

► Uporaba umetne inteligence in strojnega učenja v sodobnem nogometu: sistematični pregled literature

Rok Vrban¹, Seamus Kelly², Uroš Rajkovič¹, Mirjana Kljajić Borštnar¹

¹Fakulteta za organizacijske vede, 4000 Kranj

²University College Dublin, D04 C1P1 Dublin

rok.vrban@student.um.si, seamus.kelly@ucd.ie, uros.rajkovic@um.si, mirjana.kljajic@um.si

Izveček

Strojno učenje in umetna inteligenca postajata ključna dejavnika pri razvoju sodobnega nogometa, saj omogočata globlje razumevanje igralnih procesov in učinkovitejše odločanje. Namen sistematičnega pregleda literature je analizirati uporabo teh tehnologij pri prepoznavanju talentov, napovedovanju poškodb, napovedovanju rezultatov tekem ter analizi tehnično-taktičnih značilnosti igre. V pregled je bilo vključenih 35 empiričnih študij iz obdobja 2020 – 2025, pridobljenih iz vodilnih znanstvenih baz podatkov. Rezultati kažejo, da algoritmi strojnega učenja omogočajo bolj natančne in zanesljive napovedi ter razvoj individualiziranih trenažnih strategij v primerjavi s tradicionalnimi pristopi. Analiza potrjuje, da uporaba podatkovno podprtih metod izboljšuje proces selekcije, zmanjšuje tveganje za poškodbe in prispeva k večji taktični učinkovitosti ekip. Sistematični pregled poudarja potrebo po nadaljnjem razvoju standardiziranih modelov, ki bodo omogočili etično, varno in učinkovito uporabo umetne inteligence v športnem okolju.

Ključne besede: digitalne tehnologije, nogomet, strojno učenje, umetna inteligenca

Use of Artificial Intelligence and Machine Learning in Modern Football: A Systematic Review

Abstract

Machine learning and artificial intelligence are becoming key components in the development of modern football, enabling deeper insights into player performance and more effective decision-making.

The purpose of this study was to conduct a systematic literature review to analyze the use of these technologies in talent identification, injury prediction, match outcome forecasting, and technical-tactical performance analysis. The analysis included a total of 35 empirical studies published between 2020 and 2025, sourced from major scientific databases.

The results indicate that machine learning algorithms provide more accurate and reliable predictions and support the development of individualized training strategies compared to traditional approaches. The analysis confirms that data-driven methods enhance player selection, reduce injury risk, and improve teams' tactical efficiency. This systematic review highlights the need for further development of standardized models to ensure the ethical, safe, and effective implementation of artificial intelligence in sports environments.

Keywords: artificial intelligence, digital technologies, football, machine learning

1 UVOD

Nogomet je najpopularnejši šport na svetu, saj v njem po ocenah [1] aktivno sodeluje približno 270 milijonov ljudi. Njegov vpliv presega športno dimenzijo in vključuje pomembne ekonomske, družbene ter kulturne razsežnosti, kar ustvarja širok raziskovalni interes v različnih akademskih disciplinah, od sociologije in medicine do inženiringa in računalništva [2]. Zaradi svoje razširjenosti, kompleksnosti in strukturiranega tekmovalnega okolja se nogomet pogosto uporablja kot raziskovalni poligon za interdisciplinarne študije, saj omogoča preplet različnih metodoloških in teoretičnih pristopov. Globalizacija in hitro spreminjajoče se poslovno ter športno okolje zahtevata nove strategije upravljanja talentov tako v podjetjih kot v športnih organizacijah [3]. Povečana konkurenca in boj za vrhunske kadre sta povzročila, da so procesi identifikacije, razvoja in zadrževanja talentov strateško pomembni tudi v športu, zlasti v nogometu. Klubi in nogometne zveze so danes pod pritiskom, da obetavne športnike prepoznajo že v zgodnjih letih in jih razvijajo v profesionalne igralce najvišjega ranga [4].

Prepoznavanje talenta je kompleksen proces, ki vključuje identifikacijo posameznikov z izjemnimi sposobnostmi in napovedovanje njihovega potenciala za prihodnji razvoj. Tradicionalni postopki so pogosto temeljili na subjektivnih opažanjih trenerjev, intuiciji in trenutnih tekmovalnih rezultatih [5]. Takšni pristopi ne upoštevajo kompleksnosti razvoja igralcev in lahko vodijo do napačnih ocen, saj se osredotočajo na trenutno stanje, ne pa na dolgoročni potencial. Posledica so nesistematične in pristranske odločitve, ki lahko vodijo k izgubi talentov ali nezmožnosti doseganja njihovega polnega potenciala [6], [7].

Razlike med vrhunskimi športniki in manj uspešnimi posamezniki izhajajo iz kombinacije perceptivno-kognitivnih, motoričnih, psiholoških in okoljskih dejavnikov [8]. Ekološki pristop k razvoju talentov [9], [10] poudarja, da športni razvoj ni rezultat zgolj posameznikovih sposobnosti, temveč kompleksen preplet interakcij med športnikom in njegovim družbenim, kulturnim in fizičnim okoljem. Pomembni dejavniki vključujejo tako kraj rojstva, socialno-ekonomski status, športne politike, podporo družine, vrstnikov in trenerjev, kot dostop do športne infrastrukture ter kakovost razvojnih programov [11].

Raznolikost raziskovalnih pristopov na področju razvoja talentov potrjuje bogata paleta teoretičnih modelov, kot so Stages of Talent Development, Deliberate Practice, Developmental Model of Sport Participation (DMSP), Long-Term Athlete Development (LTAD), Differentiated Model of Giftedness and Talent (DMGT), Athletic Talent Development Environment Model (ATDE), Three-Dimensional Athlete Development Model (3D-AD) in Foundations, Talent, Elite and Mastery Framework (FTEM) [12]. Širjenje števila modelov odraža kompleksnost interakcij med posameznikom in njegovim okoljem, pri čemer je ključna sistematična in načrtna vadba v obdobju otroštva in adolescence [13].

Raziskave na področju nogometa se naslanjajo na različne metodološke pristope, od kvalitativnih intervjujev in obsežnih anket do sekundarnih analiz obstoječih podatkov in kvazi-longitudinalnih študij [14]. Longitudinalne raziskave omogočajo zanesljive rezultate, vendar so pogosto problematične zaradi možnega izpada sodelujočih, hitrega zastaranja meril ter omejene dostopnosti objektivnih kazalnikov uspešnosti [2], [15]. Zaradi tega narašča interes za sistematične preglede, ki združujejo kvantitativne, kvalitativne in mešane metode [16]–[19].

Z razvojem digitalnih tehnologij, umetne inteligence in zmogljivih računalniških orodij je šport vstopil v novo obdobje, kjer podatkovno podprti pristopi dopolnjujejo ali nadomeščajo tradicionalne metode [20], [21]. Nosljivi senzorji, sistemi GPS (angl. global positioning system – sistem globalnega pozicioniranja), avtomatizirana videoanalitika, strojno učenje ter orodja navidezne in obogatene resničnosti omogočajo zbiranje ogromnih količin podatkov o fizičnih, tehničnih, taktičnih in psiholoških značilnostih športnikov [5], [22]. Tako nastajajo celoviti profili igralcev, ki olajšajo razlikovanje med rastjo, zrelostjo in trenažno starostjo ter omogočajo personalizirane razvojne programe.

Vendar pa implementacija teh pristopov ni brez izzivov. Glavne ovire vključujejo pomanjkanje strokovnega znanja za interpretacijo podatkov, organizacijske omejitve ter pravna in etična vprašanja glede varstva osebnih podatkov [22]. Kljub temu se krepí zavedanje, da vlaganja v tehnološko infrastrukturo in usposabljanje kadrov prispevajo k dolgoročni konkurenčnosti nogometnih klubov [23].

Metode strojnega učenja so se v nogometu izkazale kot posebej obetavne na štirih področjih: napove-

dovanje poškodb, analiza tehnično-taktične uspešnosti, napovedovanje talentov ter napovedovanje rezultatov tekem [24]. Tehnološki napredek omogoča zbiranje in obdelavo podatkov, ki se v tradicionalnih postopkih ne bi mogli sistematično zajeti, kar omogoča objektivnejše, pravičnejše in natančnejše odločanje ter strateško načrtovanje.

S sistematičnim pregledom literature želimo predstaviti področja, hkrati pa povzemamo najnovejše ugotovitve o uporabi naprednih tehnologij, konkretnije uporabo strojnega učenja pri prepoznavanju in razvoju nogometnega talenta, napovedi poškodb, rezultatov in napovedi tehnično-taktičnih aspektov tekme. Osredotočamo se na empirične izsledke, tehnološke pristope, izzive in etične vidike ter ponujamo teoretični in aplikativni okvir za nogometne akademije in klube, ki želijo tehnologijo še bolj sistematično vključiti v svoje procese dela.

2 METODOLOGIJA

Pri pregledu literature smo upoštevali smernice PRISMA modela. Smernice so namenjene raziskovalcem v pomoč pri izvajanju in poročanju o sistematičnih pregledih in meta analizah na pregleden in ponovljiv način. Glavni cilj PRISME je izboljšati kakovost poročanja in zagotoviti, da so pregledi celoviti, sistematični in zanesljivi [25]. Z upoštevanjem smernic PRISMA zagotavljamo, da je naš pregled literature o uporabi strojnega učenja v nogometu metodološko zanesljiv, celovit in pregleden. To poveča zanesljivost naših ugotovitev in olajša ponovljivost drugim raziskovalcem.

Sistematično smo pregledali štiri spletne baze podatkov, in sicer Web of Science (WoS), Scopus, ScienceDirect in ProQuest Dissertations and Theses. Baze vsebujejo veliko število relevantnih člankov na področju športa, digitalnih tehnologij in upravljanja s človeškimi viri. Članke smo iskali v obdobju med leti 2020 in 2025, z namenom izluščanja najsodobnejših raziskav, ki povezujejo omenjena področja. V bazah smo iskali po sistemu ključnih besed v angleškem jeziku. Za ključne besede smo izbrali »Football«, »Soccer«, »Digital technology«, »Artificial Intelligence«, »Machine learning« in »Performance analysis«. S pomočjo Boolovih operatorjev AND in OR smo oblikovali iskalni niz: (football OR soccer) AND (digital technology OR artificial intelligence) AND (machine learning OR performance analysis). Iskanje literature je potekalo septembra 2025. Kot vključitvene kriterije

smo upoštevali posamezne kvantitativne raziskave, ki obravnavajo področje vpliva digitalnih tehnologij in umetne inteligence na prepoznavanje in razvoj talenta pri mladih nogometaših, so v angleškem jeziku in niso starejše od pet let (tabela 1).

Tabela 1: **Vključitveni in izključitveni kriteriji**

Vključitveni kriteriji
Populacija Profesionalni nogometaši
Intervencija Uporaba strojnega učenja za napoved poškodb, talenta ali rezultata
Primerjava Tradicionalni postopki in sodobni postopki napovedovanja
Izid Merila uspešnosti: poškodbe, talent, rezultat ali tehnično-taktične lastnosti
Vrste raziskav Empirične/kvantitativne
Časovni okvir Zadnjih 5 let (2020 – 2025)
Jezik Angleščina
Izključitveni kriteriji
Raziskave, ki se ne nanašajo na nogomet ali druge tematsko nesorodne raziskave, članki, ki se osredotočajo izključno na rekreativne ali amaterske igralce, ne-empirični prispevki, študije, ki ne uporabljajo digitalnih tehnologij ali umetne inteligence, publikacije, ki niso v angleškem jeziku, starejše raziskave.

Pri identifikaciji primerov (tabela 2) smo na osnovi naslovov, podnaslovov in povzetkov identificirali 146 zapisov gradiv v mednarodnih bazah podatkov Web of Science (n = 39), Scopus (n = 65), ScienceDirect (n = 26) in ProQuest Dissertations and Theses (n = 16), ki ustrezajo omenjenim iskalnim nizom. Ponavljajoči zapisi med bazami so bili trije. Po začetnem izločanju duplikatov smo v natančnejše preverjanje ustreznosti izbrali 143 zapisov. Na osnovi natančnejšega pregleda povzetka smo izločili 74 zapisov. Neizbrani zapisi so bili bodisi nerelevantni ali nespecifični za izbrano tematiko. Prav tako smo izločili zapise, pri katerih celotna vsebina ni bila na voljo. Vseh 69 zapisov smo nato natančneje pregledali, pri čemer smo 20 zapisov izločili bodisi zaradi neskladnosti oziroma premajhne sorodnosti z namenom naše analize primera. V zadnji fazi smo med 49 relevantnimi ter metodološko najustreznejšimi zapisi izbrali 35 zapisov.

Tabela 2: Identifikacija raziskav v podatkovnih bazah in registrih




Tabela 3: Prikaz raziskav, ki preučujejo uporabo metod strojnega učenja z izbranimi področji v nogometu

Avtor	Leto	Poškodbe	Talent	Rezultat	Tehnično/Taktične odločitve	N°
AlMulla, idr.	2020			✓		1
Rommers, idr.	2020	✓				2
Beal, idr.	2021			✓		3
Bauer, idr.	2021				✓	4
Goes, idr.	2021				✓	5
Jamil, idr.	2021		✓			6
Perri, idr.	2021				✓	7
Ćwiklinski, idr.	2021		✓			8
Sheng, idr.	2021				✓	9
Li & Hong	2022			✓		10

Di Giacomo, idr.	2022		✓	11
Sánchez Gálvez, idr.	2022		✓	12
Cho, idr.	2022		✓	13
Hecksteden, idr.	2022	✓		14
Valle, idr.	2022	✓		15
Buyrukoğlu & Savaş	2022		✓	16
Kelly, idr.	2022		✓	17
Hewitt & Karakuş	2023		✓	18
Forcher, idr.	2023		✓	19
AlMulla, idr.	2023		✓	20
Robles-Palazón, idr.	2023	✓		21
Mohandas, idr.	2023		✓	22
Munoz-Macho, idr.	2024	✓		23
Gu, idr.	2024		✓	24
Wong, idr.	2024		✓	25
Morciano idr.	2024		✓	26
Song, idr.	2024		✓	27
Duncan, idr.	2024		✓	28
Altmann, idr.	2024		✓	29
de Haan, idr.	2025		✓	30
Rahimian, idr.	2025		✓	31
van Arem, idr.	2025		✓	32
Takamido, idr.	2025		✓	33
Yazbeck, idr.	2025		✓	34
Freitas, idr.	2025	✓		35

3 REZULTATI

Rezultati raziskav kažejo, da strojno učenje pomembno prispeva k napovedovanju poškodb, razvoju talentov, napovedovanju rezultatov in analizi tehnično-taktičnih sposobnosti v nogometu. Na vseh področjih je mogoče opaziti jasne trende: modeli, ki vključujejo več virov podatkov in napredne algoritme, dosegajo večjo napovedno natančnost, medtem ko združevanje fizičnih, tehničnih, psiholoških in kontekstualnih kazalnikov omogoča celovitejše razumevanje igralčeve uspešnosti in potenciala.

3.1 Napovedovanje poškodb

Analiza šestih raziskav [26]–[31] kaže, da strojno učenje omogoča celovit pristop k napovedovanju poškodb in optimizaciji treninga. Vse raziskave temeljijo na prospektivnih vzorcih, ki obsegajo od 34 do 734 nogometašev in zajemajo tako mladince kot profesionalne igralce. Večina študij združuje različne vrste podatkov: antropometrične in fizične meritve, funkcionalne teste, zgodovino poškodb, podatke o treningu in tekmah ter klinične ali telemetrične podatke, kot so meritve GPS in ECG (angl. electrocardiogram – elektrokardiogram). Rommers idr. [26] in

Robles-Palazón idr. [29] so se osredotočili na mladinske igralce in identificirala kombinacije antropometričnih in funkcionalnih kazalnikov, ki napovedujejo tveganje poškodb spodnjih okončin. Hecksteden idr. [27] in Freitas idr. [31] poudarjajo pomen kombinacije predsezonskega ocenjevanja in dnevnega spremljanja, ki vključuje tako telesno obremenitev kot kontekstualne dejavnike treninga in tekme. Valle idr. [28] uporabljajo podatke magnetnoresonančnega slikanja (angl. magnetic resonance imaging – MRI) za napoved časa okrevanja po poškodbi, Munoz-Macho idr. [30] pa vključujejo profesionalno bazo ECG za odkrivanje srčnih anomalij. Skupna ugotovitev vseh raziskav je, da posamezni kazalniki, kot so starost, višina, moč ali hitrost, pogosto nimajo dovolj visoke napovedne moči, medtem ko njihova kombinacija z algoritmi strojnega učenja omogoča robustno identifikacijo tveganja poškodb. Gradient boosting modeli, zlasti XGBoost, so se izkazali kot učinkoviti pri klasifikaciji poškodb in napovedovanju časa okrevanja, medtem ko so druge metode, kot sta npr. Naključni gozd (angl. Random Forest) ali metoda podpornih vektorjev (angl. Support Vector Machine – SVM), primerna za specifične aplikacije, in sicer detekcijo srčnih anomalij ali spremljanje obremenitev med treningom. Pomemben vidik implementacije teh modelov je dostopnost in praktičnost podatkov. Merjenje ključnih kazalnikov, kot so fleksibilnost, moč, ravnotežje ali GPS parametri, je hitro in zahteva minimalno opremo, kar omogoča integracijo modelov v vsakodnevni trenažni proces. Prav tako je poudarjena kalibracija in validacija modelov, še posebej pri majhnih vzorcih ali nizki incidenci poškodb. Te raziskave kažejo, da strojno učenje omogoča celosten pristop k napovedovanju poškodb, optimizaciji treninga in izboljšanju kliničnega odločanja. Združitev več tipov podatkov, uporaba naprednih algoritmov in identifikacija kombiniranih kazalnikov omogoča ne le napoved poškodb, temveč tudi prilagojene intervencije za zmanjšanje tveganja in izboljšanje okrevanja. Kljub temu je potrebno nadaljnje raziskovanje z večjimi, raznolikimi vzorci ter vključevanje dinamičnega spremljanja in ponovljenih testiranj za izboljšanje napovedne natančnosti in generalizacijo modelov. Z metodološkega vidika ostaja napovedovanje poškodb tehnično zahtevno predvsem zaradi izrazite neuravnoteženosti podatkov (razredov), saj je poškodb v primerjavi z zdravimi opazovanji malo; posledično je ocena točnosti preoptimistična, zato so

primernejše mere, kot sta AUC (angl. area under the ROC curve – ploščina pod krivuljo ROC) in umerjenost napovedanih verjetnosti (angl. calibration), npr. Brierjeva ocena. Pri majhnih vzorcih, saj nekatere študije vključujejo le nekaj deset igralcev, se pojavlja tveganje prekomernega prilaganja (angl. Overfitting) in pristranskost ocen uspešnosti, kadar validacija ne poteka na ločeni, neodvisni ravni oziroma s prečnim preverjanjem. Modeli so večinoma validirani znotraj enega kluba ali ene sezone, zato je njihova zunanja in časovna posplošljivost šibka, prenos med ekipami z različnimi merilnimi protokoli (npr. različni GPS-sistemi in frekvence vzorčenja) pa pogosto sploh ni preverjen.

3.2 Identifikacija in razvoj talentov

Pregled sedmih raziskav kaže, da je za natančno ocenjevanje potenciala nogometašev potreben večdimenzionalen pristop, ki vključuje tehnične, fizične, psihološke in socialne dejavnike. Raziskave obravnavajo različne starostne skupine, od mladinskih akademij (U8–U19) do profesionalnih igralcev, in vključujejo različne pozicije, vključno z vratarji. Tehnični parametri, kot so natančnost podaj, hitrost reakcije in kontrola žoge, so ključni pri prestopih in selekciji igralcev. Fizične sposobnosti, kot so hitrost, moč, skok in aerobna zmogljivost, močno vplivajo na razvoj tehničnih veščin in uspešnost igralcev [32]–[34]. Psihološki dejavniki, vključno z odpornostjo, motivacijo in sposobnostjo strukturiranja treninga, omogočajo dolgotrajni razvoj in zmanjšujejo tveganje za prezgodnje izgorevanje ali neuspeh [35], [36]. Individualizacija treningov glede na starost, pozicijo in specifične sposobnosti se izkaže za učinkovito strategijo za razvoj talentov. De Haan idr. [37] so pokazali, da tradicionalna klasifikacija po pozicijah pogosto prikriva individualne razlike, medtem ko podatkovno vodeno gručenje omogoča natančnejšo prilagoditev treninga. Strojno učenje omogoča napoved kakovosti in tržne vrednosti igralcev, optimizacijo treningov ter personalizacijo razvoja, pri čemer rezultati temeljijo na kombinaciji tehničnih, fizičnih, psiholoških in socialnih kazalnikov. Vse raziskave poudarjajo, da uporaba strojnega učenja omogoča obdelavo velikih količin podatkov, identifikacijo ključnih dejavnikov in podporo pri odločanju glede prestopov, selekcije in razvoja mladih igralcev. Rezultati kažejo, da kombinacija tehničnih, fizičnih in psiholoških kazalnikov omogoča bolj zanesljive napovedi potenciala, med-

tem ko individualizacija treninga prispeva k optimizaciji razvoja talentov [38]. Pomembna omejitev tega področja je sama opredelitev ciljne spremenljivke: »talent« oziroma »uspeh«, saj je ocena le-tega mnogokrat posredna (npr. uvrstitev v profesionalno ekipo, tržna vrednost ali nadaljnja selekcija), kar v učne oznake vnaša subjektivnost in pristranskost. V vzorcih so praviloma le igralci, ki so že prešli predhodna sita selekcije. Pozitivni razred (perspektivni igralci) je redek, vzorci pa majhni in ne celoviti, zato modeli zlahka zajamejo značilnosti merilnega okolja namesto dejanskega potenciala. Pogosta je tudi visoka kolinearnost med antropometričnimi in fizičnimi atributi ter učinek relativne starosti, ki lahko pri gradnji ocene igralca popači pomembnosti spremenljivk. Zaradi tega so napovedi dolgoročnega razvoja kljub visoki točnosti na učnih podatkih le delno zanesljive brez večkratne validacije.

3.3 Napoved rezultatov tekem

Analiza devetih raziskav je pokazala, da uporaba strojnega učenja omogoča napoved rezultatov tekem z visoko natančnostjo, od 63 % do 85 %, odvisno od kakovosti in raznolikosti podatkov. Raziskave vključujejo profesionalne lige v Katarju, Angliji, Mehiki, na Kitajskem in svetovni nivo (FIFA World Cup). Viri podatkov vključujejo tehnične, fizične in taktične statistike igralcev, podatke o golih, kazalnike xG (angl. expected goals – pričakovani zadetki), sledenje igralcev in kontrolo prostora na igrišču. Pomembni napovedni dejavniki vključujejo natančnost strelav, uspešnost podaj, pretečeno razdaljo pri visokih hitrostih, discipliniranost (manj kartonov), kakovost napadov in posest žoge, pa tudi specifične xG kazalnike za posamezne igralce in pozicije. Sekvenčni modeli LSTM (angl. long short-term memory) in GRU (angl. gated recurrent unit) ter nevronske mreže ANN (angl. artificial neural network) in CNN (angl. convolutional neural network) so pokazali višjo napovedno moč kot klasični statistični modeli [39]. Vključitev več sezon ali zgodovinskih podatkov povečuje zanesljivost napovedi. Pomembno je tudi vključevanje kontekstualnih informacij, kot sta npr. značilnosti nasprotnika in okoljski pogoji [40]–[43]. Ansambelske metode (angl. ensemble learning) izboljšajo robustnost modelov, globoko učenje (angl. deep learning) pa omogoča razumevanje kompleksnih interakcij med tehničnimi, fizičnimi in taktičnimi kazalniki. Rezultati kažejo, da kombinacija tehničnih, fizičnih in

taktičnih kazalnikov omogoča celovito razumevanje uspešnosti ekip [44]. Sekvenčni modeli omogočajo ne le napoved rezultatov, temveč tudi vpogled v učinkovitost posameznikov, prostorsko kontrolo in optimizacijo taktičnih strategij [45], [46]. Pri tem je treba poročane natančnosti razlagati previdno. Nogometni izid je močno stohastičen pojav z nizko frekvenco golov, zato obstaja zgornja meja napovedljivosti, navedeni razpon (od 63 % do 85 %) pa ni neposredno primerljiv med študijami, ker se razlikujejo definicije naloge (dvorazredna ali trirazredna klasifikacija, angl. two-class or three-class classification, pri čemer trirazredna vključuje izenačenje kot samostojen razred), izbor lige in osnovne vrednosti. Trirazredna klasifikacija (zmaga, izenačenje, poraz) je zaradi izenačenj razredno neuravnotežena, kar lahko umetno zviša izmerjeno točnost modela (angl. inflated accuracy). Pri vključevanju statistik znotraj iste tekme obstaja resno tveganje uhajanja podatkov (angl. Data leakage), saj nekateri agregati (npr. skupni xG ali posest) postanejo na voljo šele po koncu dogodka; metodološko ustrezno je strogo časovno (kronološko) razdeljevanje podatkov in validacija na prihodnjih sezonah namesto naključnega prečnega preverjanja. Sekvenčni in globoki modeli (LSTM, GRU) so poleg tega podatkovno potratni in nagnjeni k prekomernemu prileganju pri kratkih časovnih vrstah ene lige, kar dodatno omejuje prenosljivost med tekmovanji.

3.4 Tehnično-taktične sposobnosti

Raziskave na tem področju kažejo, da je mogoče kvantificirati in napovedati timske taktične vzorce, spremljati igralce v realnem času ter oceniti individualno uspešnost [47]–[54]. Ugotovitve poudarjajo pomen prostorske razporeditve [55], kompaktnosti in koordiniranih premikov ekipe. Uspešen povratni pritisk po izgubljeni žogi (t. i. protipressing, angl. counter-pressing), ciljano asinhrono gibanje in ustvarjanje prostora povečujejo verjetnost strelav in golov, medtem ko neusklajena obramba povečuje tveganje prejetih zadetkov [56]. Individualne sposobnosti igralcev, kot so natančnost podaj, moč strelav, trajanje pritiska in uporaba telesa, so ključne za taktični uspeh. Sledenje igralcev z videom in biometričnimi podatki omogoča napoved pripravljenosti, uspešnosti in optimizacijo menjav. Napredni modeli, kot so naključni gozd (angl. Random Forest), nevronske mreže (ANN) in ansambelske metode [57], dosega-

jo visoko natančnost pri napovedi podaj, strelav in timskega vedenja [58]. Vizualizacije, kot so toplotne karte, radarji in 3D diagrami, trenerjem omogočajo celovito oceno igralcev, analizo nasprotnikov in strateško načrtovanje [59]. Strojno učenje tako omogoča natančno spremljanje tako timske kot individualnih taktičnih vzorcev, napovedovanje uspešnosti posameznikov, optimizacijo treningov, upravljanje menjav in podporo strateškemu odločanju [59], [60]. Integracija podatkov z algoritmi strojnega učenja omogoča interpretacijo in praktično uporabo analitike v realnem času. Tehnično najzahtevnejši del tega področja je sama priprava podatkov: analize slonijo na podatkih o sledenju dogodkovnih podatkih, ki jih dobavlja peščica lastniških ponudnikov kot sta npr. StatsBomb [61] in Wyscout [62], pri čemer se definicije dogodkov, frekvence vzorčenja in ročno označevanje med ponudniki razlikujejo, kar slabi ponovljivost in primerljivost rezultatov. Označevanje taktičnih konceptov (npr. povratni pritisk) je delno subjektivno, zato lahko v model vnese pristranskost označevalca. Pri spremljanju v realnem času so dodatni izzivi zakasnitve obdelave, sinhronizacija videa in pozicijskih tokov ter robustnost meritev. Ne nazadnje mnogi modeli (kot npr. nevronske mreže) delujejo kot črna škatla (angl. Black box), zato se v zadnjem času uveljavljajo metode razložljive umetne inteligence (npr. SHAP, angl. SHapley Additive exPlanations), ki naj bi trenerjem zagotovile preglednost (angl. transparency) in zaupanje v napovedi.

4 DISKUSIJA

Rezultati sistematičnega pregleda kažejo, da uporaba umetne inteligence in strojnega učenja v nogometu ni več zgolj teorija, temveč že konkretno vpliva na številna področja trenažnega procesa, selekcije in analize igre. Glavna ugotovitev raziskave je, da sodobni algoritmi omogočajo bolj natančne, objektivne in pravočasne odločitve v primerjavi s tradicionalnimi pristopi, ki so pogosto temeljili na subjektivni oceni trenerjev ali analitikov. To potrjuje premik v paradigmi, in sicer iz odločitev, ki bazirajo na izkušnjah k odločitvam, ki so podatkovno podprte.

Na področju napovedovanja poškodb rezultati dokazujejo, da kombinacija več vrst podatkov, kot so fiziološki, biomehanski, antropometrični in kontekstualnih, skupaj z naprednimi algoritmi, kot so XGBoost, naključni gozd (angl. random forest) ali metoda podpornih vektorjev (SVM), omogočajo bolj

zanesljivo prepoznavanje potencialnih poškodb. To odpira nove možnosti za preventivo in individualizacijo treningov. Pomemben prispevek teh modelov je tudi v sposobnosti zaznavanja skritih vzorcev, ki jih klasične metode statistične analize pogosto spregledajo. Kljub temu ostajajo izzivi pri prenosu modelov v prakso, predvsem zaradi potrebe po standardiziranih protokolih zbiranja podatkov, etične obravnave osebnih informacij ter pomanjkanja enotnih sistemov za validacijo modelov med različnimi ekipami.

V kontekstu razvoja talentov se jasno kaže pomen integracije večdimenzionalnih kazalnikov, kot so tehnični, fizični, kognitivni in socialni kazalniki. Raziskave potrjujejo, da strojno učenje omogoča identifikacijo obetavnih igralcev že v zgodnjih fazah razvoja, hkrati pa nudi orodja za načrtovanje personaliziranih razvojnih poti. Takšen pristop presega tradicionalne modele selekcije, ki pogosto temeljijo le na trenutni uspešnosti, saj omogoča napoved dolgoročnega potenciala. Pomemben vidik je tudi zmanjševanje pristranskosti pri ocenjevanju igralcev, kar prispeva k večji objektivnosti in pravičnosti procesa selekcije.

Pri napovedovanju rezultatov tekem je vidno, da kompleksni modeli, kot so nevronske mreže in rekurenčni algoritmi (LSTM, GRU), dosegajo visoko natančnost napovedi, hkrati pa omogočajo globlje razumevanje odnosa med tehničnimi, fizičnimi, kognitivnimi in taktičnimi spremenljivkami. Uporaba takih modelov daje klubom konkurenčno prednost, saj omogoča strateško pripravo na tekme in učinkovitejšo odločanje med igro. Zanimiv trend predstavlja tudi vključevanje zunanjih dejavnikov, kot so vremenske razmere, značilnosti nasprotnikov in psihološka priprava, kar dodatno povečuje robustnost modelov.

Analize tehnično-taktičnih sposobnosti so pokazale, da umetna inteligenca omogoča nov nivo razumevanja dinamike igre. Sledenje igralcev, prostorska analiza in algoritmi za prepoznavo vzorcev gibanja omogočajo natančno kvantifikacijo taktičnih odločitev in timske koherence. Takšne analize niso uporabne le za retrospektivno oceno tekem, temveč tudi za sprotno prilagajanje strategij med igro, kar lahko pomembno vpliva na izid.

Kljub številnim prednostim uporabe strojnega učenja v nogometu je treba opozoriti na več ključnih izzivov. Največji ostaja kakovost in dostopnost podatkov, saj so ti pogosto razpršeni med različnimi

sistemi, merilnimi orodji in organizacijami. Prav tako obstaja tveganje pretirane odvisnosti od algoritmov, kar lahko vodi v izgubo človeške presoje, ki je v športu še vedno ključna. Pomembno je ohraniti ravnovesje med tehnološko podporo in strokovnim znanjem trenerjev ter športnih analitikov. Etika uporabe osebnih podatkov športnikov ostaja občutljivo področje, kjer je potrebna ustrezna regulacija in nadzor. Poleg teh splošnih ovir je smiselno izpostaviti vrsto bolj specifičnih, tehničnih izzivov, ki se ponavljajo v pregledanih študijah. Mednje sodi razredna neuravnoteženost in majhni vzorci (značilni zlasti za napovedovanje poškodb in selekcijo talentov) pogosto vodijo v optimistično pristranske ocene uspešnosti; točnost je v takih primerih zavajajoča mera, ustrežnejše pa so npr. AUC, F1 in umerjenost napovedanih verjetnosti (angl. calibration). Naslednji problem je prevladujoča šibka validacija: modeli so večinoma preizkušeni le znotraj ene lige, enega kluba ali ene sezone, redko pa z zunanjo oziroma časovno (kronološko) validacijo. Težava lahko nastane tudi pri podatkih znotraj iste tekme, saj je pogosto prisotno tveganje uhajanja podatkov. Pomanjkljivost ocene modela lahko predstavljajo tudi sami podatki, saj so heterogeni in nestandardizirani: različni ponudniki sledilnih in dogodkovnih podatkov uporabljajo različne definicije dogodkov, frekvence vzorčenja in postopke označevanja, kar otežuje združevanje podatkov ter neposredno primerjavo med študijami. Večina uporabljenih pristopov je močno odvisna od ekspertnih definicij, kar v modele vnaša pristranskost in omejuje avtomatizacijo. Težave se lahko pojavijo tudi pri oceni napovedno najuspešnejših modelov (npr. nevronske mreže) saj so rezultati slabo razložljivi, zato se uveljavljajo metode razložljive umetne inteligence (npr. SHAP), ki povečujejo preglednost in zaupanje uporabnikov. In ne nazadnje, ponovljivost je nizka, saj so podatkovni nabori pogosto lastniški, koda in natančni protokoli pa redko javno dostopni; pomanjkanje skupnih primerjalnih naborov oziroma »benchmarking« onemogoča pošteno primerjavo med metodami. Naslavljanje teh tehničnih vrzeli, predvsem standardizacije podatkov, strožjih validacijskih protokolov in razložljivosti, je verjetno pomembnejši pogoj za zanesljivo rabo v praksi kot zgolj uvajanje kompleksnejših algoritmov.

Splošno gledano, sistematični pregled potrjuje, da umetna inteligenca in strojno učenje predstavljata pomemben paradigmatški premik v načinu razume-

vanja, analiziranja in upravljanja nogometnih procesov. Njuna uporaba ni omejena zgolj na elitni profesionalni nivo, temveč ima potencial tudi za mladinske akademije, kjer bi lahko pomagala pri zgodnjem odkrivanju in usmerjanju talentov. Nadaljnje raziskave bi morale vključevati longitudinalne pristope, primerjave med različnimi starostnimi in kakovostnimi ravnmi igralcev ter razvoj standardiziranih modelov za praktično uporabo.

Diskusija tako potrjuje, da je prihodnost nogometa neločljivo povezana z razvojem digitalnih tehnologij in zmožnostjo klubov, akademij ter trenerjev, da te tehnologije učinkovito integrirajo v svoje delovne procese. Umetna inteligenca ne nadomešča človeka, temveč razširja njegovo sposobnost zaznavanja, interpretacije in odločanja, kar pomeni, da bo vloga podatkovno pismenih strokovnjakov v prihodnje še pomembnejša.

5 ZAKLJUČEK

Pregled obstoječe literature jasno kaže, da strojno učenje in napredne digitalne tehnologije močno vplivajo na profesionalni nogomet. Pregledane študije potrjujejo dodano vrednost na vseh štirih obravnavanih področjih, in sicer pri napovedovanju poškodb, prepoznavanju in razvoju talentov, napovedovanju rezultatov ter analizi tehnično-taktičnih sposobnosti, pri čemer modeli, ki združujejo več virov podatkov in napredne algoritme, praviloma presegajo tradicionalne pristope. Te prednosti pa so v praksi pogojene z reševanjem tehničnih vrzeli, izpostavljenih v diskusiji, predvsem standardizacije podatkov, strožje zunanje in časovne validacije ter razložljivosti modelov, brez katerih ostaja posplošljivost rezultatov negotova. Za nogometne akademije in klube je zato priporočljivo postopno vključevanje podatkovno podprtih pristopov, v kombinaciji z ustreznim usposabljanjem kadrov in razvojem infrastrukture. Celovit in sistematičen pristop, ki vključuje več virov podatkov in napredne algoritme, omogoča ne le izboljšano odločanje na kratki rok, temveč tudi dolgoročni razvoj igralcev in optimizacijo uspešnosti ekip. Rezultati tega pregleda poudarjajo, da strojno učenje predstavlja strateško orodje, ki lahko transformira procese talent managementa, analize tekem in taktičnega planiranja v profesionalnem nogometu, s čimer odpira nove možnosti za inovativne in podatkovno vodene pristope v športni praksi.

6 LITERATURA

- [1] M. J. Asken and R. Rabinovici, »The global reach of soccer: cultural, medical, and performance perspectives,« *Sports Med.*, vol. 51, pp. 233–245, 2021. [Online]. Available: <https://doi.org/10.1007/s40279-020-01369-8>
- [2] A. M. Williams, *Science and soccer: developing elite performers*, 4th ed., London: Routledge, 2020.
- [3] B. Dalayga and A. Baskaran, »Globalization and talent management strategies in organizations,« *Int. J. Bus. Manage.*, vol. 14, no. 5, pp. 1–11, 2019. [Online]. Available: <https://doi.org/10.5539/ijbm.v14n5p1>
- [4] M. Carlsson-Wall, K. Kraus, and M. Messner, »Global talent management in professional football clubs,« *Account., Org. Soc.*, vol. 103, 101460, 2023. [Online]. Available: <https://doi.org/10.1016/j.aos.2022.101460>
- [5] N. Leite, J. Baker, and J. Sampaio, »Talent identification and development in sport: an overview of research and practice,« *Int. J. Sports Sci. Coaching*, vol. 16, no. 2, pp. 512–526, 2021. [Online]. Available: <https://doi.org/10.1177/1747954121992049>
- [6] A. H. Roberts, D. Greenwood, M. Stanley, C. Humberstone, F. Iredale, and A. Raynor, »Coach knowledge in talent identification: a systematic review and meta-synthesis,« *J. Sci. Med. Sport*, vol. 22, no. 10, pp. 1163–1172, 2019. [Online]. Available: <https://doi.org/10.1016/j.jsams.2019.05.008>
- [7] K. Till and J. Baker, »Challenges and future directions in talent identification and development in sport,« *Front. Sports Act. Living*, vol. 2, 601012, 2020. [Online]. Available: <https://doi.org/10.3389/fspor.2020.601012>
- [8] D. Farrow, »Expertise in sport skill acquisition and transfer: implications for talent identification and development,« *J. Sports Sci.*, vol. 28, no. 13, pp. 1347–1358, 2010. [Online]. Available: <https://doi.org/10.1080/02640414.2010.511752>
- [9] C. H. Larsen, D. Alfermann, K. Henriksen, and M. K. Christensen, »Successful talent development in soccer: the ecology of talent development environments in Denmark,« *Scand. J. Med. Sci. Sports*, vol. 23, no. 6, pp. 679–693, 2013. [Online]. Available: <https://doi.org/10.1111/sms.12018>
- [10] K. Henriksen, L. K. Storm, and C. H. Larsen, »Ecological approaches to talent development in sport: a review and future directions,« *Int. Rev. Sport Exerc. Psychol.*, vol. 16, no. 1, pp. 124–147, 2023. [Online]. Available: <https://doi.org/10.1080/1750984X.2021.1976748>
- [11] V. Gesbert, F. D'Arripe-Longueville, and D. Hauw, »Ecological dynamics and talent development in sport: the role of socio-cultural constraints,« *Front. Psychol.*, vol. 12, 627567, 2021. [Online]. Available: <https://doi.org/10.3389/fpsyg.2021.627567>
- [12] M. Barth, »Models of talent development in sport: a systematic review,« *Int. J. Sports Sci. Coaching*, vol. 15, no. 3, pp. 459–475, 2020. [Online]. Available: <https://doi.org/10.1177/1747954119897844>
- [13] J. Baker, N. Wattie, and J. Schorer, »A proposed conceptualization of talent in sport: the first step in a long and winding road,« *Psychol. Sport Exerc.*, vol. 51, 101804, 2020. [Online]. Available: <https://doi.org/10.1016/j.psychsport.2020.101804>
- [14] J. Baker and J. Schorer, »Identification and development of talent in sport – introduction to the special issue,« *Talent Dev. & Excellence*, vol. 2, no. 2, pp. 119–121, 2010.
- [15] T. L. G. Bergkamp, A. M. Tinga, A. S. M. Niessen, and W. G. P. Frencken, »The validity and reliability of talent identification tests in youth soccer: a systematic review,« *J. Sports Sci.*, vol. 37, no. 20, pp. 2310–2321, 2019. [Online]. Available: <https://doi.org/10.1080/02640414.2019.1643377>
- [16] M. Preciado, D. Villa, and M. Franco, »Mixed-methods systematic reviews in sport sciences: challenges and opportunities,« *Int. Rev. Sport Exerc. Psychol.*, vol. 12, no. 1, pp. 155–172, 2019. [Online]. Available: <https://doi.org/10.1080/1750984X.2018.1488262>
- [17] M. Sandelowski, C. I. Voils, and J. Barroso, »Defining and designing mixed research synthesis studies,« *Res. Schools*, vol. 13, no. 1, pp. 29–40, 2006.
- [18] M. Heyvaert, B. Maes, and P. Onghena, »Mixed methods research synthesis: Definition, framework, and potential,« *Qual. Quant.*, vol. 47, no. 2, pp. 659–676, 2013. [Online]. Available: <https://doi.org/10.1007/s11135-011-9538-6>
- [19] P. Pluye and Q. N. Hong, »Combining the power of stories and the power of numbers: mixed methods research and mixed studies reviews,« *Annu. Rev. Public Health*, vol. 35, pp. 29–45, 2014. [Online]. Available: <https://doi.org/10.1146/annurev-publhealth-032013-182440>
- [20] M. N. Elstak, P. Wylleman, and C. Visscher, »The integration of technology in talent development environments: a systematic review,« *Eur. J. Sport Sci.*, vol. 24, no. 1, pp. 45–63, 2024. [Online]. Available: <https://doi.org/10.1080/17461391.2023.2187610>
- [21] M. Lehnert, R. Vaeyens, and A. M. Williams, »Technology and youth soccer: a review of advances and applications,« *Sports Med.*, vol. 54, no. 2, pp. 231–248, 2024. [Online]. Available: <https://doi.org/10.1007/s40279-023-01885-2>
- [22] E. Monsees, »AI in football: challenges and opportunities in data-driven performance analysis,« *Artif. Intell. Sport*, vol. 2, no. 1, pp. 15–34, 2025. [Online]. Available: <https://doi.org/10.1016/j.aisport.2025.100021>
- [23] N. Chmait and H. Westerbeek, »Digital transformation in professional football: strategies for talent development and performance,« *Eur. Sport Manage. Q.*, vol. 21, no. 4, pp. 515–534, 2021. [Online]. Available: <https://doi.org/10.1080/16184742.2020.1791209>
- [24] M. Rico-González, A. Los Arcos, and F. Y. Nakamura, »Machine learning applications in soccer: a systematic review,« *Sports*, vol. 11, no. 2, 33, 2023. [Online]. Available: <https://doi.org/10.3390/sports11020033>
- [25] M. J. Abelha, S. Fernandes, D. Mesquita, F. Seabra, and A. T. Ferreira-Oliveira, »Graduate Employability and Competence Development in Higher Education—A Systematic Literature Review Using PRISMA,« *Sustainability*, vol. 12, 5900, 2020. [Online]. Available: <https://doi.org/10.3390/su12155900>
- [26] N. Rommers, R. Rössler, E. Verhagen, F. Vandecasteele, S. Verstockt, R. Vaeyens, M. Lenoir, E. D'Hondt, and E. Witvrouw, »A machine learning approach to assess injury risk in elite youth football players,« *Med. Sci. Sports Exerc.*, vol. 52, no. 8, pp. 1745–1751, 2020. [Online]. Available: <https://doi.org/10.1249/MSS.0000000000002305>
- [27] A. Hecksteden, G. P. Schmartz, Y. Egyptien, K. Aus der Füntten, A. Keller, and T. Meyer, »Forecasting football injuries by combining screening, monitoring and machine learning,« *Sci. Med. Football*, vol. 7, no. 3, pp. 214–228, 2022. [Online]. Available: <https://doi.org/10.1080/24733938.2022.2095006>
- [28] X. Valle, S. Mechó, E. Alentorn-Geli, et al., »Return to play prediction accuracy of the MLG-R classification system for hamstring injuries in football players: A machine learning approach,« *Sports Med.*, vol. 52, no. 12, pp. 2271–2282, 2022. [Online]. Available: <https://doi.org/10.1007/s40279-022-01672-5>
- [29] F. J. Robles-Palazón, J. M. Puerta-Callejón, J. A. Gámez, M. De Ste Croix, A. Cejudo, F. Santonja, P. Sainz de Baranda, and F. Ayala, »Predicting injury risk using machine learning in male youth soccer players,« *Chaos Solitons Fractals*, vol. 167,

- 113079, 2023. [Online]. Available: <https://doi.org/10.1016/j.chaos.2022.113079>
- [30] A. A. Munoz-Macho, M. J. Dominguez-Morales, and J. L. Sevillano-Ramos, »Analyzing ECG signals in professional football players using machine learning techniques,« *Heliyon*, vol. 10, no. 5, e26789, 2024. [Online]. Available: <https://doi.org/10.1016/j.heliyon.2024.e26789>
- [31] D. N. Freitas, S. S. Mostafa, R. Caldeira, F. Santos, E. Fermé, E. R. Gouveia, et al., »Predicting noncontact injuries of professional football players using machine learning,« *PLoS ONE*, vol. 20, no. 1, e0315481, 2025. [Online]. Available: <https://doi.org/10.1371/journal.pone.0315481>
- [32] M. Jamil, A. Phatak, S. Mehta, M. Beato, D. Memmert, and M. Connor, »Using multiple machine learning algorithms to classify elite and sub-elite goalkeepers in professional men's football,« *Sci. Rep.*, vol. 11, pp. 1–12, 2021. [Online]. Available: <https://doi.org/10.1038/s41598-021-01187-5>
- [33] M. J. Duncan, E. L. J. Eyre, N. Clarke, A. Hamid, and Y. Jing, »Importance of fundamental movement skills to predict technical skills in youth grassroots soccer: A machine learning approach,« *Int. J. Sports Sci. Coaching*, vol. 19, no. 3, pp. 1–15, 2024. [Online]. Available: <https://doi.org/10.1177/17479541231202015>
- [34] S. Altmann, L. Ruf, S. Thiem, T. Beckmann, O. Wohak, C. Romeike, and S. Härtel, »Prediction of talent selection in elite male youth soccer across 7 seasons: A machine-learning approach,« *J. Sports Sci.*, vol. 42, no. 24, pp. 2481–2494, Dec. 2024. [Online]. Available: <https://doi.org/10.1080/02640414.2024.2442850>
- [35] B. Ćwikliński, A. Giełczyk, and M. Choraś, »Who Will Score? A Machine Learning Approach to Supporting Football Team Building and Transfers,« *Entropy*, vol. 23, 90, 2021. [Online]. Available: <https://doi.org/10.3390/e23010090>
- [36] A. L. Kelly, C. A. Williams, and M. R. Wilson, »Machine learning and youth soccer development: opportunities and challenges,« *J. Sports Sci.*, vol. 40, no. 10, pp. 1112–1120, 2022. [Online]. Available: <https://doi.org/10.1080/02640414.2021.1965215>
- [37] M. de Haan, S. van der Zwaard, J. Sanders, P. J. Beek, and R. T. Jaspers, »Beyond playing positions: Categorizing soccer players based on match-specific running performance using machine learning,« *J. Sports Sci. Med.*, vol. 24, no. 3, pp. 565–577, 2025. [Online]. Available: <https://doi.org/10.52082/jssm.2025.565>
- [38] K. van Arem, F. Goes-Smit, and J. Söhl, »Forecasting the future development in quality and value of professional football players,« *Appl. Sci.*, vol. 15, no. 16, 8916, 2025. [Online]. Available: <https://doi.org/10.3390/app15168916>
- [39] A. M. Sánchez Gálvez, R. Álvarez González, S. Sánchez Gálvez, and M. Anzures García, »Model for prediction of the result of a soccer match based on the number of goals scored by a single team,« *Computación y Sistemas*, vol. 26, no. 1, pp. 295–302, 2022. [Online]. Available: <https://doi.org/10.13053/CyS-26-1-4172>
- [40] J. AIMulla and T. Alam, »Machine learning models reveal key performance metrics of football players to win matches in Qatar Stars League,« *IEEE Access*, vol. 8, pp. 213695–213705, 2020. [Online]. Available: <https://doi.org/10.1109/ACCESS.2020.3038601>
- [41] R. Beal, S. E. Middleton, T. J. Norman, and S. D. Ramchurn, »Combining machine learning and human experts to predict match outcomes in football: A baseline model,« *Proc. AAAI Conf. Artif. Intell.*, vol. 35, no. 13, pp. 15447–15455, 2021. [Online]. Available: <https://doi.org/10.1609/aaai.v35i13.17815>
- [42] J. AIMulla, M. T. Islam, H. R. H. Al-Absi, and T. Alam, »SoccerNet: A Gated Recurrent Unit-based model to predict soccer match winners,« *PLoS ONE*, vol. 18, no. 8, e0288933, 2023. [Online]. Available: <https://doi.org/10.1371/journal.pone.0288933>
- [43] Y. Song, G. Sun, C. Wu, B. Pang, W. Zhao, and R. Zhou, »Construction of 2022 Qatar World Cup match result prediction model and analysis of performance indicators,« *Front. Sports Act. Living*, vol. 6, 1410632, 2024. [Online]. Available: <https://doi.org/10.3389/fspor.2024.1410632>
- [44] Y. Li and Y. Hong, »Prediction of football match results based on edge computing and machine learning technology,« *Int. J. Mobile Comput. Multimedia Commun.*, vol. 13, no. 2, pp. 1–10, 2022. [Online]. Available: <https://doi.org/10.4018/IJM-CMC.293749>
- [45] A. Wong, E. Li, H. Le, G. Bhangu, and S. Bhatia, »A predictive analytics framework for forecasting soccer match outcomes using machine learning models,« *Decis. Anal. J.*, vol. 14, 100537, 2024. [Online]. Available: <https://doi.org/10.1016/j.dajour.2024.100537>
- [46] C. Gu, V. De Silva, and M. Caine, »A machine learning framework for quantifying in-game space-control efficiency in football,« *Knowl.-Based Syst.*, vol. 283, 111123, 2024. [Online]. Available: <https://doi.org/10.1016/j.knosys.2023.111123>
- [47] P. Bauer and G. Anzer, »Data-driven detection of counterpressing in professional football: A supervised machine learning task based on synchronized positional and event data with expert-based feature extraction,« *Data Min. Knowl. Discov.*, vol. 35, pp. 2009–2049, 2021. [Online]. Available: <https://doi.org/10.1007/s10618-021-00763-7>
- [48] F. R. Goes, M. S. Brink, M. T. Elferink-Gemser, M. Kempe, and K. A. P. M. Lemmink, »The tactics of successful attacks in professional association football: Large-scale spatiotemporal analysis of dynamic subgroups using position tracking data,« *J. Sports Sci.*, vol. 39, no. 5, pp. 523–532, 2021. [Online]. Available: <https://doi.org/10.1080/02640414.2020.1834689>
- [49] Z. Sheng, H. Zhang, J. Sun, et al., »GreenSea: a machine learning decision support system for soccer coaching,« *Expert Syst. Appl.*, vol. 176, 114897, 2021. [Online]. Available: <https://doi.org/10.1016/j.eswa.2021.114897>
- [50] H. Cho, H. Ryu, and M. Song, »Pass2vec: Analyzing soccer players' passing style using deep learning,« *Int. J. Sports Sci. Coaching*, vol. 17, no. 2, pp. 355–365, 2022. [Online]. Available: <https://doi.org/10.1177/17479541211033078>
- [51] T. Forcher, T. Beckmann, O. Wohak, C. Romeike, F. Graf, and S. Altmann, »Prediction of defensive success in elite soccer using machine learning Tactical analysis of defensive play using tracking data and explainable AI,« *Sci. Med. Football*, vol. 8, no. 4, pp. 317–332, 2023. [Online]. doi: 10.1080/24733938.2023.2239766.
- [52] R. Takamido, J. Ota, and H. Nakamoto, »PassAI: Explainable artificial intelligence algorithm for soccer pass analysis using multimodal information resources,« *arXiv*, 2025. [Online]. Available: <https://doi.org/10.48550/arXiv.2503.08945>
- [53] P. Rahimian, J. Flisar, and D. Sumpter, »Automated explanation of machine learning models of footballing actions in words,« *arXiv*, 2025. [Online]. Available: <https://doi.org/10.48550/arXiv.2504.00767>
- [54] M. Yazbeck, M. Abdullah, S. Alhanouti, E. Vatne, J. Hagen, T. T. Allen, and S. Krening, »Perfect shot reveal: Machine learning analysis of goal-scoring strategies in soccer,« *Int. J. Sports Sci. Coaching*, vol. 20, no. 4, pp. 1549–1563, 2025. [Online]. Available: <https://doi.org/10.1177/17479541251333941>

- [55] S. Buyrukoğlu and S. Savaş, »Stacked-based ensemble machine learning model for positioning footballer,« *Arab. J. Sci. Eng.*, vol. 48, pp. 1371–1383, 2022. [Online]. Available: <https://doi.org/10.1007/s13369-022-06857-8>
- [56] U. Di Giacomo, F. Mercaldo, A. Santone, and G. Capobianco, »Machine learning on soccer player positions,« *Int. J. Decis. Support Syst. Technol.*, vol. 14, no. 1, pp. 1–16, 2022. [Online]. Available: <https://doi.org/10.4018/IJDSST.286678>
- [57] G. Morciano, A. Zingoni, and G. Calabrò, »Optimization and comparison of machine learning algorithms for the prediction of the performance of football players,« *Neural Comput. Appl.*, vol. 36, pp. 19653–19666, 2024. [Online]. Available: <https://doi.org/10.1007/s00521-024-10260-9>
- [58] J. H. Hewitt and O. Karakuş, »A machine learning approach for player and position classification in football event data,« *Sports Analytics*, vol. 2, no. 1, 100015, 2023. [Online]. Available: <https://doi.org/10.1016/j.spa.2023.100015>
- [59] A. Mohandas, M. Ahsan, and J. Haider, »Tactically maximize game advantage by predicting football substitutions using machine learning,« *Big Data and Cognitive Computing*, vol. 7, no. 2, p. 117, 2023. [Online]. Available: <https://doi.org/10.3390/bdcc7020117>
- [60] P. Perri, C. Simonelli, A. Rossi, A. Trecroci, G. Alberti, and F. M. Iaia, »Relationship between wellness index and internal training load in soccer: Application of a machine learning model,« *Int. J. Sports Physiol. Perform.*, vol. 16, no. 5, pp. 695–703, 2021. [Online]. Available: <https://doi.org/10.1123/ijspp.2020-0093>
- [61] StatsBomb, »StatsBomb: Football data and analytics.« [Online]. Available: <https://statsbomb.com> (dostop: 5. 7. 2026).
- [62] Hudl, »Wyscout: Football video analysis and data platform.« [Online]. Available: <https://www.hudl.com/products/wyscout> (dostop: 5. 7. 2026).

■

Rok Vrban je magister ekonomskih in poslovnih ved ter zaposlen kot samostojni strokovni sodelavec in vodja projektov na Znanstveno-raziskovalnem središču (ZRS) Bistra Ptuj. Njegovo strokovno delo obsega predvsem vodenje mednarodnih razvojnih in raziskovalnih projektov (npr. v okviru programov Interreg). Raziskovalno je aktiven na področju športnega managementa, športne informatike ter uporabe digitalnih tehnologij in metod strojnega učenja (umetne inteligence) pri odločanju, s poudarkom na identifikaciji in analizi talentov v nogometnih akademijah ter klasifikaciji nogometnih tehnik.

■

Seamus Kelly je izredni profesor za športni menedžment na Šoli za javno zdravje, fizioterapijo in športne znanosti Univerze v Dublinu (UCD). Je nekdanji profesionalni nogometaš, ki je igral v Združenem kraljestvu in na Irskem, ter ima trenerske izkušnje na Irskem. Kot kvalitativni raziskovalec se posebej posveča preučevanju vidikov menedžmenta v profesionalnem nogometu.

■

Uroš Rajkovič je izredni profesor za področje informacijskih sistemov na Fakulteti za organizacijske vede (FOV) Univerze v Mariboru. Doktorat znanosti s področja managementa informacijskih sistemov je pridobil leta 2009 na FOV, kjer danes poučuje predmete s področja podatkovnih baz, sistemov za podporo odločanju in zdravstvene informatike. Njegovo raziskovalno delo se osredotoča na razvoj odločitvenih modelov (večkriterijsko kvalitativno modeliranje), zdravstveno informatiko (podpora odločanju v procesu zdravstvene nege) ter optimizacijo procesov z uporabo ekspertnih sistemov in simulacij. Je aktiven član uredniškega odbora revije *Uporabna informatika* in predsednik programskega odbora konference Vzgoja in izobraževanje v informacijski družbi (VIVID).

■

Mirjana Kljajić Borštnar je redna profesorica za področje informacijskih sistemov na Fakulteti za organizacijske vede Univerze v Mariboru. Njeno raziskovalno delo obsega uporabo metod umetne inteligence za podporo odločanju, podatkovno podprto odločanje ter digitalno preobrazbo organizacij. Je avtorica in soavtorica številnih znanstvenih člankov, objavljenih v mednarodnih znanstvenih revijah in zbornikih konferenc. Je so-predsedujoča programskemu odboru Blejske e-konference in Simpozija o operacijskih raziskavah v Sloveniji. Aktivno deluje v Slovenskem društvu INFORMATIKA kot glavna urednica revije *Uporabna informatika*.