

ANALIZA ODBOJKARSKE IGRE Z UPORABO ALGORITMOV RAČUNALNIŠKEGA VIDA

MARKO PLANKELJ, UROŠ MLAKAR

Univerza v Mariboru, Fakulteta za elektrotehniko računalništvo in informatiko, Maribor,
Slovenija

marko.plankelj@student.um.si, uros.mlakar@um.si

V zadnjih letih so sodobne tehnologije naredile šport bolj dostopen širšemu občinstvu z zagotavljanjem interaktivnih podatkov med prenosi, zmanjšanjem tveganja človeške napake in izboljšanjem uspešnosti športnikov s pomočjo realno časovne analize in ciljnih vpogledov v trening. Ta članek združuje teoretične in praktične pristope z razvojem aplikacije, ki temelji na specifičnih konvolucijskih nevronskih mrežah za zaznavanje igrišča za odbojko in sledenje žogi. Rezultati prikazujejo sposobnost napredne video analitike v športu, ki uporabnikom omogoča raziskovanje priložnosti sodobne tehnologije pri izboljšanju športne uspešnosti.

DOI
[https://doi.org/
10.18690/um.feri.2.2025.8](https://doi.org/10.18690/um.feri.2.2025.8)

ISBN
978-961-286-960-1

Ključne besede:
računalniški vid,
konvolucijske nevronske
mreže,
detekcija objektov,
odbojka,
spletna aplikacija

Prispevek temelji na:
Plankelj, M. (2025). *Analiza odbojcarske igre z uporabo algoritmov računalniškega vida in strojnega učenja*. magistrsko delo, Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko. Maribor.



Univerzitetna založba
Univerze v Mariboru

DOI
[https://doi.org/
10.18690/um.feri.2.2025.8](https://doi.org/10.18690/um.feri.2.2025.8)

ISBN
978-961-286-960-1

Keywords:

computer vision,
convolutional neural
networks,
object detection,
volleyball,
web application

The proceedings is based

on: Plankelj, M. (2025).
*Analiza odbojske igre z
uporabo algoritmov
računalniškega vida in strojnega
učenja*: magistrsko delo,
University of Maribor,
Faculty of Electrical
Engineering and Computer
Science. Maribor

VOLLEYBALL GAME ANALYSIS USING COMPUTER VISION ALGORITHMS

MARKO PLANKELJ, UROŠ MLAKAR

University of Maribor, Faculty of Electrical Engineering and Computer Science,
Maribor, Slovenia
marko.plankelj@student.um.si, uros.mlakar@um.si

In recent years, modern technologies have made sports more accessible to a wider audience by providing interactive data during broadcasts, reducing the risk of human error, and enhancing athletes performance through real-time analysis and targeted training insights. This paper combines theoretical and practical approaches by developing an application based on specific convolutional neural networks for volleyball court detection and ball tracking. The results demonstrate the potential of advanced video analytics in sports, allowing users to explore the opportunities of modern technology in improving sports performance.



1 Uvod

Šport je za ljudi že od nekdanj oblika sprostitve, druženja, priložnost za iskanje novih prijateljstev z dokazano koristnimi učinki na zdravje. Svetovna zdravstvena organizacija priporoča telesno aktivnost kot del zdravega načina življenja v programu, s pomočjo katerega želijo ljudem približati telesno aktivnost kot priložnost za bolj zdravo, srečno in produktivno življenje (World Health Organization, 2024). Na drugi strani iz dneva v dan spremljamo razvoj sodobnih tehnologij in njihovo uporabo na najrazličnejših področjih, med drugim tudi v športu.

Šport in sodobne tehnologije, kot sta računalniški vid in strojno učenje, sta bila, še pred nekaj leti, povsem nezdržljiva pojma, danes pa si skorajda ne moremo predstavljati spremljanja ali udeleževanja v športu brez uporabe sodobnih tehnologij (B.T. Naik, 2022). Kljub številnim izzivom, kot so slabša kvaliteta vhodnih podatkov ali prekrivanja igralcev, je uporaba sistemov za detekcijo igrišča, igralcev in njihovih akcij ter sledenja žogi med igro vse pogostejša. Z njihovo uporabo želijo preprečiti sporne situacije na tekmah, izboljšati treninge in analizo tekme, z namenom preprečevanja poškodb predvidevati obremenitve na treningih in tekmah ter izboljšati izkušnjo gledalcem z analizo pred, med in po tekmi (Plankelj, 2025).

2 Predstavitev problema

Obravnavan problem in predstavljeno rešitev lahko razdelimo na štiri korake:

1. Priprava podatkov za učenje, ki je vključevala zbiranje, predobdelavo in označevanje podatkov, ki smo jih kasneje dodatno augmentirali z namenom povečanja raznolikosti in obsega nabora podatkov.
2. Implementacija in učenje modelov konvolucijske nevronske mreže na podlagi pripravljenega nabora podatkov.
3. Perspektivna transformacija odbojcarskega igrišča.
4. Razvoj spletne aplikacije in integracija naučenih modelov konvolucijske nevronske mreže v povezavi s perspektivno projekcijo za prikaz končnih rezultatov.

2.1 Obstoječe rešitve

Uporaba sodobnih tehnologij ni več omejena na pilotne projekte in dogodke nižjega ranga, temveč se vse bolj uveljavlja na najvišjih svetovnih športnih dogodkih.

Na lanskih olimpijskih igrah v Parizu so v sodelovanju s pomočjo partnerja, podjetja Intel, predstavili tehnologije za izboljšanje izkušenj udeležencev in gledalcev. Mednarodni olimpijski komite je med drugim tudi oznanil začetek celostnega programa uporabe umetne inteligence v športu, s katerim želijo nasloviti področja vključevanja umetne inteligence v šport, in sicer z namenom izboljšanja tako uspešnosti športnikov kot izkušnje gledalcev (Olympics, 2024).

Na svetovnem nogometnem prvenstvu v Katarju leta 2022 pa so po več uspešnih testiranjih za preverbo prepovedanega položaja med igro vpeljali tudi uporabo polavtomatske tehnologije. Tehnologija uporablja dvanajst kamer, nameščenih pod vrhom stadiona, za izračun položaja devetindvajsetih ključnih točk na vsakem igralcu petdesetkrat na sekundo. Za natančno zaznavanje udarca žoge uporabljajo senzor IMU (angl. inertial measurement unit), ki se nahaja na sredini žoge in posreduje podatke o žogi v sobo za pregled posnetka petstokrat na sekundo (Inside FIFA, 2024).

V športih, kot sta tenis in odbojka, se že vrsto let uporablja sistem Hawk-eye za sledenje poti žoge in določanje njenega položaja s pomočjo hitrih kamer, nameščenih okrog igralne površine. Sistem v vsakem izmed njih identificira piksle, ki ustrezajo žogi, in nato s pomočjo vsaj dveh slik, posnetih iz drugih kamer (ki so postavljene na druge lokacije), primerja njen položaj in ga potrди oz. primerno popravi (Hawk Eye, 2024).

Kot že omenjeno, tudi v odbojki, tako kot v drugih športih, uvajanje naprednih tehnologij ni izjema. Platforma Balltime z umetno inteligenco Volleyball AI (VOLL-E) razdeli odbojgarsko igro v različne segmente, s pomočjo katerih olajša analizo tekme in pripravo igralcev na naslednje tekme. Z uporabo modela konvolucijske nevronske mreže, ki se je učil na obsežni zbirki odbojgarskih posnetkov, se nato iz naloženega videoposnetka tekme omogoča avtomatska zaznava žoge ter vsakega izmed igralcev na igrišču. Na podlagi prepoznanih položajev žoge in igralcev platforma prepozna akcije, kot sta sprejem ali obramba, in samodejno določi smer napada ter jo vizualno predstavi. S pomočjo zbranih podatkov izračuna hitrost žoge

in sortiranje ter izbiro elementov igre glede na posameznika v igrišču (Balltime Academy, 2024).

Podobno funkcionalnost, kot jo ponuja zgoraj opisana platforma Balltime, omogoča tudi aplikacija za mobilne naprave znamke Apple, imenovana Avais, ki za razliko spremlja in analizira odbojbarsko igro v realnem času. Posledično se izognemo čakanju med nalaganjem videoposnetka odbojbarske tekme in lahko podatke za analizo pridobimo še v istem trenutku (Avais, 2024).


3 Implementacija lastne rešitve

Končna rešitev je bila izvedena v več korakih z uporabo različnih tehnologij. Z namenom boljše in lažje dostopnosti, neodvisno od lokacije in naprave končnega uporabnika, je bila razvita spletna aplikacija, ki uporabi naučene modele nevronske mreže za zaznavo odbojbarskega igrišča ter sledenje odbojbarski žogi skozi slike v krajšem izseku.

3.1 Zbiranje, predobdelava, označevanje ter augmentacija učnih podatkov

Primarno zbiranje podatkov je potekalo s pomočjo prosto dostopnih podatkov na svetovnem spletu. Zaradi zamudnega iskanja podatkov, ki zadoščajo postavljenim merilom (slika celotnega odbojbarskega igrišča, zajetega s pomočjo ene kamere, postavljene za odbojbarskim igriščem) smo kot drugi vir podatkov zajeli lastni posnetek odbojbarske tekme. Za pretvorbo iz video sekvence v slike smo implementirali skripto v programskem jeziku Python in jih shranili v formatu JPG (angl. Joint Photographic Experts Group) v zaporednem časovnem intervalu ene slike na sekundo.

Zaradi različnih virov podatkov smo v predobdelavi podatkov najprej želeli poenotiti dimenzije vseh slik, za kar smo pripravili enostavno skripto in poenotili dimenzije vseh slik spremenili na želeno velikost. Nato smo nadaljevali z označevanjem učnih podatkov z uporabo dveh ločenih metod. Pri prvi metodi smo ročno izbrali šest točk na vsaki sliki in nato za vsako od šestih izbranih točk shranili koordinate x in y v formatu JSON (angl. JavaScript Object Notation) za kasnejšo uporabo, kot je prikazano na sliki 1.



Slika 1: Program, ki omogoča označbo zelenih ključnih točk na odbojgarskem igrišču.

Vir: lasten.

Pri drugi tehniki označevanja podatkov, uporabljeni v učni množici za zaznavanje žog, smo izkoristili funkcionalnost spletne platforme Roboflow, ki razvijalcem ponuja celovite storitve za izdelavo aplikacij računalniškega vida, vključno z označevanjem podatkov v učni množici (Roboflow, 2024).

Zaradi manjšega števila podatkov v učnem naboru smo se odločili za augmentacijo učnih podatkov, kot je prikazano na sliki 2. Uporabili smo **imgaug**, namensko knjižnico za povečanje učne množice s pomočjo različnih tehnik augmentacije, ki jih podpira (Imgaug, 2024). Za ohranitev celotnega igrišča na sliki po augmentaciji smo prebrali koordinate kotov odbojgarskega igrišča in glede na njihovo oddaljenost od roba slike določili transformacije, ki smo jih uporabili. Transformacije so bile izvedene v naključnem vrstnem redu s funkcijo Sequential. Po transformacijah smo preverili, ali so vse označene točke igrišča ostale znotraj slike. V primeru, da je katera koli izmed točk padla izven omejenega območja, smo postopek transformacije ponovili največ petkrat in v primeru neuspeha s polovično verjetnostjo aplicirali zgolj horizontalno zrcaljenje.




Slika 2: Praktičen prikaz podatkov pred in po augmentaciji (afina transformacija).

Vir: lasten.

3.2 Perspektivna transformacija odbojcarskega igrišča

Perspektivne transformacije se uporabljajo na različnih področjih, vključno z avtonomno vožnjo. Pri tem se posnetki več kamer, nameščenih na vozilo, s pomočjo perspektivne transformacije pretvorijo v prikaz iz ptičje perspektive, ki zajema celotno okolico vozila. To omogoča lažje ocenjevanje razdalj med objekti v okolici (Joseph Redmon, 2016).

V našem primeru smo za izvedbo perspektivne transformacije uporabili knjižnico OpenCV, specializirano za računalniški vid. Najprej smo izračunali matriko homografije in jo nato uporabili za preoblikovanje med izvornimi in ciljnimi točkami. Končni rezultat je pogled iz ptičje perspektive na odbojcarsko igrišče, kot je prikazano na sliki 3, kar omogoča enostavnejšo analizo igre.



Slika 3: Prikaz perspektivne transformacije slike.

Vir: lasten.

3.3 Implementacija in učenje modelov konvolucijske nevronske mreže

Za učenje smo izbrali dva ločena modela konvolucijske nevronske mreže: segmentacijsko nevronske mrežo U-Net, ki je bila uporabljena za zaznavo odbojarskega igrišča, ter model YOLOv8, ki je bil uporabljen za zaznavo žoge. V obeh primerih smo temeljili na pristopu, kjer smo za učenje in testiranje uporabljali ločene učne množice, torej med učenjem nismo uporabili nobene izmed slik, ki bi bila kasneje uporabljena za testiranje uspešnosti katerega izmed modelov nevronskih mrež.

Segmentacijsko nevronske mrežo U-Net, katere simetrično strukturo sestavljata kodirnik in dekodirnik, je bila implementirana z uporabo odprtokodnega ogrodja za strojno učenje, imenovan PyTorch.

Za model YOLO smo se odločili uporabiti eno od novejših verzij, natančneje verzijo osem, razvito s strani podjetja Ultralytics (Ultralytics, 2024). Čeprav bi lahko učenje izvajali na platformi podjetja Ultralytics, smo knjižnico Ultralytics raje namestili lokalno ter nato integrirali v Python program. Za namen učenja smo uporabili predhodno učen model YOLOv8, ki smo ga s pomočjo predhodno označenih podatkov nato zgolj dodatno učili na lastnih podatkih. Lastne podatke smo imeli shranjene v formatu za serializacijo, imenovanem YAML, ki smo ga predhodno generirali na platformi Roboflow, ob označevanju podatkov

3.4 Implementacija spletne aplikacije

Z namenom boljše in lažje dostopnosti, neodvisno od lokacije in naprave končnega uporabnika, smo razvili spletno aplikacijo, katere glavni namen je uporaba naučenih modelov nevronskih mrež za zaznavo odbojarskega igrišča ter sledenje odbojarski žogi skozi slike v krajšem izseku odbojarske tekme. Razvoj je potekal v programskem okolju PyCharm, kjer smo za zaledje aplikacije uporabili spletno mikro-ogrodje Flask, medtem ko smo videz nadgradili in izboljšali z odprtokodnim CSS ogrodjem Bootstrap.

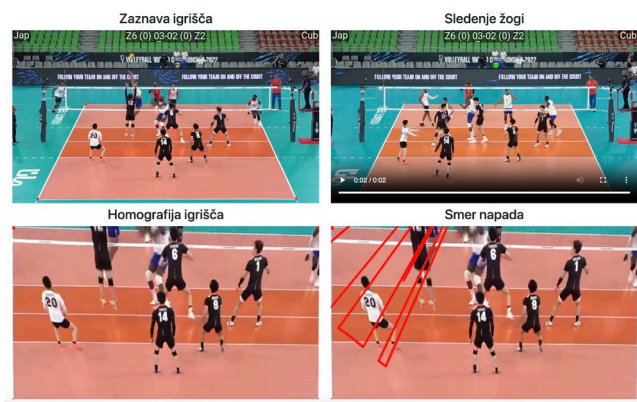
4 Rezultati

V tem poglavju so predstavljeni tako rezultati implementirane aplikacije kakor tudi glavne funkcionalnosti le te.

4.1 Predstavitev aplikacije in uporabniškega vmesnika

Aplikacija je idejno razdeljena na dva glavna dela. V prvem delu lahko uporabnik izbira med predpripravljenimi posnetki ali izbere lasten videoposnetek iz naprave, preko katere dostopa do spletne aplikacije. Ob uspešni izbiri, lahko uporabnik začne analizo katere rezultat se prikaže v štirih predpripravljenih poljih (kot je prikazano na sliki 4):

- **Zaznava igrišča** – zaznava odbojcarskega igrišča na prvi sliki videoposnetka s pomočjo naučenega modela konvolucijske nevronske mreže z arhitekturo U-Net. Kote odbojcarskega igrišča označimo z rdečimi pikami.
- **Sledenje žogi** – zaznava odbojcarske žoge na prvi sliki videoposnetka s pomočjo naučenega modela konvolucijske nevronske mreže z arhitekturo YOLO. Zaznano odbojcarsko žogo označimo s piko zelene barve.
- **Homografija igrišča** – perspektivna transformacija odbojcarskega igrišča, s pomočjo katere za lažjo analizo poti žoge ustvarimo pogled od zgoraj navzdol.
- **Smer napada** – prikaz gibanja odbojcarske žoge skozi zaporedje slik celotne dolžine videoposnetka, kjer za vsako sliko shranimo podatke o lokaciji žoge in ob koncu povežemo zaporedne položaje ter jih prikažemo kot pot njenega premikanja na igrišču, prikazanem s ptičje perspektive. Pot žoge označimo s črto rdeče barve.



Slika 4: Rezultati analize izbranega videoposnetka.

Vir: lasten.

4.2 Statistična in vizualna primerjava rezultatov

Predstavitvi aplikacije in uporabniškega vmesnika sledijo rezultati uspešnosti zaznave odbojarskega igrišča in žoge, kar smo testirali na različnih testnih podatkih.


4.2.1 Analiza zaznave odbojarskega igrišča

Rezultate zaznave igrišča smo statistično ovrednotili s pomočjo standardne metrike, ki se uporablja pri segmentaciji, in sicer oceno prekrivanja napovedanih segmentov IoU (angl. Intersection over Union), ki meri natančnost prekrivanja med napovedanimi segmenti (A) in dejanskimi ročnimi oznakami (B) po naslednji formuli:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

Model smo testirali na naboru 174 naključno izbranih slik, ki so bile posnete z različnih zornih kotov, v različnih športnih dvoranah, s čimer smo omogočili oceno robustnosti in prilagodljivosti modela. Model je dosegel povprečno vrednost 0,8627, kar pomeni, da se v povprečju 86,27 % segmentiranih površin ujema z ročno označenimi segmenti odbojarskega igrišča. Visok odstotek potrjuje uspešnost modela pri zaznavi odbojarskega igrišča, kljub temu pa smo opazili določene primere in pogoje, pri katerih model ne vrne pričakovanih rezultatov.

Slika 5 prikazuje primer, kjer so robovi (natančneje zgornji rob) odbojarskega igrišča prekriti z igralci. V tem primeru je model imel težave pri zaznavanju segmentov igrišča, saj so igralci blokirali vidne meje in s tem zameglili robove igrišča. Posledično so bile napovedane meje manj ostre in natančne, kar je pripeljalo do višje stopnje napak pri segmentaciji (in posledično nižje vrednosti metrike IoU). Podobne težave smo opazili ob nepravilni postavitvi kamere (npr. kamera, postavljena ob stran odbojarskega igrišča).



Slika 5: Slabša segmentacija odbojkarskega igrišča ob prikritih robovih.

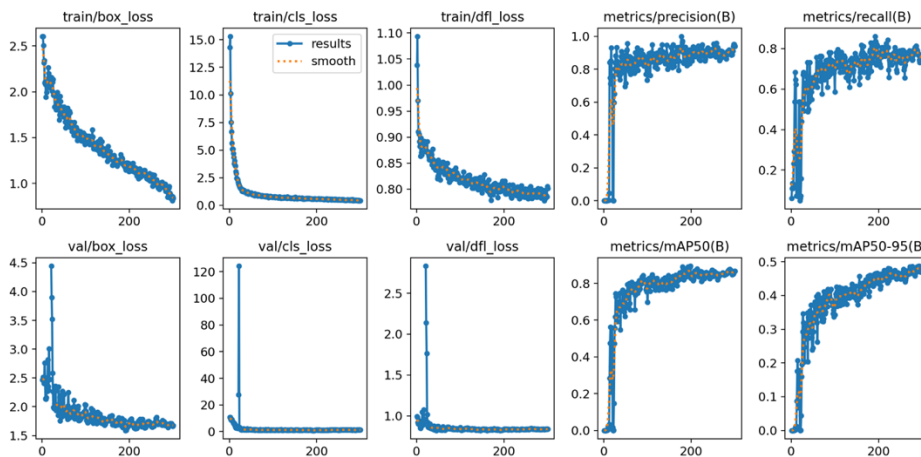
Vir: lasten.

4.2.2 Analiza zaznave odbojkarske žoge

Po zaključku učenja smo analizirali grafe, ki prikazujejo rezultate na učni in validacijski množici. Omogočajo nam pomemben vpogled v delovanje modela in ocene njegove generalizacije in robustnosti. V analizi se osredotočimo zgolj na nekaj izmed ključnih metrik oziroma grafov, ki jih prikazuje slika 6:


- Train/box_loss in val/box_loss – metrika, ki predstavlja natančnost zaznanih okvirjev glede na dejanski položaj žoge. Padajoči graf predstavlja izboljšanje učenja in bolj natančno zaznavo žoge, hkrati pa opazimo zmanjšanje izgube na validacijski množici. Pri izgubi na validacijski množici smo dosegli vrednost okoli 1.5, kar kaže na ustrezno generalizacijo modela tudi na nove podatke (slike), ki niso bili del učne množice, brez očitnih znakov prenaučnosti.
- Metrics/mA50(B) – metrika, ki predstavlja povprečno natančnost zaznanih okvirjev pri 50 % prekrivanju med napovedanim in dejanskim okvirjem, torej 50 % vrednostjo IoU (glej poglavje 4.2.1). Vrednost, ki jo dosega naš model, je 85 %, kar kaže na visoko stopnjo natančnosti pri nižjem pragu prekrivanja.
- Metrics/mAP50-95(B) – pri višjem pragu prekrivanja (povprečna natančnost preko različnih pragov prekrivanja od 50 do 95 %), ki je prikazan

na grafu z naslovom `metrics/mAP50-95(B)`, je imel model večje težave pri natančnem umeščanju okvirjev, zlasti v situacijah, kjer se žoga nahaja blizu drugih objektov ali v slabših svetlobnih pogojih.



Slika 6: Grafični prikaz rezultatov učenja..

Vir: lasten.



Slika 7: Neuspešna zaznava odbojcarske žoge ob delnem prekrivanju žoge.

Vir: lasten.

Za celovito oceno delovanja modela smo rezultate preverili tudi vizualno, s prikazom zaznanih pozicij odbojcarske žoge na slikah, ki niso bile del učne množice. Testiranje modela smo lahko izvedli na platformi Roboflow. Rezultati so bili uspešni v primeru, da je žoga na sliki jasno vidna, na sliki ni prisotnih več žog, osvetlitveni pogoji pa so optimalni. Neuspešna zaznava se je pojavila v primeru, ko pogoji niso bili idealni, kot prikazuje slika 7. Žoga na sliki ni jasno vidna zaradi prekrivanja z drugimi objekti (odbojcarsko mrežo), zaradi česar je imel model težave pri zaznavi žoge in le to zaznal na več mestih zaznal potencialno prisotnost odbojcarske žoge, vendar z nizkimi stopnjami zaupanja. Rdeča puščica na sliki 7 označuje dejansko lokacijo žoge.

Kljub prisotnosti motečih elementov na igrišču in v ozadju je model sposoben uspešno prepoznati pravo žogo, kot je prikazano na sliki 8, kjer slika vsebuje več kot eno odbojcarsko žogo. Model je pravilno zaznal lokacijo obeh žog z različnima stopnjama zaupanja, pri čemer je prava lokacija žoge označena z višjo, 88-odstotno stopnjo zaupanja.



Slika 8: Uspešna zaznava in izbira odbojcarske žoge.

Vir: lasten.

4.3 Možne izboljšave

Kljub uspešni implementaciji zelenih funkcionalnosti se aplikacija v določenih situacijah ne obnese odlično. To postane očitno predvsem v primerih, ko vhodni video vsebuje slike, ki se razlikujejo od tistih, ki se uporabljajo za usposabljanje konvolucijskih nevronske mreže. Najpogostejše težave, ki smo jih opazili, so bile:

- Različni položaji kamere: ko je odbojcarska tekma posneta pod kotom kamere, ki se razlikuje od tistih, uporabljenih v naboru podatkov o treningu.
- Več vrstic na igrišču: ko videoposnetek vključuje več vrstic, ki se ne nanašajo samo na igrišče za odbojko.
- Barvna shema žoge: v nekaterih ligah (tudi v najvišjih ligah, na primer v Italiji) uporabljajo žogo druge barve. Poleg tega se lahko barvne sheme igrišča prekrivajo z žogo, zaradi česar je težko natančno zaznati žogo.
- Ključne točke igrišča ali žoga, ki jo pokrivajo igralci: ko ključne točke igrišča pokrivajo igralci ali druge ovire (npr. mreža, ki pokriva črto na najbolj oddaljenem igrišču od kamere, če je kamera postavljena prenizko), kar povzroči težave pri zaznavanju igrišča za odbojko ali žoge.
- Omejitve obdelave v realnem času: glede na računalniške vire in kompleksnost spletne aplikacije lahko pretakanje v realnem času in analiza videa (zlasti z višjo ločljivostjo) povzročita zakasnitev ali vplivata na zmogljivost.

5 Zaključek

V prispevku smo predstavili proces od začetne ideje do funkcionalne spletne aplikacije, ki nudi rešitev za prvotni koncept, ki je bil samodejna analiza in vizualna predstavitev rezultatov uporabniku. Uporabljene metode so temeljile na zbiranju, pripravi, označevanju in augmentaciji podatkov, ki so bili nato uporabljeni za učenje dveh konvolucijskih nevronske mreže. Naučeni modeli so bili nato uporabljeni v povezavi s perspektivno transformacijo igrišča za analizo in vizualno predstavitev rezultatov uporabniku. Končni rezultat je bil predstavljen kot uporabniku prijazna spletna aplikacija, kjer lahko uporabnik izbere želene video in v nekaj sekundah prejme osnovno analizo, vključno z zaznavo igrišča in sledenjem odbojcarski žogi.

Aplikacija ima kljub uspešni implementaciji nekaj slabosti in scenarijev, kjer rezultati niso takšni, kot so pričakovani. Izzivi vključujejo različne položaje kamere, barvne sheme žog in igrišč ali, motnje, ki lahko zakrijejo ključne točke igrišča ali samo žogo. Poleg tega lahko na obdelavo v realnem času vplivajo računalniške omejitve in kakovost videa, kar lahko vpliva na zmogljivost.

Kljub temu implementirana aplikacija služi kot temelj, ki omogoča številne nadgradnje, ki bi se lahko zgledovale po obstoječih rešitvah in izboljšale njihove pomanjkljivosti. Kot končni rezultat bi lahko uporabnikom posredovali realno časovno statistiko odbojcarske tekme, platformo pa bi lahko nadgradili tudi na druge športe in s tem pritegnili širši krog uporabnikov. Vsi našteti razlogi spodbujajo zavedanje, da vpeljava sodobnih tehnologij v vse segmente našega življenja, tudi šport, ni več binarno vprašanje, ampak zgolj vprašanje časa.

Viri in literatura

- Avais*. (2. 6 2024). Pridobljeno iz <https://www.avais.ai/features>
- B.T. Naik, M. H. (2022). A Comprehensive Review of Computer Vision in Sports: Open Issues, Future Trends and Research Directions. *Applied Sciences*.
- Balltime Academy*. (2. 6 2024). Pridobljeno iz What is Volleyball AI: <https://academy.balltime.com/getting-started/what-is-volleyball-ai>
- Hawk Eye*. (2. 6 2024). Pridobljeno iz <https://en.wikipedia.org/wiki/Hawk-Eye>
- Imgaug*. (2. 6 2024). Pridobljeno iz <https://imgaug.readthedocs.io/en/latest>
- Inside FIFA*. (2. 6 2024). Pridobljeno iz Semi-automated Offside Technology to be Used at FIFA World Cup 2022: <https://inside.fifa.com/technical/media-releases/semi-automated-offside-technology-to-be-used-at-fifa-world-cup-2022-tm>
- Joseph Redmon, S. D. (2016). You Only Look Once: Unified, Real-Time Object Detection. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (str. 779-788).
- Olympics*. (2. 6 2024). Pridobljeno iz IOC Takes the Lead for the Olympic Movement and Launches Olympic AI Agenda: <https://olympics.com/ioc/news/ioc-takes-the-lead-for-the-olympic-movement-and-launches-olympic-ai-agenda>
- Plankelj, M. (2025). Analiza odbojcarske igre z uporabo algoritmov računalniškega vida in strojnega učenja: magistrsko delo, Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko. Maribor.
- Roboflow*. (2. 6 2024). Pridobljeno iz Our Company: <https://roboflow.com/about>
- Ultralytics*. (2024). Pridobljeno iz YOLOv8 Models Documentation.
- World Health Organization*. (30. 8 2024). Pridobljeno iz Sports and Health Initiative: <https://www.who.int/initiatives/sports-and-health>

