

Savjetovanje pravilnog držanja tijela tijekom bicikliranja primjenom strojnog učenja

Švenda, Lovro

Undergraduate thesis / Završni 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:168:279106>

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

Download date / Datum preuzimanja: **2025-03-29**



Repository / Repozitorij:

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



SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

ZAVRŠNI RAD br. 1581

**SAVJETOVANJE PRAVILNOG DRŽANJA TIJELA TIJEKOM
BICIKLIRANJA PRIMJENOM STROJNOG UČENJA**

Lovro Švenda

Zagreb, lipanj 2024.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

ZAVRŠNI RAD br. 1581

**SAVJETOVANJE PRAVILNOG DRŽANJA TIJELA TIJEKOM
BICIKLIRANJA PRIMJENOM STROJNOG UČENJA**

Lovro Švenda

Zagreb, lipanj 2024.

Zagreb, 4. ožujka 2024.

ZAVRŠNI ZADATAK br. 1581

Pristupnik:	Lovro Švenda (0036541060)
Studij:	Elektrotehnika i informacijska tehnologija i Računarstvo
Modul:	Računarstvo
Mentor:	izv. prof. dr. sc. Vinko Lešić
Zadatak:	Savjetovanje pravilnog držanja tijela tijekom bicikliranja primjenom strojnog učenja

Opis zadatka:

Transport je jedan od najbrže rastućih svjetskih potrošača energije i zagadivača okoliša stakleničkim plinovima. Biciklizam je jedna od izglednih alternativa dnevnih migracija unutar grada te se, kao rekreativska metoda, pozitivno odražava na zdravlje kardiovaskularnog sustava dok ujedno štiti zglobove i jača muskulaturu. U radu je potrebno proučiti literaturu u području identificiranih smjernica za pravilno držanje tijela tijekom bicikliranja uz fokus na određivanje položaja zglobova i određivanja međusobnih kutova različitih dijelova tijela. Potrebno je zatim načiniti algoritam za obradu videosnimaka položaja tijela za vrijeme bicikliranja te na videosnimci putem proširene stvarnosti prikazati položaj zglobova korisnika u odnosu na dane smjernice i preporuke. Kao rezultat kontinuirane usporedbe držanja tijela tijekom bicikliranja, potrebno je davati parametre za preporučeni odabir i podešenje bicikla koristeći klasifikacijske algoritme strojnog učenja.

Rok za predaju rada: 14. lipnja 2024.

Sadržaj

Uvod.....	1
Motivacija	2
1. Strojno učenje	3
1.1. Linearna i logistička regresija	5
1.2. Stabla odluka i ansambli stabala odluka	6
1.3. Umjetne neuronske mreže.....	8
2. Sakupljanje i obrada podataka	11
2.1. Sakupljanje podataka	11
2.2. Obrada podataka	14
3. REZULTATI.....	18
3.1. Regresijski problem	18
3.2. Klasifikacijski problem	22
3.3. Stvarni primjer	23
4. Zaključak.....	26
Literatura.....	27
Sažetak	28
Summary	29

Uvod

Biciklizam je jedna od češćih i razvijenijih sportskih aktivnosti u svijetu. Ljudi se bave biciklizmom u sklopu rekreacije ili se služe njime kao prijevoznim sredstvom. Stoga je vrlo bitno da se na njemu osjećaju udobno i da tijekom bicikliranja ne osjećaju bol. U tom kontekstu, koncept „*bike fittinga*“ postaje sve važniji. *Bike fitting* predstavlja pristup biciklizmu koji se sve više primjenjuju u cilju postizanja optimalne udobnosti i učinkovitosti tijekom vožnje bicikla. Kroz precizno podešavanje geometrije bicikla i položaja vozača, *bike fitting* ima potencijal transformirati iskustvo biciklizma za profesionalce i rekreativce podjednako. Ovaj rad istražuje koncept *bike fittinga* iz perspektive utjecaja na performanse i udobnost vozača. Kroz analizu pozicije vozača otkrit će se kako *bike fitting* može pružiti konkretne koristi te kako može doprinijeti smanjenju rizika od ozljeda i poboljšanju performansi vozača. Ključni aspekti analize uključuju visinu sjedala, kut sjedala, udaljenost volana, visina volana i druge parametre koji utječu na udobnost i učinkovitost biciklista. Osim toga, analiza će omogućiti biciklistima da prilagode svoj bicikl prema vlastitim karakteristikama kao što su visina i građa tijela. Također, kroz ovaj rad istražit će se različiti aspekti *bike fittinga* koji uključuju standardne položaje tijela, tehnike prilagodbe bicikla i potencijalne koristi za bicikliste. Analiza će pružiti korisne smjernice i ukazati na područja koja bi trebalo bolje prilagoditi, kao što su recimo premali ili preveliki kut iza koljena. U nastavku će biti detaljno opisani ključni aspekti analize položaja tijela tijekom bicikliranja te će se opisati način kako ih ugoditi.

Motivacija

Ideja za ovaj rad proizlazi iz uočene potrebe među biciklističkom zajednicom. Prilično česti problemi s kojima se ljudi susreću tijekom bicikliranja su nelagoda i bol u tijelu. Bol se najčešće odnosi na bolove u koljenu ili donjem dijelu leđa. Glavni uzrok i posljedica tih bolova je krivo namještена pozicija tijela na biciklu što dovodi bicikliste da traže stručnu pomoć kao što su usluge *bike fittinga*. S obzirom da takve usluge mogu biti skupocjene i nedostupne većini rekreativnih biciklista, cilj ovog rada je pružiti jednostavno i pristupačno rješenje koje će omogućiti svim biciklistima da prilagode svoj bicikl prema svojim individualnim potrebama i željama. Razvojem ove aplikacije za analizu položaja tijela tijekom bicikliranja želi se osigurati da biciklisti imaju alat za ugađanje bicikla na dohvrat ruke bez potrebe za skupim, profesionalnim uslugama. Cilj aplikacije je omogućiti da svaka osoba može uživati u vožnji na biciklu bez obzira na razinu iskustva ili aktivnosti.

Za izvedbu ovoga rada koristit će se danas dobro poznato strojno učenje. Strojno učenje će omogućiti da na temelju različitih kutova tijela tijekom bicikliranja, korisnici dobiju povratnu informaciju o kvaliteti trenutnog položaja na biciklu. Za predikciju kvalitete položaja na biciklu koriste se algoritmi strojnog učenja kao što su stabla odluke, linearna regresija i umjetne neuronske mreže.

1. Strojno učenje

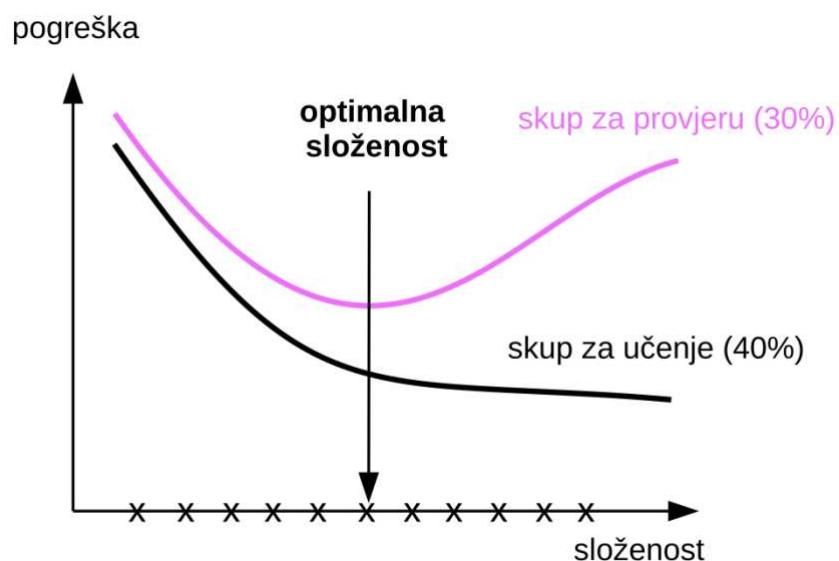
Strojno učenje aktualna je tema u istraživanju i u industriji, a nove se metode kontinuirano pojavljuju i razvijaju. Algoritmi strojnog učenja „uče“ informacije i odnose među njima izravno iz podataka ne oslanjajući se na teorijske jednadžbe i matematičke modele. Zadatak strojnog učenja je pronaći prirodne uzorke i poveznice u podatcima te na temelju toga stići uvid i zatim odlučivati i predviđati [1]. To nije klasično programiranje nekih zadataka, već programiranje računala na način da optimiziraju neki kriterij uspješnosti temeljem podatkovnih primjera ili prethodnog iskustva. Raspolažemo modelom koji je definiran do na neke parametre, a učenje se svodi na izvođenje algoritma koji optimizira parametre modela na temelju podataka ili prethodnog iskustva. Predviđanje se odvija na temelju već viđenih podataka, odnosno model se uči na viđenim podatcima, a mora moći predvidjeti svojstva novih, još neviđenih podataka [4].

Potreba za strojnim učenjem su problemi koji su presloženi da bi ih se riješilo algoritamski kao što je na primjer raspoznavanje govora ili slova u tekstu. Također takvi sustavi imaju ogromne količine podataka (medicina i proizvodnja) i podložni su dinamičkim promjenama (roboti). Danas najrašireniji primjer strojnog učenja je duboko učenje jer omogućava modelu da iskoristi veliku količinu danas široko dostupnih podataka. Duboko učenje, zvano još i neuronske mreže nazvane su po neuronima u ljudskom mozgu zato što imitiraju njihov način rada [4].

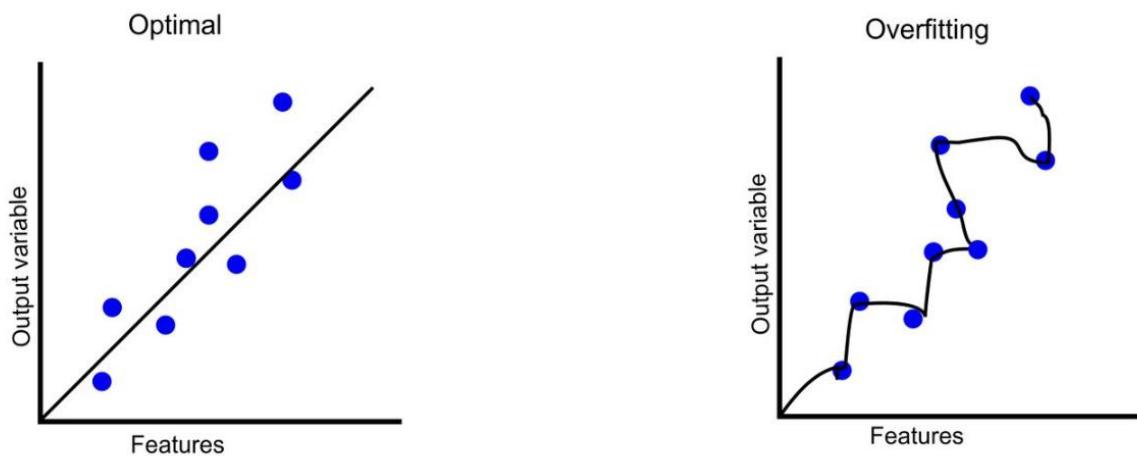
Strojno učenje dijeli se na tri vrste: nadzirano, nenadzirano i podržano strojno učenje. Nadzirano strojno učenje bazira se na podatcima koji imaju definirane ulaze i izlaze, te modeli traže poveznice između tih ulaza i izlaza. Nenadzirano učenje bazira se na podatcima koji imaju definirane samo ulaze bez izlaza te modeli pokušavaju naći pravilnosti među podatcima (npr. svrstavanje u grupe (engl. clustering)), a podržano učenje se bazira na učenju optimalne strategije pomoću negativnog ili pozitivnog nagrađivanja nakon svakog koraka [4].

U ovom radu koriste se samo algoritmi nadziranog strojnog učenja. Nadzirano učenje dijeli se klasifikacijske probleme i regresijske probleme. Klasifikacijski problemi imaju konstantnu/konačnu izlaznu kategoriju kao što su recimo medicinske dijagnostike je li tumor kancerogen ili nije. Regresijski problemi se bave predviđanjem kontinuiranih vrijednosti izlaza kao što su fluktuacije potrošnje električne energije u elektroenergetskom sustavu. Nadzirani model treba najprije trenirati na označenim primjerima, a nakon toga se može koristiti za predikciju na dotad neviđenim primjerima. Tijekom treniranja, model na ulazu dobiva primjere X_{train} i njihove označke Y_{train} , dok prilikom predikcije, model na ulazu dobiva samo

primjere X_test , a na izlazu daje oznake Y_pred koje se zatim uspoređuju s oznakama Y_test te se računa točnost modela. Cilj svakog modela strojnog učenja je da model dobro generalizira odnosno daje točne vrijednosti na svim primjerima X. Česta pojava u strojnem učenju je prenaučenost modela koja se dešava kada je model presložen, odnosno jako dobro naučen na podacima za treniranje, ali daje loše predikcije na neviđenim podacima. Kako ne bi došlo do prenaučenosti, dio podataka iz podataka za treniranje izdvajaju se za testiranje (20%) koji će služiti kao neviđeni podatci za evaluaciju je li naš model dobro generalizira. Osim podataka za testiranje neki modeli koriste i podatke za provjeru kako bi se mogla ugadati složenost modela. U tom slučaju, podatci se dijele na podatke za treniranje, podatke za provjeru, podatke za testiranje u omjerima 60% : 20% : 20%. Cilj strojnog učenja je izgraditi model koji će dobro generalizirati (naći dobru poveznicu između podataka X i Y), ali ga pritom ne prenaučiti. Vjerojatnost pojave prenaučenosti povećava se s povećanjem brojem ulaznih značajki modela, a smanjuje s povećanjem broja primjera odnosno podataka u skupu za treniranje [4]. Slika 1.1 prikazuje graf pogreške modela u ovisnosti o njegovoj složenosti. Iz grafa je vidljivo da na polovici grafa model postaje pretreniran, odnosno jako dobro radi nad podatcima za treniranje, ali slabo generalizira. Slika 1.2 prikazuje kako se ta prenaučenost manifestira nad podatcima. Desni graf loše predviđati primjere koji se ne nalaze točno na toj krivulji, dok će lijevi graf predviđati primjere s malom pogreškom što znači da je vrlo blizu točnog rješenja.



Slika 1.1: Ovisnost pogreške modela o njegovoj složenosti [4]



Slika 1.2: Primjer dobro naučenog i prenaučenog modela [2]

1.1. Linearna i logistička regresija

Linearna i logistička regresija su linearni modeli strojnog učenja koji spadaju u nadzirano učenje. Iako su ova dva modela jedni od najjednostavnijih modela strojnog učenja i dalje su vrlo korisni i moćni. Osim toga, zbog svoje jednostavnosti nisu skloni prenaučenosti kao neki složeniji algoritmi. Linearna regresija koristi se za regresijske probleme odnosno predviđanje kontinuiranih vrijednosti. Cilj linearne regresijske modela je pronaći linearnu ovisnost između ulaznih značajki i ciljnih varijabli. Linearna regresija izražena je formulom (1):

$$(1) \quad y' = w \cdot x + b$$

gdje y' predstavlja ciljnu varijablu, $w \cdot x$ predstavlja skalarni produkt vektora težina i vektora ulaznih značajki, a b predstavlja vektor pristranosti odnosno iskrivljenja. Cilj modela je minimizirati pristranost kako bi mogao što bolje generalizirati nad novim podatcima [6].

Logistička regresija koristi se za klasifikacijske probleme, odnosno predviđanje vjerojatnosti pripadnosti podataka određenoj klasi. Cilj logističkog regresijskog modela je klasificirati ciljnu varijablu kao „da“ ili „ne“, odnosno 1 ili 0. Formula logističke regresije bazira se na takozvanoj sigmoidnoj funkciji izraženoj u formuli (2):

$$(2) \quad \sigma(\alpha) = \frac{1}{1+\exp(-\alpha)}$$

gdje α predstavlja linearu funkciju iz linearne regresije izraženoj u formuli (3):

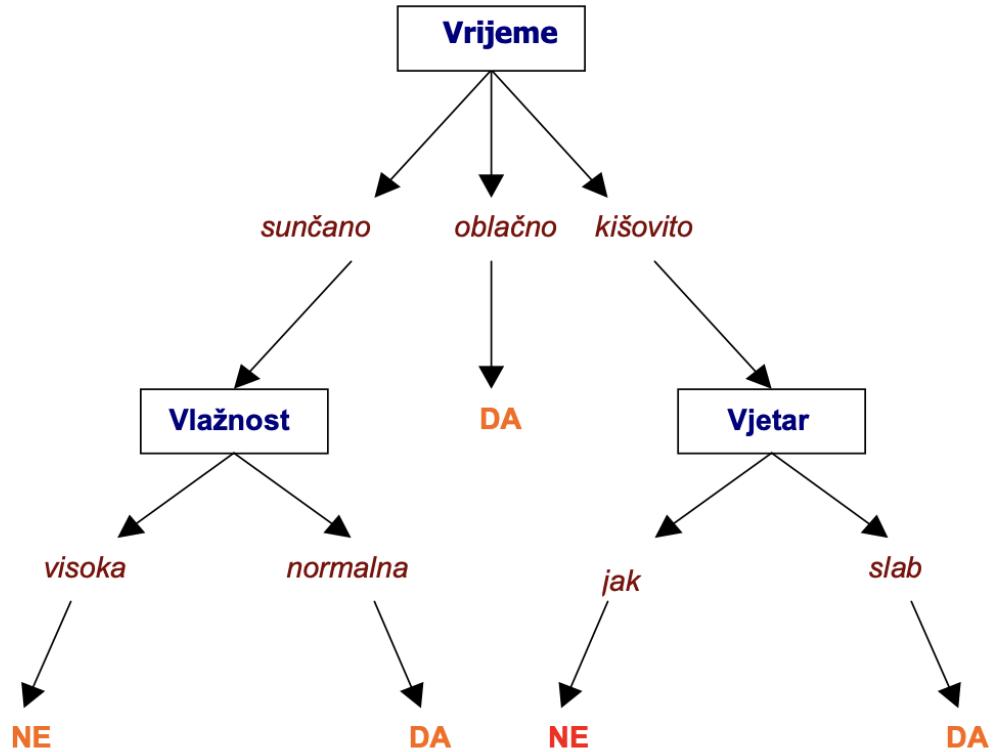
$$(3) \quad f(x) = \frac{1}{1+\exp(-(w \cdot x + b))}$$

[7].

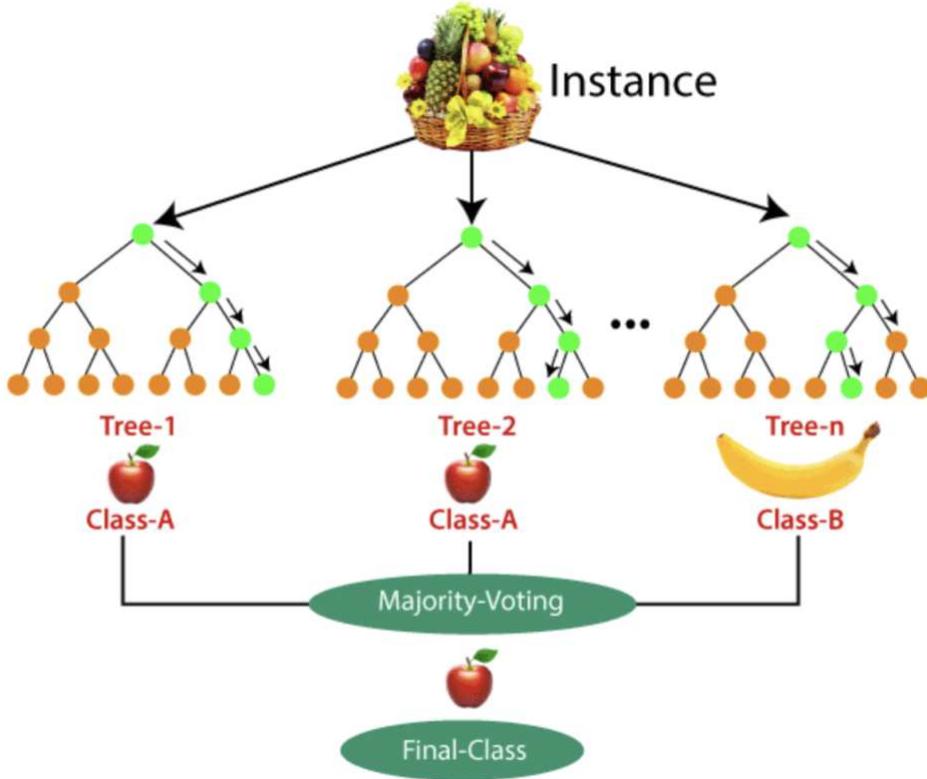
1.2. Stabla odluka i ansamblji stabala odluka

Stabla odluka još su jedan od modela strojnog učenja. Za razliku od linearne i logističke regresije, stabla odluka su kompleksniji algoritmi. Izgrađena su od unutarnjih čvorova koji predstavljaju ulazne značajke modela, grane ispod svakog čvora koje predstavljaju vrijednosti dotične značajke i listova koji određuju povratnu vrijednost (predikciju) modela. Izgradnja stabla radi se pomoću poznatih algoritama kao što su ID3, ASSISTANT, C4.5 itd. Tijekom izgradnje koriste se parametri kao što su entropija i informacijska dobit. Cilj stabla je da minimizira entropiju, a informacijska dobit mu javlja o očekivanom manjenju entropije u sljedećem koraku, što znači da je svakim korakom cilj dobiti što veću informacijsku dobit. Stabla odluka koriste se i za klasifikaciju i regresiju, no imaju problem što se lako mogu prenaučiti [4]. Do prenaučenosti dolazi zbog velikog broja čvorova stabla, stoga se u praksi preferiraju stabla sa što manje čvorova koja i dalje dovoljno dobro generaliziraju. Prenaučenost stabla najčešće se rješava ograničavanjem dubine stabla te podrezivanjem stabla koje funkcionira na principu pada točnosti, odnosno porasta pogreške na skupu primjera za provjeru. Prenaučenost se može reducirati i primjenom ansambla stabala kao što je model slučajne šume [2]. Slučajna šuma je model strojnog učenja koji kombinira više (100 i više) slabijih modela (stabala) kako bi se dobio jedan snažan model koji će raditi bolje predikcije, odnosno bolje generalizirati. U procesu treniranja koriste se različiti uzorci podataka iz originalnog skupa podataka, što znači da svako stablo dobiva svoj podskup za treniranje. U klasifikacijskim zadatcima, svako stablo daje svoj glas za neku klasu, te se konačna klasa određuje većinskom odlukom. U regresijskim problemima, predikcija je prosjek predikcija svih pojedinačnih stabala. Jedini nedostatak ansambla stabala je u brzini izvođenja. Iako je algoritam vrlo točan i otporan na prenaučenost, kompleksan je i može biti računalno intenzivan i spor za treniranje

i predikciju [3]. Primjer stabla odluke dobivenog algoritmom ID3 prikazan je na slici 1.3, dok je primjer modela slučajne šume prikazan na slici 1.4.



Slika 1.3: Primjer stabla odluke dobiven ID3 algoritmom [4]



Slika 1.4: Primjer modela slučajne šume [3]

1.3. Umjetne neuronske mreže

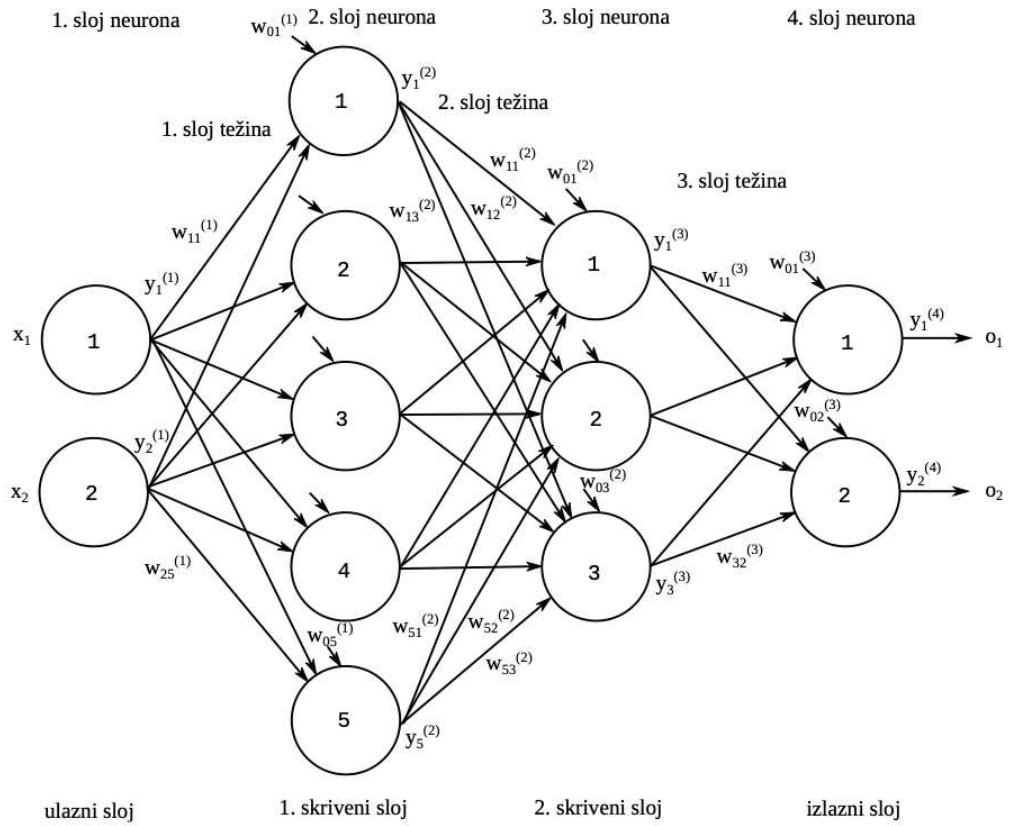
Zadnji model strojnog učenja kojeg se obrađuje u ovome radu su umjetne neuronske mreže. Ideja umjetnih neuronskih mreža analogna je shvaćanju načina rada ljudskog mozga. To podrazumijeva da će se sustav sastojti od puno vrsta različitih neurona i svaki neuron će raditi jednu vrlo jednostavnu obradu nad podatcima koje konstantno dobiva. Umjetna neuronska mreža je skup međusobno povezanih jednostavnih procesnih elemenata (neurona) čija je funkcionalnost inspirirana biološkim neuronom i koji služe distribuiranoj paralelnoj obradi podataka. Takvi neuroni omogućavaju vrlo robusnu obradu podataka, može ih se koristiti i za regresijske i za klasifikacijske probleme te su sposobni učiti iz podataka. Učenje je iterativan postupak predočavanja ulaznih primjera i očekivanog izlaza pri čemu dolazi do postupnog prilagođavanja težina veza između neurona. Jedno predočavanje svih uzoraka naziva se epohom. Učenje/treniranje svrstava se u tri grupe: pojedinačno učenje gdje se učenje događa nakon svakog predočenog uzorka, učenje s minigrupama gdje se učenje događa nakon više predočenih uzoraka i grupno učenje gdje se učenje događa tek nakon svih predočenih uzoraka.

S obzirom da se neuronske mreže može koristiti za sve tri vrste strojnog učenja, one se također mogu svrstati u nadzirane, nenadzirane i podržane neuronske mreže. Umjetna neuronska mreža sastoji se od više slojeva neurona, gdje svaki sloj sadrži proizvoljan broj neurona. Svaki neuron predstavlja prijenosnu funkciju koja može biti linearna funkcija, logistička (sigmoidna) itd. No, kako bi se povećala ekspresivnost neuronske mreže i omogućilo joj modeliranje nelinearnih odnosa, neuroni moraju imati funkcije koje su nelinearne. Danas se za to koristi ReLu funkcija jer je vrlo brza i omogućava treniranje mreža s više slojeva. ReLu funkcija prikazana je formulom (4):

$$(4) \quad ReLu(x) = f(x) = \max(0, x).$$

Postupak na kojem se zasniva treniranje neuronske mreže naziva se postupak propagacije pogreške unazad. Postupak se temelji na učinkovitom izračunu svih parcijalnih derivacija i njihovo primjeni na određivanje iznosa kojim se korigira svaku od težina neurona. Neuronske mreže su vrlo raširen model strojnog učenja, no treba im puno podataka za treniranje kako bi ispravno radile. Neki od primjera problema za koje se koriste neuronske mreže su: raspoznavanje lica, autonomna vozila, robotika, prepoznavanje govora i teksta itd. [\[5\]](#)

Na slici 1.5 prikazana je građa neuronske mreže. Mreža se sastoji od ulaznog i izlaznog sloja te dva skrivena sloja koji mogu imati proizvoljan broj neurona. Prvi skriveni sloj ima 5 neurona dok drugi sloj ima 3 neurona. Ulazni sloj se sastoji od broja neurona koji je jednak broju značajki u podatcima za treniranje. Isto tako izlazni sloj mreže mora imati jednak broj neurona koliko i podatci za treniranje imaju ciljnih varijabli u slučaju da se neuronska mreža koristi za nadzirano učenje. Također svaki neuron sadrži svoj vektor težina koji se množi kao skalarni produkt sa izlaznim rezultatom iz prethodnog neurona. Vektor težina svakog neurona je upravo dio mreže koji se trenira i omogućava točnu predikciju krajnjih varijabli.



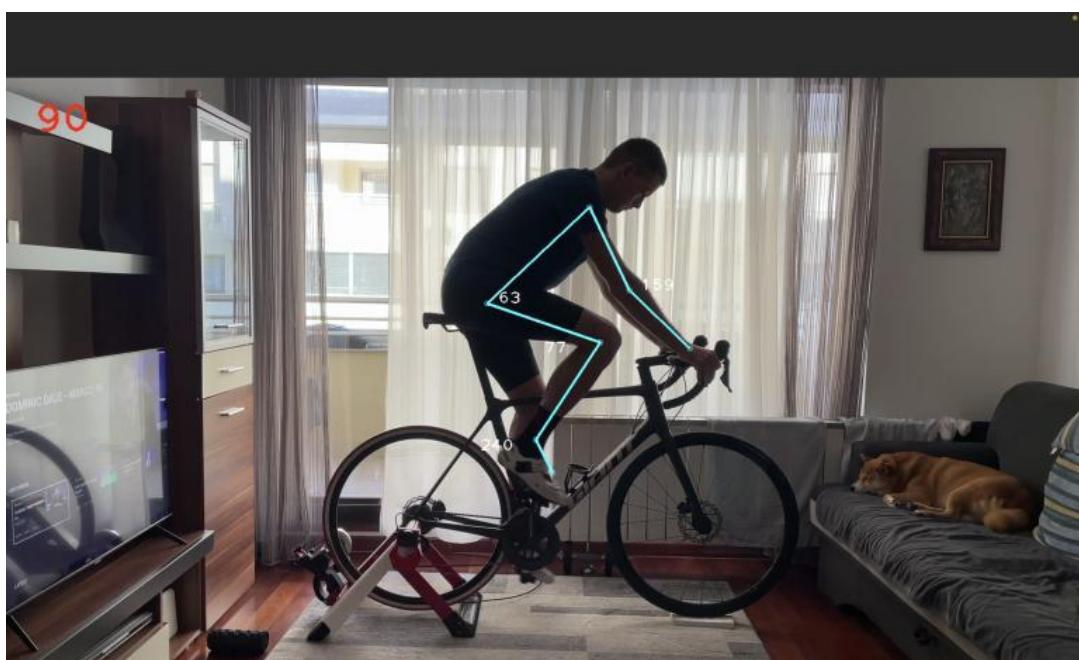
Slika 1.5: Oblik i struktura neuronske mreže [4]

2. Sakupljanje i obrada podataka

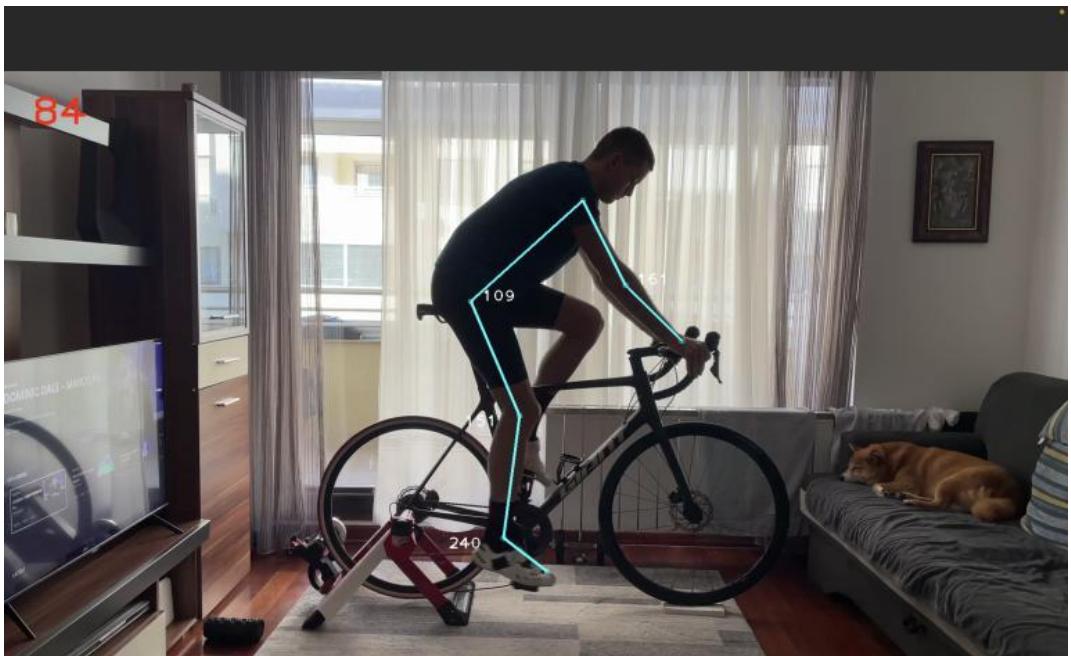
Podatci ovoga rada sastoje od različitih kutova koji su dobiveni iz položaja tijela tijekom bicikliranja. Podatci su podijeljeni na dvije vrste: podatci za regresiju i podatci za klasifikaciju. Podatci za regresiju sastoje se od 4 kuta koji predstavljaju ulazne značajke modela i jedne izlazne varijable koja može poprimiti bilo koje vrijednosti između 0 i 1. S druge strane podatci za klasifikaciju se sastoje od 4 ulazne značajke i 4 izlazne varijable od kojih svaka može poprimiti jednu od vrijednosti -1, 0 ili 1.

2.1. Sakupljanje podataka

Oba skupa podataka kreirana su tijekom analize videa ljudi kako bicikliraju. U sklopu izrade rada, prikupljeno je 8 različitih videa iz kojih su izvučeni kutovi u određenim pozicijama tijela i spremani u datoteku. Pozicije tijela odnose se na poziciju tijekom koje se nogu osobe nalazi u najvišem i najnižem položaju tijekom bicikliranja (12 sati i 6 sati). Razlog tome je što su za *bike fitting* najbitnije veličine kutova upravo u tim položajima tijekom bicikliranja. Navedene pozicije prikazane su na slikama 2.1 i 2.2.



Slika 2.1: Pozicija tijela u najvišem položaju noge



Slika 2.2: Pozicija tijela u najnižem položaju noge

Analiza videa rađena je pomoću poznatih Python biblioteka: *opencv* za računalni vid i *mediapipe* za detekciju zglobova na ljudskom tijelu. Tijekom analize videa, na osobi su spojene sve ključne točke zglobova na jednoj strani tijela. Tu spadaju: rame, lakat, zglob na ruci i nozi, koljeno i kuk. Zatim, između linija koje spajaju te točke izračunati su kutovi iz čega se dobivaju 4 ključna kuta za funkcionalnost modela strojnog učenja: kut iza koljena, kut između natkoljenice i trbuha (kut kuka), kut iznad lakta (između podlaktice i nadlaktice) te kut iza zgloba stopala. Za klasifikacijski skup podataka, za svaki kut je određeno nalazi li se u prihvatljivom intervalu vrijednosti. U slučaju da je kut veći od najveće dopuštene vrijednosti pridružena mu je izlazna vrijednost 1, u slučaju da je kut manji od najmanje dopuštene vrijednosti pridružena mu je izlazna vrijednost -1 i u slučaju da je kut u prihvatljivom intervalu, pridružena mu je izlazna vrijednost 0. Za regresijski skup podataka, ciljna varijabla označava procijenjenu točnost ukupne pozicije na biciklu. Točnost se izražava vrijednostima između 0 i 1, a računa se na temelju kutova tijekom bicikliranja. Točnost se računa pomoću formule (5), kako slijedi:

$$(5) \quad accuracy = \frac{(5*err_{knee} + 3*err_{hip} + err_{elbow} + err_{ankle})}{10}.$$

Err_{knee} , err_{hip} , err_{elbow} i err_{ankle} predstavljaju pogreške pojedinog kuta koje se računaju kao odstupanje pojedinog kuta od njegove optimalne vrijednosti. Ovi postupci su primjenjeni iz razloga jer ne postoje stvarni izlazni podatci pa se moraju simulirati ciljne varijable kako bi model strojnog učenja mogao raditi. Nakon što je određen element za regresijski i klasifikacijski skupa podataka, radi se provjera postojanosti elementa u skupu podataka. U slučaju da identičan element već postoji u skupu, ne dodaje se. Oba skupa podataka sadrže oko 450 primjera na kojima se model strojnog učenja trenira i testira. Slike 2.3 i 2.4 predstavljaju klasifikacijski, regresijski skup podataka.

```

1  knee,hip,elbow,ankle,knee_value,hip_value,elbow_value,ankle_value
2  54,46,162,269,-1,-1,0,1
3  140,95,164,255,-1,-1,0,1
4  52,48,161,261,-1,-1,0,1
5  143,101,165,253,-1,-1,0,1
6  54,45,162,263, 합-1,0,1
7  146,99,158,247,0,-1,0,1
8  53,48,160,265,-1,-1,0,1
9  152,102,162,257,0,-1,0,1
10 51,49,162,264,-1,-1,0,1
11 152,102,161,250,0,-1,0,1
12 53,49,163,263,-1,-1,0,1
13 153,100,161,249,0,-1,0,1
14 52,51,164,261,-1,-1,0,1
15 158,103,158,250,1,-1,0,1
16 54,50,160,246,-1,-1,0,0
17 156,106,159,246,1,0,0,1
18 53,46,161,262,-1,-1,0,1
19 152,101,161,252,0,-1,0,1
20 54,50,160,268,-1,-1,0,1
21 152,100,158,250,0,-1,0,1
22 52,48,161,256,-1,-1,0,1
23 150,101,160,248,0,-1,0,1
24 55,48,162,265,-1,-1,0,1
25 150,102,158,250,0,-1,0,1
26 54,49,159,259,-1,-1,0,1
27 153,103,158,249,0,-1,0,1
28 57,49,160,259,-1,-1,0,1
29 152,102,159,251,0,-1,0,1
30 57,49,160,262,-1,-1,0,1

```

Slika 2.3: Prikaz pvih 30 primjera klasifikacijskog skupa podataka

```

1 knee,hip,elbow,ankle,accuracy
2 153,104,157,235,0.6400
3 73,65,156,241,0.8733
4 155,105,155,239,0.5233
5 68,63,157,243,0.7067
6 157,106,155,235,0.4800
7 73,67,155,244,0.8233
8 157,106,155,233,0.4667
9 74,69,157,242,0.7200
10 154,106,157,237,0.6367
11 73,68,157,247,0.8067
12 151,104,156,234,0.7233
13 67,63,156,240,0.6267
14 151,104,157,232,0.7200
15 68,68,158,247,0.5667
16 150,104,156,236,0.7733
17 72,60,155,247,0.7967
18 62,60,157,229,0.2233
19 153,102,159,231,0.5733
20 64,63,158,231,0.4367
21 156,105,157,234,0.5133
22 66,60,157,242,0.5100
23 150,101,156,234,0.6833
24 67,63,159,237,0.6367
25 153,102,158,229,0.5500
26 65,57,157,235,0.3233
27 149,103,157,232,0.6900
28 64,59,152,239,0.3100
29 150,101,154,228,0.6233
30 64,61,157,237,0.4067

```

Slika 2.4: Prikaz prvih 30 primjera regresijskog skupa podataka

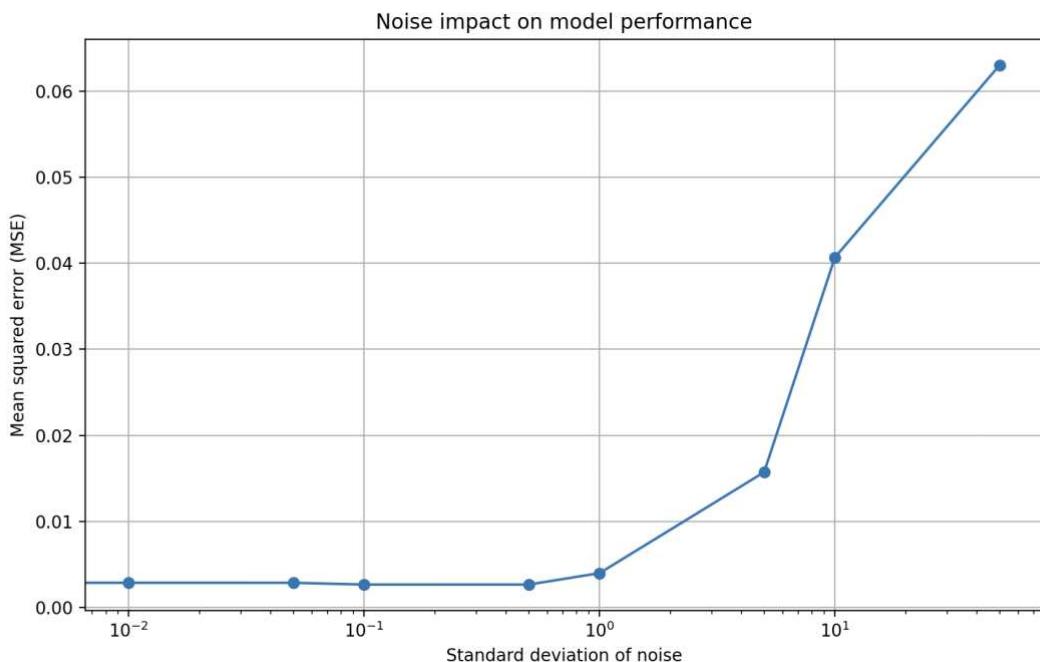
2.2. Obrada podataka

Za obradu podataka koriste se 4 različita modela strojnog učenja prilikom obrade podataka regresijskog problema te 3 različita modela strojnog učenja prilikom obrade podataka

klasifikacijskog problema. Prije treniranja regresijskih modela na podatcima, kako bi modeli bili robusniji i otporniji na odstupanja/varijabilnost podataka u stvarnom svijetu, podatcima je dodan šum. Šum predstavlja vrijednost dobivenu iz normalne razdiobe sa zadanom standardnom devijacijom. Kako bi se odredila najbolja standardna devijacija, uzeto je više vrijednosti standardne devijacije nad kojim je pokrenut model slučajne šume kako bi se vidjelo njegovo ponašanje u odnosu od standardnoj devijaciji. Ponašanje modela (točnosti) izraženo je pomoću mjere pogreške između dobivenih rezultata i stvarnih rezultata. Kao mjera pogreške, korištena je srednja kvadratna pogreška (engl. *Mean Squared Error (MSE)*) prikazana izrazom (6):

$$(6) \quad MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

gdje $(y_i - \hat{y}_i)^2$ predstavlja kvadrat razlike između stvarnih vrijednosti (Y_{train}) i predviđenih vrijednosti (Y_{pred}). Za treniranje modela korišteno je 80% podataka, a 20% je korišteno kao skup za treniranje modela. Što je model točniji, njegov MSE je manji i obrnuto. Na slici 2.5, vidi se da model, koji se trenira nad podatcima sa šumom iz normalne razdiobe sa standardnom devijacijom 0.5, daje najtočinje rezultate, odnosno ima najmanju mjeru pogreške.



Slika 2.5: Graf ovisnosti standardne devijacije i pogreške regresijskog modela

Nakon što je nađena idealna vrijednost šuma koja će se pridodati podatcima, podatci sa šumom trenirani su na 4 modela strojnog učenja. Korišteni modeli su: linearna regresija, stablo odluke, slučajna šuma i neuronska mreža. Svaki model je treniran na 80% podataka, a 20% podataka je ostavljeno za testiranje točnosti modela. Kao mjera pogreške, osim već spomenute mjere MSE, korištena je i mjera pogreške R2 vrijednost izražena formulom (7):

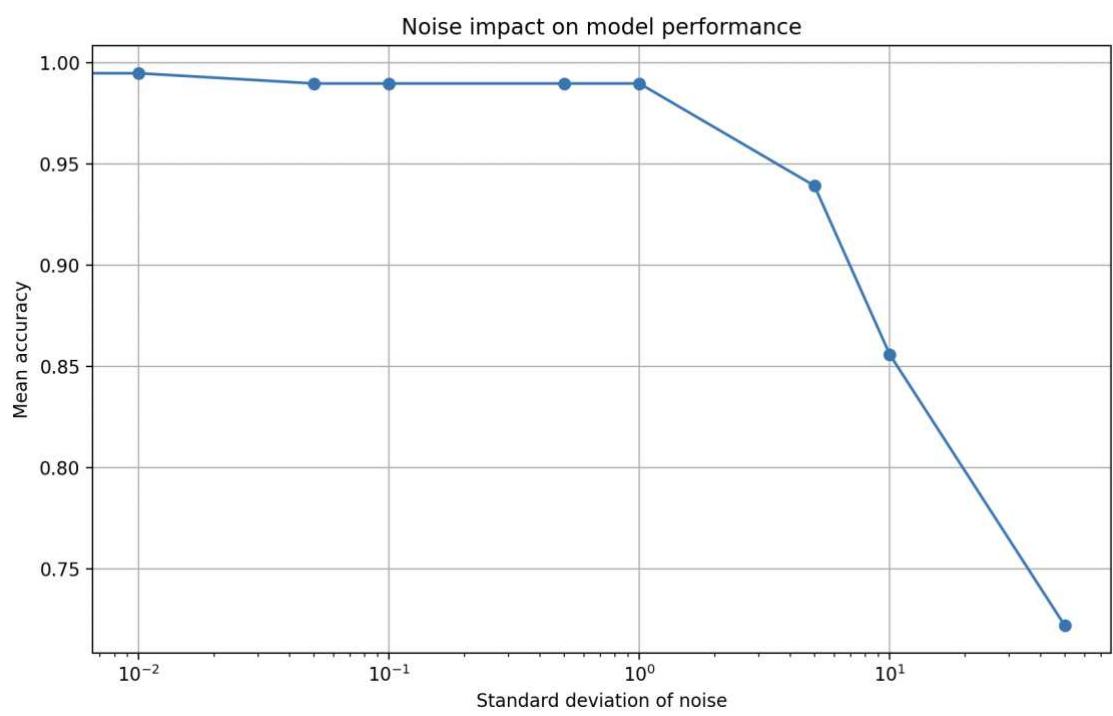
$$(7) \quad R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

gdje $(y_i - \hat{y}_i)^2$ predstavlja kvadrat razlike između stvarnih vrijednosti (Y_{train}) i prosječnih vrijednosti stvarnih vrijednosti. Za klasifikacijski problem, podatcima je također dodan šum sa dobiven iz normalne razdiobe sa standardnom devijacijom 0.5. Korišteni modeli strojnog učenja prilikom obrade klasifikacijskih podataka su: logistička regresija, stablo odluke i slučajna šuma. Kao mjere pogreške (točnosti) modela korištena je točnost prikazana formulom (8):

$$(8) \quad Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

gdje TP predstavlja primjere koji su pozitivni i ispravno klasificirani kao pozitivni, TN primjere koji su negativni i ispravno klasificirani kao negativni, FP primjere koji su pozitivni i pogrešno klasificirani kao negativni i FN primjere koji su negativni i pogrešno klasificirani kao pozitivni. Ova točnost računata je za svaku ciljnu varijablu posebno jer postoje 4 izlaza, te je ukupna (srednja) točnost dobivena kao zbroj pojedinačnih točnosti podijeljen s brojem izlaza.

Na slici 2.6 je kao i na slici 2.5 korišten model slučajne šume za prikaz odnosa šuma i točnosti modela klasifikacijskog problema.



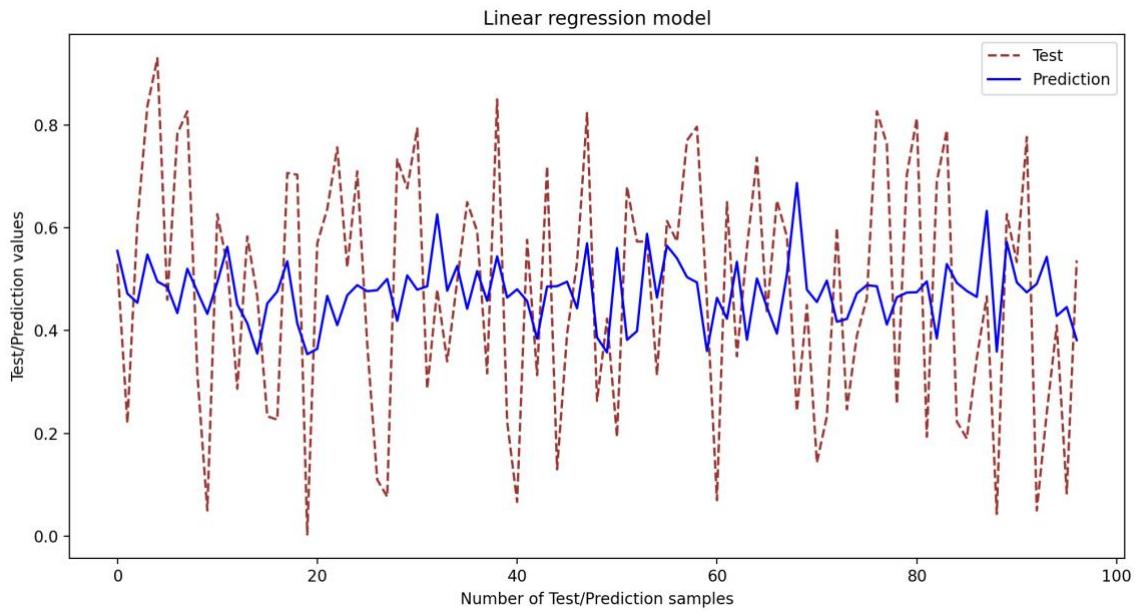
Slika 2.6: Graf ovisnosti standardne devijacije i točnosti klasifikacijskog modela

3. REZULTATI

Kao rezultate ovog rada prikazat ćeemo kako pojedini model radi nad podatcima te kako model radi kad se pokrene nad testnim videom u stvarnom vremenu. Rezultati će nam prikazati koji model daje najbolju točnost pozicije na temelju danih kutova, te koji model najbolje klasificira dane kutove. Regresijski model se koristi za dobivanje ocijene biciklističke pozicije, a klasifikacijski model za davanje savjeta biciklistu o tome koji kut ne valja i što treba promjeniti. Prvo ćemo prikazati rezultate regresijskog problema, a zatim klasifikacijskog.

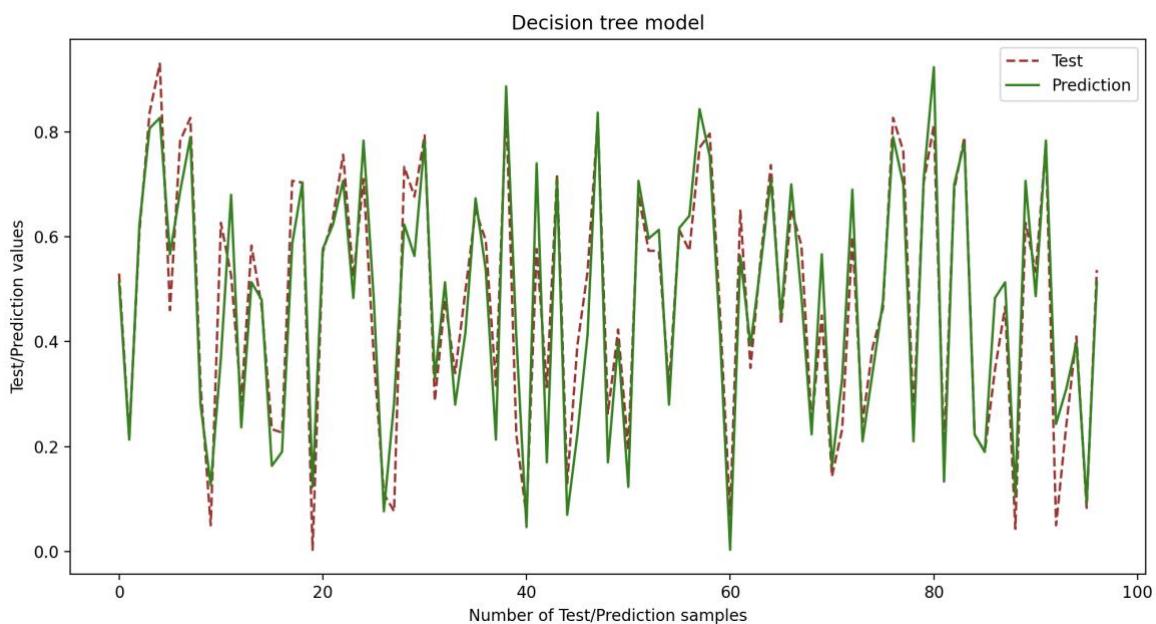
3.1. Regresijski problem

Na prva 4 grafa, puna obojana linija prikazuje vrijednosti ocijene pozicije koje model predviđa nad testnim podatcima, a smeđa isprekidana linija prikazuje stvarne vrijednosti ocijene pozicije. Ocjene se protežu između vrijednosti 0 i 1, odnosno prikazane su u postotku. Na x osi će se prikazivati broj testnih primjera, a na y osi ciljne vrijednosti testnih primjera (ocjene). Na slici 3.1 vidi se točnost rada modela linearne regresije nad testnim podatcima. Iz slike se može vidjeti kako model linerne regresije ne radi najbolje za ovaj problem jer ima dosta velika odstupanja. Puna plava linija je puno uža, nego smeđa isprekidana linija, što znači da model za svaki testni primjer (koji se sastoji od kutova koljena, kuka, lakti i zglobo stopala) daje ocjenu od 0.4 do 0.6 dok su stvarne ocjene testnih primjera u rasponu od 0.1 do 0.9.



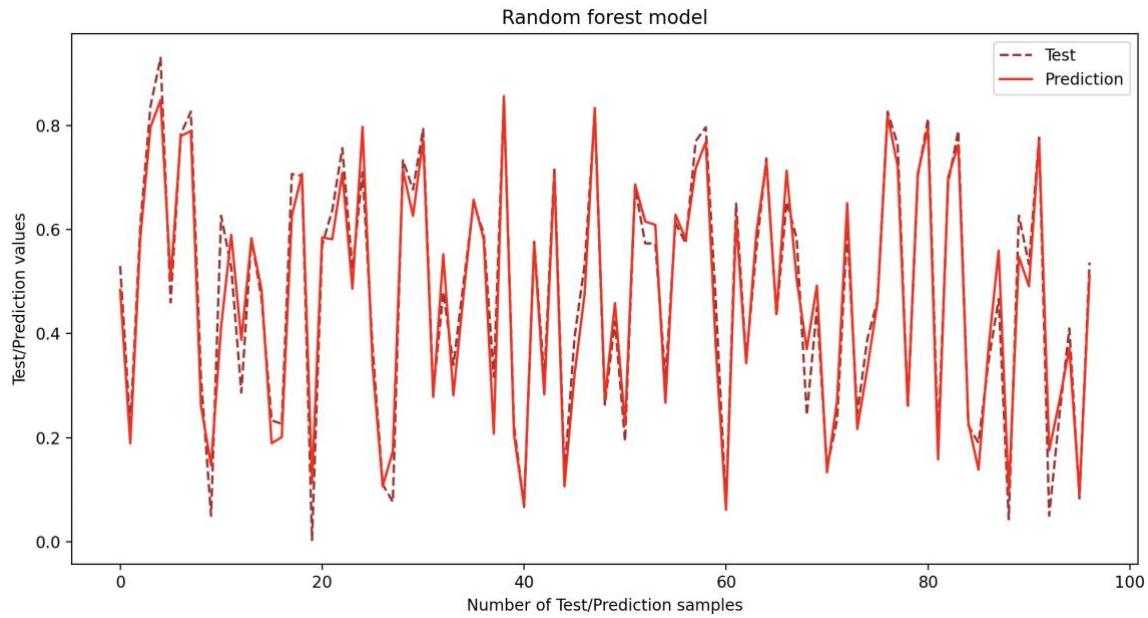
Slika 3.1: Prikaz odstupanja modela linearne regresije od stvarnih podataka

Slika 3.2 prikazuje točnost rada modela stabla odluke nad testnim podatcima. Može se primjetiti da model stabla odluke radi puno bolje od modela linearne regresije jer je zelena obojana linija puno sličnija smeđe obojanoj liniji iako ne nekim mjestima također promašuje stvarne vrijednosti.



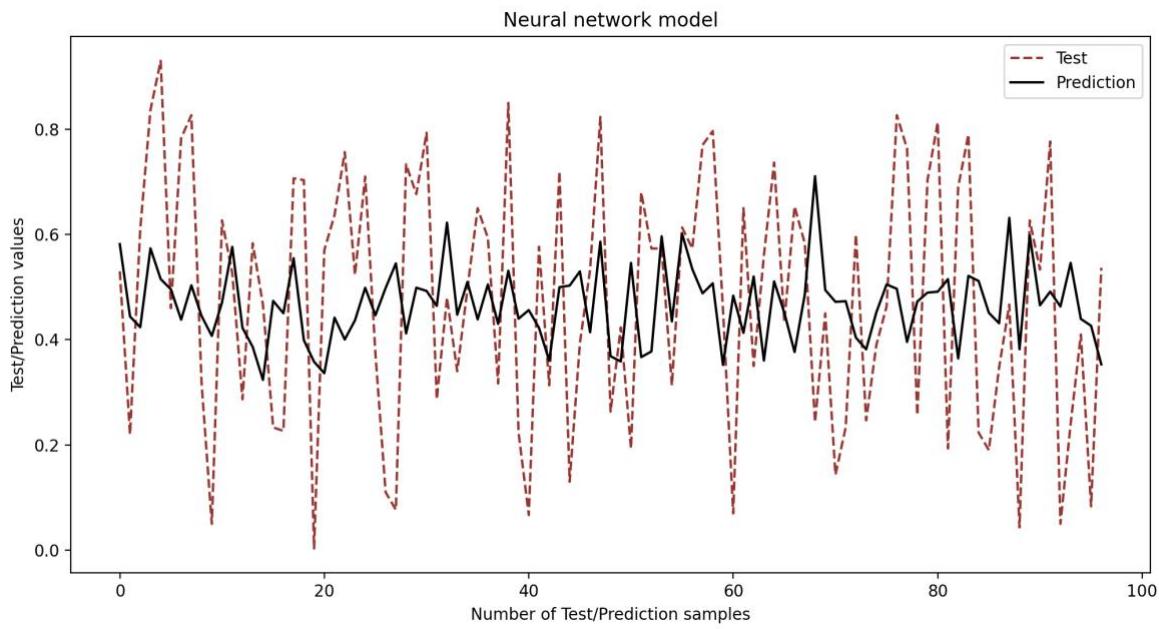
Slika 3.2: Prikaz odstupanja modela stabla odluke od stvarnih podataka

Na slici 3.3 se vidi prikaz mode slučajne šume koji radi najbolje od do sada viđenih modela, zato što najmanje pormašuje od sva tri modela, odnosno crvena linija najbolje pogadja (najsličnija je) smeđu liniju.



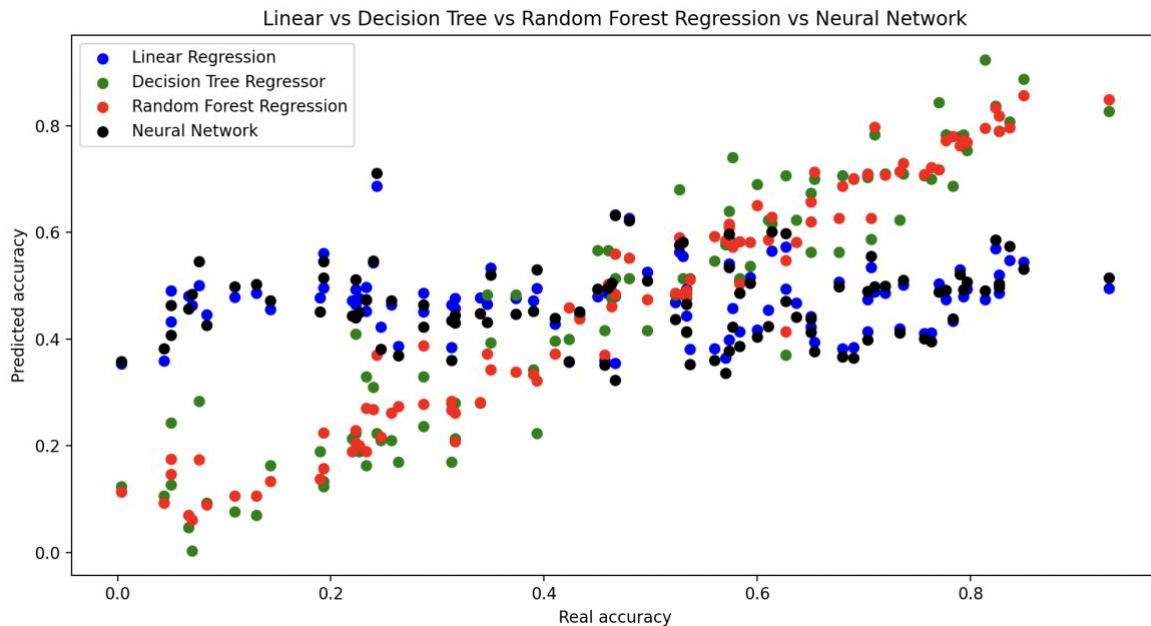
Slika 3.3: Prikaz odstupanja modela slučajne šume od stvarnih podataka

Na slici 3.4, vidi se prikaz rezultata pokretanja modela neuronske mreže nad testnim podatcima. Neuronska mreža radi loše i slično kao model linearne regresije. To je iz razloga jer nemamo dovoljno podataka na kojima bi trenirali neuronsku mrežu. Neuronska mreža je vrlo jak algoritam koji se koristi u zahtjevnim problemima sa velikim skupom podataka, dok je ovaj problem prejednostavan kako bi ga neuronska mreža uspjela riješiti. Model neuronske mreže građen je od 2 skrivena sloja, gdje se prvi sloj sastoji od 8 neurona, a drugi sloj od 4 neurona.



Slika 3.4: Prikaz odstupanja modela neuronske mreže od stvarnih podataka

Slika 3.5 prikazuje graf gdje se može uočiti kako koji model strojnog učenja radi. X os prikazuje stvarnu ciljnu vrijednost testnih podataka (stvarnu ocjenu), a y os prikazuje predviđenu ciljnu vrijednost (predviđenu ocjenu) pojedinog algoritma nad testnim podatcima. Plavo obojane točke su model linearne regresije, zeleno obojane točke model stabla odluke, crveno obojane točke model slučajne šume i crno obojane točke model neuronske mreže. Može se vidjeti da su model stabla odluke i slučajne šume jedini koji su uspjeli uočiti linearnu ovisnost ulaznih i izlaznih vrijednosti, dok je model slučajne šume najprecizniji model.



Slika 3.5: Prikaz odnosa predviđenih vrijednosti sva 4 modela zajedno

Na slici 3.6 mogu se vidjeti greške pojedinih modela. Model slučajne šume ima najmanji MSE i najveći R2 iz čega slijedi da model najbolje predviđa ciljne varijable od sva 4 modela.

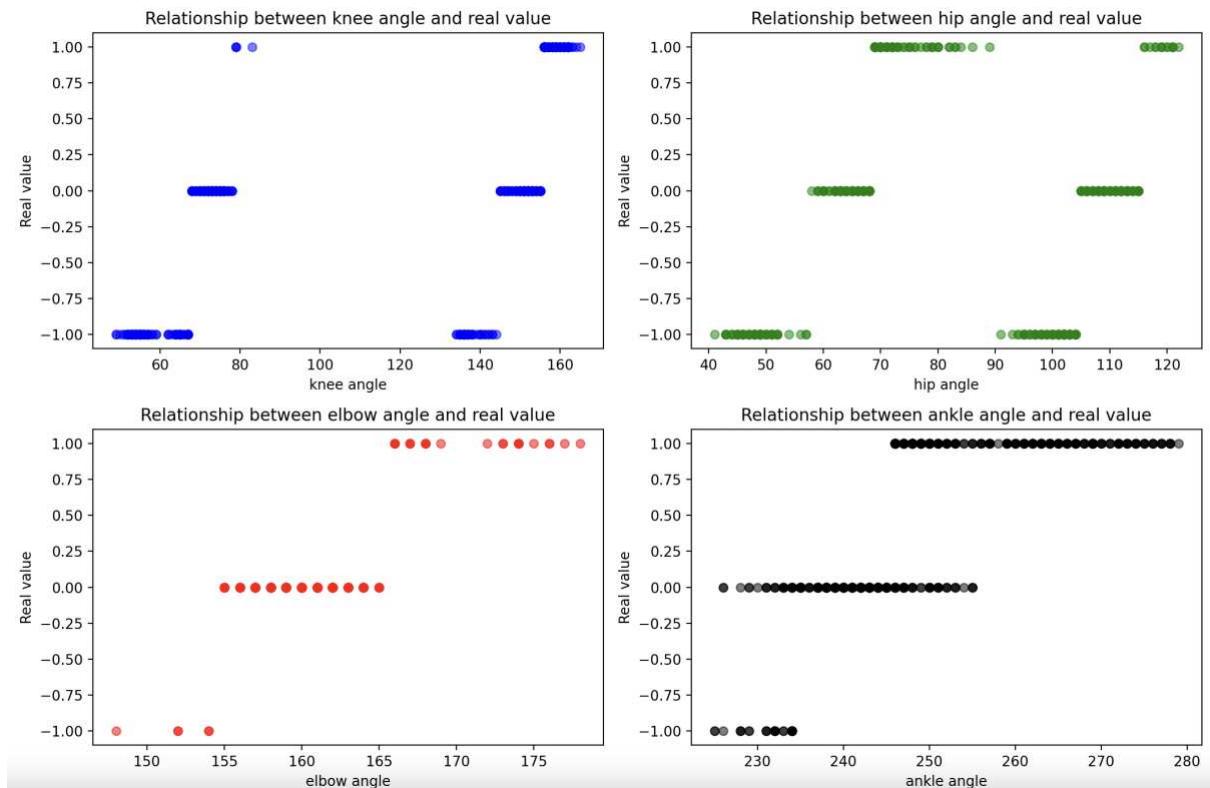
Metric	Linear regression	Decision Tree	Random forest	Neural Network
MSE/degree ²	0.0575	0.0063	0.0028	0.0631
R2	-0.0209	0.8873	0.9503	-0.1198

Slika 3.6: Prikaz mjera pogreške za pojedini model

3.2. Klasifikacijski problem

S obzirom na jednostavnost ovog klasifikacijskog problema, prikazat ćemo samo graf ovisnosti pojedinog kuta o njegovoj ciljnoj varijabli nad ukupnim podatcima te srednju točnost svakog modela.

Na slici 3.7 vidi se ovisnost pojedinih vrijednosti kutova o njihovoj izlaznoj vrijednosti. Na x osi nalazi se vrijednost pojedinog kuta izražena u stupnjevima, a na y osi njihove izlazne vrijednosti za taj kut. Izlazne vrijednosti mogu biti -1, 0 ili 1. Plavo obojane točke se odnose na kut koljena, zeleno obojane na kut kuka, crveno obojane na kut laka i crno obojane na kut zgloba stopala.



Slika 3.7: Prikaz ovisnosti pojedinog kuta o njegovoj izlaznoj vrijednosti

Slika 3.8 prikazuje srednju točnost za pojedini model. Točnosti su vrlo velike radi jednostavnosti klasifikacijskog problema, no stablo odluke i slučajna šuma su ipak precizniji modeli od logističke regresije.

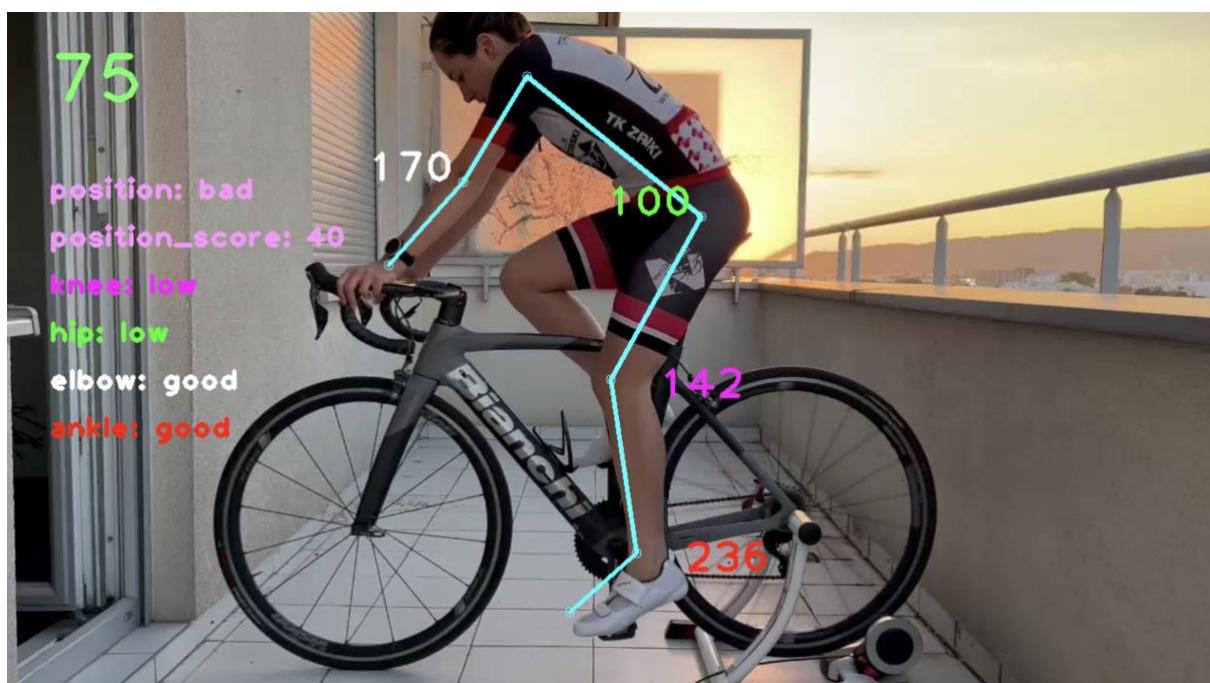
Metric	Logistic Regression	Decision Tree	Random Forest
Mean accuracy	0.9217	0.9975	0.9975

Slika 3.8: Prikaz srednje točnosti za pojedini model

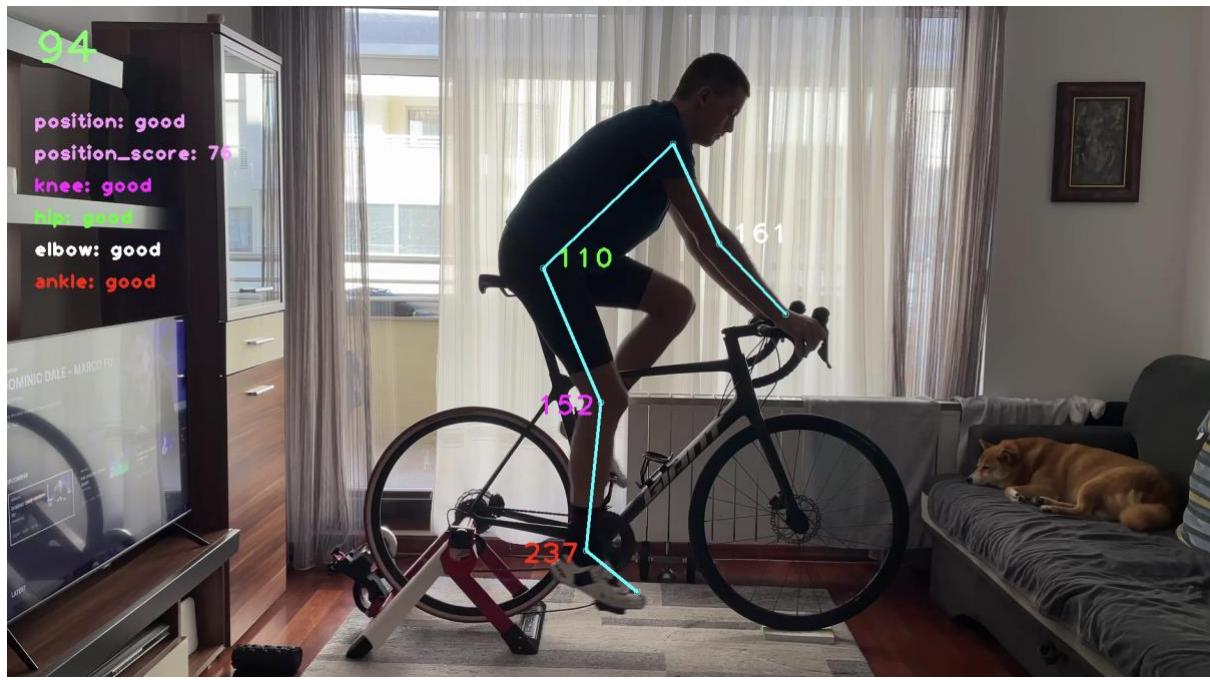
3.3. Stvarni primjer

U ovome dijelu, prikazat će se i objasniti predviđanja modela slučajne šume na dva testna videa. S obzirom da svaki kut ima neku svoju optimalnu vrijednost, model će nam izbaciti i prikazati na videou u kakvom su stanju pojedini kutovi našeg tijela te će nam ocijeniti ukupnu poziciju.

Na slikama 3.9 i 3.10 može se uočiti rad modela strojnog učenja. Model slučajne šume uzima stvarne vrijednosti kutova tijekom bicikliranja i vraća određene vrijednosti (ocjene) na temelju kojih se dobivaju vrijednosti na lijevome dijelu slike. Broj u gornjem lijevom kutu prikazuje kadencu, odnosno broj okretaja pedale u minuti i on nema veze s modelom strojnog učenja. Varijabla „*position*“ dobiva se iz varijable „*position_score*“ koja se računa kao izlazna vrijednost regresijskog modela pomnožena sa 100 koja može poprimiti vrijednosti između 0 i 100. Te dvije varijable govore o kvaliteti cjelokupne pozicije na biciklu. Varijable „*knee*“, „*hip*“, „*elbow*“, „*ankle*“ dobivaju se kao rezultat klasifikacijskog modela. Te varijable nam govore o kvaliteti pojedinog kuta tijekom bicikliranja. Ako je izlaz klasifikacijskog algoritma -1, varijabla poprima vrijednost „*low*“ što znači da bi kut trebao biti veći, ako je izlaz 0 kut ima dobre vrijednosti i poprima vrijednost „*good*“, te ako je izlaz 1 kut je prevelik i varijabla poprima vrijednost „*high*“. Na temelju ovih varijabli, može se napraviti analiza videa dok se biciklira i se mogu se uočiti dijelovi koje bi trebalo popraviti.



Slika 3.9: Primjer loše biciklističke pozicije



Slika 3.10: Primjer dobre biciklističke pozicije

4. Zaključak

Ovaj rad istražio je važnost *bike fittinga* u kontekstu biciklizma, naglašavajući kako precizno podešavanje geometrije bicikla i položaja vozača može značajno poboljšati udobnost i učinkovitost tijekom vožnje. Analizom parametara kao što su kut koljena, kut kuka, kut lakta i kut zgloba stopala, pokazano je kako pravilno prilagođavanje ovih parametara može smanjiti rizik od ozljeda i povećati performanse biciklista. Implementacija strojnog učenja u *bike fittingu* predstavlja inovativan pristup koji može revolucionirati ovu praksu. Korištenjem algoritama poput stabala odluka, linearne regresije i neuronskih mreža, moguće je razviti modelle koji analiziraju kutove tijela biciklista i daju povratnu informaciju o kvaliteti trenutnog položaja na biciklu. Ovo omogućava personalizirano podešavanje bicikla prema individualnim potrebama i karakteristikama vozača, bez potrebe za skupim profesionalnim uslugama. Kroz preciznu analizu optimalnih kutova tijela, biciklisti svih razina iskustva mogu uživati u vožnji bez nelagode i bolova. Uvođenje aplikacije za analizu položaja tijela tijekom bicikliranja otvara vrata široj primjeni *bike fittinga*, čineći ga dostupnim većem broju biciklista. Ovaj rad pruža temeljne smjernice za daljnja istraživanja i praktičnu primjenu strojnog učenja u *bike fittingu*. Implementacija ovakvih tehnologija može dovesti do značajnih unapređenja u biciklističkoj zajednici, omogućavajući vozačima da postignu optimalnu udobnost i performanse, te da uživaju u zdravijem i sigurnijem biciklističkom iskustvu.

Literatura

- [1] Bolf N., *Strojno učenje*, Osvježimo znanje, (2021, rujan). Poveznica: <https://hrcak.srce.hr/file/382926>; pristupljeno 6. lipnja 2024.
- [2] Ogbemi M. E., *What is overfitting in Machine Learning*, Machine Learning, (2023, listopad). Poveznica: <https://www.freecodecamp.org/news/what-is-overfitting-machine-learning/>; pristupljeno 6. lipnja 2024.
- [3] Jaiswal S., *Random Forest Algorithm*, Machine Learning, (2011. – 2021.). Poveznica: <https://www.javatpoint.com/machine-learning-random-forest-algorithm>; pristupljeno 6. lipnja 2024.
- [4] Prof. dr. sc. Bojana Dalbelo Bašić i izv. Prof. dr. sc. Jan Šnajder, Uvod u umjetnu inteligenciju, 10. Strojno učenje, prezentacija, 2020.
- [5] Prof. dr. sc. Bojana Dalbelo Bašić i izv. Prof. dr. sc. Jan Šnajder, Uvod u umjetnu inteligenciju, 11. Umjetne neuronske mreže, prezentacija, 2020.
- [6] izv. Prof. dr. sc. Jan Šnajder, Strojno učenje 1, 3. Linearna regresija, prezentacija, 2023.
- [7] izv. Prof. dr. sc. Jan Šnajder, Strojno učenje 1, 6. Logistička regresija, prezentacija, 2023.

Sažetak

Savjetovanje pravilnog držanja tijela tijekom bicikliranja primjenom strojnog učenja

Bike fitting je ključan za bicikliste, bilo profesionalce ili rekreativce, jer osigurava udobnost i smanjuje rizik od ozljeda. Kroz prilagodbu bicikla prema individualnim karakteristikama vozača, bike fitting omogućava efikasniju i ugodniju vožnju. Primjena strojnog učenja, posebno kroz algoritme kao što su linearna regresija, stabla odluka i neuronske mreže, omogućila je razvijanje aplikacije koja može pomoći biciklistima da sami prilagode svoj bicikl. Analiza videozapisa biciklista pružila je podatke potrebne za treniranje modela, koji su kasnije korišteni za predikciju optimalnih postavki bicikla. Uvođenjem šuma u podatke, modeli su postali robusniji i otporniji na varijabilnosti u stvarnim uvjetima. Rezultati pokazuju da modeli strojnog učenja, poput slučajne šume, pružaju točne predikcije i mogu pomoći u optimizaciji postavki bicikla. Ovi modeli mogu identificirati nepravilnosti u položaju vozača i preporučiti prilagodbe koje poboljšavaju udobnost i performanse. U budućnosti, daljnje istraživanje može uključivati proširenje skupa podataka kako bi se obuhvatili različiti tipovi bicikala, brzina vožnje, otpor zraka, tjelesne karakteristike vozača kao što su visina, težina, duljina nogu... Također, integracija senzora za praćenje stvarnog vremena može omogućiti dinamičko prilagođavanje postavki bicikla tijekom vožnje, pružajući još veću razinu personalizacije i udobnosti. Kroz kontinuirano unapređenje algoritama i povećanje baze podataka, bike fitting može postati pristupačniji i učinkovitiji za sve bicikliste.

Ključne riječi: bike fitting, strojno učenje, slučajna šuma

Summary

Advising proper posture during cycling using machine learning

Bike fitting is crucial for cyclists, whether professionals or recreational riders, as it ensures comfort and reduces the risk of injuries. By adjusting the bike according to the individual characteristics of the rider, bike fitting enables a more efficient and enjoyable ride. The application of machine learning, particularly through algorithms such as linear regression, decision trees, and neural networks, has enabled the development of an application that can help cyclists adjust their bikes themselves. Video analysis of cyclists provided the necessary data to train the models, which were later used to predict optimal bike settings. By introducing noise into the data, the models became more robust and resistant to variability in real-world conditions. The results show that machine learning models, such as random forests, provide accurate predictions and can help optimize bike settings. These models can identify irregularities in the rider's position and recommend adjustments that improve comfort and performance. In the future, further research may include expanding the dataset to cover different types of bikes, riding speeds, air resistance, and physical characteristics of riders such as height, weight, and leg length. Additionally, the integration of real-time monitoring sensors can enable dynamic adjustment of bike settings during the ride, providing an even greater level of personalization and comfort. Through continuous improvement of algorithms and expansion of the database, bike fitting can become more accessible and effective for all cyclists.

Keywords: bike fitting, machine learning, random forest