Vedran Biokšić
Sveučilište u Mostaru, Filozofski fakultet
vedran.bioksic@gmail.com
Anita Glibić
Sveučilište u Mostaru, Filozofski fakultet
Ani.bosnjak@gmail.com
Nino Ćorić
Sveučilište u Mostaru, Filozofski fakultet
nino.coric@ff.sum.ba
UDK: 004.087: 004.8
004.087: 796.332
DOI: https://doi.org/10.47960/3029-3103.2025.11.109
Prethodno priopćenje

UPOTREBA UMJETNE INTELIGENCIJE ZA EVALUACIJU UČINKA NOGOMETAŠA I OBJAVA U ELEKTRONIČKIM MEDIJIMA: PRIMJER *SOFASCORE*

Sažetak

Sport, posebno nogomet, društveni je fenomen koji privlači milijune sportaša i još više navijača. Sportsko novinarstvo, kao posebna grana novinarstva, izvještava o sportskim događajima, natjecanjima, sportašima i ekipama. Obuhvaća analize, komentare, intervjue i istraživanja s ciljem informiranja, educiranja i zabave publike.

Takvo novinarstvo ima ključnu ulogu u informiranju navijača i ljubitelja nogometa o najnovijim događajima, rezultatima utakmica i učinku pojedinih igrača. Tradicionalno, novinari su koristili svoje subjektivne procjene i analize u vrednovanju učinka igrača. Međutim, razvojem umjetne inteligencije, sve je veći broj medijskih platformi koje koriste automatizirane sustave za evaluaciju učinka nogometaša poput aplikacije SofaScore. Ona koristi kompleksne algoritme za analizu različitih aspekata igre igrača, uključujući statistike, poziciju na terenu, ključne akcije i utjecaj na rezultat.

Ovaj rad donosi nove uvide u promjene u sportskom novinarstvu koje proizlaze iz primjene umjetne inteligencije. Cilj ovoga rada jest istražiti i analizirati primjenu umjetne inteligencije u sportskoj analitici i novinarstvu, s naglaskom na njezinu ulogu u evaluaciji učinka nogometaša. Temelji se na analizi primjene umjetne inteligencije u sportskoj analitici i novinarstvu kroz pregled dostupne literature, studije slučaja te komparativnu analizu alata poput SofaScore-a. Korištena je kvalitativna metoda analize ako bi se utvrdila količina i način korištenja aplikacije generiranom umjetnom inteligencijom na pet najčitanijih portala u Hrvatskoj. Hipoteza ovoga rada glasi: "Umjetna inteligencija se aktivno koristi u sportskoj analitici i novinarstvu, unapređujući proces sportskog izvještavanja i evaluacije učinka sportaša".

Ključne riječi: umjetna inteligencija (UI); sportsko novinarstvo; nogomet; učinak nogometaša.

USE OF ARTIFICIAL INTELLIGENCE FOR THE EVALUATION OF FOOTBALL PLAYERS' PERFORMANCE AND PUBLICATION IN DIGITAL MEDIA: THE CASE OF SOFASCORE

Abstract

Sport, especially football, is a social phenomenon that attracts millions of athletes and even more fans. Sports journalism, as a distinct branch of journalism, reports on sporting events, competitions, athletes, and teams. It includes analyses, commentaries, interviews, and investigations aimed at informing, educating, and entertaining the audience.

Such journalism plays a key role in informing fans and football enthusiasts about the latest events, match results, and the performance of individual players. Traditionally, journalists relied on their subjective assessments and analyses when evaluating players' performance. However, with the development of artificial intelligence, an increasing number of media platforms are using automated systems to evaluate football players' performance, such as the SofaScore application. This app uses complex algorithms to analyze various aspects of a player's game, including statistics, field position, key actions, and impact on the outcome.

This paper offers new insights into changes in sports journalism resulting from the application of artificial intelligence. The aim of the paper is to explore and analyze the use of artificial intelligence in sports analytics and journalism, with a focus on its role in evaluating football players' performance. It is based on an analysis of the use of artificial intelligence in sports analytics and journalism through a review of available literature, case studies, and a comparative analysis of tools such as SofaScore. A qualitative analysis method was used to determine the extent and manner in which AI-generated applications are used on the five most-read news portals in Croatia.

The hypothesis of this paper is: "Artificial intelligence is actively used in sports analytics and journalism, enhancing the process of sports reporting and the evaluation of athletes' performance."

Keywords: artificial intelligence (AI); sports journalism; football; football players' performance.

UVOD

Umjetna inteligencija (UI) sve više postaje ključna komponenta u različitim područjima života, a njezina primjena u sportu i novinarstvu posebno privlači pozornost. Nogomet je globalno najpopularniji sport kojeg prate milijarde ljudi, pogotovo na velikim natjecanjima te u koji se ulaže golema količina novca. Takva masovna popularnost i globalna gledanost stvorili su potrebu za primjenom suvremenih tehnologija u analizi podataka, s ciljem poboljšanja razumijevanja igre i njezinih elemenata. Umjetna inteligencija i strojno učenje omogućili su prikupljanje i obradu velikih količi-

na podataka, što je značajno unaprijedilo donošenje odluka u nogometu, od upravljanja momčadima do sportske analitike i medijskog izvještavanja. Statistička analiza, potpomognuta UI-em, omogućava detaljniju evaluaciju učinka igrača i momčadi, što zauzvrat utječe na sportske rezultate, menadžerske odluke i način izvještavanja o sportskim događajima.

S druge strane, novinarstvo se već desetljećima prilagođava tehnološkim inovacijama, a integracija umjetne inteligencije nudi nove mogućnosti u kreiranju sadržaja i prikupljanju informacija. Sportsko novinarstvo, kao grana specijaliziranoga novinarstva, prednjači u korištenju ovih tehnologija, omogućujući novinarima bržu obradu podataka i objektivniju evaluaciju sportaša.

Cilj ovoga rada jest istražiti i analizirati primjenu umjetne inteligencije u sportskoj analitici i novinarstvu, s naglaskom na njezinu ulogu u evaluaciji učinka nogometaša. Temelji se na analizi primjene umjetne inteligencije u sportskoj analitici i novinarstvu kroz pregled dostupne literature, studije slučaja te komparativnu analizu alata poput SofaScore-a. Korištena je kvalitativna metoda analize ako bi se utvrdila količina i način korištenja aplikacije generiranom umjetnom inteligencijom na pet najčitanijih portala u Hrvatskoj koji su određeni prema relevantnim izvorima.

Hipoteza ovoga rada glasi: "Umjetna inteligencija se aktivno koristi u sportskoj analitici i novinarstvu, unapređujući proces sportskog izvještavanja i evaluacije učinka sportaša".

1. UMJETNA INTELIGENCIJA I NOGOMET

Smatra se da je nogomet raširenija od demokracije, interneta ili tržišne ekonomije. Teško je naći mjesto gdje se ne igra, što potvrđuje "gledanost Svjetskog prvenstva FIFA-e 2018. od 3,5 milijarde ljudi, što predstavlja polovicu svjetske populacije starije od četiri godine".[1] Njegova popularnost i ekonomski utjecaj privukli su tehnologije poput umjetne inteligencije (UI) i velikih podataka. Umjetna inteligencija i strojno učenje omogućuju preciznije prikupljanje i analizu podataka, što poboljšava donošenje odluka u nogometu i upravljanju klubovima, a ključan je i utjecaj na sportsko izvještavanje, temu ovoga rada. "Umjetna inteligencija je proučavanje strojeva ili računalnih metoda koji opažaju, stječu znanje i donose odluke usklađene s ciljevima."[2]

1 Benno Torgler, „Big Data, Artificial Intelligence, and Quantum Computing in Sports", Sascha L. Schmidt (ur.), *21st Century Sports: How Technologies Will Change Sports in the Digital Age - second edition*, Springer, 2021., str. 169.

2 Chris Brady - Karl Tuyls - Shayegan Omidshafiei, *AI for Sports*, CRC Press, 2022., str. 1.

Pioniri u sportskim analizama, poput nogometnih trenera Charlesa Reepa i Valerija Lobanovskog, pokazali su moć podataka u nogometu, dok su knjiga *Moneyball* iz 2003. iako nije izravno povezana s UI-em te potom snimljeni istoimeni film podigli sportske analize na novu razinu.[3] Danas nove tehnologije omogućuju "snažnije informacijske sustave i napredne analize"[4] za postizanje konkurentskih prednosti, dok tehnološke inovacije postaju potencijalni katalizator zbivanja s "posebnim osvrtom u profesionalnom sportu na povećanje sustava i novih uređaja koji prikupljaju i pružaju podatke o praćenju pozicija igrača".[5]

UI se koristi za praćenje učinka momčadi i igrača. Danas različite metode umjetne inteligencije poput strojnog učenja (SL), računalnog vida (CV) i teorije igara daju ključne smjernice za donošenje odluka u sportu, posebno u nogometu. Značajan alat VAEP povezuje akcije igrača s rezultatom utakmice, evaluirajući doprinos svake akcije, poput udaraca i dodavanja.[6] "Osnovni alati statističkog učenja, kao što je analiza glavnih komponenti (PCA) već omogućuju automatsko prepoznavanje tipova igrača, treniranje modela za predviđanje putanja pojedinačnih timova ili oponašanje prosječnih ponašanja u ligi, te vrednovanje odluka pojedinih igrača (kao što su dodavanja ili uklizavanja) u nizu akcija koje vode do pogotka."[7] Na tragu takva analiziranja učinka ističe se relativno nov dodatak alatu za statistiku nogometa koji istraživači sa sveučilišta Leuven i tvrtka za podatkovnu inteligenciju SciSports (Enschede, Nizozemska) nazivaju VAEP (Procjena akcija pr. ocjenom vjerojatnosti). "Koncept pokušava povezati kako akcije igrača utječu na rezultat utakmice analizirajući i napadačke i obrambene doprinose. Model to čini evaluacijom učinka svake akcije s loptom na rezultat - udarci, dodavanja, driblinzi, uklizavanja itd. - kojih može biti čak 2000 po utakmici."[8] Prikupljanje i obrađivanje podataka je prije bio veoma zahtjevan proces, dok sad novi tehnološki razvoj omogućava automatsko generiranje podataka izravno iz video snimaka, čime se uklanjaju ljudski faktori iz procesa i automatski proizvode statistike performansi razumljive ljudima. Ovakva obrada podataka i mogućnosti koje nudi poput emitiranja uživo sigurno će povećati zanimanje i uključenost svih koji prate nogomet, a isto tako medijsko izvještavanje evaluacijom i ocjenom učinka nogometaša.

3 Usp. *Isto*, str. 40.
4 Adam Karg, „Data and the Sport Consumer", Michael L. Naraine - Ted Hayduk III - Jason P. Doyle (ur.), *The Routledge Handbook of Digital Sport Management*, Routledge, 2023., str. 273.
5 Robert Rein - Daniel Memmert, *Big data and tactical analysis in elite soccer: future challenges and opportunities for sports science*, Springerplus, 2016., str. 141.
6 Usp. C. Brady - K. Tuyls - S. Omidshafiei, *n. dj*., str. 74.
7 Tom Decroos i dr., „Actions speak louder than goals: Valuing player actions in soccer", *In Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*, KDD, 2019., str. 1853.
8 C. Brady i dr., *n. dj*., str. 74.

2. UMJETNA INTELIGENCIJA I NOVINARSTVO

Novinarstvo se oduvijek brzo prilagođavalo tehnološkim inovacijama, a danas se suočava s integracijom umjetne inteligencije u medijsko izvještavanje. Prikupljanje informacija i kreiranje vijesti uvijek su bili izazovi za novinare, koji su često koristili kreativne pristupe i različite alate. Pojavom Interneta novinarski rad doživio je značajan pomak, a UI donosi novu evoluciju u tom procesu. "AI danas ima široku ulogu u analizi podataka, personalizaciji sadržaja, istraživačkom novinarstvu i uredničkim odlukama",[9] te u provjeri lažnih vijesti.[10]

Jedan od pionira računalno potpomognutog izvještavanja bio je Phillip Meyer, koji je 1967. godine koristio statističku analizu kako bi opovrgnuo teze o društvenom porijeklu sudionika nereda u Detroitu. Za ovo istraživanje dobio je Pulitzerovu nagradu, a njegovo djelo smatra se prvim pokušajem primjene analitičkih metoda društvenih znanosti i računala kao alata u novinarstvu.[11] Tijekom godina računalno potpomognuto izvještavanje evoluiralo je u podatkovno novinarstvo "koje obuhvaća analizu i vizualizaciju podataka, računalno novinarstvo, kartografiju te izvještavanje o algoritamskoj odgovornosti".[12]

Podatkovno novinarstvo danas ima još šire dimenzije, uključujući interakciju s korisnicima preko vizualnih prikaza i aplikacija temeljenih na UI. Autori Fernandez i dr. u svom istraživanju[13] ističu kako ono omogućuje analizu velike baze podataka za predstavljanje i otkrivanje vijesti. Novinari u svome radu koriste podatke u raznim izvještavanjima, a autori tu vrstu novinarstva zovu podatkovno novinarstvo. Druga skupina autora smatra "da je zahvaljujući dostupnosti podataka i alata podatkovno novinarstvo postalo središnji oblik izvještavanja".[14]

---

9 Bahroun Zied i dr., „Transforming Education: A Comprehensive Review of Generative Artificial Intelligence in Educational Setting through Bibliometric and Content Analysis", *Sustainability*, MDPI, 15(17), 2023., str. 11.

10 Usp. Nicholas Diakopoulos, *Automating the news: How algorithms are rewriting the media*, Harvard University Press, 2019., str. 68.

11 Vidi: Alexandre Lechenet, *Global database investigations: The role of the computer-assisted reporter*, Reuters Institute fellowship paper, 2014., str. 5.

12 Meredith Broussard, *Artificial Unintelligence: How Computers Misunderstand the World*, The MIT Press, 2018., str. 45.

13 Sonia Parratt-Fernández - Javier Mayoral-Sánchez - Montse Mera-Fernández, „The application of artificial intelligence to journalism: an analysis of academic production", *Profesional de la información*, 30(3), 2021., str. 6.

14 Olga Kalatzi - Charalampos Bratsas - Andreas Veglis, „The Principles Featur es and Techn iques of Data Journalism", *Studies in Media and Communication*, 6(2), 2018., str. 43.

Automatizirano novinarstvo, gdje vijesti generiraju računala bez ljudske intervencije, poznato je kao algoritamsko ili robotsko novinarstvo.[15] Međutim, Diakopulos[16] navodi ograničenja automatiziranoga novinarstva, uključujući fleksibilnost, interpretaciju i kvalitetu pisanja. Kombinacija podatkovnoga i računalnoga novinarstva predstavlja najbolji pristup, jer UI aplikacije omogućuju novinarima brzu analizu i obradu podataka, što dovodi do kvalitetnijeg izvještavanja i dublje analize vijesti.

2.1. Stvaranje novih vrijednosti u novinarstvu

Postoji detaljna podjela faza integracije umjetne inteligencije u novinarstvo. U posljednjim desetljećima 20. stoljeća javili su se prvi digitalni alati i baze podataka, dok su početkom 21. stoljeća uvedeni generirani jezik i automatizacija sadržaja. Razvojem algoritama i strojnog učenja omogućena je analiza velike količine podataka i predikcije događanja, a "posljednje desetljeće donosi uspon personalizacije sadržaja, provjere činjenica i borbu protiv lažnih vijesti, uz sve češća etička pitanja".[17]

Lutz[18] ističe da je UI postala središnja sastavnica modernoga novinarstva, osobito u analizi i obradi podataka. Uloga novinara se u potpunosti mijenja, a autori smatraju kako korištenjem umjetne inteligencije u redakciji dobivaju priliku za kvalitetnije izvještavanje, što potvrđuje i Marconi: "Umjesto trošenja vrijednih radnih sati, na transkripciju intervjua i ručno unošenje podataka, novinarske dnevne dužnosti mogu biti usmjerene na donošenje važnih odluka i istraživanje tragova dobivenih iz uvida umjetne inteligencije."[19] Broussard[20] smatra kako umjetna inteligencija obavlja dosadne poslove, dok se novinari mogu usredotočiti na zanimljivije poslove. Time su novinari dobili prostor "da sada mogu dublje ući u komplekse priče, koristeći svoju ljudsku introspekciju, empatiju, istraživačke vještine na načine koji prije nisu bili mogući".[21] Iako UI otkriva i prati događaje, Diakopulos naglašava da tehnologija ne može zamijeniti novinare.[22] Automatizacija omogu-

15 Usp. Matt Carlson, „The robotic reporter: Automated journalism and the redefinition of labor, compositional forms, and journalistic authority", *Digital journalism*, 3(3), 2015., str. 416-431.

16 Usp. N. Diakopoulos, *n. dj.*, str. 9.

17 Peter N. Amponsah - Atianashie Miracle Atianashie, „Navigating the New Frontier: A Comprehensive Review of AI in Journalism", *Advances in Journalism and Communication*, 12(1), 2024., str. 3.

18 Usp. Cristoph Lutz, „Digital Inequalities in the Age of Artificial Intelligence and Big Dana", *Human Behavior and Emerging Technologies*, 1, 2019., str. 141-148.

19 Francesco Marconi, *Newsmakers: Artificial Intelligence and the future of journalism*, Columbia University Press, 2020., str. 38.

20 Usp. M. Broussard, *n. dj.*, str. 178.

21 P. N. Amponsah i dr., *n. dj.*, str. 5.

22 Usp. N. Diakopoulos, *n. dj.*, str. 28.

ćuje širinu pokrivenosti prikupljanja informacija i vijesti, dok kombinacija s novinarima dodaje dubinu i kvalitetniji sadržaj prikupljenim vijestima.[23]

Drugi autor Davis[24] ističe da nove tehnike omogućuju gledanje podataka na načine koji bi inače bili nemogući. UI ubrzava procese i olakšava prikupljanje vijesti zamjenjujući ljudski napor. "Rudarenje podataka može ubrzati procese brže nego što bi to ikada mogla osoba, kao i uštedjeti napor ljudi koji bi inače morali neprestano pratiti izvore informacija."[25] Integracija UI u novinarstvo "pojednostavila je procese i obogatila sadržaj, označavajući značajan napredak u izvještavanju".[26] Prisutnost UI u novinarstvu nije pitanje budućnosti - ona je već duboko integrirana pa stoga novinari i medijske kuće moraju početi prihvaćati novu stvarnost. "Nije pitanje hoće li novinari koristiti podatke, već kako, kada, gdje i zašto."[27]

Diakopoulos[28] predlaže stvaranje zasebnoga studija za računalno i podatkovno novinarstvo, gdje će biti potrebne vještine kombiniranja podataka, algoritama i društvenih konteksta.

2.2. Primjena umjetne inteligencije u sportskom novinarstvu

Novinarstvo se prvo može podijeliti prema vrsti medija (televizija, radio, tisak, web), a zatim prema sadržaju (politika, sport, kultura). "Specijalizirano novinarstvo odnosi se na prikupljanje i distribuciju informacija o specifičnim temama."[29] Razvoj specijaliziranoga novinarstva uslijedio je nakon industrijske revolucije, kada su tematske cjeline tiska konkurirale radiju i televiziji. Sport je brzo postao popularna tema u specijaliziranom novinarstvu, a sportski kanali na televiziji potvrdili su njegovu važnost. Prema Vasilju, "sportsko novinarstvo najavljuje, prenosi, komentira i analizira sportske događaje".[30]

Pojavom umjetne inteligencije sportsko novinarstvo brzo je usvojilo nove tehnologije. Algoritmi mogu koristiti velike količine statističkih podataka,[31] a predlošci se lako prilagođavaju rezultatima.[32] Zbog toga sportsko

23 *Isto*, str. 49.
24 Prema Chase Davis u N. Diakopoulos, *n. dj.*, str.79.
25 N. Diakopoulos, *n. dj.*, str. 79.
26 P. N. Amponsah i dr., *n. dj.*, str. 8.
27 O. Kalatzi i dr., *n. dj.*, str. 40.
28 N. Diakopoulos, *n. dj.*, str. 251.
29 Vicente Romano, „Introducción al Periodismo", *Barcelona - Teide*, 1984., str. 11.
30 Miroslav Vasilj, *Sportsko novinarstvo*, Synopsis, 2014., str. 23.
31 Vidi: Seth C. Lewis - Amy Kristin Sanders - Casey Carmody, „Libel by Algorithm? Automated Journalism and the Threat of Legal Liability", *Journalism, and Mass Communication Quarterly*, 96, 2019., str. 67.
32 Vidi: Arjen van Dalen, „The algorithms behind the headlines: How machine-written news redefines the core skills of human journalists", *Journalism Practice*, 6, 2012., str. 649.

novinarstvo predvodi u korištenju umjetne inteligencije u proizvodnji vijesti.[33] Diakopoulosove teorije o širini i dubini pokrivenosti prikupljanja i obrađivanja vijesti zahvaljujući umjetnoj inteligenciji u medijima se najbolje vide na primjerima sportskoga novinarstva. Zbog sportskih događaja koji se nerijetko odigravaju u istim terminima zahvaljujući alatima umjetne inteligencije može doći do automatskog objavljivanja vijesti. Upravo to radi Associated Press u suradnji s Automated Insight, "koji koristi tehnologiju prirodnog jezika za prevođenje statistika u narative".[34] Zahvaljujući aplikacijama generiranim umjetnom inteligencijom, novinari brže dolaze do informacija te imaju vremena za kvalitetnije istraživanje, analizu sportskih nastupa i učinka sportaša, kao i za različite predikcije i najave mnogih sportskih događaja. Marconi ističe da strojno učenje u košarci može upozoriti novinare na neobične statističke korelacije, čime poboljšava sportsko izvještavanje.[35]

Objektivno ocjenjivanje učinka nogometaša na terenu je oduvijek bio izazov za sportske novinare, a nije zanemariv ni veliki pritisak koji trpe od nogometaša, njihovih obitelji, prijatelja, menadžera kao i kolega novinara.[36] Zdravko Reić, koji je gotovo cijelu karijeru i životni vijek proveo kao novinar u tiskanim novinama, ističe kako "kriterij u ocjenjivanju igrača isključivo treba biti doprinos na terenu", a kod portala isti novinar primjećuje izostanak ocjenjivanja nogometaša od strane novinara smatrajući kako "ne žele preuzeti odgovornost kako ne bi pogriješili".[37] UI i strojno učenje omogućili su novu razinu evaluacije performansi momčadi i igrača. Kroz sustave poput VAEP-a, koji procjenjuje učinak svake pojedinačne akcije na ishod utakmice. Aplikacije generirane umjetnom inteligencijom, a jedna od mnogo njih je Sofascore, koja je zauzela primat u domaćim medijima.

3. *SOFASCORE*

Sofascore je sportska platforma u obliku aplikacije koja je primarno nastala za praćenje rezultata uživo, s vrlo velikom pokrivenošću od 20.000 natjecanja u više od 20 različitih sportova. Vrlo brzo proširila je svoje djelovanje na detaljne statistike uz kvalitetne pružatelje podataka, distribuirajući pouzdane i dubinske statistike za momčadi, igrače i utakmice.[38]

33 João Canavilhas, „Artificial Intelligence and Journalism: Current Situation and Expectations in the Portuguese Sports Media", *Journal Media*, 2022., str. 513.
34 N. Diakopoulos, *n. dj.*, str. 376.
35 Usp. F. Marconi, *n. dj.*, str. 80.
36 Prema: Zdravko Reić, u: M. Vasilj, *n. dj*., str. 131.
37 *Isto*, str. 131.
38 „Inspired by sports, driven by dana", *Sofascore - službena web stranica*, https://corporate.sofascore.com/about, (28. IX. 2024.).

Već je istaknut značaj vizualizacije u medijskom izvještavanju i ulozi umjetne inteligencije, a kroz ovu aplikaciju svi podatci prikupljeni tijekom natjecanja uživo vizualiziraju se. Za utakmice se posebno ističu "Attack Momentum", "Attribute Overview", "Sofascore Heatmap" i "Shotmap".[39] Posebno je popularan i zanimljiv "Sofascore rating", odnosno evaluacija učinka nogometaša na terenu jedinstvenom ocjenom.

Aplikacija uz pomoć algoritma analizira stotine podataka primljenih od pružatelja podataka, koje tijekom svake utakmice izračunava, a zatim sve te složene podatke pretvara u jedan jedinstveni broj/ocjenu. Kako su iz Sofascorea naglasili "algoritam za ocjenjivanje nezamisliv je bez odgovarajuće statističke analize".[40] Početci su bili sa znatno manje podataka, ali s godinama je skup podataka dramatično rastao, što je omogućavalo lakše utvrđivanje korelacija između sirovih podataka i ishoda utakmica. Iz Sofascorea su potvrdili da su, uz veću količinu podataka, krenuli u smjeru korištenja prediktivne analize kako bi dali još više konteksta ocjenjivanju. Ukupna distribucija ocjena po svim pozicijama, prema njihovim riječima, gotovo je savršena normalna distribucija.

Algoritam koristi primljene podatke, a neki od pozitivnih čimbenika koji utječu na ocjenu nogometaša su postizanje gola, dodijeljena asistencija, stvaranje velike prilike, obrana jedanaesterca, spašavanje sigurnog pogotka, izboren jedanaesterac, čišćenje lopte s gol-linije, uspješna obrana skokom itd.[41] Negativni čimbenici koji utječu na konačnu ocjenu uključuju isključenje igrača, postizanje autogola, skrivljeni jedanaesterac, grešku koja je dovela do gola, propuštenu veliku priliku, neuspješne driblinge, izgubljene dvoboje itd.[42]

Sofascore rating danas je skaliran na više od 250 nogometnih natjecanja, od kojih se 180 pokriva ažuriranje ocjena uživo otprilike 60 puta tijekom utakmice. To je značajan broj iteracija koje dodaju dimenziju učinkovitosti u jednadžbu. Algoritam se kontinuirano poboljšava s dostupnošću novih podataka kako bi dao najbolji mogući prikaz igračeve izvedbe, istaknuli su iz Sofascorea.

39 Usp. *N. mj*.
40 Službeni odgovori iz Sofascorea.
41 „Inspired by sports, driven by dana", *Sofascore - službena web stranica*, https://corporate.sofascore.com/about, (28. IX. 2024.).
42 *N. mj*.

4. ISTRAŽIVANJE: APLIKACIJA *SOFASCORE* U MEDIJSKOM IZVJEŠTAVANJU *ONLINE* MEDIJA U HRVATSKOJ

Prema istraživanju Reutersova[43] instituta, čak 80 % građana najviše konzumira vijesti preko online medija, a nakon njih slijede televizija, društvene mreže i tiskani mediji. Prema istom izvoru, najčitaniji web portal u Hrvatskoj za 2023. i 2024. godinu je Index.hr, a slijede ga 24sata.hr, Dnevnik.hr, Jutarnji.hr i Tportal.hr. Prema mjerenju čitanosti portala Gemius, Indeks.hr nije obuhvaćen, a od preostalih na vrhu se nalaze Jutarnji.hr, 24sata.hr, Dnevnik.hr i Večernji.hr. SimilarWeb[44] kao najčitanije portale u Hrvatskoj navodi Index.hr i Jutarnji.hr.

Za potrebe ovoga rada analizirano je pet portala koji se uglavnom ponavljaju u više relevantnih izvora kao najčitaniji i najpopularniji: Index.hr, Jutarnji.hr, 24sata.hr, Dnevnik.hr i Večernji.hr. Važno je naglasiti kako Jutarnji.hr ima posebnu sportsku verziju portala sportske.jutarnji.hr, koja će biti predmet istraživanja, kao i gol.dnevnik.hr, koji je dio portala Dnevnik.hr. Istraživanje je provedeno za travanj 2024. godine.

Svi analizirani portali koristili su aplikaciju Sofascore za evaluaciju učinka nogometaša i izvještavanje o njihovim izvedbama na terenu. Prema broju objavljenih članaka, najčitaniji portal Index.hr najviše koristi aplikaciju Sofascore, a odmah iza njega slijedi 24sata.hr. Sportske.jutarnji.hr i gol.dnevnik.hr rjeđe koriste ovu aplikaciju, dok se Večernji.hr nalazi u sredini.

Index.hr je u travnju 62 puta koristio aplikaciju Sofascore za analizu učinka nogometaša ili ocjenjivanje igrača nakon završetka utakmica. Ova redovita upotreba obuhvaćala je analizu više od 20 igrača, uglavnom iz domaćega hrvatskog prvenstva te ključnih igrača u borbi za naslov, ali i nastupa hrvatskih nogometaša u europskim ligama. Nešto manje analizirani su učinci stranih nogometaša u ligama petice i europskim ligama, kao i analize i komentari uz moguće najave prelaska nogometaša iz jednoga u drugi klub.

Nakon Index.hr, portal 24sata.hr koristio je aplikaciju 26 puta, uglavnom za ocjene nogometaša u domaćem prvenstvu i nastupe hrvatskih igrača u inozemstvu. Jedan od zanimljivijih članaka bila je analiza povratničkoga nastupa Ivana Perišića nakon ozljede.[45]

43 Zrinjka Peruško, „Croatia", *Reuters Institute*, 14. VI. 2023., https://reutersinstitute.politics.ox.ac.uk/digital-news-report/2023/croatia, (28. IX. 2024.).

44 „Similar web", službena web stranica, https://pro.similarweb.com/#/digitalsuite/home.

45 Boris Trifunović, „Perišić debitirao i dobio ovacije Riječana. Evo koliko je Hajduk akcija stvorio s njim, koliko bez", *24sata.hr*, 7. 4. 2024., https://www.24sata.hr/sport/perisic-debitirao-i-dobio-ovacije-rijecana-evo-koliko-je-hajduk-akcija-stvorio-s-njim-koliko-bez-975464, (28. IX. 2024.).

Večernji.hr je aplikaciju Sofascore koristio manje u odnosu na prethodna dva portala, no objavio je nekoliko detaljnih analiza učinka različitih nogometaša. Jedan od zanimljivijih članaka bio je onaj koji se bavio analizom uspješnosti izvođenja kaznenih udaraca Luke Modrića. Nakon što je promašio kazneni udarac u utakmici Lige prvaka, Sofascore je, uz pomoć svoje baze podataka, analizirao sve Modrićeve kaznene udarce u karijeri i usporedio ih s učincima drugih hrvatskih reprezentativaca.[46]

Gol.dnevnik.hr je u travnju koristio aplikaciju osam puta, s naglaskom na analize učinka hrvatskih nogometaša u europskim ligama, posebno onih koji bi mogli postati kandidati za nastup na Europskom prvenstvu.

Sportske novosti najmanje su koristile aplikaciju Sofascore - samo četiri puta. One su jedini analizirani portal koji se u većoj mjeri oslanja na tradicionalno vrednovanje učinka nogometaša od strane novinara koji prate utakmicu.

Osim Sofascorea portali su povremeno koristili i podatke iz drugih izvora generiranih umjetnom inteligencijom, poput CIES-a i Football Meetsa, no takva praksa bila je rijetka.

4.1. O čemu su pisali portali uz pomoć aplikacije *Sofascore*

Na portalu Index.hr jedan od istaknutih primjera je analiza učinka novog igrača Bayerna Münchena, Nestoryja Irankundea, koji dolazi iz australske momčadi Adelaide United.[47] S obzirom na slabiju praćenost australske lige, bilo je teško doći do relevantnih informacija o njegovim kvalitetama. Ipak, koristeći SofaScore, izrađene su sve relevantne statistike njegovih nastupa, poput broja odigranih utakmica, postignutih pogodaka, kreiranih velikih prilika, uspješnosti u dvobojima i slično. Novinari su iskoristili priliku i napisali članak u kojem su ga usporedili sa zvijezdom Manchester Cityja, Erlingom Haalandom, i njegovim brojkama iz razdoblja kada je bio u istim godinama kao spomenuti nogometaš. Ovo potvrđuje teoriju da novinari, uz pomoć alata umjetne inteligencije, lakše mogu doći do novih vijesti te se, koristeći algoritme, mogu upustiti u kvalitetnije analize i komentare.

Na portalu 24sata.hr izdvaja se tekst o povratničkom nastupu Ivana Perišića u dresu Hajduka nakon dugog izbivanja zbog ozljede.[48] Iako je proveo

46 Martin Bubanović, "Treba li Modrić i dalje pucati penale za vatrene? Njegova statistika ne izgleda najbolje", *Vecernji.hr*, 18. 4. 2024., https://www.vecernji.hr/sport/treba-li-modric-i-dalje-pucati-penale-za-vatrene-njegova-statistika-ne-izgleda-najbolje-1762662, (28. IX. 2024.).

47 "Novi Haaland? U Australiji su ga otkrili Hrvati, sad će igrati za Bayern", *Indeks.hr*, 16. IV. 2024., https://www.index.hr/sport/clanak/novi-haaland-u-australiji-su-ga-otkrili-hrvati-sad-ce-igrati-za-bayern/2556833.aspx, (28. IX. 2024.).

48 B. Trifunović, „Perišić debitirao i dobio ovacije Riječana. Evo koliko je Hajduk akcija stvorio s njim, koliko bez", (28. IX. 2024.).

vrlo kratko vrijeme na terenu, novinarima je to bilo dovoljno da analiziraju koliko je Hajduk imao veći posjed lopte s njim u igri, koliko je kreirano opasnih prilika te da vizualnim prikazom potvrde napadačke akcije.

Portal Večernjeg lista manje je koristio SofaScore u svojim tekstovima, ali se posebno ističe analizom uspješnosti izvođenja kaznenih udaraca Luke Modrića.[49] Modrić je promašio kazneni udarac u utakmici Lige prvaka, što je novinarima bio dovoljan povod za analizu i raspravu o tome bi li trebao nastaviti izvoditi kaznene udarce u dresu reprezentacije. Uz pomoć aplikacije SofaScore, analizirani su njegovi kazneni udarci kroz cijelu karijeru, a njegova uspješnost uspoređena je s drugim hrvatskim reprezentativcima, poput Andreja Kramarića, Ante Budimira, Brune Petkovića i Lovre Majera.

Novinari na navedenim portalima izvještavanje i analize učinka nogometaša najviše su fokusirali na hrvatsko prvenstvo, pri čemu su posebno do izražaja došle ocjene igrača i određivanje momčadi kola na temelju tih ocjena. Nekada su različiti novinari pratili utakmice i donosili subjektivne procjene o nogometašima, dok danas algoritmi na jednak način pristupaju izvedbama svih igrača na svim utakmicama hrvatske nogometne lige. Umjetna inteligencija donosi veću objektivnost i točnost u procjeni učinka igrača na terenu, istovremeno smanjujući utjecaj subjektivnih procjena novinara i trenera.

ZAKLJUČAK

Razvoj umjetne inteligencije (UI) donosi revolucionarne promjene u nogometu i sportskom novinarstvu, pružajući preciznije analize i drugačije razumijevanje sportskih događaja, omogućavajući novu razinu evaluacije performansi momčadi i igrača. Sustavima koji procjenjuju učinak svake pojedinačne akcije na ishod utakmice, UI donosi objektivnost i točnost procjene učinka igrača na nogometnom terenu, uz istovremeno smanjivanje utjecaja subjektivnih procjena novinara i trenera.

Podatkovno novinarstvo, koje koristi velike baze podataka za analizu i izvještavanje, omogućuje novinarima učinkovitije i brže kreiranje vijesti. UI je posebno značajan u sportskom novinarstvu, gdje algoritmi koriste podatke za automatsko generiranje izvještaja i ocjenjivanje performansi sportaša. Primjerice analizirana aplikacija Sofascore koristi umjetnu inteligenciju za praćenje i evaluaciju učinka nogometaša. Njihova ocjenjivanja, temeljena na podatcima o svakom potezu igrača tijekom utakmice, postala su ključna referenca u sportskim medijima, što potvrđuje i analiza najčitanijih portala u Hrvatskoj.

49 M. Bubanović, „Treba li Modrić i dalje pucati penale za vatrene? Njegova statistika ne izgleda najbolje“, (28. IX. 2024.).

Ovaj alat omogućuje dublju analizu i uvid u igre, što novinarima daje više prostora za interpretaciju i predikcije, odnosno što se naziva kvalitetnijim novinarstvom ili novinarstvom višega reda.

Hipoteza ovoga rada glasila je "Umjetna inteligencija se aktivno koristi u sportskoj analitici i novinarstvu, unapređujući proces sportskog izvještavanja i evaluacije učinka sportaša". Analizom dostupne literature i teorijskih osnova, a zatim i provedenog istraživanja, može se zaključiti kako je hipoteza potvrđena.

Algoritmi omogućuju novinarima da se usmjere na složenije zadatke poput analize i komentiranja, dok automatski generirani podatci osiguravaju preciznost u evaluaciji. Povećana je mogućnost prikupljanja novih vijesti i otkrivanja novih priča. Novinari sada jednim alatom mogu istražiti učinke nogometaša u različitim ligama, što im je prije bilo potpuno nedostupno ili su se morali oslanjati na izvještavanja inozemnih medija.

Unatoč tome što još uvijek ne može u potpunosti zamijeniti novinarske vještine poput empatije, kreativnosti i istraživačkoga pristupa, umjetna inteligencija postala je neizbježan alat u modernom sportskom novinarstvu koji transformira način na koji se vijesti stvaraju, prenose i konzumiraju. Njegova primjena, osobito u nogometu, omogućava dublje razumijevanje igre i pruža preciznije ocjene igrača, čime se podiže razina kvalitete izvještavanja u sportskim medijima. Novinari, koristeći prednosti umjetne inteligencije, imaju priliku razviti nove forme izvještavanja i obogatiti sadržaj koji donose svojoj publici.

Doprinos znanosti je analiza korištenja UI-a u sportskim medijima, naglašavanje objektivizacije sportskih analiza i automatizacije novinarskog izvještavanja, što može utjecati na način interpretacije sportskih podataka. Buduća istraživanja mogu se usmjeriti na korištenje drugih alata umjetne inteligencije poput prediktivnih modela, vizualizacije podataka, ili drugih statističkih stranica. Posebno istraživanje može se odnositi na etičke aspekte korištenja UI-a u sportskom novinarstvu, utjecaj UI-evaluacija na karijere sportaša te usporedbu različitih UI sustava u procjeni učinka igrača.