1 < 0.1$ . Následne sme potrebovali zistiť, ktoré z týchto parametrov sú pre rôzne osoby čo najviac odlišné. Postup bol rovnaký ako v predchádzajúcom prípade s tým rozdielom, že sme použili 8 záznamov chôdze od 8 rôznych ľudí. V tomto prípade sme však hľadali parametre, ktorých hodnota  $e_1$  by bola čo možno najväčšia, aby sme zistili, ktorými parametrami sa rôzne osoby, čo najviac od seba odlišujú. Výsledky uvedenej analýzy sme spísali do tabuľky 2.6.

	Označenie	Parameter	$e_1$
1	$d_{P_{17,21}}$	Vzdialenosť piat	0.4325
2	$d_{P_{16,20}}$	Vzdialenosť kolien	0.4000
3	$a_{P_{17}}$	Zrýchlenie pravej päty	0.2251
4	$a_{P_{21}}$	Zrýchlenie ľavej päty	0.2124
5	$\varphi_{\beta_L}$	Ohyb ľavej nohy	0.2119
6	$\varphi_{\beta_P}$	Ohyb pravej nohy	0.1597
7	$a_{P_{20}}$	Zrýchlenie ľavého kolena	0.1273
8	$d_{P_{18,22}}$	Vzdialenosť špičiek	-
9	$a_{P_{22}}$	Zrýchlenie ľavej špičky	-
10	$a_{P_{18}}$	Zrýchlenie pravej špičky	-

Tabuľka 2.6: Časovo závislé parametre zoradené podľa relevantnosti.

Mnohé záznamy chôdze neobsahovali špičku nohy. Preto sme nemohli vypočítať hodnoty  $e_1$  pre parametre  $d_{P_{18,22}}$ ,  $a_{P_{22}}$  a  $a_{P_{18}}$ . Zistili sme však relevantnosť jednotlivých parametrov, o ktorú sa budeme opierať pri validácii výsledkov.

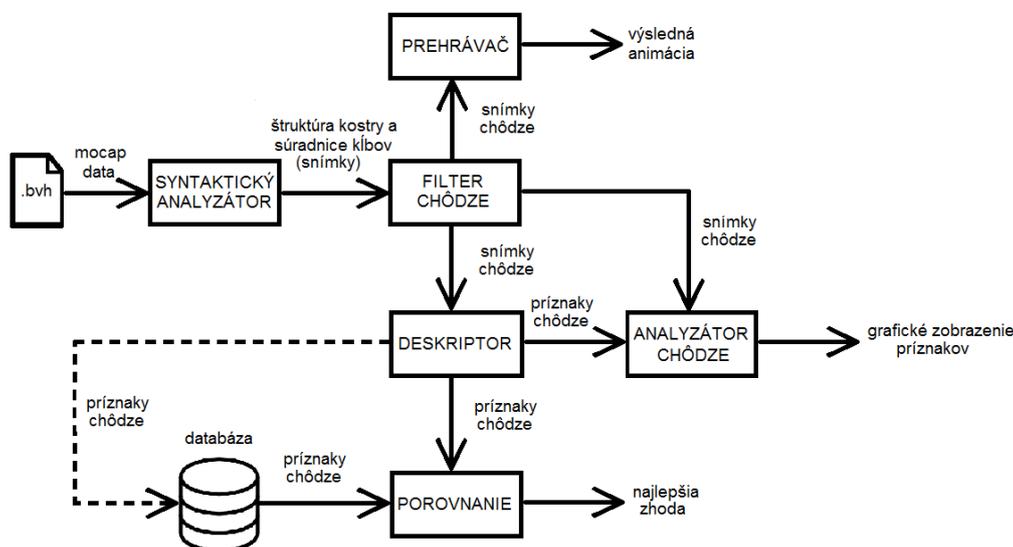
# Kapitola 3

## Implementácia

V tejto časti si popíšeme, ako sme na základe teoretických poznatkov a analýz z predošlej sekcie navrhli a implementovali systém slúžiaci na rozpoznávanie osôb podľa ich chôdze.

### 3.1 Návrh systému

Systém sme sa rozhodli realizovať ako webovú aplikáciu, ktorá by bola dostupná online. Použili sme štandardné webové technológie ako *PHP*, *JavaScript*, *HTML*, *CSS* a *MySQL*. Aplikácia sa skladala z niekoľkých modulov, ktoré si detailne popíšeme. Celkovú štruktúru môžeme vidieť na diagrame 3.1.



Obr. 3.1: Návrh systému.

### 3.1.1 Syntaktický analyzátor

Základným prvkom celej aplikácie bol syntaktický analyzátor, ktorého úlohou bolo spracovať dáta z *bvh* formátu a uložiť ich do dátovej štruktúry, s ktorou by sa dalo dobre a efektívne pracovať. Výsledkom boli jednotlivé snímky pohybu. Každá snímka obsahovala osobitnú konfiguráciu celej kostry. Kostru sme reprezentovali ako graf, kde hrany predstavujú kosti a vrcholy kĺby. Každý z kĺbov mal zadaný svoj názov, predka, potomka a samozrejme polohu definovanú súradnicami  $(x, y, z)$ .

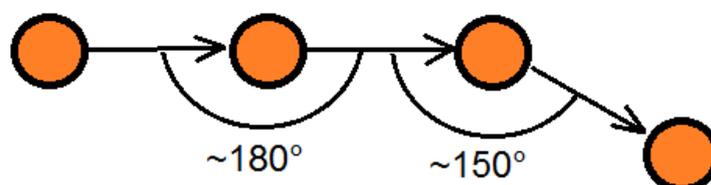
### 3.1.2 Filter chôdze

Pre analýzu a identifikáciu chôdze bolo potrebné najskôr z pohybu extrahovať samotnú chôdzu. Na uvedený účel slúži práve tento filter. Jeho cieľom

je označiť snímky, ktoré túto chôdzu obsahujú. Za chôdzu sme považovali pohyb, pri ktorom bod  $P_1$  (bedrá) nemení smer a pohybuje sa v stanovenom rýchlostnom rozmedzí.

V prvom kroku filter vypočíta rýchlosť bodu  $P_1$  pre každý snímok a vyberie iba také, v ktorých sa rýchlosť pohybuje v stanovenom limite. Tento limit sme získali testovaním rôznych chôdzí. Spodná hranica limitu bola stanovená najpomalšou chôdzou a horná zase tou najrýchlejšou. Z pohybu sme tak odstránili beh a státie na mieste.

Druhým krokom bolo vyfiltrovanie pohybu, pri ktorom osoba nemení smer a pohybuje sa po rovnej dráhe. Vysvetlíme si to pomocou obrázku 3.2, ktorý ukazuje pohľad zhora na to, ako sa pohybuje bod  $P_1$  v čase. Medzi každými dvoma pozíciami tohto bodu vieme vypočítať smerový vektor. Z dvoch smerových vektorov vieme vypočítať, aký uhol zvierajú. Týmto spôsobom sme vedeli z celej sekvencie chôdze vyfiltrovať tie snímky, na ktorých sa osoba pohybovala po rovnej trajektórii a kedy naopak nie.



Obr. 3.2: Ukážka filtrovania pohybu po rovnej trajektórii.

Pozorovaním sme zistili, že pri chôdzi po rovnej trajektórii dochádza k odchýlkam v rozmedzí  $3^\circ$ . Za chôdzu po rovnej trajektórii sme považovali úsek, v ktorom každé dva po sebe idúce vektory, zvierali uhol v rozmedzí  $177^\circ$  až  $183^\circ$ . Ak sa však v celej sekvencii vyskytlo takýchto úsekov viac, filter vybral vždy ten dlhší.

Ďalším zistením bolo, že rôzna snímkovacia frekvencia spôsobuje odchýlky vo výpočtoch parametrov. Museli sme preto pridať filter, ktorý by všetky

sekvencie chôdze upravil na jednotných 30 snímok za sekundu.

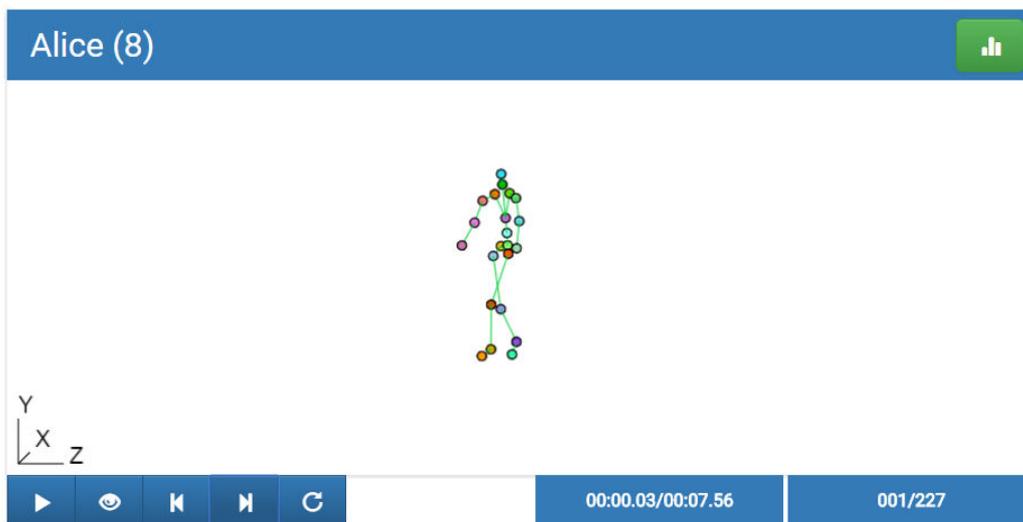
### 3.1.3 Prehrávač

Súčasťou aplikácie bol taktiež prehrávač, ktorý dokázal prehrať animáciu uloženú v *bvh* formáte. Animáciu bolo možné pozastaviť, krokovať, znova prehrať a taktiež zobrazíť celú sekvenciu pohybu naraz. Ukážku prehrávača môžeme vidieť na obrázku 3.3.

Prehrávač bol realizovaný pomocou HTML5 *canvasu*, do ktorého sme kreslili pomocou programovacieho jazyka *JavaScript*. Vstupom pre prehrávač boli snímky chôdze. Tie následne prešli filtrom chôdze. Prehrávač však musel zobrazíť každý pohyb a nie iba vyfiltrovanú chôdzu. Filter bol preto navrhnutý spôsobom, aby snímky s chôdzou iba označoval. Tieto označené snímky boli následne vykresľované inou farbou, aby bolo možné rozlíšiť, kedy sa jedná o chôdzu a kedy nie.

Snímky boli v podstate grafy, ktorých vrcholy predstavovali kĺby a hrany predstavovali kosti. Každý vrchol obsahoval svoju polohu definovanú troma súradnicami  $(x, y, z)$ . Takže pri vykresľovaní stačilo rekurzívne prejsť celý graf a vykresliť všetky vrcholy a hrany na správne súradnice. Súradnice však bolo potrebné pretransformovať do kamerových súradníc. Snímky boli navyše posunuté tak, aby sa model kostry z prvej snímky nachádzal vždy v strede plochy.

Výsledná animácia bola tvorená vykresľovaním jednej snímky za druhou. Rýchlosť vykresľovania bola určená hodnotou zadanou priamo v *bvh* súbore.



Obr. 3.3: Prehrávač bvh záznamov.

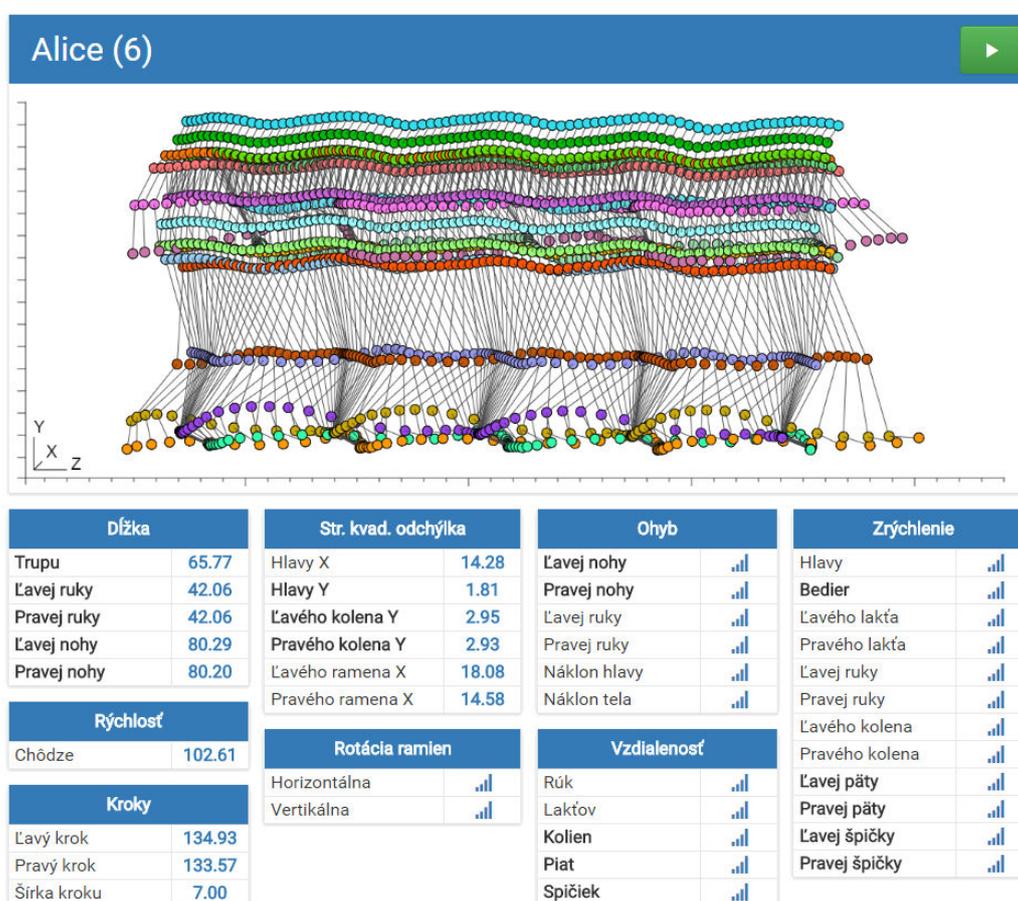
### 3.1.4 Deskriptor

Úlohou deskriptora bolo vypočítať z vyfiltrovaných snímok všetky parametre, ktoré sme si popísali v sekcii 2.5. Vstupom sú snímky chôdze a výstupom je zoznam parametrov s vypočítanými hodnotami. Pri implementácii sa však vyskytlo niekoľko problémov, s ktorými sa na teoretickej úrovni nepočítalo.

Pri detekcii krokov, respektíve bodov, v ktorých sa noha dotkla zeme, dochádzalo k problému, že z detegovaných pozícií týchto bodov, nebolo možné určiť poradie krokov. Toto poradie bolo dôležité pri výpočte šírky a dĺžky krokov. Riešením bolo, že sme pre každý z týchto bodov počítali vzdialenosť od bodu  $P_1$  z prvého snímku chôdze. Znamenalo to, že každý nasledujúci krok mal túto vzdialenosť väčšiu ako krok predchádzajúci. Mohlo však dôjsť k problému, ak by osoba chodila napríklad do kruhu, čo by znamenalo, že posledný krok by bol rovnako vzdialený od počiatočného bodu ako prvý. Tento problém nám vyriešil filter chôdze, ktorý prepúšťa iba chôdzu po rovnej trajektórii.

### 3.1.5 Analyzátor chôdze

Súčasťou aplikácie bol aj nástroj na vizualizáciu vypočítaných parametrov. Jeho vstupom boli snímky chôdze, ktoré prešli filtrom a parametre získané z deskriptora. Tieto parametre bolo možné následne reprezentovať graficky. Rozhranie obsahovalo výpis zoznamu parametrov. Pri prechádzaní myšou po jednotlivých položkách tohto zoznamu, sa menil grafický výstup. Príklad môžeme vidieť na obrázku 3.4.



Obr. 3.4: Ukážka nástroja pre analyzovanie chôdze.

Pre názornú ilustráciu parametrov, sme potrebovali vykresliť sekvenciu chôdze z bočného pohľadu. Snímky z filtra bolo potrebné pred vykreslením najskôr

rotovať tak, aby sme získali tento pohľad. Z pozícií bodu  $P_1$  prvého a posledného snímku, sme získali vektor, ktorý reprezentoval smer, ktorým osoba kráčala. Na základe tohto smeru sme už boli schopní vypočítať uhol, o ktorý bolo potrebné rotovať celú sekvenciu tak, aby osoba kráčala v smere osi  $Z$ . Takýmto spôsobom sme získali pohľad z boku.

Vykresľovanie bolo taktiež realizované pomocou HTML5 *canvasu* a programovacieho jazyku *JavaScript*. Na vykresľovanie jednotlivých parametrov sme použili vlastnú grafickú knižnicu, ktorá je taktiež súčasťou aplikácie. V prípade, že sa jednalo o vykreslenie parametra, ktorý bol klasifikovaný ako signál, výsledkom bol graf. Na vykresľovanie grafov sme použili knižnicu *zingchart.js* [19].

### 3.1.6 Porovnanie

Pre funkčnosť tohto modulu sme najskôr potrebovali databázu naplnenú dátami. Pripravili sme si rozhranie, ktoré umožňovalo nahrávanie *bvh* súborov na server. Tento súbor po nahraní prešiel syntaktickým analyzárom, filtrom chôdze a nakoniec deskriptorom, ktorý vypočítal potrebné parametre. Tie sa následne uložili do databázy.

Porovnávanie fungovalo na strane servera, aby sa zvýšila rýchlosť. Bolo potrebné však vytvoriť funkcie, určené na porovnávanie, ktoré sme si popísali v sekcii 2.6 aj na serverovej strane. Okrem toho sme vytvorili nové rozhranie, ktoré umožňovalo načítať *bvh* súbor. Jeho spracovaním sa získali potrebné parametre, ktoré sa odoslali na server, kde boli porovnané s parametrami uloženými v databáze.

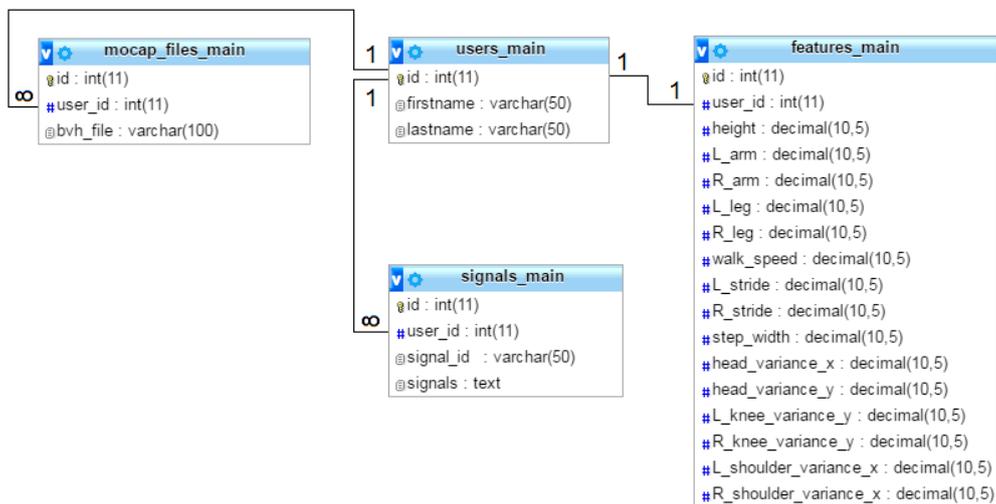
Princíp porovnávania fungoval tak, že sa pre všetky osoby v databáze porovnal každý parameter hľadanej osoby zvlášť. Zhoda fyziologických a pohybových parametrov bola vypočítaná ako relatívna chyba  $E_m$  dvoch hodnôt, kde  $m \in \{\gamma, \alpha_P, \alpha_L, \beta_P, \beta_L, \nu, \delta_L, \delta_P, \kappa, \sigma_{P_6,x}^2, \sigma_{P_6,y}^2, \sigma_{P_{20},y}^2, \sigma_{P_{16},y}^2, \sigma_{P_7,x}^2, \sigma_{P_{11},x}^2\}$ .

Časovo závislé parametre boli porovnané pomocou krížovej korelácie  $r_n$ , kde  $n$  predstavuje množinu parametrov z tabuľky 2.3. Všetky vypočítané zhody boli v percentách. K rozhraniu sme navyše pridali aj možnosť nastavenia váh jednotlivých parametrov. Pre každý parameter bolo možné meniť jeho váhu, ktorá sa taktiež započítala k výsledku. Výslednú zhodu sme vypočítali podľa vzorca 3.1.

$$Match = \frac{\sum E_m V(m) + \sum r_n V(n)}{\sum V(m) + \sum V(n)}, \quad (3.1)$$

kde  $V$  bolo reálne číslo predstavujúce váhu jednotlivých parametrov. Výsledná zhoda  $Match$  bola percentuálna hodnota. Osoba z databáze, ktorá dosiahla najlepšiu zhodu predstavovala hľadanú osobu.

## 3.2 Návrh databázy



Obr. 3.5: Štruktúra databázy.

Naše dáta chôdze pozostávali zo súborov vo formáte *bvh*. Z týchto vstupných dát sme vypočítali všetky spomínané parametre chôdze. Pre efektívnosť vyhľadávania bolo potrebné, všetky tieto parametre uložiť do vhodnej dátovej štruktúry, ktorá by umožňovala rýchle vyhľadávanie. Rozhodli sme sa použiť *MySQL* databázu, ktorej štruktúra je vyobrazená na obrázku 3.5.

Databáza pozostáva zo štyroch tabuliek. Tabuľka *users\_main* obsahuje základné informácie o osobách. V našom prípade nám stačilo iba meno a priezvisko. Každá z osôb v databáze má pridelené unikátne identifikačné číslo, takzvané *user\_id*. Na základe tohoto *id* je možné ku každej osobe jednoznačne priradiť správne parametre, ktoré sa nachádzajú v ostatných troch tabuľkách. Tabuľka *mocap\_files\_main* obsahuje odkaz na súbor *bvh* so záznamom chôdze danej osoby. Každá z osôb môže mať viacero záznamov.

Na uloženie všetkých fyziologických a pohybových parametrov slúži tabuľka *features\_main*. Tieto parametre sú uložené ako číselné hodnoty a jednej osobe prislúcha práve jedna sada parametrov.

Časovo závislé parametre pozostávajú zo série, po sebe idúcich číselných hodnôt, pričom každej hodnote prislúcha presný čas. Naskytlo sa niekoľko možností, ako tieto dáta uložiť. Jednou z nich bolo vytvoriť v databáze nový riadok pre každú hodnotu zvlášť spolu s príslušným časom. Pre jeden takýto signál by sme však dostali viac ako 200 riadkov. Naše signály sú však diskkrétne, inými slovami sú definované v presne určených časových okamihoch. Tieto časové okamihy sú v každom zo signálov rovnaké, nakoľko sú zhodné s časom jednotlivých snímok chôdze. Nebolo preto potrebné ukladať do databázy aj čas, ktorý sa dal jednoducho vypočítať, ako poradie vzorky signálu vynásobené časom jedného snímku. Rozhodli sme sa zakódovať tento signál do formátu *json* [22] ako postupnosť číselných hodnôt a uložiť ich ako text do tabuľky *signals\_main*. Pre jeden signál sme dostali jeden záznam. Každá osoba má však pridelených viac ako 20 rôznych signálov. Údaj *signal\_id* je text, ktorý popisuje o aký signál sa jedná.

# Kapitola 4

## Validácia

Pri testovaní našej metódy sme mali k dispozícii 32 záznamov chôdze od 8 rôznych ľudí. Z pôvodných 32 záznamov sme 11 z nich uložili do databázy. Pričom každej osobe prislúchal minimálne jeden záznam. Naším cieľom bolo priradiť zvyšných 21 záznamov ku správnym osobám.

Kostry v jednotlivých záznamoch však neboli rovnaké. Mali rôzne počty kĺbov. Chýbajúce kĺby spôsobovali problém s výpočtom niektorých parametrov. Napríklad vzdialenosť a zrýchlenie špičiek nebolo možné vypočítať, ak kostre chýbali špičky na nohách. Systém sme museli upraviť tak, aby rozdiely v kostrách ignoroval a bral do úvahy iba kĺby, respektíve parametre, ktoré boli pre porovnávané osoby dostupné. Rovnakým problémom bola aj dĺžka záznamov chôdze. Niektoré boli tak krátke, že nezachytávali ani jeden krok chôdze. Tým pádom nebolo možné vypočítať šírku a dĺžku krokov. Z uvedeného dôvodu sme pri testovaní tieto parametre nepoužívali.

Váhy použitých parametrov	Úspešnosť
$V(\gamma) = 1, V(\alpha_P) = 1, V(\alpha_L) = 1, V(\beta_P) = 1, V(\beta_L) = 1$	100%
$V(\gamma) = 3, V(\alpha_P) = 3, V(\alpha_L) = 3, V(\beta_P) = 3, V(\beta_L) = 3,$ $V(d_{P_{16,20}}) = 1, V(d_{P_{17,21}}) = 1$	95%
$V(\gamma) = 2, V(\alpha_P) = 2, V(\alpha_L) = 2, V(\beta_P) = 2, V(\beta_L) = 2,$ $V(d_{P_{16,20}}) = 1, V(d_{P_{17,21}}) = 1, V(\sigma_{P_{6,y}}^2) = 1, V(\sigma_{P_{20,y}}^2) = 1,$ $V(\sigma_{P_{16,y}}^2) = 1$	66%
$V(\gamma) = 5, V(\alpha_P) = 5, V(\alpha_L) = 5, V(\beta_P) = 5, V(\beta_L) = 5,$ $V(d_{P_{16,20}}) = 1, V(d_{P_{17,21}}) = 1, V(\sigma_{P_{6,y}}^2) = 1, V(\sigma_{P_{20,y}}^2) = 1,$ $V(\sigma_{P_{16,y}}^2) = 1$	80%
$V(d_{P_{16,20}}) = 1, V(d_{P_{17,21}}) = 1$	33%
$V(\sigma_{P_{6,y}}^2) = 1, V(\sigma_{P_{20,y}}^2) = 1, V(\sigma_{P_{16,y}}^2) = 1$	57%
$V(d_{P_{16,20}}) = 1, V(d_{P_{17,21}}) = 1, V(\sigma_{P_{6,y}}^2) = 1, V(\sigma_{P_{20,y}}^2) = 1,$ $V(\sigma_{P_{16,y}}^2) = 1$	57%
$V(\omega_h) = 1, V(\omega_v) = 1$	62%
$V(a_{P_1}) = 1, V(a_{P_{10}}) = 1, V(a_{P_{14}}) = 1, V(a_{P_{17}}) = 1, V(a_{P_{21}}) =$ $1,$	57%
$V(a_{P_1}) = 1$	47%
$V(a_{P_1}) = 1, V(a_{P_6}) = 1, V(a_{P_9}) = 1, V(a_{P_{13}}) = 1, V(a_{P_{21}}) =$ $1, V(a_{P_{17}}) = 1$	71%
$V(\varphi_{\beta_L}) = 1, V(\varphi_{\beta_P}) = 1, V(d_{P_{10,14}}) = 1, V(d_{P_{9,13}}) = 1,$ $V(d_{P_{16,20}}) = 1, V(d_{P_{17,21}}) = 1, V(a_{P_1}) = 1, V(a_{P_9}) = 1,$ $V(a_{P_{13}}) = 1, V(a_{P_{10}}) = 1, V(a_{P_{14}}) = 1, V(a_{P_{20}}) = 1, V(a_{P_{16}}) =$ $1, V(a_{P_{21}}) = 1, V(a_{P_{17}}) = 1$	62%

Tabuľka 4.1: Výsledky validácie.

Počas testovania sme sa opierali o dáta získané pri analýze. Testovali sme, či na základe parametrov označených analýzou ako relevantné, dokážeme jednoznačne priradiť chôdzu k správnej osobe. Skúmali sme rôzne kombinácie parametrov a výsledky porovnávania sme zaznačili do tabuľky 4.1. Okrem typu parametrov sme pri testoch menili aj ich váhu. Pokúšali sme sa relevant-

nejším parametrom prideliť väčšiu váhu, ako tým menej relevantným. Váha predstavovala reálne číslo, ktorým sa násobila sila jednotlivých parametrov. Parametre, ktoré neboli uvedené v tabuľke, mali váhu nastavenú na 0. Tým pádom nehrali pri identifikácii žiadnu úlohu.

Výsledky však boli prekvapivé. Ukázalo sa, že aj pri použití parametrov, ktoré boli analýzou označené ako najmenej relevantné, napríklad rotácie ramien, sme dokázali, správne priradiť až 62% záznamov chôdze. To znamenalo, že každý z parametrov, bez ohľadu na jeho relevantnosť, istým spôsobom unikátne opisuje chôdzu danej osoby. Pri hlbšom skúmaní sa navyše ukázalo, že každá skupina parametrov dokáže rozdielne vystihnúť inú skupinu osôb. Napríklad pre osoby 1-4 mali niektoré parametre väčšiu úspešnosť ako pre osoby 5-8. Pre inú skupinu parametrov to bolo zase naopak. To znamená, že každá osoba vykonáva niektorou z končatín pohyb unikátnym spôsobom, ktorý je špecifický iba pre danú osobu. Pre každú osobu je však táto končatina, respektíve kĺb iný. Tým pádom je veľmi ťažké nájsť univerzálny parameter, ktorý by vedel osobu identifikovať s úspešnosťou 100%. Kľúčom k jednoznačnej identifikácii však môže byť niektorá z možných kombinácií parametrov, ktoré budú navyše dokonale vyvážené.

# Kapitola 5

## Záver

V tejto práci sme popísali parametre chôdze, spôsoby akými sme ich vypočítali a metódy, ktorými sme skúmali ich relevantnosť. Nakoniec sme tieto výsledky použili pre validáciu ich správnosti. Prišli sme však k záveru, že parametre, ktoré sme skúmali nedokážu jednoznačne priradiť spôsob chôdze k danej osobe. Štýl chôdze je totiž napodobniteľný a parametre, o ktoré sme sa opierali nedokážu s dostatočnou presnosťou vystihnúť unikátnosť každého z nás, tak ako napríklad odtlačok prsta, DNA či očná dúhovka. Prišli sme však k záveru, že zo skúmanej množiny parametrov sú najunikátnejšie práve tie, ktoré nemožno meniť. Sú to telesné proporcie ako výška, dĺžka rúk a nôh. Všetky ostatné parametre sa týkali správania a to je možné do istej miery napodobniť. Okrem úmyselného napodobovania do hry však vstupujú ďalšie faktory, ktoré ovplyvňujú výsledok. Medzi ne patrí napríklad psychické rozpoloženie osoby, typ obuvi, oblečenia, rôzne zranenia a podobne. Všetky tieto faktory by dokázali chôdzu pozmeniť na nepoznanie. Je však vysoko pravdepodobné, že chôdza ukrýva unikátny biometrický podpis, ktorý by dokázal so sto percentnou úspešnosťou identifikovať človeka. Nám sa ho však odhaliť nepodarilo.

# Literatúra

- [1] Barclay C., Cutting J., and Kozlowski L. (1978). Temporal and Spatial Factors in Gait Perception That Influence Gender Recognition, Perception & Psychophysics, Vol. 23(2), 145–152.
- [2] Elena G., Marco G., Maurizio L., Nello B. 'Human Classification Using Gait Features', Dipartimento di Informatica, Università degli Studi di Torino. 2014.
- [3] Barry B., Maria I. Varela-Silvia (2010). Leg Length, Body Proportion, and Health: A Review with a Note on Beauty. International Journal of Environmental Research and Public Health, 7, 1047-1075. doi:10.3390/ijerph7031047.
- [4] Hakan Haberdar, 'Generating Random Number from Image of a Probability Density Function', Computer Science Tutorials. [Online]. K dispozícii: <http://www.haberdar.org/discrete-cosine-transform-tutorial.htm>. [Prístupné: 5.8.2016]
- [5] Brad Osgood, 'The Fourier Transform and its Applications', Electrical Engineering Department Stanford University. [Online], K dispozícii: <https://see.stanford.edu/materials/lsoftaee261/book-fall-07.pdf>. [Prístupné: 10.8.2016]
- [6] Christopher D. Manning, Prabhakar Raghavan and Hinrich Schütze (2008). Introduction to Information Retrieval, Cambridge University

- Press. [Online]. K dispozícií: <http://www-nlp.stanford.edu/IR-book/>. [Prístupné: 4.8.2016]
- [7] The Ohio State University Advanced Computing Center for the Arts and Design, 'Motion capture lab', 2003. [Online]. K dispozícií: [https://accad.osu.edu/research/mocap/mocap\\_data.htm](https://accad.osu.edu/research/mocap/mocap_data.htm). [Prístupné: 1.9.2016]
- [8] The Pennsylvania State University, 'Regression Methods' (2017). [Online]. K dispozícií: <https://onlinecourses.science.psu.edu/stat501/node/254>. [Prístupné: 3.1.2017]
- [9] David M. Lane, 'Online Statistics Education: An Interactive Multimedia Course of Study', Introduction to Linear Regression. [Online]. K dispozícií: <http://onlinestatbook.com/2/regression/intro.html>. [Prístupné: 9.9.2016]
- [10] Lindsay I. Smith, 'A tutorial on Principal Components Analysis' (2002). [Online]. K dispozícií: <http://faculty.iiit.ac.in/~mkrishna/PrincipalComponents.pdf>. [Prístupné: 9.2.2017]
- [11] CMU Graphics Lab Motion Capture Database. [Online]. K dispozícií: <http://mocap.cs.cmu.edu/>. [Prístupné: 1.6.2016]
- [12] Forrest W. Young, 'Multidimensional scaling' (1984). [Online]. K dispozícií: <http://forrest.psych.unc.edu/teaching/p208a/mds/mds.html>. [Prístupné: 9.1.2017]
- [13] Stephen P. Borgatti, 'Analytic Technologies', Multidimensional scaling (1997). [Online]. K dispozícií: <http://www.analytictech.com/borgatti/mds.htm>. [Prístupné: 9.1.2017]
- [14] Sungkyu Jung, 'Advanced Applied Multivariate Analysis', Multidimensional scaling (2013). [Online]. K dispozícií: [http://www.stat.pitt.edu/sungkyu/course/2221Fall13/lec8\\_mds\\_combined.pdf](http://www.stat.pitt.edu/sungkyu/course/2221Fall13/lec8_mds_combined.pdf). [Prístupné: 10.1.2017]

- [15] Discreet, a division of Autodesk, Inc., 'BVH File Specification', 2000. [Online]. K dispozícií: [http://www.character-studio.net/bvh\\_file\\_specification.htm](http://www.character-studio.net/bvh_file_specification.htm). [Prístupné: 10.8.2016]
- [16] Prof. Thomas C. O'Haver, 'A Pragmatic Introduction to Signal Processing', 2008. [Online]. K dispozícií: <http://terpconnect.umd.edu/~toh/spectrum/Smoothing.html>. [Prístupné: 6.8.2016]
- [17] Paul Bourke, 'Mathematics / Statistics', 1996. [Online]. K dispozícií: <http://paulbourke.net/miscellaneous/correlate/>. [Prístupné: 22.8.2016]
- [18] MATLAB verzia 9.0.0. Natick, Massachusetts: The MathWorks Inc., 2016
- [19] ZingChart, Inc. [Online]. K dispozícií: <https://www.zingchart.com>. [Prístupné: 8.1.2017]
- [20] Joshua Nava Arts. [Online]. K dispozícií: [http://www.joshuanava.biz/manga-2/images/1829\\_33\\_259-manga-human-figures.jpg](http://www.joshuanava.biz/manga-2/images/1829_33_259-manga-human-figures.jpg) [Prístupné: 22.1.2017]
- [21] Vista animations. [Online]. K dispozícií: <http://www.vistanimations.com> [Prístupné: 16.7.2016]
- [22] JSON. [Online]. K dispozícií: <http://www.json.org> [Prístupné: 12.3.2017]

# Zoznam obrázkov

2.1	Priebeh metódy snímania pohybu [21]. . . . .	4
2.2	Model kostry. $P_1$ -bedrá (stred), $P_2$ -kostrč, $P_3$ -dolný chrbát, $P_4$ -horný chrbát, $P_5$ -krk, $P_6$ -hlava, $P_7$ -ľavé rameno, $P_8$ -ľavá ruka, $P_9$ -ľavý lakeť, $P_{10}$ -ľavá dľaň, $P_{11}$ -pravé rameno, $P_{12}$ -pravá ruka, $P_{13}$ -pravý lakeť, $P_{14}$ -pravá dľaň, $P_{15}$ -pravý bedrový kĺb, $P_{16}$ -pravé koleno, $P_{17}$ -pravá päta, $P_{18}$ -pravá špička, $P_{19}$ -ľavý bedrový kĺb, $P_{20}$ -ľavé koleno, $P_{21}$ -ľavá päta, $P_{22}$ -ľavá špička. . . . .	8
2.3	Sekvencia reprezentovanej chôdze. . . . .	10
2.4	Dĺžka kroku ľavej nohy. . . . .	15
2.5	Šírka kroku - pohľad z hora. . . . .	16
2.6	Variancia hlavy po osi X. . . . .	18
2.7	Lineárna regresia $\hat{y}$ a stredná hodnota $\mu$ . . . . .	18
2.8	Zrýchlenie bedrového kĺbu - pôvodný signál. . . . .	21
2.9	Zrýchlenie bedrového kĺbu - vyhladený signál. . . . .	22
2.10	Horizontálna (a) a vertikálna (b) rotácia ramien [20]. . . . .	22

ZOZNAM OBRÁZKOV	58
2.11 Veľkosť vertikálnej rotácie ramien. . . . .	23
2.12 Vzďialenosť piat . . . . .	24
2.13 Ohyb nohy. . . . .	25
2.14 Ohyb pravej nohy. . . . .	26
2.15 Diskrétna kosínusova transformácia signálov zrýchlenia bedier. . . . .	29
2.16 Ukážka princípu PCA metódy. . . . .	32
2.17 Diagonálna matica reprezentujúca vypočítané vlastné čísla. . . . .	35
2.18 Matica vzdialeností medzi mestami v USA. [13] . . . . .	37
2.19 Mapa miest v USA vytvorená pomocou MDS metódy. [13] . . . . .	37
3.1 Návrh systému. . . . .	42
3.2 Ukážka filtrovania pohybu po rovnej trajektórií. . . . .	43
3.3 Prehrávač bvň záznamov. . . . .	45
3.4 Ukážka nástroja pre analyzovanie chôdze. . . . .	46
3.5 Štruktúra databázy. . . . .	48