

Sustav za procjenu poze sportaša temeljen na dubokom učenju

Pavlić, Pino

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Electrical Engineering and Computing / Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:168:003219>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2025-03-12**



Repository / Repozitorij:

[FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repository](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 567

**SUSTAV ZA PROCJENU POZE SPORTAŠA TEMELJEN NA
DUBOKOM UČENJU**

Pino Pavlić

Zagreb, lipanj 2024.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 567

**SUSTAV ZA PROCJENU POZE SPORTAŠA TEMELJEN NA
DUBOKOM UČENJU**

Pino Pavlić

Zagreb, lipanj 2024.

DIPLOMSKI ZADATAK br. 567

Pristupnik: **Pino Pavlić (0036523277)**
Studij: Računarstvo
Profil: Računarska znanost
Mentor: izv. prof. dr. sc. Vladimir Čeperić

Zadatak: **Sustav za procjenu poze sportaša temeljen na dubokom učenju**

Opis zadatka:

Opisati problem određivanja poze osoba, specifično sportaša, iz slika. Predstaviti dosadašnja istraživanja na tu temu i odabrati prikladan model dubokog učenja te pristupiti implementaciji. Opisati osnove dubokog učenja. Opisati postupak odabira i pripreme skupa slika za učenje, validaciju i ispitivanje na skupu podataka Leeds Sports Poses. Analizirati utjecaj veličine mreže, različitih regularizacijskih metoda, aktivacijskih funkcija te tehnika učenja. Uhodati postupke učenja i validiranja hiperparametara. Opisati postupak učenja na većem skupu slika, interpretirati dobivene rezultate, ukazati na moguće probleme, nedostatke i ograničenja implementacije. Predložiti moguće buduće nadogradnje modela. Radu priložiti izvorne tekstove programa, dobivene rezultate uz potrebna pojašnjenja i korištenu literaturu.

Rok za predaju rada: 28. lipnja 2024.

Zahvaljujem svojoj obitelji na bezuvjetnoj potpori i strpljenju kroz cijeli proces obrazovanja.

Zahvaljujem svom mentoru izv. prof. dr. sc. Vladimiru Čeperiću na pomoći prilikom izrade ovog diplomskog rada.

Sadržaj

Uvod	1
1. Modeli za procjenu položaja tijela	2
2. Slobodno bacanje u košarci.....	8
3. Priprema podataka.....	10
4. Poravnavanje podataka.....	17
5. Analiza pokreta	26
5.1. Desno zapešće.....	26
5.2. Desni lakat	29
5.3. Lijevo rame.....	30
5.4. Lijevi kuk.....	32
5.5. Kut koljena	34
6. Klasifikacija pokreta	36
6.1. Izbor hiperparametara.....	39
6.2. Izbor značajki	41
Zaključak	44
Sažetak.....	45
Summary.....	46
Literatura	47

Uvod

U današnjem dobu napredne tehnologije i digitalizacije, analiza sportskih pokreta može značajno doprinijeti poboljšanju performansi sportaša, prevenciji ozljeda i optimizaciji treninga. Ovaj rad bavi se analizom ispravnosti pokreta šuta slobodnog bacanja u košarci, koristeći metode dubokog učenja.

Košarka je sport koji zahtijeva visoku razinu tehničkih vještina, koordinacije i preciznosti. Iako se naizgled čini jednostavnim, šut slobodnog bacanja je prilično složen. Ispravan pokret tijekom izvođenja šuta slobodnog bacanja uključuje koordinaciju cijelog tijela, od nogu preko trupa do ruku. Stoga detaljna analiza i optimizacija ovog pokreta može ukazati na nedostatke i probleme koji nisu uočljivi subjektivnim metodama procjene.

Razvoj tehnologije i algoritama dubokog učenja omogućuje nam objektivnu i preciznu analizu pokreta. Korištenjem algoritama za procjenu položaja tijela, možemo klasificirati ispravan od neispravnog pokreta igrača te dobiti detaljan uvid u njihovu tehniku. Algoritmi strojnog učenja, kao što je XGBoost, omogućuju nam da automatski prepoznamo i klasificiramo ispravnost pokreta na temelju velikog broja uzoraka, što povećava točnost i pouzdanost analize.


U ovom radu objasniti ćemo osnove modela za procjenu položaja tijela te proces dobivanja podataka o koordinatama ključnih točaka tijela iz videozapisa. Detaljno ćemo analizirati ispravnost pokreta šuta slobodnog bacanja u košarci, ističući ključne značajke koje razlikuju ispravne od neispravnih pokreta. Na kraju, izgraditi ćemo model za klasifikaciju ispravnosti pokreta slobodnog bacanja koristeći napredne metode strojnog učenja.

1. Modeli za procjenu položaja tijela

Procjena poze jedan je od temeljnih zadataka u području računalnog vida. Generalno, to je proces određivanja položaja i orijentacije tijela u prostoru na temelju videa ili slike [1]. Osnovni cilj je identificirati i pratiti ključne točke tijela, koje kao cjelina pružaju uvid u položaj cijelog tijela. Postoje tri različite vrste pristupa prikazu ljudskog tijela:

- a) model zasnovan na kosturu, zvan i kinematski model
- b) model zasnovan na konturama, zvan i planarni model
- c) model temeljen na volumenu, zvan i volumetrijski model

U ovom radu koristit će se model zasnovan na kosturu, odnosno kinematski model, prikazan slikom Sl. 1.1.



Sl. 1.1 Vrste prikaza ljudskog tijela – preuzeto iz [1]

Koje ključne točke će se pronaći na slici ovisi o modelu koji izaberemo, dok model biramo ovisno o tematici problema koji pokušavamo riješiti. Ako je cilj analizirati položaj cijelog tijela, ključne točke obično uključuju zglobove kao što su ramena, laktovi, zapešća, kukovi, koljena i gležnjevi. S druge strane, ako je fokus na prepoznavanju izraza lica ili položaja ruke, koristit ćemo model koji pronalazi više ključnih točki po licu kao što su, oči, uši, nos, kutovi usana, kutovi brade, odnosno za ruke članci prstiju, vrhovi prstiju, rubovi dlanova, itd. U ovom radu baviti ću se problemom određivanja položaja tijela, stoga ću i koristiti modele koji pružaju odgovarajući skup ključnih točki.

Procjena položaja tijela ima jako široku lepezu primjena. U zdravstvu se koristi, primjerice, u fizioterapijama gdje omogućuje praćenje i analizu pokreta pacijenata radi boljeg planiranja rehabilitacije. U sektoru zabave, uobičajeno se koristi u virtualnoj stvarnosti i snimanju

pokreta za video igre, čime se omogućuje realističnija interakcija i doživljaj korisnika. Može se koristiti u sportu u svrhu poboljšanja performansi sportaša i prevenciji ozljeda putem detaljne analize pokreta i tehnike koja se izvodi. Također se može koristiti u svrhu učenje ili poboljšavanja sportskog pokreta, kao što ćemo vidjeti u nastavku ovog rada.

Proces procjene poze iz videa započinje razdvajanjem videa na njegove video okvire, odnosno slike koje čine dani video. Tim putem, detaljno se analizira svaki pojedinačni trenutak unutar videa, što je od iznimne važnosti za određivanje poze osobe. Prije samog algoritma, odvija se faza pretprocesiranja slike [2]. U ovoj fazi, slika se uobičajeno konvertira u crno-bijeli format kako bi se smanjila količina podataka za obradu. Također, slike se normaliziraju, što uključuje uklanjanje šumova i prilagodbu kontrasta. Nakon pretprocesiranja slijedi korak detekcije objekta. U tu svrhu koristi se neki od raznih algoritama, poput YOLO (You Only Look Once) ili SSD (Single Shot MultiBox Detector) koji stvaraju pravokutnik (*engl.* bounding box) koji obuhvaća područje na slici koje zauzima objekt, pomažući da se fokus usmjeri na relevantne dijelove slike. Na izdvojeni pravokutnik, primjenjuje se neki od algoritama za procjenu položaja tijela poput OpenPose, DeepPose ili MoveNet. Ti algoritmi su zaduženi za pronalazak ključnih točki označenog objekta. Svaka ključna točka sastoji se od tri vrijednosti:

- x koordinate
- y koordinate
- faktor povjerenja

Faktor povjerenja je vrijednost između 0 i 1, koja pokazuje koliko je algoritam siguran u točnost procjene određene ključne točke. Faktor povjerenja može biti jako korisna informacija u sljedećoj fazi, postprocesiranje slike. Faza postprocesiranja uključuje filtriranje i izračunavanje prosjeka za one točke koje su imale nizak faktor povjerenja. Nepouzdana točke se uklanjaju i podaci se zaglađuju kroz vrijeme. Primjerice, ako su neki zglobovi skriveni te imaju nizak faktor povjerenja, algoritam može koristiti kontekst iz susjednih okvira za interpolaciju i procjenu njihovog položaja. Time se osigurava konzistentnija i preciznija procjena ključnih točki, a time ujedno i poze tijela.

Kroz povijest postojalo je više rješenja temeljenih na klasičnom računalnom vidu, s fokusom na promjene u bojama i kontrastu te na pojedine specifične dijelove slike. Međutim, posljednjih nekoliko godina ovim područjem dominiraju rješenja iz domene dubokog

učenja. Ta rješenja možemo podijeliti u dvije temeljne skupine, odnosno dva temeljna pristupa određivanju položaja ljudskog tijela:

- bottom-up pristup
- top-down pristup


Bottom-up pristup prvo detektira ključne točke za sve osobe na slici, a potom te ključne točke grupira kako bi se formirali kinematski modeli svake osobe. Prednost ovog pristupa je u tome što nudi bolje performanse kod složenih scena s više osoba. S druge strane, top-down pristup prvo obavlja detekciju osoba na slici, a zatim, neovisno za svaku osobu, obavlja procjenu položaja tijela [3].

Unatoč velikom napretku u procjeni položaja tijela metodama dubokog učenja, postoje brojni nedostaci i ograničenja koja otežavaju njihovu primjenu u stvarnim scenarijima.

Jedan od najvećih izazova jest određivanje skrivenih zglobova, odnosno identificiranje zglobova koji nisu vidljivi na slici ili se nalaze iza drugih dijelova tijela ili objekata. Na primjer, ruke koje su iza leđa ili noge koje su prekrivene jedna preko druge mogu biti posebno teške za identificirati. U takvim situacijama, uzima se nekoliko slika video okvira prije, odnosno poslije, video okvira na kojemu je problematični zglob, te se na temelju vrijednosti ključne točke tih okvira provodi interpolacija i računa prosječna vrijednost kako bi precizno odredili položaj tog problematičnog zgloba.

Drugi veliki problem jest određivanja položaja tijela na slikama, odnosno videima, loše kvalitete. Postavke videa, poput rezolucije i broja okvira u sekundi (*engl.* frames per second, fps), izravno utječu na performanse algoritama. Niža rezolucija može rezultirati gubitkom detalja, čineći ključne točke teže prepoznatljivima. Zamućenje ili šum također mogu smanjiti preciznost procjene poze, s obzirom na to da algoritmi ne mogu jasno razlučiti granice i obrise tijela.

Danas postoji mnogo treniranih modela za procjenu položaja tijela. Jedan od najpoznatijih i najraširenijih jest OpenPose. Broj pronađenih točki ovisi o konfiguraciji OpenPose modela i dijelovima tijela koji se procjenjuju. Već smo spomenuli kako se može određivati položaj specifičnih dijelova tijela, poput lica i ruke. No, u ovom radu bavimo se problemom određivanja položaja cijelog tijela.

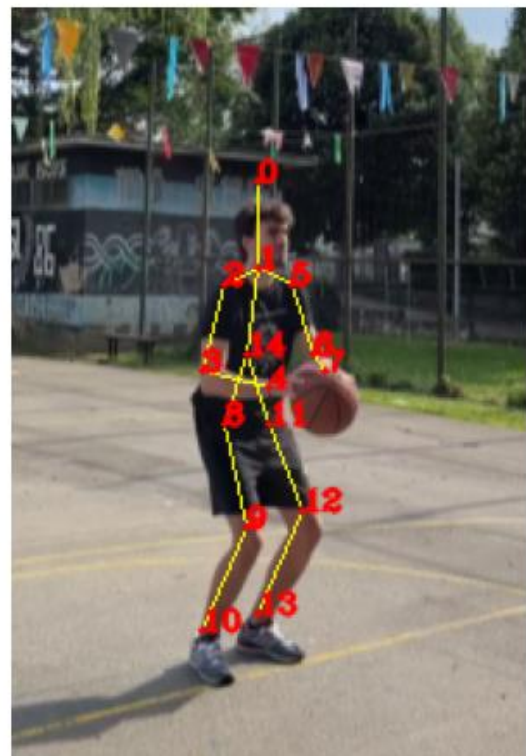


Sl. 1.2 Modeli za procjenu položaja cijelog tijela

Na (Sl. 1.2) vidimo 3 modela za procjenu položaja cijelog tijela. S obzirom na temu ovog rada, u kojoj nas ne zanimaju pretjerano detalji lica, MPI model je prikladniji, jer sadrži ključne točke koje su najrelevantnije za problem koji pokušavamo riješiti.

OpenPose MPI, prikazan na (Sl. 1.3), pruža kinematski model s 15 ključnih točki:


0. glava
1. vrat
2. lijevo rame
3. lijevi lakat
4. lijevo zapešće
5. desno rame
6. desni lakat
7. desno zapešće
8. lijevi kuk
9. lijevo koljeno
10. lijevi gležanj
11. desni kuk
12. desno koljeno
13. desni gležanj
14. prsa



Sl. 1.3 Ključne točke modela MPI

Drugi, također vrlo popularni trenirani model jest Movenet, razvijen od strane Googlea, kinematski model sa 17 ključnih točki. Glavna razlika u odnosu na OpenPose jest njegova brzina i manja računalna kompleksnost. To Movenet čini optimiziranim za primjene u stvarnom vremenu uz zadržavanje visoke točnosti u otkrivanju ključnih točaka.

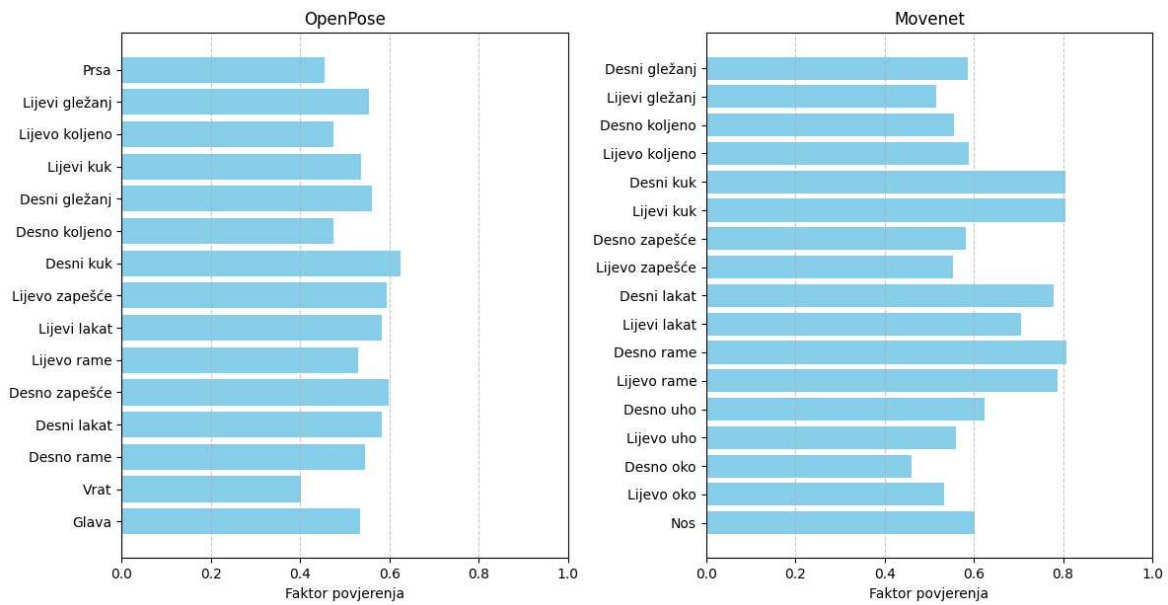
Za odabir modela u ovom radu razmatramo OpenPose i MoveNet. U tu svrhu provest ćemo kratki eksperiment u kojemu ćemo usporediti prosječni faktor povjerenja za svaku ključnu točku kroz sve video okvire. Kada na ulaz modela dovedemo video zapis u *mp4*. formatu, dobijemo rezultate prikazane na (Sl. 1.4).



Sl. 1.4 Faktor povjerenja Openpose i Movenet modela

Vidimo da OpenPose model ima izrazito veće prosječne faktore povjerenja za svaku ključnu točku. Vrijednosti faktora povjerenja od oko 0.4 kod Movenet modela pokazuju vrlo nisku točnost, te se koordinate dobivene tim modelom ne mogu smatrati valjanim skupom podataka za daljnji rad.

S druge strane kada je ulaz modela povezana kamera (*real-time video*) dobijemo značajno drugačije rezultate za oba modela, kako je prikazano na (Sl. 1.5).



Sl. 1.5 Faktor povjerenja Openpose i Movenet modela

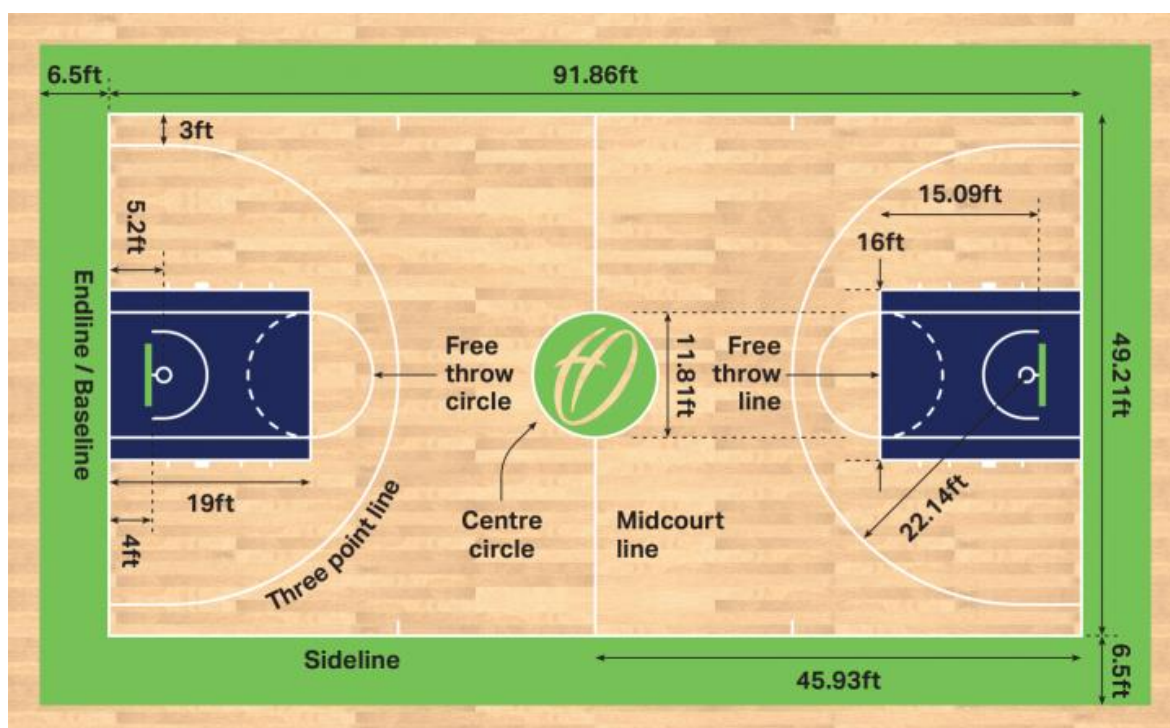
U ovom slučaju, MoveNet pokazuje nešto bolje performanse. S obzirom na to da za treniranje sustava koristimo podatke u obliku video zapisa, koristit ćemo OpenPose model koji se pokazao uspješnijim u toj situaciji. Međutim, kada koristimo istrenirani sustav i želimo odmah vidjeti rezultate, koristit ćemo MoveNet model.

Ovaj pristup omogućuje nam iskorištavanje prednosti oba modela, osiguravajući visoku točnost tijekom treniranja i brzinu tijekom *real-time* primjene.

2. Slobodno bacanje u košarci

Kao što je već objašnjeno u uvodu, sportski pokret koji se analizira u ovom radu jest gađanje koša s linije slobodnog bacanja.

U košarci, slobodna bacanja su pokušaji da se postignu bodovi pucanjem iza linije slobodnog bacanja, neslužbeno poznate kao linija za prekršaje ili engl. *charity stripe*. Ova crta nalazi se na kraju područja ispred koša. Slobodna bacanja općenito se dodjeljuju nakon prekršaja protivničke momčadi nad strijelcem, analogno kaznenim udarcima u drugim momčadskim sportovima. Ovisno o situaciji, igraču se može dodijeliti između jednog i tri slobodna bacanja. Svako uspješno slobodno bacanje vrijedi jedan bod.



Sl. 2.1 Dimenzije košarkaškog terena – preuzeto iz [4]

Dimenzije, prikazane na (Sl. 2.1), košarkaškog terena određene su jasnim pravilima. Naravno nas zanimaju samo pravila vezana za područje slobodnog bacanja. Linija slobodnog bacanja mora biti nacrtana paralelno s krajnjim linijama terena. Njezin najudaljeniji rub mora biti 5,80 metara od unutarnjeg ruba krajnje linije te 4,60 metara od prednjeg okvira koša. Sama linija mora biti dugačka 3,60 metara. Središnji dio mora ležati na zamišljenoj liniji koja spaja središnje točke dviju krajnjih linija. [5]

Iako bi se svaka tehnika izvođenja pokreta koja rezultira pogotkom mogla smatrati uspješnom, u ovom radu kao primjer pravilnog izvođenja pokreta koristimo skup videa

dobiven snimanjem osobe za koju je procijenjeno da zna pravilno izvesti pokret. Sve druge tehnike, koje se razlikuju od ove demonstrirane pravilne forme, smatramo netočnima. Ovo uključuje i tehniku izvođenja slobodnog bacanja ispod ruke, poznatu kao engl. *granny shot*, koja, unatoč visokom postotku uspješnosti, ne spada pod pravilno izvođenje pokreta prema standardima korištenima u ovom istraživanju.

Pokret slobodnog bacanja u košarci, prikazan (Sl. 2.2), započinje pravilnim postavljanjem igrača. Igrač stoji iza linije slobodnog bacanja s nogama u širini ramena, blago savijenim koljenima i tijelom u ravnoteži. Loptu drži s obje ruke, s dominantnom rukom iznad lopte i drugom rukom sa strane, pružajući potporu. Loptu drži u razini kukova, dok su sami kukovi blago zabačeni unazad, čime igrač preuzima lagano nagnuti položaj prema naprijed. S pogledom na koš, igrač lagano savija koljena dok istovremeno podiže loptu prema gore. Ključni moment u izvođenju slobodnog bacanja je fluidno ispravljanje koljena i ruku u



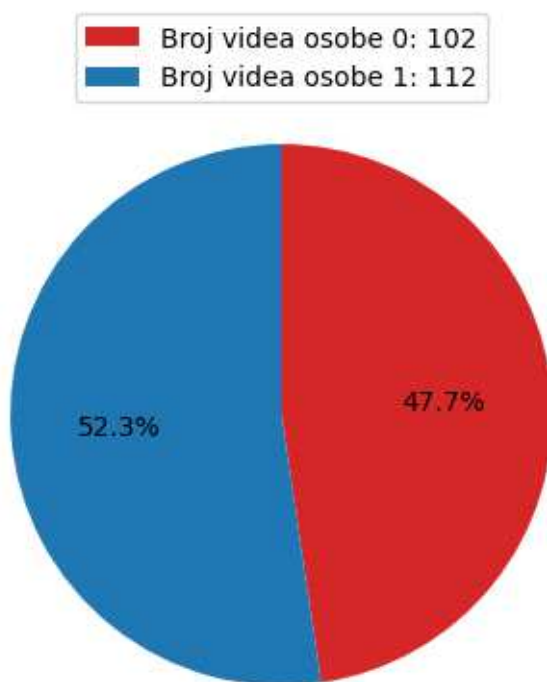
Sl. 2.2 Primjer pokreta slobodnog bacanja

koordiniranom pokretu, s dominantnom rukom koja gura loptu prema košu, dok prsti druge ruke pružaju stabilnost i kontrolu. Ovaj pokret mora biti gladak i dosljedan, s igračem koji ostaje fokusiran na cilj i održava pravilan balans tijela sve dok lopta ne napusti njegove ruke. Pokret završava s potpuno ispravljenim trupom i ravnom dominantnom rukom koja je podignuta iznad glave. Cilj je postići pravilan luk i preciznost kako bi lopta ušla u koš.

3. Priprema podataka


Iako postoje mnoge baze podataka s videozapisima raznih sportskih pokreta, nijedna nije potpuno prikladna za specifični problem koji obrađujemo u ovom radu. Zbog toga je za potrebe istraživanja kreiran vlastiti skup podataka. Snimljen je ukupno 221 videozapis izvođenja pokreta slobodnog bacanja, svaki sniman iz iste pozicije, pod istim kutom i s iste udaljenosti. Snimane su dvije osobe, koje ćemo u daljnjem tekstu označavati kao Osoba 0 i Osoba 1.

Snimke Osobe 1 predstavljaju primjer pravilnog izvođenja pokreta slobodnog bacanja, dok snimke Osobe 0 prikazuju nepravilno izvođenje istog pokreta. Raspodjela broja videozapisa prikazana je na (Sl. 3.1), iz koje je vidljivo da videozapisa na kojima se nalazi Osoba 0 ima 102, dok videozapisa na kojima se nalazi Osoba 1 ima 119.



Sl. 3.1 Raspodjela broja videozapisa

Duljine videozapisa su različite, većinom se kreću u rasponu od 1 do 3 sekunde. Distribuciju duljine videozapisa našeg skupa podataka možemo vidjeti na (Sl. 3.2), koja prikazuje broj video okvira u svakom videu.



Sl. 3.2 Distribucija duljine videozapisa

Trenutna distribucija duljine videa nije optimalna za naše potrebe, te ćemo se rješavanjem ovog problema pozabavit kasnije u istraživanju.

Sada kada smo prikupili videozapise, možemo započeti proces izdvajanja podataka ključnih točki. Kao što je već objašnjeno koristimo OpenPose MPI model. Postupak provodimo iterativno prolazeći kroz svaki videozapis, primjenjujući OpenPose MPI model za pronalaženje ključnih točki na svakoj slici. Tijekom svake iteracije, u kojoj se obrađuje jedna po jedna slika, model vraća tri vrijednosti za svaku od 15 ključnih točki: x koordinatu, y koordinatu te faktor povjerenja. Stoga, svaka iteracija rezultira s 2D listom elemenata u obliku (broj video okvira, 15, 3). S obzirom na to da imamo 221 video, iteracija se ponavlja 221 put. Podatke iz svake iteracije spremamo u konačnu listu koja na kraju ima oblik (221, broj video okvira, 15, 3). Ova konačna lista predstavlja naše podatke, koje zatim pretvaramo u tablicu koristeći Python biblioteku *pandas*. Stupci u tablici su generirani tako da su vrijednosti x i y koordinata te faktora povjerenja svake ključne točke spremljene u zasebne stupce, što rezultira s ukupno 45 stupaca. Za svaki videozapis zapisujemo i dodatne 4 vrijednosti:

- redni broj videa
- provjera je li pokret rezultirao pogotkom
- osoba koja je izvodila pokret

- redni broj video okvira trenutnog videa

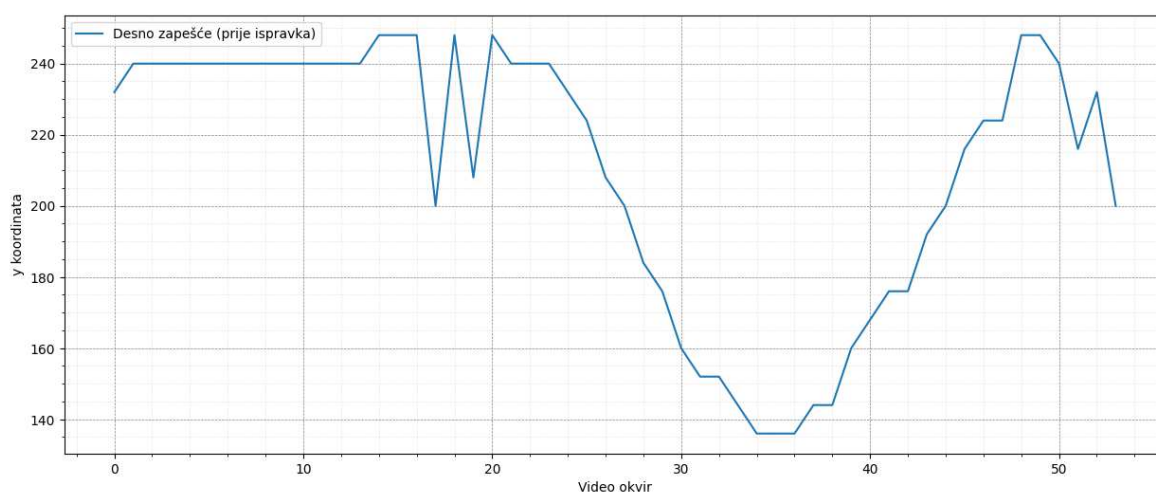
Te vrijednosti čine dodatne stupce, što ukupni broj stupaca naše tablice dovodi do 49. Primjer tablice prikazan je na (Sl. 3.3).

	video_num	target	person	frame	rshoulder_x	rshoulder_y	rshoulder_conf	lwrist_x	lwrist_y	lwrist_conf	
	0	1	1	0	1	184.0	208.0	0.464136	152.0	224.0	0.558638
	1	1	1	0	2	184.0	208.0	0.455918	152.0	224.0	0.512898
	2	1	1	0	3	184.0	208.0	0.498696	152.0	224.0	0.500217
	3	1	1	0	4	152.0	208.0	0.374284	176.0	208.0	0.211604
	4	1	1	0	5	184.0	208.0	0.579423	160.0	224.0	0.549031
...
	17309	214	0	1	49	168.0	184.0	0.541161	176.0	224.0	0.423453
	17310	214	0	1	50	136.0	184.0	0.758941	168.0	224.0	0.271640
	17311	214	0	1	51	176.0	184.0	0.700484	128.0	232.0	0.667000
	17312	214	0	1	52	144.0	176.0	0.626267	176.0	216.0	0.262687
	17313	214	0	1	53	176.0	184.0	0.663321	88.0	224.0	0.836952

Sl. 3.3 Primjer tablice

Sada kada imamo podatke u tablici, sljedeći zadatak je riješiti problem nedostajućih vrijednosti i stršecih podataka. Budući da smo od OpenPose modela dobivali koordinate za svaku ključnu točku bez obzira na njihov faktor povjerenja, svaka ključna točka ima vrijednost u svakom video okviru. Stoga, u našoj tablici nema nedostajućih vrijednosti.

Problem stršecih podataka jest malo kompliciraniji. Koordinate svake ključne točke se mijenjaju kroz video okvire, što otežava uočavanje anomalija samo na temelju numeričkih podataka. Za ilustraciju, na (Sl. 3.4) prikazan je graf koji prikazuje kretanje vrijednosti y koordinate desnog zapešća kroz različite video okvire jednog od naših videozapisa.



Sl. 3.4 Koordinata y desnog zapešća prije ispravka

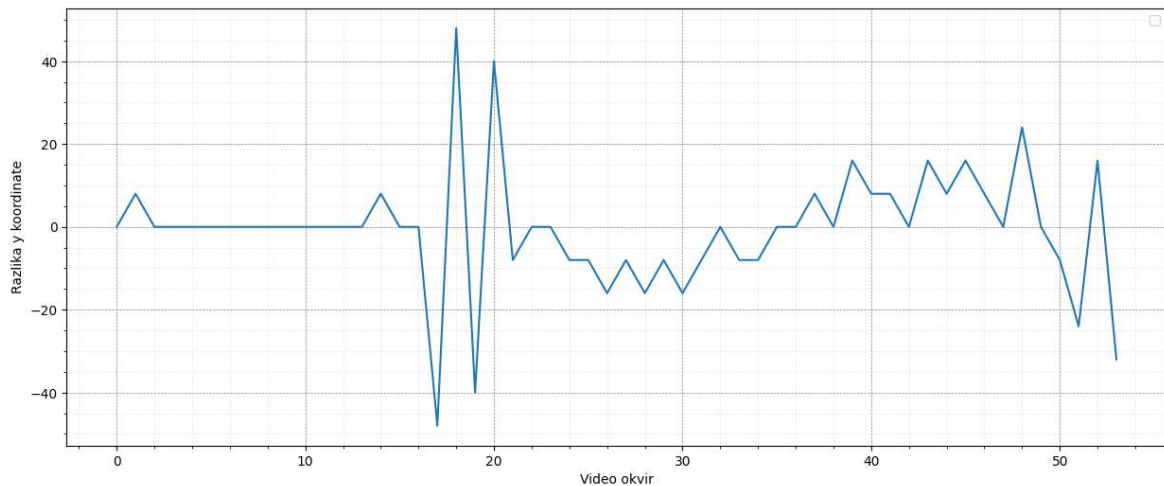
Gledajući graf, možemo pretpostaviti tijek pokreta koji se odvijao tijekom snimanja. U video okvirima od 0 do 23, osoba se pripremala za šut držeći ruke u mirnom položaju. Od video okvira 24 do 34, vrijednosti koordinate y se počinju smanjivati, što ukazuje na podizanje ruke prema gore, nakon čega se vrijednosti malo stabiliziraju, što sugerira na kratku pauzu u pokretu. Nakon toga, od video okvira 35 do 48, koordinate polako rastu, što ukazuje na spuštanje ruke.

Međutim, možemo primijetiti da se jedan dio grafa izdvaja od ostalih. Vrijednosti u video okvirima 17 i 19 izrazito naglo opadaju, što bi sugeriralo naglo podizanje ruke. No, pregledom video okvira u tim trenucima, koji su prikazani na (Sl. 3.5), vidimo da ruka zapravo ostaje u mirnom položaju tijekom tog vremena.



Sl. 3.5 Video okviri 17, 18, 19 i 20

OpenPose model očito nije ispravno mapirao koordinate u tim video okvirima. Zbog toga, potrebno je provesti proces ispravljanja svih takvih stršećih vrijednosti u našim podacima. Analizom razlike između uzastopnih vrijednosti y koordinate dobivamo bolji uvid prikaz stršećih podataka. Graf razlike, prikazan na (Sl. 3.6), pokazuje da su uobičajene vrijednosti do 20, dok su vrijednosti za video okvire od 17 do 20 gotovo dvostruko veće, oko 40.




Sl. 3.6 Razlika y koordinata desnog zapešća

Proces rješavanja stršenja podataka u našoj tablici temelji se na analizi razlike između uzastopnih koordinata, kako bi se identificirale i ispravile anomalije. Prolazimo iterativno kroz razlike između uzastopnih koordinata svake ključne točke u video okvirima. Ako je razlika veća od 30, što ukazuje na naglu promjenu vrijednosti, provjeravamo i sljedeći video okvir. Ako je i ta razlika također veća od 30, brišemo samo vrijednost y koordinate za trenutni video okvir. Inače, brišemo vrijednost y koordinate za trenutni i sljedeći video okvir.

Na primjeru grafa razlike, primjećujemo da su samo dvije vrijednosti y koordinate krive, one u video okvirima 17 i 19. Međutim, graf razlike između koordinata pokazuje da su četiri vrijednosti veće od 30 - za video okvire 17, 18, 19 i 20. Razlog tome je što je vrijednost y koordinate zapešća naglo pala u video okviru 17, ali se u okviru 18 odmah vratila na ispravnu poziciju, što uzrokuje veliku promjenu i u video okviru 18. Ovaj proces omogućuje nam učinkovito uklanjanje ili ispravljanje stršenja u podacima ključnih točaka, čime osiguravamo točnost analize i interpretaciju pokreta u videu.

Nakon što provrtimo algoritam ispravljanja stršećih podataka, koordinate izgledaju mnogo zaglađenije, što se možemo i vidjeti na (Sl. 3.7).



Sl. 3.7 Koordinata y desnog zapešća poslije ispravka

Nakon što smo ispravili sve stršeeće vrijednosti, možemo dodati nove značajke našim podacima. S obzirom na pokret koji analiziramo, slobodno bacanje u košarci, kutovi između različitih zglobova mogu biti od velike važnosti. Kako bismo izračunali kut, potrebne su nam tri ključne točke: dvije vanjske točke i jedna središnja točka između njih.

Izračun kutova između zglobova obavlja se tako da se prvo odrede vektori između središnje točke i svake od vanjskih točaka. Zatim se koristi skalarni produkt i magnitude tih vektora kako bi se izračunao kut između njih. Ovi kutovi se konvertiraju iz radijana u stupnjeve i dodaju se u našu tablicu kao nove značajke.

Nakon dodavanja kutova, moguće je da neki stupci sadrže nedostajuće vrijednosti. To se uobičajeno događa kada su dvije ključne točke poklopljene, odnosno kada se čini da su na istoj koordinati. To može biti rezultat situacije kada jedna točka stoji iza druge u stvarnom prostoru, ali kamera snima obje točke na istom mjestu na slici. U takvim slučajevima nije moguće izračunati kut jer su vektori potrebni za izračunavanje istovremeno usmjereni prema istoj točki, što matematički onemogućava određivanje kuta. Kako bismo osigurali konzistentnost podataka, koristimo metodu interpolacije za popunjavanje tih vrijednosti.

Rezultati izračunavanja kutova mogu biti u nekim dijelovima nestabilni zbog ovisnosti o vrijednostima koordinata triju točaka. Budući da smo vidjeli kako vrijednosti koordinata koje vraća OpenPose model nisu uvijek sasvim precizne te znaju malo varirati. Stoga, čak i male promjene u koordinatama svake od tri točke mogu značajno promijeniti kut između njih. Upravo nam je zbog toga bilo od velike važnosti ispraviti one male stršeeće vrijednosti, jer to dovodi do znatno preciznijih izračuna kutova.


Ovaj postupak omogućuje nam da obogatimo naš skup podataka dodatnim značajkama koje su ključne za precizniju analizu i interpretaciju pokreta tijekom slobodnog bacanja.

4. Poravnavanje podataka

Duljine svih videozapisa nisu jednake, kao što smo već vidjeli na (Sl. 3.2). To znači da ni pokret koji analiziramo ne započinje u istom trenutku, odnosno u istom video okviru, u svakom videu. Takav pomak u podacima nije optimalan za naše potrebe, budući da naši podaci prikazuju isti pokret.

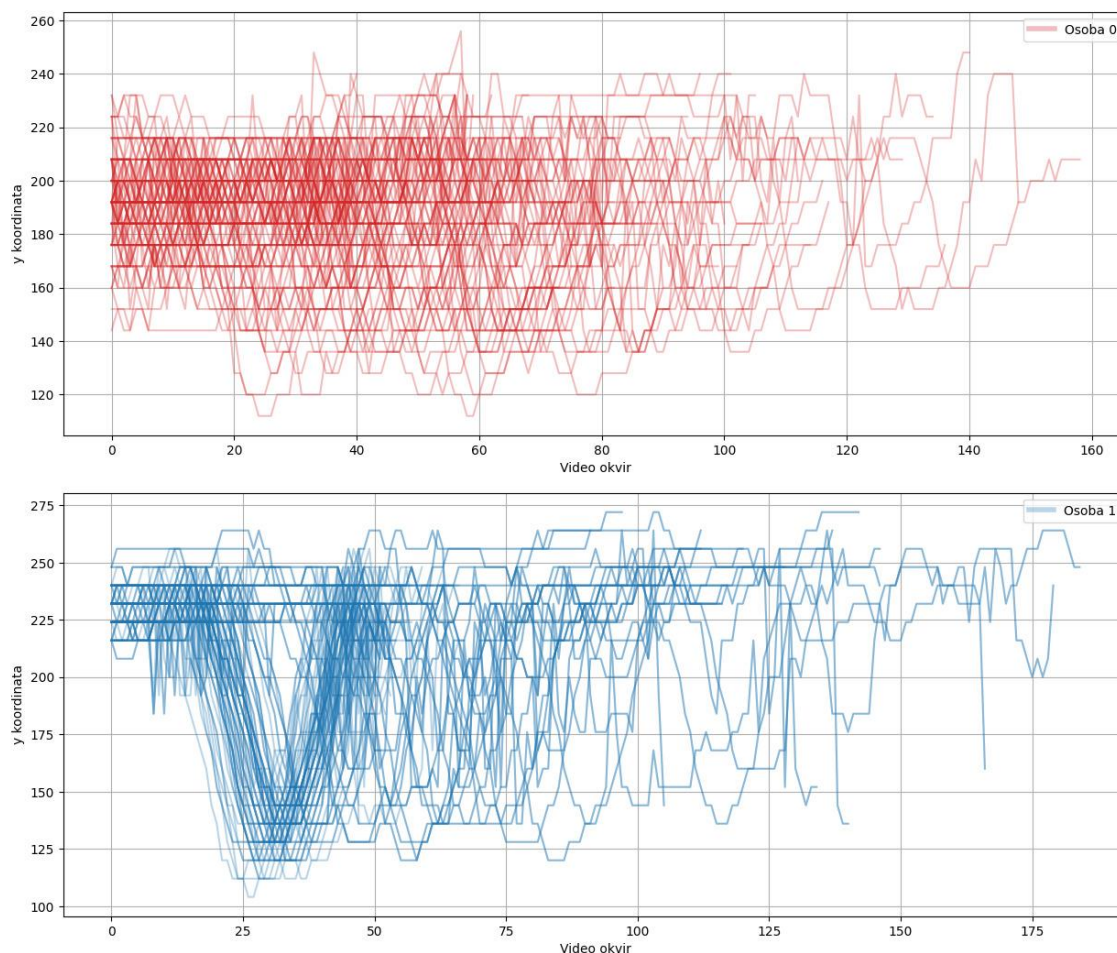
Poravnanje podataka ključno je kako bismo mogli precizno analizirati pokrete, odnosno kako bismo dobili točnije i usporedljive analize. Neporavnani podaci otežavaju usporedbu između različitih videozapisa, jer se isti pokreti ne događaju u istim vremenskim točkama. Poravnanje omogućava dosljednost i olakšava prepoznavanje obrazaca u pokretima, kao i identifikaciju odstupanja koja mogu ukazivati na nepravilnosti u izvođenju slobodnog bacanja. Također, poravnanje će nam mnogo pomoći kod primjene algoritama strojnog učenja, s obzirom na to da ti algoritmi često zahtijevaju konzistentne vremenske serije za preciznu analizu i predviđanje.

Proces poravnavanje podataka započinjemo identificirajući referentnu točku koja označava određeni dio pokreta u svakom videozapisu. Nakon toga, svi videozapisi mogu biti prilagođeni tako da ta referentna točka bude u istom okviru. Tako, svi pokreti će biti sinkronizirani, omogućavajući izravnu usporedbu između različitih izvođenja slobodnog bacanja. Ovaj postupak osigurava da se analiza temelji na usporedivim podacima, što je ključno za točne i pouzdane rezultate.



Sl. 4.1 Promjena y koordinate desnog zapešća svih videozapisa

Kada prikazemo sve vrijednosti neke ključne točke, primjerice desnog zapešća, kroz video okvire grupirane po osobi kojoj ključna točka pripada, možemo primijetiti pojavu određenog konzistentnog obrasca, kao što je prikazano na (Sl. 4.1). Ovaj obrazac postaje još uočljiviji kada se grupe prikažu na zasebnim grafovima, kao na (Sl. 4.2).




Sl. 4.2 Promjena y koordinate desnog zapešća osobe 0 i osobe 1

Dok se obrazac osobe 0, koja je neispravno izvodila udarac, ne može baš odmah prepoznati, obrazac osobe 1 je mnogo izraženiji. Vidimo da y koordinata desnog zapešća, u većini videa osobe 1, doseže minimalnu vrijednost između video okvira 25 i 50. Međutim, neki videozapisi dosežu minimalnu vrijednost mnogo kasnije, iako im je oblik grafa sličan ostalima. Stoga nam je cilj "poravnati" grafove kako bi se svi podudarali.

Proces dinamičkog vremenskog poravnavanja (engl. *Dynamic Time Warping*, *DTW*) je algoritam koji se koristi za mjerenje sličnosti između dviju vremenskih serija koje mogu varirati u brzini ili vremenskom razmaku. Ovaj algoritam omogućava prilagodbu vremenskih serija kako bi se minimizirale razlike između njih, poravnavajući grafove tako

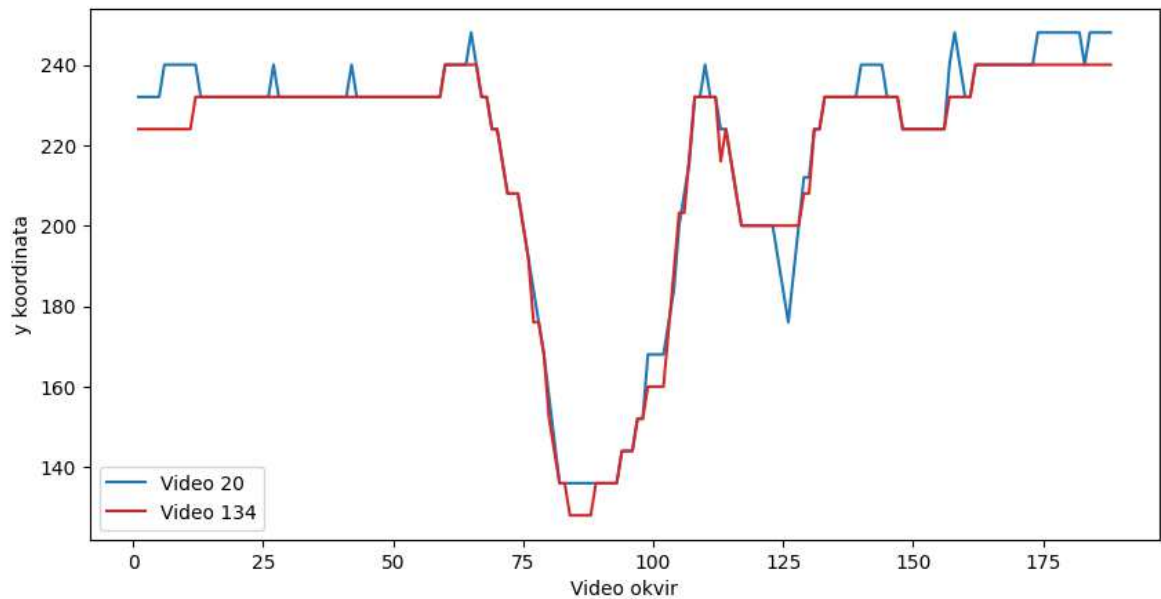
da prate isti uzorak. DTW je posebno koristan kada analiziramo podatke koji nisu savršeno sinkronizirani, jer omogućava da svi pokreti započnu i završe u istim trenucima unatoč razlikama u trajanju pojedinih videozapisa. U našem radu, navedeni algoritam ćemo koristiti za poravnavanje vremenskih serija podataka o koordinatama ključnih točki, osiguravajući da se svi grafovi usklade i prikazuju konzistentne obrasce.

Za primjer ćemo izabrati dva nasumična videa iste osobe, primjerice videozapis 20 i 134. Na (Sl. 4.3) vidimo vrijednosti y koordinata desnog zapešća tih dvaju videozapisa. Uočavamo sličnost grafova, međutim pokret videozapisa 20 je započeo nešto kasnije nego pokret videozapisa 134.



Sl. 4.3 koordinata y desnog zapešća videozapisa 20 i 134

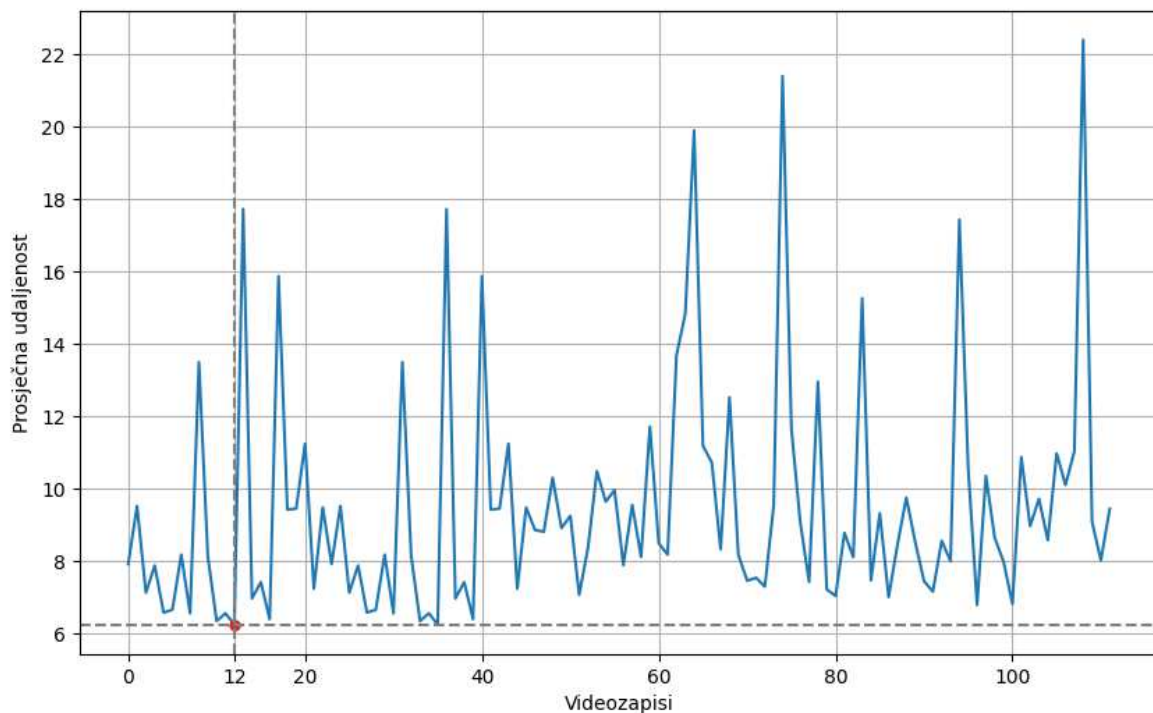
Koristeći proces dinamičkog vremenskog poravnavanja, pokušavamo smanjiti razliku između grafova pokreta te dobivamo rezultat prikazan na (Sl. 4.4).



Sl. 4.4 koordinata y desnog zapešća videozapisa 20 i 134 nakon procesa poravnavanja

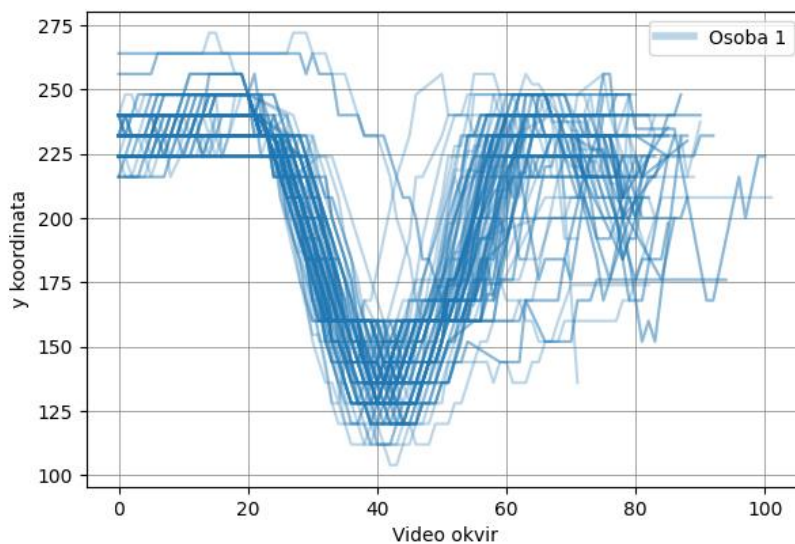
Možemo uočiti da se ukupni broj video okvira povećao s oko 120 na preko 175 te sada su oba videozapisa jednake duljine. U ovom slučaju poravnavali smo samo dva videozapisa, međutim naš cilj jest poravnati sve videozapise u obje grupe. To ćemo ostvariti tako što ćemo izabrati jedan referentni videozapis te zatim iterativno provesti algoritam za taj videozapis te sve ostale videozapise iz naše grupe.

Stoga se postavlja pitanje koji videozapis izabrati kao referentni. U tome nam može pomoći činjenica da dtw računa zbroj udaljenosti između parova elemenata dvaju nizova duž optimalnog puta koji je pronađen između ta dva niza. To bi bila nekakva ukupna cijena poravnanja dvaju nizova. Što je udaljenost manja, to su vremenski nizovi sličniji. Provesti ćemo algoritam koji će iterativno birati referentni videozapis te provjeravati prosječnu ukupnu udaljenost. Na (Sl. 4.5) vidimo graf kretanja prosječne udaljenosti za svaki videozapis osobe 1.



Sl. 4.5 Graf kretanja prosječne udaljenosti za osobu 1


Najbolji referentni videozapis jest videozapis s rednim brojem 12. Kada provedemo proces dinamičkog vremenskog poravnavanja za sve videozapise dobivamo poravnate grafove prikazane na (Sl. 4.6).



Sl. 4.6 Promjena y koordinate desnog zapešća svih videozapisa osobe 1 nakon poravnavanja

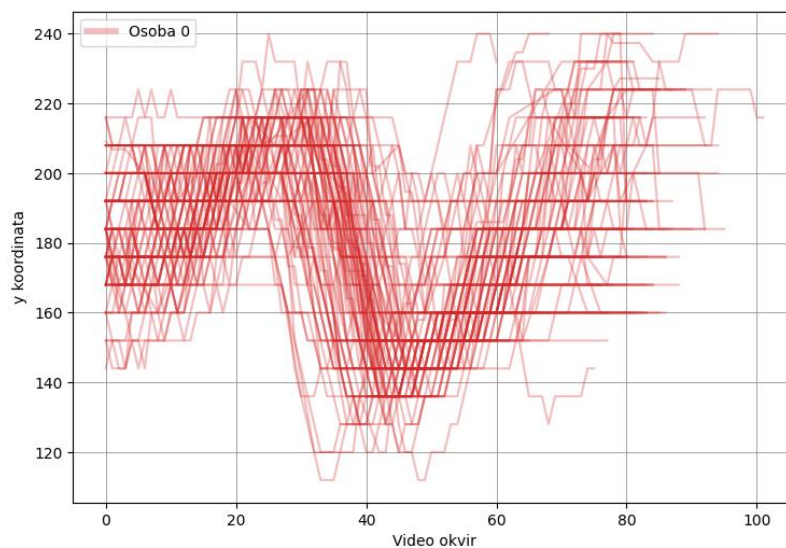
Postupak poravnanja grafova proveli smo na temelju minimalne vrijednosti y koordinate desnog zapešća u svakom videozapisu. S obzirom na to da nas najviše zanimaju video okviri oko same minimalne vrijednosti, odnosno samo dio videozapisa u kojem se izvodi srž pokreta, uzimamo 30 video okvira prije, odnosno poslije, video okvira s minimalnom vrijednosti y koordinate. Te vrijednosti ulaze u algoritam poravnanja podataka te koristeći proces dinamičkog vremenskog poravnanja dobivamo nove vrijednosti y koordinate desnog zapešća svakog videozapisa.

Jednaki algoritam provodimo i za videozapise osobe 0. S obzirom na to da pokret osobe 0 nije uvijek identičan, vrijednosti je malo teže poravnati. To vidimo po grafu kretanja prosječne udaljenosti za svaki videozapis osobe 0, prikazan na (Sl. 4.7).




Sl. 4.7 Graf kretanja prosječne udaljenosti za osobu 0

Međutim koristeći videozapis s rednim brojem 29, dobivamo donekle poravnate grafove, prikazane na (Sl. 4.8). Usporedivši dobivene vrijednosti s vrijednostima prije poravnanja prikazanim na (Sl. 4.2), vidimo znatno uočljiviji obrazac.

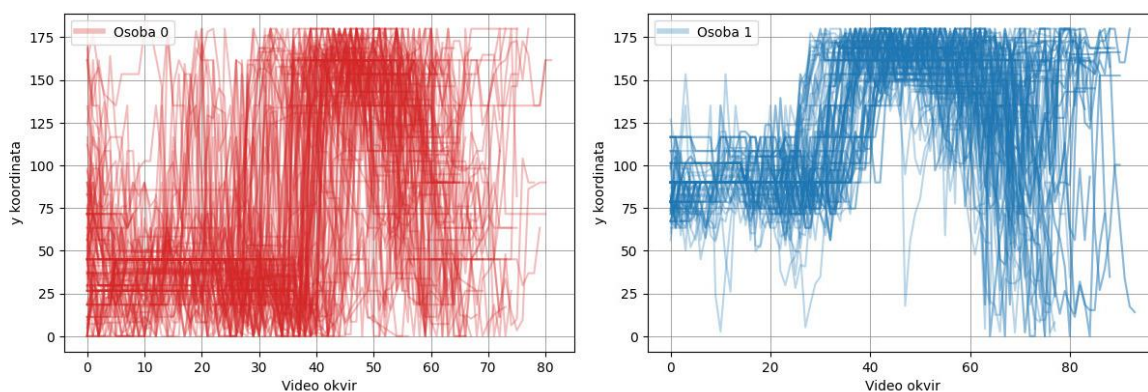


Sl. 4.8 Promjena y koordinate desnog zapešća svih videozapisa osobe 0 nakon poravnavanja

Kako ne bismo provjeravali ispravnosti poravnavanja podataka samo na osnovu vrijednosti y koordinate desnog zapešća, možemo provjeriti ispravnost usporedivši vrijednosti nekih drugih značajki tablice, poput kuta desnog lakta, kao što je prikazano na (Sl. 4.9) te (Sl. Sl. 4.10).



Sl. 4.9 Promjena kuta desnog lakta svih videozapisa prije poravnavanja



Sl. 4.10 Promjena kuta desnog lakta svih videozapisa poslije poravnavanja

Pokazali smo kako možemo poravnati vrijednosti y koordinate desnog zapešća, no mi u našoj tablici imamo mnoge druge stupce. Naravno, vrijednosti njih svih želimo poravnati. Stoga provodimo cjelokupni proces, biramo referentni videozapis te iterativno prolazimo kroz svaki stupac te provodimo postupak dinamičkog vremenskog poravnavanja za njegove vrijednosti. To naravno radimo za vrijednosti obje grupe, odnosno obje osobe.

Jedan od problema koji nastaje, jest činjenica da ne dobivamo jednak broj vrijednosti za svaki stupac. Kao što smo već spomenuli, proces dinamičkog vremenskog poravnavanja mijenja broj vrijednosti, smanjujući podatke brisanjem ili povećavajući ih interpolacijom. Time, za različite stupce, dobivamo različit broj redaka te kada stupce idemo spojiti u tablicu to naravno ne možemo napraviti. Primjerice, videozapis pod rednim brojem 1 ima 102 video okvira. Kada mu poravnamo vrijednosti y koordinate desnog zapešća, broj video okvira se smanji na 94. Kada mu poravnamo vrijednosti kuta desnog lakta, broj video okvira se smanji na 86. Kad bismo ta dva stupca dodali u tablicu, videozapis bi imao za jedne vrijednosti 94 retka, a za druge 86 redaka. To naravno nije moguće.

Jedna opcija bi bila da ostatak redaka ispunimo nedostajućim (*engl. NaN*) vrijednostima. S obzirom na to da želimo za svaki video okvir imati sve te da predikcijski model ne može obrađivati vrijednosti koje sadrže nan vrijednosti, odbacujemo tu mogućnost.

Druga opcija je da od svih stupaca koje želimo dodati, uzmemo onaj s najmanjim brojem redaka te sve ostale stupce skratimo na tu veličinu. Time gubimo određeni broj informacija, čak i više nego bismo li s prvom opcijom, međutim glavni dio pokreta obavlja se na početku, s obzirom na to da smo se fokusirali na sami srž pokreta, odnosno 30 video okvira prije te 30 video okvira poslije trenutka kada je ruka u najvišem položaju. S obzirom na to da je u


tom trenutku najvažniji dio pokreta završen, gubitkom nekolicine video okvira nakon, ne gubimo previše.

5. Analiza pokreta

U ovom poglavlju detaljno ćemo analizirati razliku u izvedbi pokreta između osobe koja je pravilno izvodila pokret slobodnog bacanja te osobe koja je taj isti pokret izvodila nepravilno. Cilj nije samo klasificirati pokret kao pravilan ili nepravilan, već i razumjeti temeljne uzroke koji dovode do nepravilne izvedbe. Tako ćemo steći dublji uvid u tehničke aspekte analiziranog pokreta.


5.1. Desno zapešće

Prvi aspekt koji ćemo analizirati jest kretanje desnog zapešća. Iz (Sl. 4.1) te (Sl. 4.2) ne možemo puno zaključiti o razlikama u grafovima, stoga iz svakog grafa izračunavamo medijan vrijednosti svakog video okvira, kao što je prikazano (Sl. 5.1).



Sl. 5.1 Medijani y koordinate desnog zapešća osobe 0 i osobe 1


Prvo što uočavamo je značajna razlika u početnim vrijednostima y koordinata između dvije osobe. Osoba 1 započinje pokret s višim y koordinatama, dok osoba 0 isti taj pokret započinje s nižim vrijednostima. Ove vrijednosti sugeriraju da osoba 1 na slici drži ruke u nižem položaju prilikom pripreme za pokret u usporedbi s osobom 0. Tu razliku možemo dodatno prikazati uspoređujući položaj desnog zapešća svake osobe s položajem desnog kuka, kao što je prikazano na (Sl. 5.2).



Sl. 5.2 Razlika y koordinate desnog kuka i desnog zapešća svih videozapisa


S obzirom na to da računamo razliku između y koordinata kuka i zapešća, pozitivne vrijednosti ukazuju na to da je vrijednost y koordinate zapešća manja od kuka, što znači da je pozicija zapešća na slici niža u odnosu na kuk. Razlike u vrijednostima osobe 0 su pozitivne, i to s vrlo velikim vrijednostima, dok su razlike osobe 1 gotovo sve negativne.

Također uočavamo veliku razliku u promjenama između najniže i najviše vrijednosti prije nje, kao što je prikazano grafom na (Sl. 5.3). Kod osobe 1, promjena je znatno veća, odnosno kretanje zapešća je mnogo izraženije što ukazuje na veću amplitudu pokreta ruke. S druge strane, vrijednosti y koordinate osobe 0 imaju manju promjenu što sugerira da je položaj zapešća više statičan, odnosno osoba ima ograničeniji i manje dinamičan raspon pokreta.



Sl. 5.3 Promjene najniže i najviše vrijednosti y koordinate desnog zapešća


Na temelju prikazanih grafova možemo zaključiti da se pravilno izveden pokret karakterizira početnim položajem desne ruke u razini kukova. Ruka se zatim kontrolirano podiže iznad glave, dosežući svoj najviši položaj. Analizirajući vrijednosti y koordinate lijevog zapešća dobivamo slične rezultate, prikazane na (Sl. 5.4).



Sl. 5.4 Promjene najniže i najviše vrijednosti y koordinate lijevog zapešća

5.2. Desni lakat

Nastavljajući analizirati položaj desne ruke kroz pokret izvođenja slobodnog bacanja, sada pobliže analiziramo kretnju desnog lakta.



Sl. 5.5 Medijani kuta desnog lakta osobe 0 i osobe 1


Gledajući graf promjene kuta desnog lakta, prikazan na (Sl. 5.5), uočavamo nekoliko ključnih razlika između ispravnog i neispravnog izvođenja pokreta. U početnim video okvirima, vrijednost kuta kod osobe 1 je oko 90 stupnjeva. Ove vrijednosti su konzistentne, što ukazuje na stabilan početni položaj ruke. Kut zatim kontrolirano raste, a oko video okvira 40 doseže maksimalnu vrijednost, što je trenutak kada lopta napušta ruku, završavajući pokret. S druge strane, osoba 0 drži ruku pod znatno manjim kutom tijekom pripreme za šut, približno upola manjim od ispravnog kuta. Kada se pokret započne, kut odjednom naglo raste, mnogo brže nego kod osobe 1, što ukazuje na manjak kontrole i preciznosti u izvedbi pokreta. Te razlike možemo i učiti na (Sl. 5.6)



Sl. 5.6 Faza pripreme izvođenja pokreta

5.3. Lijevo rame

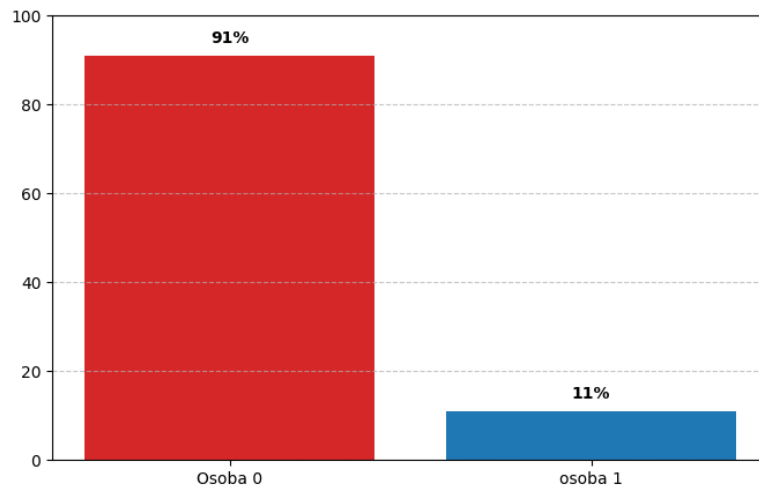
Sada ćemo malo pobliže analizirati pokrete lijeve ruke. Promatrajući medijane kuta lijevog ramena obaju osoba, kut između lakta, ramena te kuka, prikazane na slici (Sl. 5.7), možemo donijeti određene zaključke o položaju lijeve ruke tijekom izvođenja pokreta.



Sl. 5.7 Medijani kuta lijevog ramena osobe 0 i osobe 1

Kao i kod kuta desnog lakta, prvo što uočavamo jest velika razlika početnih vrijednosti. Mala vrijednost kuta osobe 1, označava da je njena ruka uz tijelo. S druge strane osoba 0, ima velik kut što označava da joj lijevi lakat strši previše ustranu, kao što možemo vidjeti na slici

(Sl. 5.6). Također, uočavamo različit smjer rasta prvih 20-ak video okvira. Kut osobe 1 započinje s nižim vrijednostima te zatim kontinuirano raste, dok s druge strane kut osobe 0, prvih nekoliko video okvira opada, da bih tek onda naglo narastao i to na vrijednosti mnogo veće nego one od osobe 1. Razliku u početnom položaju osoba, vidimo i na (Sl. 5.8), koja uspoređuje postotak videozapisa kojima kut ne pada ispod 45 stupnjeva u prvih 10 video okvira. Kod osobe 0, gotovo svaki video, njih 91 %, ima vrijednost kuta iznad 45 stupnjeva.



Sl. 5.8 Postotak videozapisa kojima kut ne pada ispod 45 stupnjeva u prvih 10 video okvira

Osoba 1 završava pokret s kutom ramena od 90 stupnjeva te ga zadržava nekoliko trenutaka, kao što možemo vidjeti po ravnoj liniji dijela grafa oko video okvira 40 te na (Sl. 5.9), gdje nakon završenog pokreta ruka ostaje pod kutom nekoliko video okvira. Osoba 0 pokret završava s kutom od oko 120, odnosno mnogo više ispruženom rukom. Uloga lijeve ruke, kod izvođenja šuta slobodnog bacanja jest osigurati kontrolu i stabilnost tijekom pokreta. Zbog toga su pokreti osobe 0, uobičajeno slabije koordinirani i kaotičniji.



Sl. 5.9 Završni dio pokreta osobe 1

Analizirajući pokrete gornjeg dijela tijela u prethodna tri potpoglavlja, došli smo do nekoliko ključnih zaključaka za pravilno izvođenje pokreta. Na početku pokreta, ruke treba držati u razini kukova, usko uz tijelo. Zatim ih polagano podizati do razine iznad glave. Desni lakat bi trebao biti savijen pod kutom od oko 90 stupnjeva, koji se zatim postupno povećava. Lijeva ruka igra ključnu ulogu u održavanju stabilnosti pokreta, te nakon šuta ostaje pod kutom od 90 stupnjeva, sličnim kao i lijevi lakat. Ova precizna koordinacija između položaja i kretanja ruku osigurava pravilnu tehniku i povećava učinkovitost izvođenja pokreta. Jasno definirane faze pokreta, od početnog položaja ruku do završne pozicije nakon šuta, omogućuju kontrolu i stabilnost, što je ključno za postizanje dosljednih rezultata. Kao što smo zaključili, jedan od problema koji smo uočili u podacima osobe 0 su nagle promjene vrijednosti, bilo promjene kuta ili pozicije ključne točke.


5.4. Lijevi kuk

Sada ćemo pobliže analizirati položaj trupa kod izvođenja pokreta. Analizirajući položaje tijela osoba prije šuta, prikazane na (Sl. 5.10), uočavamo da su obje osobe blago nagnute unaprijed.



Sl. 5.10 Faza pripreme izvođenja pokreta


Graf medijana kuta jednog od kukova, primjerice lijevog kuka prikazanog na (Sl. 5.11), nam pruža malo bolji uvid u situaciju. Osoba 1 se malo više saginje u struku, dosežući minimalnu vrijednost kuka od oko 120 stupnjeva, dok osoba 0 doseže vrijednost od oko 140 stupnjeva.



Sl. 5.11 Medijani kuta desnog kuka osobe 0 i osobe 1

Međutim, razlika od 20 stupnjeva nije toliko značajna, posebno kada se graf prikaže na drugačiji način, na primjer od 0 do 180 stupnjeva, prikazan na (Sl. 5.12). Ovakav način prikaza može relativizirati razlike između kutova, čineći ih manje očiglednim i ukazujući da je razlika u nagibu između dva grafa manja nego što bi se na prvi pogled moglo činiti. Još

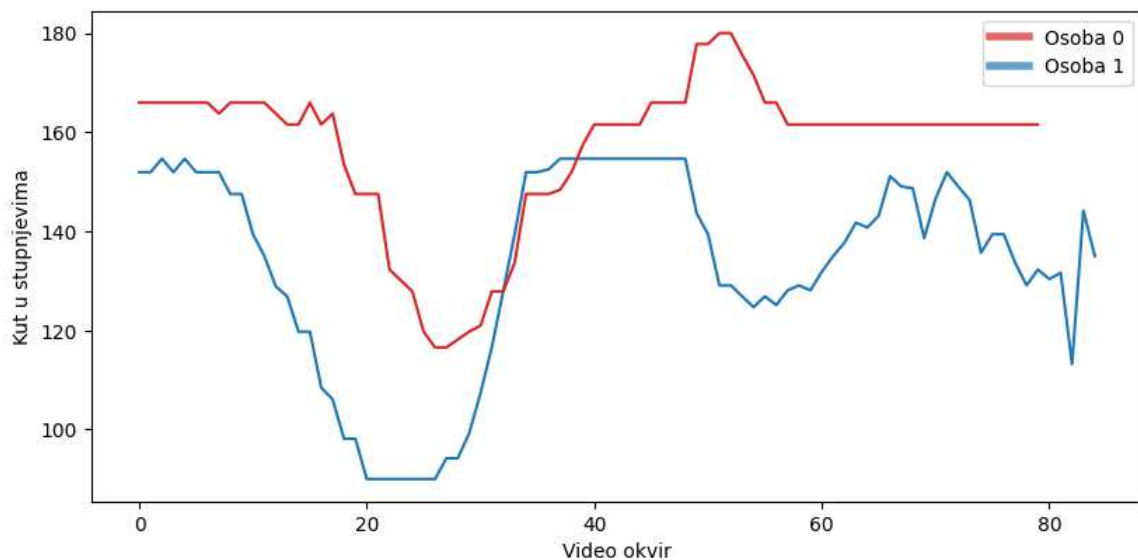
jedna uočljiva razlika je ta da osoba 1 pokazuje nešto veću promjenu kuta, što sugerira dodatno angažiranje kukova prilikom šuta.



Sl. 5.12 Relativni medijani kuta desnog kuka osobe 0 i osobe 1

5.5. Kut koljena

Nakon ruku i trupa, sada ćemo analizirati donji dio tijela. Fokusirat ćemo se na kut koljena, konkretnije kut između zgloba, koljena i kuka osobe. Na grafu promjene kuta lijevog koljena, prikazanom na (Sl. 5.13), uočavamo sličnu situaciju kao i s ostalim ključnim točkama.



Sl. 5.13 Medijani kuta lijevog koljena osobe 0 i osobe 1

Kut osobe 1 doseže znatno manju vrijednost, što ukazuje na dublji pokret čučanja. Zatim kut naglo raste, pokazujući kako se osoba brzo ispravlja dok obavlja pokret šuta. S druge strane, osoba 0 ima manju amplitudu promjene kuta, što pokazuje da se manje saginje i ima manju fleksibilnost prilikom izvođenja pokreta. Ova razlika u amplitudi također može utjecati na snagu i kontrolu šuta, budući da veće savijanje omogućuje bolju pripremu i eksplozivnost prilikom ispravljanja donjeg dijela tijela.


6. Klasifikacija pokreta

Dosad smo prikazali detaljnu analizu ispravnog pokreta šuta slobodnog bacanja. Sada ćemo se usmjeriti na primjenu metoda strojnog učenja. Cilj nam je izraditi model koji će klasificirati ispravnost pokreta na temelju video zapisa, a potom i klasifikaciju uspješnosti šuta. Za treniranje modela odabrali smo XGBoost.

XGBoost, (engl. *Extreme Gradient Boosting*), jedan je od najpopularnijih i najsnažnijih alata u području strojnog učenja. Razvijen od strane Tianqi Chena i suradnika [6], XGBoost je ubrzo postao standardni alat za mnoge zadatke strojnog učenja, zahvaljujući svojoj izuzetnoj učinkovitosti, brzini i točnosti.

Postoji nekoliko ključnih značajki koje XGBoost čine drugačijim i moćnijim u usporedbi s drugim algoritmima za pojačavanje gradijenta [7]:

- XGBoost koristi napredne tehnike regularizacije kako bi spriječio prekomjerno prilagođavanje modela. To uključuje L1 i L2 regularizaciju koje održavaju balans između složenosti modela i njegove sposobnosti generalizacije na nove podatke
- Tehnika Proporcionalnog Smanjivanja Lisnih Čvorova pomaže u sprječavanju prekomjernog rasta stabala i poboljšava točnost predikcija.
- XGBoost implementira Newtonovo pojačanje koje koristi druge redne derivate u procesu optimizacije, što rezultira bržom i preciznijom konvergencijom.
- Uvođenje randomizacije u postupak treniranja modela pomaže u smanjenju varijance i poboljšava robusnost modela. To uključuje nasumično uzorkovanje podataka i značajki, što rezultira različitim varijantama stabala.



Sl. 6.1 Promjena y koordinate desnog zapešća osobe 0 i osobe 1

Prvi korak koji moramo napraviti jest pripremiti podatke za ulaz u model. Trenutno imamo videozapise različitih duljina, odnosno različitog broja video okvira. Kako bismo sve videozapise postavili na isti broj video okvira, potrebno je izabrati određeni trenutak u svakom videu koji ćemo koristiti kao referentnu točku. Najlogičniji trenutak za izabrati bio bi video okvir u kojem lopta napušta ruke osobe koja izvodi pokret. U našim podacima taj video okvir ćemo najjednostavnije pronaći tražeći najmanju vrijednost y koordinate desnog zapešća za svaki videozapis. Na (Sl. 6.1). vidimo da je najmanja vrijednost y koordinate desnog zapešća za osobu 0 u video okviru 54, dok je najmanja vrijednost za osobu 1 u video okviru 62.

Ako pogledamo ta dva video okvira prikazana na (Sl. 6.2), vidimo da lopta zaista napušta ruku upravo u tim trenucima.



Sl. 6.2 Faza završetka izvođenja pokreta

S obzirom na to da lopta napušta ruku, pokret smatramo završenim te taj video okvir označavamo kao zadnji video okvir pokreta. Provodimo postupak stvaranja nove tablice tako da iterativno za svaki videozapis tražimo navedeni, zadnji video okvir te u novu tablicu dodajemo podatke tog video okvira kao i podatke prethodnih 14 video okvira. Tako stvaramo novu tablicu u kojoj svaki videozapis ima jednak broj video okvira, odnosno 15 najbitnijih video okvira našeg pokreta.

Nova tablica, nažalost, još nije spremna za ulaz u model. Budući da radimo klasifikaciju videozapisa, a ne zasebno svakog video okvira, ulaz mora biti cijeli video. To možemo ostvariti tako da "izravnamo" tablicu. Svaki od 15 redaka videa pretvorit ćemo u jedan redak s 15 puta više stupaca. Naša tablica trenutno ima stupce za x i y koordinate svake ključne točke, kao i kutove lakta, ramena, kukova i koljena obje strane tijela, ukupno 38 stupaca. Međutim, budući da obavljamo klasifikaciju dviju različitih osoba, ne možemo koristiti x i y koordinate, s obzirom na to da su osobe različitih dimenzija, a time se i podaci koordinata bitno razlikuju. Međutim ta razlika ne smije utjecati na odluku modela. Stoga za naš model razmatramo samo značajke kutova. Budući da imamo 214 videozapisa, a svaki ima 15 video okvira, nova tablica će imati 214 redaka i 120 stupaca.

Sada kada imamo pripremljene podatke, vrijeme je za klasifikaciju ispravnosti pokreta. Ulaz u model je jedan redak iz naše tablice, a izlaz je 0 ako je pokret neispravan i 1 ako je pokret ispravan.

U prvoj iteraciji treniranja modela, koristimo iduće parametre:

- `max_depth`: 8
- `eta`: 0.2
- `gamma`: 0
- `min_child_weight`: 1
- `subsample`: 1
- `colsample_bytree`: 1

Trenirajući model sa zadanim hiperparametrima, dobili smo sljedeće rezultate:

- Specifičnost (engl. *specificity*): 0.9205
- Odziv (engl. *recall*): 0.9554
- Točnost (engl. *accuracy*): 0.94
- F₁-mjera (engl. *F₁-score*): 0.9469

Vidimo da su rezultati vrlo visoki, ali još uvijek postoji prostor za poboljšanje.

6.1. Izbor hiperparametara

Za optimalno treniranje modela, potrebno je pažljivo odabrati hiperparametre koji će omogućiti najbolju izvedbu. Proces izbora hiperparametara započinjemo definiranjem raspona mogućih vrijednosti za svaki hiperparametar. U našem slučaju, definirali smo različite vrijednosti za parametre:

- `max_depth`: 4, 8, 12
- `eta`: 0.01, 0.1, 0.2
- `gamma`: 0, 0.1, 0.2
- `min_child_weight`: 1, 3, 5
- `subsample`: 0.6, 0.8, 1.0
- `colsample_bytree`: 0.6, 0.8, 1.0

Kako bismo istražili sve moguće kombinacije zadanih vrijednosti, iterativno odabirali kombinacije hiperparametara. Takav pristup osigurava da svaka kombinacija bude

evaluirana, čime povećavamo šansu za pronalazak optimalnih vrijednosti. Evaluacija svake kombinacije hiperparametara provodimo tako što pokušavamo maksimizirati metriku F_1 -mjera. Svaka kombinacija hiperparametara je evaluirana, a najbolja kombinacija koja je postigla najviše vrijednosti za F_1 -mjeru je pohranjena kao optimalna. Ovaj pristup iscrpne pretrage hiperparametara omogućuje nam da pronađemo najbolje postavke za naš model, što je ključno za postizanje visoke točnosti i performansi prilikom klasifikacije ispravnosti pokreta.

Nakon provedenog postupka iscrpne pretrage hiperparametara, najbolje vrijednosti koje smo dobili za naš model XGBoost su sljedeće:

- `max_depth`: 12
- `eta`: 0.1
- `gamma`: 0.1
- `min_child_weight`: 1
- `subsample`: 0.6
- `colsample_bytree`: 0.6

Primjenom ovih hiperparametara na naš model, dobivamo poboljšanje rezultata. Konkretno, postigli smo sljedeće vrijednosti evaluacijskih metrika:

- Specifičnost: 0.9432
- Odziv: 0.9554
- Točnost: 0.95
- F_1 -mjera: 0.9554

Ovi rezultati pokazuju značajan napredak, posebno za evaluacijsku metriku specifičnost. Povećanje specifičnosti ukazuje na bolju sposobnost modela da ispravno klasificira negativne primjere, odnosno slučajeve gdje je pokret slobodnog bacanja označen kao neispravan. To je ključno za naš projekt jer želimo osigurati da model može precizno razlikovati ispravne od neispravnih pokreta, minimizirajući lažno pozitivne klasifikacije. Ovaj napredak specifičnosti znači da naš model sada učinkovitije prepoznaje i klasificira neispravne pokrete, što je od velike važnosti za osiguranje kvalitete i točnosti naših rezultata. Povećanje ukupne točnosti s 94 % na 95 % dodatno potvrđuje da smo uspjeli poboljšati model i postići još malo višu razinu performansi.


6.2. Izbor značajki

Naš model trenutno koristi svih 120 stupaca tablice, odnosno značajki, za treniranje. Međutim, nemaju sve značajke jednaki doprinosi točnosti modela. Stoga, potrebno je obaviti postupak identificiranja najvažnijih značajki koje najviše doprinose performansama našeg modela. Ovaj proces omogućit će nam optimizaciju modela, smanjenje složenosti i potencijalno poboljšanje točnosti predikcija.

Za izbor značajki koje će se koristiti u našem modelu, primijenili smo metodu odabira najboljih značajki na temelju statističke analize. Prvi korak u ovom procesu je izdvajanje značajki i ciljne varijable iz našeg skupa podataka. S obzirom na veliki broj značajki koje imamo na raspolaganju, ključno je standardizirati podatke kako bismo osigurali da svaka značajka ima jednak utjecaj na model.

Nakon standardizacije podataka, koristimo tehniku odabira najboljih značajki na temelju ANOVA F-testa. Ova metoda omogućava nam da identificiramo značajke koje su najviše povezane s ciljnom varijablom, odnosno ispravnost pokreta.

Da bismo odredili optimalan broj značajki, postupamo iterativno istražujući različite brojeve značajki. Počinjemo s jednom najboljom značajkom i zatim u svakoj iteraciji dodajemo sljedeću najbolju značajku. Tijekom svake iteracije analiziramo performanse modela kako bismo dobili najbolji mogući skup značajki. U svakoj iteraciji, izračunavamo točnost modela na temelju odabranih značajki te bilježimo koje kombinacije značajki daju najbolje rezultate. Proces promjene F_1 -mjere kroz iteracije prikazan je na (Sl. 6.3).



Sl. 6.3 Promjene F_1 -mjere kroz iteracije

Nakon temeljite analize, identificirali smo skup značajki koji daje optimalne performanse modela. Iz (Sl. 6.3) vidljivo je da je najoptimalnije broj značajki 59, 60, 61 te 73. S obzirom na to da manji broj značajki nam smanjuje kompleksnost modela, odabiremo 59 najboljih značajki. Konačan broj odabranih značajki temelji se na njihovom doprinosu ukupnoj točnosti modela, kao i na njihovoj važnosti izračunatoj pomoću ANOVA F-testa. Ovaj pristup omogućio nam je da iz skupa podataka izdvojimo one značajke koje najviše doprinose ispravnoj klasifikaciji pokreta, čime smo poboljšali učinkovitost i točnost našeg modela.

Primjenom samo izabranih značajki na naš model, dobivamo poboljšanje rezultata. Konkretno, postigli smo sljedeće vrijednosti evaluacijskih metrika:

- Specifičnost: 0.9545
- Odziv: 0.9554
- Točnost: 0.955
- F_1 -mjera: 0.9597

Ovi rezultati, kao i kod odabira najboljih hiperparametara, pokazuju napredak za evaluacijsku metriku specifičnost. Naš model sada još malo učinkovitije prepoznaje i klasificira neispravne pokrete.

Sada ćemo detaljnije analizirati 59 odabranih značajki. Promotrimo li 10 značajki s najvećim ANOVA F-vrijednostima vidimo da se skup sastoji od značajki kutova koljena te kukova, specifično u prvih nekoliko video okvira.

Tablica 6.1 10 značajki s najvećim ANOVA F-vrijednostima

Redni br.	Ime značajke	ANOVA F-vrijednost
1.	right_knee_angle_4	154.57064891
2.	right_knee_angle_3	151.83847509
3.	left_knee_angle_1	142.31742179
4.	left_hip_angle_15	138.34935471
5.	right_knee_angle_2	119.76942492
6.	left_knee_angle_2	118.55006242

7.	right_knee_angle_1	110.93516423
8.	right_knee_angle_5	99.12792851
9.	left_knee_angle_3	92.36736961
10.	left_hip_angle_14	89.15432247

Iz (Tablica 6.1) možemo zaključiti da se značajna razlika između klasa očituje u fazi pripreme za šut, posebno u položajima donjeg dijela tijela osobe.

Tablica 6.2 Broj odabranih video okvira svake značajke

Redni br.	Ime značajke	Broj pojavljivanja
1.	left_shoulder_angle	15
2.	left_knee_angle	14
3.	right_knee_angle	8
4.	right_elbow_angle	8
5.	left_elbow_angle	6
6.	left_hip_angle	4
7.	right_shoulder_angle	4
8.	right_hip_angle	0

S druge strane promotrimo li koliko video okvira svake značajke je odabrano, kao što je prikazano u (Tablica 6.2), uočavamo da je vrijednost kuta lijevog ramena od velike važnosti tijekom cijelog pokreta. Iz toga zaključujemo da se kut lijevog ramena između klasa drastično razlikuje tijekom cijelog pokreta, što smo već dijelom analizirali u prethodnom poglavlju.

Također uočavamo neznan značaj vrijednosti kuta kukova. Značajka kuta lijevog kuka izabrana je u samo 4 video okvira, dok se značajka kuta desnog kuka ne pojavljuje nijednom.

Zaključak

U ovom radu bavili smo se detaljnom analizom ispravnosti pokreta šuta slobodnog bacanja u košarci. Objasnili smo osnove modela za procjenu položaja tijela te proces dobivanja podataka o koordinatama ključnih točaka tijela iz videozapisa. Detaljno smo opisali obradu podataka kako bismo ih pripremili za analizu, uključujući ispravljanje stršćih vrijednosti i popunjavanje nedostajućih podataka.

Jedan od važnijih koraka bio je izravnavanje podataka, odnosno prilagođavanje svih videozapisa na isti broj video okvira. Time smo osigurali konzistentnost podataka, što je bilo ključno za daljnju analizu i kasnije treniranje modela. Također, proveli smo detaljnu analizu pojedinačnih dijelova tijela tijekom pokreta, uspoređujući razlike između ispravnih i neispravnih pokreta. Na temelju te analize, identificirali smo najbitnije značajke koje utječu na kvalitetu šuta, što je bilo ključno za poboljšanje performansi našeg modela. Razmatranjem tih ključnih značajki tijela, kao što su kutovi kukova, koljena i laktova, mogli smo identificirati obrasce koji razlikuju ispravan pokret od neispravnog.

Na kraju, izgradili smo model za klasifikaciju ispravnosti pokreta slobodnog bacanja. Kroz iterativni proces optimizacije, pronašli smo najbolje hiperparametre za naš model, čime smo dodatno povećali već visoku točnost klasifikacije. Proces optimizacije uključivao je testiranje različitih kombinacija parametara kako bismo pronašli one koje pružaju najbolje rezultate. Također smo proveli proces odabira najvažnijih značajki, što je dodatno poboljšalo performanse modela te nam omogućilo bolji uvid u analizu ispravnosti pokreta.

Naš rad pokazuje kako se kombinacijom temeljite analize podataka i naprednih metoda strojnog učenja može postići visoka točnost u klasifikaciji složenih pokreta poput šuta slobodnog bacanja u košarci.

Sažetak

Ovaj rad bavi se detaljnom analizom ispravnosti pokreta šuta slobodnog bacanja u košarci. Objasnjava osnove modela za procjenu položaja tijela te proces dobivanja podataka o koordinatama ključnih točaka tijela iz videozapisa. Opisuje proces prilagođavanja videozapisa na isti broj okvira te detaljnu analizu ključnih dijelova tijela, pri čemu identificira najbitnije značajke koje utječu na kvalitetu šuta. Opisuje model za klasifikaciju ispravnosti pokreta slobodnog bacanja koristeći optimizirane hiperparametre i odabrane značajke. Rad pokazuje kako kombinacija temeljite analize podataka i naprednih metoda strojnog učenja može postići visoku točnost u klasifikaciji složenih pokreta u sportu.

Summary

This paper deals with a detailed analysis of the correctness of the free throw shot movement in basketball. It explains the basics of the pose estimation model and the process of obtaining data about the coordinates of body key points from a video. It describes the process of adjusting the video to the same number of frames and a detailed analysis of key body parts, identifying the most important features that affect the quality of the shot. Describes a model for classifying free throw motion accuracy using optimized hyperparameters and selected features. The paper shows how a combination of thorough data analysis and advanced machine learning methods can achieve high accuracy in the classification of complex movements in sports.

Literatura

1. Dubey, Shradha & Dixit, Manish. (2022). A comprehensive survey on human pose estimation approaches. *Multimedia Systems*. 29. 10.1007/s00530-022-00980-0.
2. Talaa, Safae & El Fezazi, Mohamed & Jilbab, A. & Alaoui, My. (2023). Computer Vision-Based Approach for Automated Monitoring and Assessment of Gait Rehabilitation at Home. *International Journal of Online and Biomedical Engineering (iJOE)*. 19. 139-157. 10.3991/ijoe.v19i18.43943.
3. A survey of top-down approaches for human pose estimation, Thong Duy Nguyen, Milan Kresovic
4. Basketball Court Size Dimensions and Markings harrod sport
5. The FIBA Official Basketball Rule Changes (Valid as of 1 October 2022). FIBA. May 1, 2022. p.12. Retrieved December 4, 2022. Poveznica: <https://www.fiba.basketball/news/fiba-official-basketball-rules-2022-set-to-come-into-force-october-1>; pristupljeno 4. lipnja 2024
6. Chen, Tianqi; Guestrin, Carlos (2016). "XGBoost: A Scalable Tree Boosting System". In Krishnapuram, Balaji; Shah, Mohak; Smola, Alexander J.; Aggarwal, Charu C.; Shen, Dou; Rastogi, Rajeev (eds.). *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, CA, USA, August 13-17, 2016. ACM.
7. Gandhi, Rohith (2019-05-24). "Gradient Boosting and XGBoost". Medium. Poveznica: <https://medium.com/hackernoon/gradient-boosting-and-xgboost-90862daa6c77>; pristupljeno 12. lipnja 2024