

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**ANALIZA DEJAVNIKOV PRIVZEMANJA PODATKOVNE
ANALITIKE V SLOVENSKEM NOGOMETU**

Ljubljana, junij 2023

MATIC MORI

IZJAVA O AVTORSTVU

Podpisani Matic Mori, študent Ekonomske fakultete Univerze v Ljubljani, avtor predloženega dela z naslovom Analiza dejavnikov privzemanja podatkovne analitike v slovenskem nogometu, pripravljenega v sodelovanju s svetovalcem red. prof. dr. Jurijem Jakličem in sosvetovalcem red. prof. dr. Goranom Vučkovičem

IZJAVLJAM

1. da sem predloženo delo pripravil samostojno;
2. da je tiskana oblika predloženega dela istovetna njegovi elektronski obliki;
3. da je besedilo predloženega dela jezikovno korektno in tehnično pripravljeno v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani, kar pomeni, da sem poskrbel, da so dela in mnenja drugih avtorjev oziroma avtoric, ki jih uporabljam oziroma navajam v besedilu, citirana oziroma povzeta v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani;
4. da se zavedam, da je plagiatorstvo – predstavljanje tujih del (v pisni ali grafični obliki) kot mojih lastnih – kaznivo po Kazenskem zakoniku Republike Slovenije;
5. da se zavedam posledic, ki bi jih na osnovi predloženega dela dokazano plagiatorstvo lahko predstavljalo za moj status na Ekonomski fakulteti Univerze v Ljubljani v skladu z relevantnim pravilnikom;
6. da sem pridobil/-a vsa potrebna dovoljenja za uporabo podatkov in avtorskih del v predloženem delu in jih v njem jasno označil;
7. da sem pri pripravi predloženega dela ravnal v skladu z etičnimi načeli in, kjer je to potrebno, za raziskavo pridobil/ soglasje etične komisije;
8. da soglašam, da se elektronska oblika predloženega dela uporabi za preverjanje podobnosti vsebine z drugimi deli s programsko opremo za preverjanje podobnosti vsebine, ki je povezana s študijskim informacijskim sistemom članice;
9. da na Univerzo v Ljubljani neodplačno, neizključno, prostorsko in časovno neomejeno prenašam pravico shranitve predloženega dela v elektronski obliki, pravico reproduciranja ter pravico dajanja predloženega dela na voljo javnosti na svetovnem spletu preko Repozitorija Univerze v Ljubljani;
10. da hkrati z objavo predloženega dela dovoljujem objavo svojih osebnih podatkov, ki so navedeni v njem in v tej izjavi.

V Ljubljani, dne _____

Podpis študenta: _____

KAZALO

UVOD	1
1 PODATKOVNA ANALITIKA	3
1.1 Opredelitev podatkovne analitike	3
1.1.1 Analitika masovnih podatkov.....	5
1.1.2 Integracija podatkovne analitike.....	5
1.2 Podatkovna analitika v športu	6
1.2.1 Moneyball kot prva zgodba o uspehu	6
1.2.2 Razvoj podatkovne analitike v športu.....	8
1.2.3 Negotovost podatkovne analitike v športu.....	9
2 PRIMERI UPORABE PODATKOVNE ANALITIKE V NOGOMETU	10
2.1 Pričakovani zadetki in nadgradnje	11
2.1.1 Definicija pričakovanih zadetkov	11
2.1.2 Uporaba pričakovanih vrednosti.....	13
2.2 Iskanje talentov in rekrutiranje igralcev	14
2.2.1 Tradicionalno in analitično iskanje talentov	15
2.2.2 Primeri uporabe pri iskanju talentov.....	16
2.2.3 Naprednejši modeli ocenjevanja igralcev	19
2.3 Taktična priprava na tekme in poročila	20
2.3.1 Podatki o dogodkih.....	21
2.3.2 Sledljivi podatki.....	22
2.4 Ostali primeri uporabe	23
2.5 Povzetek primerov uporabe	24
3 PRIVZEMANJE PODATKOVNE ANALITIKE V NOGOMETU	25
3.1 Teorija razširjanja inovacij	25
3.2 Okvir tehnologija – organizacija – okolje	27
3.2.1 Tehnološki kontekst.....	27
3.2.2 Organizacijski kontekst.....	29
3.2.3 Kontekst okolja.....	31
3.3 Modeli sprejemanja tehnologije	32
3.4 Primerjava modelov in združevanje	36

4	EMPIRIČNA RAZISKAVA UPORABE PODATKOVNE ANALITIKE V SLOVENSКИH NOGOMETNIH ORGANIZACIJAH	38
4.1	Načrt raziskave in metodologija	38
4.2	Rezultati in ključne ugotovitve	40
5	DISKUSIJA	46
5.1	Dejavniki privzemanja	47
5.2	Dejavniki sprejemanja	54
5.3	Ključni dejavniki in predlogi	55
	SKLEP	60
	LITERATURA IN VIRI	62

KAZALO TABEL

Tabela 1: Potencialni primeri uporabe.....	24
Tabela 2: Potencialno pomembni dejavniki privzemanja.....	36
Tabela 3: Potencialno pomembni dejavniki sprejemanja	37
Tabela 4: Demografski podatki sogovornikov.....	39
Tabela 5: Tabelarični povzetek pomembnosti dejavnikov privzemanja	56

KAZALO SLIK

Slika 1: Primerjalni radar.....	17
Slika 2: Primerjava večjega nabora igralcev.....	18

SEZNAM KRATIC

angl. – angleško

DOI – (angl. Diffusion of Innovation); teorija razširjanja inovacij

np_xG – (angl. Non-Penalty Expected Goals); pričakovani zadetki brez enajstmetrovk

PEOU – (angl. Percieved Ease of Use); zaznana enostavnost uporabe

PU – (angl. Percieved Usefulness); zaznana uporabnost

PS_xG – (angl. Post-Shot Expected Goals); pričakovani zadetki po strelu

TAM – (angl. Technology Acceptance Model); model sprejemanja tehnologije

TOE – (angl. Techonlogy-Organization-Environment Framework); okvir tehnologija-organizacija-okolje

xG – (angl. Expected Goals); pričakovani zadetki

xGOT – (angl. Expected Goals on Target); pričakovani zadetki pri streljih v okvir vrat
xT – (angl. Expected Threat); pričakovana nevarnost

UVOD

Z digitalizacijo in vsesplošnim napredkom je v svetu na voljo tudi vse več podatkov, ki s pomočjo napredne analitike omogočajo pridobivanje ključnih informacij za sprejemanje pravih odločitev. Te informacije lahko na primer pomagajo reševati največje svetovne družbene probleme (Alsunaidi in drugi, 2021), hkrati pa nudijo nov način konkuriranja v poslovnem okolju. Dandanes recimo zares težko najdemo konkurenčno organizacijo, ki pri svojem poslovanju ne uporablja podatkov – ne glede na panogo, lokacijo ali velikost.

V zadnjem času je zaradi poslovnega razcveta in vse večjih finančnih vložkov podatkovna analitika zelo prisotna tudi na področju športa. Veliko prelomnico predstavlja koncept Moneyball, ki opisuje zgodbo o uspešni uporabi podatkovne analitike v bejzbolu, zaradi katere se je za vedno spremenil pogled na podatke in odločanje v športu (Lewis, 2004). Dostopnost orodij in podatkov je skozi čas analitiko razširila tudi v ostale športe, kjer je popularnih zgodb o uspehih podatkovne analitike vse več. Veliko medijske pozornosti je v zadnjem obdobju denimo požela avstralska plavalna reprezentanca, ki je na OI 2022 v Tokiu presenetljivo osvojila kar 8 zlatih medalj, svoje uspehe pa med drugim pripisala uporabi podatkovnega jezera (angl. data-lake) (Sharma, 2021). V Evropi se največ pričakovano dogaja v nogometu, kjer vzpon klubov pod vodstvom karizmatičnega Matthewa Benhama (Brentford, Midtjylland) navdušuje mnoge (Hellier, 2021; Wigmore, 2018), medtem ko na univerzah že obstajajo samostojni izobraževalni programi na to tematiko (University of Akron, brez datuma; Uppsala Universitet, brez datuma).

Vrednosti nogometnih prestopov dosegajo astronomske zneske (rekord Brazilca Neymarja – 222 milijonov €), zato je vsekakor smiselno razmisliti tudi o okrepitev v smislu podatkovnih strokovnjakov (Harper, 2021). Še posebej to velja za manjše klube, ki si, podobno kot A's iz uspešnice Moneyball, ne morejo privoščiti milijonskih okrepitev. Med takšne zagotovo spadajo tudi slovenski nogometni klubi, ki za konkurenco zaostajajo v precejšnji meri ravno zaradi finančnih omejitev. Tudi zato bi bilo nerazumljivo, če tega ne bi poskusili nadoknaditi na alternativen način (Gavião, Sant'Anna, Alves Lima & de Almada Garcia, 2020).

Kljub številnim uspešnim primerom v zadnjem času so v splošnem odločevalci v nasprotju s prej omenjenim bejzbolom še vedno nagnjeni k tradicionalnemu odločanju, kar predstavlja enega od temeljnih izzivov glede uporabe podatkovne analitike v nogometu. Z drugimi besedami, odločevalci v nogometu dvomijo v vpliv poznavanja števil na izboljšanje rezultatov in že precej časa zavračajo idejo o tem, da v njihovem športu obstaja nekaj, na kar niso dovolj pozorni (Kuper & Szymanski, 2009).

Analitika v nogometu je sicer zelo raznolika in variira od relativno preprostih poročil in vizualizacij do zelo zahtevnih matematičnih modelov. Najbolj priljubljena področja vključujejo iskanje talentov, trening ali preprečevanje poškodb in različne analize ali poročila pred ter po tekmah – najpogosteje glede taktike, realizacije plana, nasprotnikov in

podobno (Bornn, Cervone & Fernandez, 2018; Kröckel, 2019; Pavitt, Braines & Tomsett, 2021).

Čeprav se je sicer v nogometu napredna analitika razširila skoraj povsod, tudi po precej manj prepoznavnih tekmovanjih (npr. belgijsko, švedsko in gruzijsko prvenstvo), bi po lastnih izkušnjah, brskanju po spletu in pogovorih s strokovnjaki (G. Vučković, pogovor, 15. 4. 2022) lahko sklepal, da je v slovenskem športu zaenkrat uporaba podatkovne analitike zelo skromna. Določene znanstvene raziskave v smeri analitike v športu sicer obstajajo, a v splošnem tega vsaj zaenkrat še ni uspelo povezati s prakso. Pri tem razmisleku pa kaj hitro pridemo do vprašanja, zakaj je to tako? Kaj je tisto, v čemer se slovenski klubi razlikujejo od na primer švedskih? Kateri so ključni dejavniki za (ne)privzemanje podatkovne analitike kot inovacije? Pred samo implementacijo je seveda treba premostiti nekaj ovir, pri čemer se mnoge nanašajo ravno na privzemanje in sprejemanje podatkovne analitike kot nove tehnologije, saj je odločitev glede uporabe novosti vse prej kot trivialna (Saha, 2019).

Pri tem gre namreč organizacija skozi celoten proces **privzemanja** (angl. adoption), ki vključuje čas od seznanjenja z neko novo tehnologijo do trenutka, ko jo začnemo uporabljati. Nanaša se na vidik organizacije in se začne že pri samem prepoznavanju obstoja določene tehnologije. Glede same uporabe je v okviru privzemanja ključnega pomena **sprejemanje** (angl. acceptance), ki se v večji meri nanaša na posameznika in se pri uporabi nove tehnologije sprašuje predvsem o uporabnikovi motivaciji glede uporabe novosti. Uporabnik se sprašuje, ali bo z uporabo hitreje, lažje ali bolje opravil svoje delo (Hernandez, Jimenez & José Martín, 2009).

Ker je poznavanje dejavnikov privzemanja podatkovne analitike v nogometu ključnega pomena za morebitno povečanje uporabe, želim z raziskavo preveriti stanje podatkovne analitike v slovenskem nogometu in identificirati dejavnike, ki na uporabo vplivajo, ter s pomočjo ugotovitev spodbuditi uporabo podatkovne analitike v slovenskih nogometnih organizacijah. Iz vsega zapisanega tako izhaja namen magistrskega dela kot povečanje oziroma spodbuditev uporabe podatkovne analitike v nogometu v Sloveniji. Temu primerno raziskovalno vprašanje je: »Kako povečati smiselno in koristno uporabo podatkovne analitike v nogometu v Sloveniji?«

Temeljni cilj magistrskega dela je identificirati najpomembnejše dejavnike privzemanja podatkovne analitike v slovenskem nogometu in analizirati, kaj bi bilo na podlagi ključnih ugotovitev smiselno narediti oziroma spremeniti ter posledično bolje izkoristiti priložnosti, ki se ponujajo v obliki analitike. Prvi podrejeni cilj je pregled obstoječe literature na temo podatkovne analitike nasploh, primerov uporabe v športu in predvsem v nogometu ter podroben pregled modelov za privzemanje in sprejemanje tehnologije, ki mu sledita tudi kritična analiza in aplikacija privzemanja na izbrano tematiko. Ob predlaganih dejavnikih identificiram tudi najpomembnejša gonila in ovire glede implementacije podatkovne analitike v slovenskem nogometnem prostoru. Naslednji cilj je izvedba empirične raziskave v obliki intervjujev, s katero raziščem trenutno stanje podatkovne analitike v nogometu v

Sloveniji in predvsem preverim relevantnost identificiranih dejavnikov privzemanja iz literature. Za potrebe intervjuja je eden izmed ciljev tudi priprava primernih primerov uporabe (angl. use case).

Uvodni del magistrskega dela temelji na osnovnem teoretičnem pregledu podatkovne analitike nasploh in primerov v športu s poudarkom na nogometu. Sledi predstavitev in vpeljava modelov privzemanja, pri čemer se naslonim na že obstoječe raziskave domačih in tujih raziskovalcev. Tako predstavim širše področje in definiram osnovne pojme, ki so potrebni za nadaljnjo raziskavo. Prav tako na podlagi modelov privzemanja in lastnega razmisleka identificiram predvidene dejavnike privzemanja ter sprejemanja podatkovne analitike v nogometu. Glavni del obravnavane literature predstavljajo znanstveni članki, pridobljeni iz podatkovni baz, ki so dostopne preko digitalne knjižnice DiKUL, medtem ko preostali del literature predstavljajo predvsem knjige in drugi članki.

V nadaljevanju se z raziskovanjem po spletu opredelim do možnosti uporabe podatkovne analitike v nogometu, pregledam primere uporabe in najustreznejše tudi identificiram. Pri tem sem pozoren na to, da so primeri primerni in prilagojeni izbranemu respondentu. Empirični del magistrskega dela temelji na polstrukturiranih intervjujih, sestavljenih na podlagi ugotovitev iz pregleda znanstvene literature. Pogovori so bili izvedeni s 6 posamezniki, ki delujejo v klubih 1. slovenske lige in bi jim lahko podatkovna analitika tako ali drugače koristila – tukaj ciljam predvsem na trenerje, njihove pomočnike in »analitike«, če v klubih obstajajo (več v poglavju 4.1). Prvi del služi ugotavljanju trenutne uporabe podatkovne analitike, medtem ko se v drugem delu osredotočim na analizo ključnih gonil, ovir in dejavnikov privzemanja ter sprejemanja.

Na koncu vse skupaj povežem v celoto s poudarkom na diskusiji in lastnem razmisleku, pri čemer izkoristim svoje izkušnje in teoretična znanja, pridobljena v času podiplomskega študija. Oblikujem okvir, na podlagi katerega bomo lahko v prihodnje spodbudili uporabo podatkovne analitike v športnih organizacijah v Sloveniji.

1 PODATKOVNA ANALITIKA

Vpliv globalizacije in digitalizacije je organizacije soočil z velikimi količinami strukturiranih in manj strukturiranih podatkov, ki prihajajo iz vseh smeri. Podatki predstavljajo veliko priložnosti predvsem z vidika izboljšane odločanja in ustvarjanja konkurenčne prednosti, a je za to treba privzeti in integrirati nekaj sodobnih analitičnih pristopov (LaValle, Lesser, Shockley, Hopkins & Kruschwitz, 2011).

1.1 Opredelitev podatkovne analitike

Po Pagano in Liotine (2020, str. 16) »podatkovna analitika vključuje obdelavo in preračunavanje velikih količin podatkov, pogosto iz širokega nabora različnih virov.

Obdelava in računanje se izvajata z veliko hitrostjo z namenom iskanja vzorcev, korelacij in drugih koristnih informacij.«

Z drugimi besedami, gre za transformacijo podatkov skozi analizo v kontekstu organizacijskega odločanja in reševanja problemov. Podatkovna analitika se lahko uporablja v najrazličnejše namene, v glavnem pa jo delimo na analiziranje preteklega dogajanja (deskriptivna), ugotavljanje vzrokov za dogajanje v preteklosti (diagnostična), predvidevanje prihodnosti z napovedovanjem verjetnosti izidov (napovedna) in pa raziskovanje, kako oziroma s čim lahko vplivamo na rezultate ali stanje v prihodnosti (predpisovalna) (Ajah & Nweke, 2019; Gartner, 2022).

V splošnem torej poznamo štiri različne vrste analitike (Ajah & Nweke, 2019, str. 7; Arthur, 2013, str. 76; Gartner, 2022; University of Bath, 2022):

- **Deskriptivna analitika** se osredotoča na analizo preteklega dogajanja, pri čemer lahko uporabniki s svojim vsebinskim razumevanjem interpretirajo ključne ugotovitve. Gre predvsem za iskanje trendov in vzorcev, ki so pogosto predstavljeni s preprostimi vizualizacijami. Ravno zaradi preprostosti in razumljivosti deskriptivne analitike gre še vedno za najpogosteje uporabljeno vrsto analitike. Glavna ovira se nanaša na omejitve povezovanja različnih podatkov in preučevanja odvisnosti med njimi.
- **Diagnostična ali razlagalna analitika** deskriptivni analitiki dodaja še malce bolj podroben pogled v smislu, zakaj so se določene stvari zgodile na takšen način, kot so se. Še vedno pa je ob uporabi razlagalne analitike ključen določen vsebinski prispevek s strani odločevalcev.
- **Prediktivna analitika** se ukvarja z napovedovanjem verjetnosti izidov skozi čas. Temelji na uporabi napovedovalnih modelov, regresijske analize, multivariatne statistike in podpora strojnega učenja (angl. machine learning). Najpogosteje takšne napovedi preprečujejo neželene situacije (goljufije, neplačila) ali odkrivajo nove priložnosti.
- **Preskriptivna analitika** nam kot nadgradnja prediktivne analitike pomaga najti pravo pot za doseganje nekega željenega rezultata ali stanja. Odgovarja na vprašanja glede ukrepov, ki jih lahko sprejmemo, da bomo prišli do željene situacije. Na eni strani lahko služi kot podpora odločevalcev, medtem ko so na drugi strani nekateri naprednejši modeli že tako daleč, da je odločanje avtomatizirano. Primer uporabe je model, ki glede na zbrane podatke izračuna smiselno akcijsko ceno za določen produkt.

Podatkovna analitika predstavlja eno od vse bolj priljubljenih poti do ustvarjanja in zadrževanja konkurenčne prednosti. Raziskave namreč kažejo na pozitivno povezavo med konkurenčnim položajem in managementom informacij (Klee, Janson & Leimeister, 2021).

Na tem mestu je vredno omeniti, da se v poslovnem svetu za (podatkovno) analitiko pojavljajo različni izrazi. Ob podatkovni analitiki se pogosto pojavljata poslovna analitika (angl. business analytics) in poslovna inteligenca (angl. business intelligence) v poslovni literaturi predstavljata pretvarjanje podatkov v koristne informacije. Kljub temu je za

obravnava primer bolj smiselni prvi izraz, saj se poslovna analitika in poslovna inteligenca vendarle malenkost bolj nanašata na poslovno poročanje in merjenje poslovnih kazalnikov (Ajah & Nweke, 2019). Sodobna različica podatkovne analitike je tako imenovana analitika masovnih podatkov (angl. big data analytics), ki v splošnem predstavlja obvladovanje in analiziranje velike količine podatkov iz različnih virov z namenom po pridobivanju uporabnih dognanj (Fosso Wamba, Akter, Edwards, Chopin & Gnanzou, 2014).

1.1.1 Analitika masovnih podatkov

Masovni podatki (angl. big data) predstavljajo eno najbolj vročih tematik v informacijski znanosti, kar je seveda tesno povezano z enormnim razvojem pametnih naprav in senzorjev, ki jih povezuje tako imenovan internet stvari (angl. Internet of Things) (Mikalef, Pappas, Krogstie & Giannakos, 2018). Posledično gre pri masovnih podatkih za izjemno veliko količino podatkov (angl. volume), ki z veliko hitrostjo (angl. velocity) prihaja v različnih oblikah in iz mnogih virov (angl. variety). Napredek v računalniški moči, pomnilniški zmogljivosti in programiranju je omogočil, da lahko tudi masovne podatke obdelujemo, analiziramo in učinkovito izkoriščamo (Manohar, 2020; Mikalef, Pappas, Krogstie & Giannakos, 2018).

Čeprav so masovni podatki najpogosteje definirani s štirimi V-ji, so bili v zadnjih letih po nekaterih definicijah dodani še trije – vrednost (angl. value) se nanaša na ekonomsko vredna dognanja in prednosti, variabilnost (angl. variability) na dejstvo, da se lahko dognanja razlikujejo glede na interpretacijo informacij, medtem ko vizualizacija (angl. visualization) pomeni, da lahko na preprost način prikažemo trende in vzorce teh podatkov (Mikalef, Pappas, Krogstie & Giannakos, 2018; Wamba in drugi, 2017).

Masovni podatki so spremenili dojemanje podatkov v organizacijah. Tradicionalno je namreč podatkovna analitika temeljila na namensko zbranih podatkih, medtem ko masovni podatki prihajajo v heterogeni in nestrukturirani obliki. Prav to predstavlja velik izziv, hkrati pa ponuja izjemno priložnost. Vse več podjetij se zaradi pojava masovnih podatkov naslanja na uporabo podatkovne analitike, ki naj bi z analiziranjem velike količine podatkov pomagala pri sprejemanju odločitev. Pri tem je treba biti pozoren na to, kako zadevo integriramo v organizacijo. Vrednost analiziranja masovnih podatkov namreč ne prihaja samo od uporabe specifičnih tehnologij, temveč je treba analitiko integrirati z organizacijo in njenimi značilnostmi. Le tako lahko podatke izkoristimo za doseganje poslovne vrednosti (Mikalef, Pappas, Krogstie & Giannakos, 2018).

1.1.2 Integracija podatkovne analitike

Omenjen razvoj podatkovne analitike je s pomočjo izdatnih investicij prinesel mnoge inovativne načine pridobivanja, shranjevanja in analiziranja podatkov, ki omogočajo uporabo podatkovne analitike v vse več primerih. Pri tem pa je vredno biti pozoren na to, da

podatkovne analitike ne uporabljamo zgolj zato, ker je vsesplošno popularna. Pomembno je, da uporabo podatkovne analitike integriramo v strategijo organizacije. V praksi namreč iz praktičnega vidika veliko organizacij probleme odpravlja s smiselno in ustrezno rabo podatkov.

Zaradi popularnosti masovnih podatkov se v zadnjem času večkrat dogaja, da odločevalci zahtevajo uporabo podatkovne analitike zgolj zaradi trenda, čeprav morda zadeve sploh ne poznajo. Takšen pristop pa namesto dodane vrednosti v organizacije prinaša le dodatno zmedo. Z drugimi besedami, organizacija naj bi vpeljala analitiko, če si predstavlja, kje in kako ji koristi in ne samo zato, ker gre za tako imenovano modno besedo (angl. buzz word) (Kiron, 2013).

Organizacije morajo razmisliti o ključnih gonilih delovanja ter o tem, katere odločitve lahko izboljšajo s pomočjo podatkovno okrepljenega načina odločanja. Za uspeh podatkovne analitike je ključno poznavanje področij, kjer lahko podatki pomagajo. Pomembno je, da si organizacija pri implementaciji analitike zastavi konkreten načrt, saj težko pridemo v željeno stanje, če ne poznamo poti do tja. Formalno oblikovani sistemi in procesi, ki so usklajeni s potrebami organizacije, skupaj z podporo vodstva in usklajenimi cilji predstavljajo zelo pomemben dejavnik za uspešnost podatkovne strategije (Cervone, 2016; Kiron, 2013). Kayser, Nehrke in Zubovic (2018, str 23-24) za uspeh analitike predlagajo manj porabljenega časa za razvoj zelo kompleksnih in sofisticiranih modelov ter več časa za samo integracijo rezultatov v trenutno infrastrukturo in procese.

1.2 Podatkovna analitika v športu

Šport je od nekdanj tesno povezan s številkami. Zmaga ali poraz se določita na podlagi numeričnih vrednosti, bodisi doseženih zadetkov, bodisi časa. Tudi individualne predstave ekipnih športnikov so beležene s številkami, ki opredeljujejo število golov, asistenc, uspešnih podaj ali udarcev ipd. Vse to že samo po sebi opozarja na možnost uporabe analitike, ki omogoča pridobivanje dodatnih informacij (Foster, O'Reilly & Naidu, 2021).

Dostopnost masovnih podatkov je povzročila naraščanje priljubljenosti podatkovne analitike v športu. Na področju tekmovalnega športa je uporaba podatkovne analitike smiselna tako na terenu (angl. on-the-field), kot tudi izven njega (angl. off-the-field). Odločevalcem na primer omogoča analize preteklih treningov in tekem, hkrati pa lahko služi kot pomoč pri ugotavljanju prednosti in slabosti nasprotnikov ter posledično boljše taktično pripravo (Bai & Bai, 2021; Szymanski, 2020).

1.2.1 Moneyball kot prva zgodba o uspehu

Velika prelomnica glede priljubljenosti podatkov v športu je bila leto 2001, ko je Billy Beane, takratni generalni direktor profesionalne bejzbolske ekipe Oakland Athletics,

zaposlil mladega in nadobudnega diplomanta ekonomije Petra Branda. Bejzbolska franšiza je bila v tistem času v precejšnjih finančnih in organizacijskih težavah, zato so morali ubrati drugačno pot. Na podlagi Brandovega statističnega modela so identificirali in pripeljali podcenjene igralce. Ob slabšem začetku so sicer s strani neusmiljenih ameriških medijev naleteli na plaz kritik, a so zelo kmalu začeli niz neporaženosti, ki je presenetil športni svet in vanj prinesel mnogo idej ter razlogov za uporabo analitike. Athletics kljub odlični sezoni do naslova sicer niso prišli. Je pa na podlagi podobnega modela legendarna ekipa Boston Red Sox osvojila svoj prvi naslov po kar 86 letih (Lewis, 2004).

Leta 2003 je bila na osnovi omenjene zgodbe izdana knjiga, 2011 pa še film, ki je spodbudil dodatno zanimanje za analitiko v športu. O tem govori tudi raziskava, ki sta jo med leti 2009 in 2016 izvedla Lindbergh in Arthur (2016). Definirala sta delovno mesto analitika (angl. quant), s čimer sta definirala zaposlenega v bejzbol klubu, ki večino delovnega časa posveti statističnemu raziskovanju, analiziranju podatkov, programiranju ali vodenju kvantitativnega oddelka. V letu 2009 je bilo v elitni ameriški bejzbol ligi zaposlenih 44 tako imenovanih kvantov, medtem ko vsaj tretjina klubov ni nudila redne zaposlitve nikomur, ki bi ustrezal zgornjemu opisu. Do leta 2012 je številka zrasla do 75, medtem ko samo štiri ekipe niso imele nobenega analitika. Le štiri leta kasneje se je število ponovno podvojilo, saj je bilo v vseh klubih kar 156 zaposlenih z namišljenim nazivom kvant, hkrati pa je imela prav vsaka ekipa oddelek za raziskave in razvoj v takšni ali drugačni obliki. Uspeh analitike v bejzbolu je dokazal tudi Freeman (2019), ki za obdobje 2015–2017 ugotavlja statistično značilne razlike v športnih rezultatih in obisku tekem med elitnimi klubi glede na uporabo analitike.

V ameriškem profesionalnem športu praktično ni več organizacije brez analitikov, ki dandanes svoje mesto najdejo tudi v univerzitetnih in srednješolskih ekipah. Kljub temu pa športne organizacije glede uporabe analitike vendarle še vedno precej zaostajajo za podjetji iz običajnih gospodarskih panog. Eden izmed potencialnih razlogov za to je dejstvo, da so športne organizacije še vedno relativno majhne organizacije, ki si posledično ne morejo privoščiti stotine analitikov v primerjavi z večjimi bankami ali trgovci. Prav tako mnogi trenerji in odločevalci v športu dvomijo v korist analitike, saj strogo verjamejo v tradicionalen način dela, ki so se ga pred leti priučili od svojih predhodnikov. Mnogi namreč še vedno trdijo, da nogometa ni mogoče razložiti s številkami. Trdijo, da je še vedno bolje delati z bolj tradicionalnim pristopom oziroma po občutku strokovnjaka (angl. gut feeling) (Anderson & Sally, 2013; Davenport, 2014b).

Ob tem zgodba Moneyball opozarja na tako imenovano organizacijsko inercijo ali negibnost (angl. organizational inertia), ki v splošnem pomeni odpor do sprememb ter posledično oviro za nadaljnji razvoj. Bejzbolski klubi so namreč brez večjih sprememb delovali več kot sto let, zaradi česar so se logično na sodobne pristope sprva odzvali negativno. Prav tako je izpostavljen pomen komunikacije pri privzemanju in sprejemanju tehnologije, saj se tudi Billy Beane šele tekom analitičnega poskusa priuči, kako ustrezno komunicirati z odklonilnimi deležniki (Roth & Matherne, 2021, str. 3).

1.2.2 Razvoj podatkovne analitike v športu

Podobni uspehi so vzpodbudili zanimanje za analitiko tudi v preostalih športih. Splošni cilj športne ekonomije iz zgodbe Moneyball je pozitivna korelacija med plačilno listo igralcev in zmagovanjem na terenu. Tako na primer Deloitte vsako leto naredi pregled razmerja med investicijami in rezultati pri klubih angleške Premier lige. V zadnjih letih so podatkovno analitiko predvsem v smeri rekrutiranja igralcev spodbudili dokazi o tem, kako lahko s previdnim in predvsem spretnim ocenjevanjem vrednosti igralcev nogometni klubi s precej manjšim proračunom dosegajo zelo dobre rezultate (Foster, O'Reilly & Naidu, 2021). Ekipe z omejenimi finančnimi sredstvi namreč lahko ostanejo konkurenčne bogatejšim rivalom le, če bolj učinkovito izkoriščajo svoj proračun (Gerrard, 2016).

V Evropi je največ govora o analitiki pričakovano v košarki in predvsem nogometu. Kot začetnika podatkovne analitike v nogometu bi lahko označili angleškega računovodjo Charlesa Reepa, ki je kot analitik v nogometnih klubih deloval že v zgodnjih petdesetih letih prejšnjega stoletja. Pred časom pa so se v javnosti pojavili zapisi iz madžarskega časopisa, ki nakazujejo na to, da se je beleženje dogodkov v relativno napredni obliki izvajalo že leta 1922 (Batorfy, 2020; Pollard, 2002).

Vse več je takšnih in drugačnih zgodb, ki govorijo o uspehu uporabe podatkovne analitike v nogometnih organizacijah. Ena bolj znanih zgodb je denimo angleški FC Brentford, ki ga je v letu 2012 prevzel karizmatični Matthew Benham. Kot navdušenec nad številkami je bil prepričan, da je namesto pogodbe za vrhunskega trenerja ali nadgradnje stadiona ključna investicija analitika. To se mu je obrestovalo, saj je svoj klub praktično takoj pripeljal iz 3. lige v elitno Premier ligo. V zadnjem času se takšnega pristopa lotevajo tudi mnogi manjši, manj bogati klubi, ki poskušajo na tak način zapolniti manko denarja (Wigmore, 2018).

Po Davenportu (2014a) v londonskem nogometnem klubu West Hamu podatkovno analitiko uporabljajo večinoma za pripravo taktike, izboljšanje pripravljenosti igralcev, preprečevanje poškodb in analizo izvedbe dogovorjenega načrta na tekmi, medtem ko v košarkarskem klubu Houston Rockets podatkovna analitika največkrat služi za identifikacijo talentov in potencialnih okrepitev, ocenjevanje kvalitete lastnih in tujih igralcev (razni modeli) ter izbiro taktike. Med drugim se analitika uporablja tudi za pripravo na tekme, med katerimi je na primer tudi analiza igre nasprotnih zvezdnikov (angl. shooting charts), na podlagi katere je mogoče prilagoditi obrambo ter tako omejiti njihov učinek (Foster, O'Reilly & Naidu, 2021).

Eden od zelo prepoznavnih primerov podatkovne analitike v športu je tudi Formula 1, kjer inženirji sproti analizirajo podatke, pridobljene na podlagi več kot 160 senzorjev iz njihovega bolida. Na podlagi razpoložljivih podatkov sprejemajo ad-hoc odločitve glede strategije na sami dirki (Leško, 2019, str. 187).

1.2.3 Negotovost podatkovne analitike v športu

V začetku je analitika v športu naletela na veliko ovir in zavračanja zaradi »tradicionalnega« mišljenja igralcev, trenerjev, skavtov in odločevalcev, ki so bili uspešni tudi brez naprednih statistik. Charles Barkley, član NBA hiše slavnih, je nekoč dejal, da analitika nima smisla in predstavlja nakladanje s strani ljudi, ki si želijo biti del sveta športa, a glede samega športa niso bili dovolj talentirani. Kljub temu pa je bilo v zadnjem času Barkleyju in ostalim dvomljivcem velikokrat dokazano, da se motijo. Danes namreč mnoge športne ekipe uporabljajo analitiko za sestavo kadra, pripravo taktike ter izboljšanje pripravljenosti. Zaradi opaznih rezultatov se je analitika hitro razširila iz bejzbola in košarke tudi na nogomet, formulo, hokej, tenis, golf in ostalo (Shields, 2018).

Tudi v nogometu analitika precej časa ni bila sprejeta, ker so odločevalci v nogometnih klubih menili, da v nogometu podatki ne morajo prispevati ničesar. Kljub mnogim primerom dobre prakse se tako imenovani podatkovni znanstveniki v športu dolgo časa niso uveljavili. V primerjavi z ostalimi športi gre za večje število spremenljivk – večje število aktivnih igralcev, vreme in podobno, kar naredi celotno zgodbo precej bolj kompleksno. Še ena specifičnost, ki je nekoliko zavirala razvoj analitike v nogometu konkretno je dejstvo, da gre za šport z majhnim številom zadetkov (angl. scoring events), kar je v nasprotju s prej omenjenima bejzbolom in košarko. Vendarle pa se v zadnjem času uspešno beležijo tudi drugi pomembni dogodki (podaje, streli, tek itd.), kar je omogočilo težko pričakovani preskok v najbolj gledanem športu na svetu. Dostopnost podatkov, nosljivih naprav (angl. wearables) in razvoj podatkovne znanosti je v zadnjih letih prepričal mnoge športne strokovnjake, da vendarle svoje odločitve podkrepijo tudi s podatki, kar je glede na astronomske denarne zneske logičen korak naprej (Foster, O'Reilly & Naidu, 2021; Kröckel, 2019).

Ravno razvoj finančnega aspekta v športu omogoča sodobnejše poslovne pristope, saj so bili stroški podatkovne analitike za šport pred časom občutno previsoki. Športne organizacije so opazile potencial, zato so se investicije v podatkovno analitiko drastično zvišale. Temu trendu ni videti konca, saj je bila vrednost trga analitike v športu v letu 2021 2,5 milijarde ameriških dolarjev, do konca leta 2026 pa naj bi se ta vrednost več kot potrojila (MarketsandMarkets, 2022).

Ker je beleženje podatkov za posamezne tekme zamudno in bi bili ti verjetno pripravljene šele, ko jih več ne bi potrebovali, so se v svetu športa uveljavili ponudniki, ki organizacijam zagotavljajo vir podatkov. Ponudniki imajo manjše razlike v modelih, saj imajo glede kakovosti podatkov vsak svoje izzive, hkrati pa lahko malenkost raznoliko definirajo beležene dogodke. To se pokaže v manjših razlikah pri primerjavi vrednosti, ravno zaradi tega pa je kakovost in posledično relevantnost podatkov eden izmed perečih izzivov podatkovne analitike v športu. Kar se tiče cene, je ta po navadi prilagojena specifičnim zahtevam organizacije (Davis & Robberechts, 2020).

2 PRIMERI UPORABE PODATKOVNE ANALITIKE V NOGOMETU

V zadnjih 50 letih so se skoraj vsi nogometni klubi preobrazili v dobičkonosne organizacije, kar je posledica obsežne komercializacije nogometa skozi zadnja desetletja, na katero sta vplivala predvsem dva dejavnika. Prvi je splošna popularnost nogometa, zaradi katere je postal zelo zanimiv za komercialne interese in posledično primeren za oglaševanje ter trženje. Drugi dejavnik je profesionalizacija nogometa, ki je skupaj s popularnostjo ustvarila močno razmerje med mediji, sponzorji, javnostjo in nogometom. Vse to v nogomet prinaša veliko denarja (Kuper & Szymanski, 2009).

Ob drugih sodobnih pristopih poslovanja se je tako v nogometu uveljavila tudi podatkovna analitika, ki iz dneva v dan pridobiva na popularnosti. Uporablja se v najrazličnejše namene, med katerimi so najpopularnejši **iskanje talentov (skavting)** oziroma **rekrutiranje igralcev, razna poročila in analize glede tekem oziroma nasprotnikov ter telesna priprava**. Ob naštetih se v zadnjem času uveljavljajo še mnogi drugi primeri uporabe, medtem ko je za nogometne organizacije zanimivo tudi poslovno poročanje (Beal, Chalkiadakis, Norman & Ramchurn, 2020; Kröckel, 2019; Sharma, 2021; Sumpter, 2016; Uppsala Universitet, brez datuma).

Pri uporabi podatkovne analitike v športu je prav tako treba biti posebej pozoren na kontekst, v katerem ugotovitve apliciramo. Če na primer pripravimo analizo nasprotne ekipe, lahko pridobimo neke splošne informacije glede njihovega načina igranja. Analiza lahko izpusti dejstva, da so bile vse analizirane tekme odigrane v dežju in proti najslabšim ekipam lige, kar je v primeru, ko smo sami ekipa iz zgornjega dela lestvice, vremenska napoved pa je sončna, zelo pomembno upoštevati (Pavitt, Braines & Tomsett, 2021, str. 4).

Razvoj podatkovne analitike v nogometu je precej pospešila dostopnost tako imenovanih podatkov o dogodkih (angl. event data), ki opisujejo posamezne dogodke s tipom dogodka, časovno oznako, lokacijo in ostalimi podrobnostmi. Med zabeleženimi dogodki so vključene podaje, preigravanja, predložki, prestrežene žoge, dueli, strelji, prekrški itd. V večini primerov so podatki o dogodkih beleženi s strani ljudi, ki podatke vnašajo preko posebej prilagojenih programskih vmesnikov (Van Haaren in drugi, 2019). Med največje ponudnike takih podatkov sodijo Opta, Statsbomb, InStat in Wyscout, ki so na voljo tudi v slovenskem prostoru in ob surovih (angl. raw) podatkih nudijo predpripravljene rešitve v obliki grafik in poročil (Sumpter, 2019).

Nekatere druge platforme, ki pripravljajo podatkovne rešitve za nogomet so še Driblab, Comparisonator, SciSports itd. Ker pa so cene na omenjenih platformah precej visoke, se organizacije v zadnjem času vse več lotevajo izdelave lastnih podatkovnih rešitev, največkrat s pomočjo programskih jezikov R in Python. Kot posledica trenda priljubljenosti in navdušenja nad podatki v športu je namreč na spletu na voljo mnogo vadnic, knjižnic (angl. programming library – zbirka pripravljene kode, ki se uporablja za optimiziran in

olajšan programski razvoj) in ostale literature (FC PYTHON, brez datuma; Nakagawara, 2020).

V naslednjih poglavjih bom predstavil nekaj najbolj priljubljenih primerov v nogometni podatkovni analitiki. Razdelil sem jih na smiselne vsebinske sklope, še vedno pa se medsebojno zelo močno povezujejo. Večina modelov se lahko uporablja na več različnih načinov, ravno takšno prepletanje pa prinaša največ dodane vrednosti.

2.1 Pričakovani zadetki in nadgradnje

Kot ena najbolj popularnih metrik v nogometni skupnosti so se uveljavili **pričakovani zadetki** (angl. expected goals, v nadaljevanju xG), ki se uporabljajo na precej različnih načinov, hkrati pa predstavljajo osnovo za mnoge zahtevnejše modele. Prvi zapisi o pričakovanih zadetkih izvirajo iz leta 1997, prvič pa jih je uradno opredelil Sam Green v letu 2012 (Uppsala Universitet, brez datuma).

2.1.1 Definicija pričakovanih zadetkov

Pričakovani zadetki temeljijo na osnovi matematične definicije o pričakovani vrednosti, ki posplošeno predstavlja dolgoročno povprečje slučajne spremenljivke X . V primeru šeststrane kocke je izračun preprost, saj je pri metu za vsako število od 1 do 6 enaka verjetnost. Na podlagi tega lahko izračunamo pričakovano vrednost, ki bo pri metu kocke enaka 3,5, ko se bomo bližali neskončnemu številu poskusov (Kenton, 2022).

xG za posamezno priložnost predstavlja vrednost na intervalu $[0, 1]$, kjer 0 pomeni priložnost iz katere je nemogoče zadeti, 1 pa predstavlja priložnost, s katere bi moral povprečen igralec vedno zadeti. Bistvo pričakovanih zadetkov se pokaže, ko posamezne priložnosti seštevamo, bodisi za posamezne igralce, bodisi za ekipe (Football Philosophy, brez datuma; Wyscout, brez datuma).

Vrednost $xG = 0,5$ pomeni, da bi v primeru 10 identičnih strelav s strani povprečnega igralca pričakovali 5 doseženih zadetkov. To pa še ne pomeni, da bo doseženih točno 5 zadetkov. Model pričakovanih zadetkov namreč temelji na matematičnem konceptu pričakovane vrednosti in deluje na principu meta kovanca, pri čemer se ne moremo izogniti določeni variabilnosti. Prav tako je na tem mestu treba biti pozoren na tako imenovano hazardersko zmoto (angl. gambler's fallacy). Če se zgodi, da kovanec desetkrat zapored pade na grb, to še vedno ne pomeni, da bo pri 11. metu kaj bolj verjetna številka, saj je verjetnost za vsako stran še vedno 0,5. Z matematičnega vidika je zgodba podobna tudi pri pričakovanih zadetkih – če je igralec zapravil priložnost, ki je bila ocenjena $xG = 0,5$, in dobi čez nekaj minut ponovno priložnost z vrednostjo $xG = 0,5$, ni verjetnost za zadetek nič večja kot v prvem primeru (Sumpter & Andrzejewski, brez datuma).

Pričakovani zadetki torej merijo kvaliteto priložnosti z izračunavanjem verjetnosti, da bo igralec iz določene pozicije (situacije) na igrišču dosegel zadetek. Vrednost temelji na več dejavnikih in je izračunana pred igralčevim strelom. Najpomembnejša dejavnika, na podlagi katerih je bila kreirana tudi ena od prvih različic modela, sta **oddaljenost** od gola in **kot strela** – večja oddaljenost ali ostrejši kot denimo pomenita nižji xG (Football Philosophy, brez datuma; Opta Analyst, 2017).

Preostali dejavniki vključujejo še del telesa, s katerim je strelec sprožil (močnejša noga, slabša noga, glava), tip strela (običajen strel, volej), tip podaje (predložek, podaja v prostor, podaje iz prekinitve) in tip napada (odbitek, podaja iz zanesljive posesti, preigravanje). Z izboljšavami v modelih so se dodali še številni drugi dejavniki, med katerimi najdemo tudi hitrost igralca ob strelu, postavljanje vratarja ali pritisk, ki so ga na strelca vršili obrambni igralci nasprotne ekipe (Brecht & Flepp, 2020; Sumpter, 2016; Sumpter & Andrzejewski, brez datuma).

Vsaka priložnost se primerja s številnimi podobnimi priložnostmi, na podlagi katerih se potem določi vrednost. Opta, eno izmed vodilnih podjetij na področju športnih podatkov, je v svoj začetni model pričakovanih zadetkov vključilo 300 tisoč priložnosti, od takrat pa model neprestano testirajo in nadgrajujejo (Opta Analyst, 2017). Kot primer, vsak kazenski strel z 11 metrov ima točno določeno vrednost xG (v primeru wyscout znaša 0,76), saj si prav vsi kazenski strelji delijo enake karakteristike, medtem ko vrednost nakazuje, da je načeloma uspešnih približno tri četrtine kazenskih strellov. Ker imajo kazenski strelji tako visoko vrednost, je marsikdaj v uporabi tudi pričakovani zadetki brez kazenskih strellov (angl. Non-Penalty Expected Goals - npxG), ki z izključevanjem enajstmetrovk prikaže manj popačeno sliko seštevka (Wyscout, brez datuma).

Podoben koncept se je uveljavil tudi za pričakovane asistencije, kjer veljajo ista določila, le da opazujemo vrednost pričakovanega zadetka, ki sledi zadnji podaji pred strelom. Ta vrednost v bistvu predstavlja nogometaševu sposobnost pripravljanja priložnosti oziroma asistiranja brez vpliva strelčeve sposobnosti zaključevanja oziroma sreče (Whitmore, 2021a).

Za pričakovanimi zadetki torej stoji kompleksen model, a sta razumevanje in uporaba za uporabnika dokaj preprosti. Model je lahko zelo koristen na različne načine, vendar v luči najpogostejše kritike in največjega izziva ni uporaben sam po sebi in ga je zato nujno treba ustrezno umestiti v celotno zgodbo in kontekst (Football Philosophy, brez datuma). Na tem mestu je vredno izpostaviti, da obstajajo najrazličnejši modeli, s katerimi različne platforme ali posamezniki izdelujejo prikazane metrike. Sam sem predstavil nekaj splošnih karakteristik za lažjo predstavitev celotne zgodbe.

2.1.2 Uporaba pričakovanih vrednosti

Priljubljenost pričakovanih zadetkov in ostalih pričakovanih vrednosti se je v zadnjem času zelo razširila, saj se dandanes uporabljajo v najrazličnejše namene. Danski klub FC Midtjylland je denimo osvojil svoj prvi državni naslov v zgodovini, ko se je za iskanje okrepitev obrnil na model pričakovanih zadetkov (Rathke, 2017).

Primerjava pričakovanih zadetkov z dejanskimi nam lahko pokaže posameznikovo spretnost zaključevanja ali prisotnost sreče. Ker se sreča načeloma na dolgi rok izravna, lahko igralce, ki konstantno presegajo pričakovane zadetke, označimo kot nadpovprečne strelce. V samih začetkih je bila glede tega večkrat prisotna hazarderska zmotna. Uporabniki so predvidevali, da igralec v naslednjih tekmah ne bo dosegel zadetka zgolj zato, ker je v prejšnjih tekmah občutno presegal svoje pričakovane zadetke. Lep fenomen, ki kaže neustreznost takšnega razmišljanja, je južnokorejski zvezdnik Son Heung-min, ki v zadnjih 4 letih presega svoj xG za več kot 40 odstotkov. Zato moramo biti pri uporabi modela pozorni na dejstvo, da vrednost xG nevtralizira sposobnosti igralcev in velja za primer povprečnega igralca (Rathke, 2017; Understat, brez datuma).

Kako oziroma kdaj je sploh smiselno uporabljati pričakovane vrednosti? Če jih opazujemo zgolj na podlagi ene ali dveh tekem, je precej naivno delati kakšne pomembnejše zaključke, saj je vrednost xG posamezne tekme še vedno precej naključna in odvisna od prevelikega števila neopazovanih spremenljivk. Lahko nam sicer koristi kot nekakšen kazalnik pripravljenih priložnosti obeh ekip, a ne meri pričakovanega izida. V kolikor ima na neodvisni tekmi ekipa A večjo vrednost xG, to še ne pomeni, da bi morala ekipa A tudi zmagati. To ponazarja primer, v katerem ekipa B na začetku tekme dvakrat zadene in se v nadaljevanju osredotoči na branjenje prednosti. Medtem ekipa A napada z večjo intenziteto in tako zbere večjo skupno vrednost pričakovanih zadetkov. Pri treh do šestih tekmah je še vedno zelo pomemben faktor (ne)sreče, medtem ko je lahko v obdobju sedmih do šestnajstih tekem analiza pričakovanih zadetkov že zelo zanimiva. Če se v takem obdobju zadetki in pričakovani zadetki še vedno drastično razlikujejo, je to nujno treba preučiti in vključiti pri nadaljnjih analizah. Po šestnajstih tekmah je ustrezno narediti tudi dolgoročneje zaključke. Če ekipa v celotni sezoni občutno presega svoje pričakovane zadetke, to preprosto pomeni, da je izvrstna v zaključevanju svojih priložnosti. Še vedno moramo biti pozorni na kontekst in ostale dejavnike – na primer vpliv samozavesti ob več zaporednih zmagah. Smiselno je analizirati tudi drseča povprečja pričakovanih zadetkov, ki lahko povedo precej o samem napredku ekipe (Sumpter & Andrzejewski, brez datuma).

Če pričakovane vrednosti razdelimo na posamezne predele po igrišču, lahko ugotovimo tudi, kje smo najšibkejši. Pogledamo lahko na primer koliko pričakovanih zadetkov si pripravimo, ko napadamo iz leve strani v primerjavi z napadi iz desne strani. Primerjamo lahko denimo tudi, kako uspešni smo iz prekinitev v primerjavi z konkurenti. Prav tako se s podobno analizo nasprotnika pripravimo na tekmo in izpostavimo največje nevarnosti.

V primeru, ko pričakovane zadetke opazujemo na ravni ekipe, se je uveljavil tudi koncept pričakovanih prejetih zadetkov (angl. expected goals against, v nadaljevanju xGA), ki predstavlja seštete vrednosti pričakovanih zadetkov nasprotne ekipe (Uppsala Universitet, brez datuma). Ob prej omenjenih primerih uporabe je zadeva zanimiva na primer tudi za ocenjevanje nogometnih vratarjev.

Z xGA lahko namreč ocenjujemo tudi kvaliteto priložnosti nasprotnika. Do še boljše metrike za ocenjevanje vratarjev pridemo, če upoštevamo pričakovane zadetke po strelu (angl. Post-Shot Expected Goals – PSxG), ki posredno opredeljujejo dejansko težavnost strela za vratarja. Alternativno poimenovanje za pričakovane zadetke po samem strelu predstavljajo pričakovani zadetki pri strelah v okvir vrat (angl. Expected Goals on Target, v nadaljevanju xGOT). Vrednost xGOT je višja, če gre žoga proti kateremu od zgornjih kotov gola in nižja, če gre po sredini vrat. Ubranjena vrednost pričakovanih zadetkov v okvir gola (xGOT – prejeti zadetki) predstavlja preprosto in relativno učinkovito metriko za ocenjevanje vratarjev, a je treba biti tudi v tem primeru pozoren na kontekst. Vrtar slabše ekipe, ki se več časa brani, ima več priložnosti za obrambe. Prav tako je lahko zgodba povsem drugačna, če je vratar obranil dve priložnosti z $xG = 0,5$ ali pa če je obranil deset priložnosti z $xG = 0,1$, kar sicer rezultira v enaki vrednosti seštetega xGA. Podobno velja tudi za napadalce. Z razliko med xGOT in xG lahko ugotovimo, kateri igralci so s svojimi streli najbolj izboljšali verjetnost zadetkov glede na priložnosti, v kateri so se znašli. S tem lahko na preprost način ponazorimo kvaliteto strelav posameznih igralcev. Vse to lahko predstavlja iztočnico za iskanje podcenjenih igralcev, kar podrobneje opisujem v naslednjem poglavju (Football Philosophy, brez datuma; Whitmore, 2021b).

2.2 Iskanje talentov in rekrutiranje igralcev

Masovni podatki so revolucionirali tudi način iskanja novih igralcev oziroma potencialnih okrepitev. Tradicionalni skavting je zahteval, da si skavt v živo ogleda tekme, kar je seveda lahko precej potratno. Sploh če skavt ne ve točno, koga opazovati. Dostopnost številnih podatkov o igralcih (vključno s posnetki) je rekrutiranje igralcev spremenilo iz povsem terenskega dela v pretežno pisarniško.

Numerične vrednosti (goli, asistence, predložki, dobljeni dvoboji, uspešnost podaj, pričakovane vrednosti itd.) so dandanes na voljo preko različnih platform oziroma ponudnikov. Takšni podatki so lahko zelo koristni, a moramo biti pozorni na kontekst. Na primer, ko gledamo uspešnost podaj, ne moramo vedeti, ali je igralec podajal pretežno enostavne podaje na svoji polovici, ali pa je velikokrat odigral tvegano podajo naprej. Tako je Transfermarkt (2020) v eni izmed novic izpostavil, kako imata nogometaša Thiago Silva (95,5 odstotkov) in Presnel Kimpembe (95 odstotkov) najvišjo uspešnost podaj med vsemi igralci v petih najmočnejših evropskih ligah. To pa še ne pomeni, da gre za najkvalitetnejša podajalca v Evropi. Vendarle gre za centralni branilski par, ki si je med seboj izmenjal ogromno kratkih podaj. Po drugi strani je vedno težavno primerjati številke igralcev iz

različnih ekip, ki igrajo različne modele igre. Še težje je seveda primerjati igralce iz različnih tekmovanj.

Kako zelo pomemben je pri razumevanju nogometnih statistik kontekst, je ponazoril tudi nekdanji vrhunski italijanski branilec Paolo Maldini. V enem izmed mnogih intervjujev je dejal, da je že storil napako, če je moral posredovati z drsečim štartom. S tem je želel izpostaviti, da je za dobro branjenje ključno postavljanje in ne uspešnost posredovanj. Absolutno število uspešnih posredovanj zato nujno ne kaže kvalitete branilca (Sumpter & Andrzejewski, brez datuma).

2.2.1 Tradicionalno in analitično iskanje talentov

Podatkovna analitika lahko podpira odločanje pri iskanju talentov predvsem na dva načina. Z analizo podatkov lahko identificiramo primerne igralce, ki jih potem preverimo še z lastnimi očmi oziroma s pristopi tradicionalnega skavtinga. Po drugem pristopu igralce, ki se nam zdijo zanimivi po ogledu njihovih tekem, ocenimo še na podlagi podatkov (Sumpter, 2016).

Pomembno se je namreč zavedati pomanjkljivosti tradicionalnega in »podatkovnega« skavtinga ter izkoristiti **pozitivne lastnosti obeh pristopov**. Tudi profesor Sumpter (2016) iz univerze Uppsala je v knjigi izpostavil, kako je skavt zagovarjal nakup določenega igralca, a so mu po hitrem pregledu statistik podali informacijo, da je bil na tekmi prisoten ravno ob verjetno njegovi najboljši predstavi v življenju. Izziv je torej iskanje ravnotežja med tako imenovanim statističnim skavtingom in uporabo tradicionalnih skavting mrež, video analiz ter ogledov tekem v živo (Gerrard, 2016).

Sumpter (2016) opisuje, kako dandanes mnogi klubi uporabljajo podatke za skavting. V največji meri se uporabljajo prav prej omenjeni pričakovani zadetki, asistence in druge naprednejše metrike, ki merijo vključenost igralcev v napadalnih akcijah. Koristni so vsekakor tudi bolj preprosti podatki, vključno s številom strelom, dobljenih duelov, prestreženih žog, uspešnih podaj in podobno. S temi kazalniki je namreč mogoče identificirati podcenjene igralce na podoben način, kot je to uspevalo odločevalcem v filmu Moneyball – izkoristili so tako imenovano informacijsko neučinkovitost konkurentov, ki v splošnem pomeni neučinkovito izkoriščanje informacij pri ocenjevanju sredstev, v tem primeru igralcev (Gerrard, 2016, str. 6).

Primer dobre prakse iz knjige Soccermetrics se nanaša na angleška kluba Aston Villa in Leicester City v sezoni 2015–16. Oba kluba sta v poletnem prestopnem roku zanesla na iskanje podcenjenih igralcev iz francoske lige. Leicester je pripeljal Riyada Mahreza in N'Gola Kanteja ter z njuno pomočjo na presenečenje vseh prvič v zgodovini osvojil ligo. Na drugi strani je Villa podpisala štiri igralce iz francoske lige, ki so bili statistično gledano na nivoju Mahreza in Kanteja, a je v isti sezoni izpadla iz lige z najnižjim izkupičkom točk v zgodovini obstoja kluba. Bistvena razlika pa se je skrivala v sami integraciji analitike


oziroma zaupanju med strokovnim štabom in analitiki. Medtem ko je Leicester uspel integrirati analitiko v večino operacij znotraj kluba, se analitska služba Ville in takratni glavni trener Tim Sherwood nikakor niso sporazumeli, kako, kje in zakaj naj se podatki sploh uporabljajo (Sumpter, 2016).

2.2.2 Primeri uporabe pri iskanju talentov

Sumpter (2016) iz prve roke poudari, da skavti vedno raje uporabljajo razne vizualizacije. Po eni strani lahko potrdijo njihovo prepričanje glede določenega igralca, po drugi pa lahko odkrijejo povsem nove igralce, ki jim je vredno nameniti več pozornosti. Na podoben način lahko potencialne okrepitve iščemo po določenih karakteristikah, ki jih potrebujemo – na primer potrebujemo defenzivnega vezista, ki zna ob veliko prestreženih žogah tudi pripraviti kakšno priložnost. Na podlagi tega zahtevka lahko iz baze podatkov pridobimo ožji izbor kandidatov, ki jih potem поблиžje pogledamo z dodatno analizo ali pa na tradicionalen način. Seveda so tudi v tej smeri lahko pripravljena takšna in drugačna poročila, ki pri dodatnem opazovanju igralca služijo kot pomoč ali potrditev. Eden od najbolj priljubljenih prikazov vrednosti za posameznega igralca je v obliki tako imenovanih »radar-jev«, pri katerih igralca razvrstimo glede na vrednosti ostalih igralcev, ki igrajo na podobni poziciji in oziroma ali v primerljivem tekmovanju.

Sam sem s pomočjo Python knjižnice `mplsoccer` (Durgapal & Rowlinson, brez datuma) in podatkov iz spletne strani `fbref` (Sports Reference LLC, brez datuma) pripravil grafiko, ki je vidna na sliki 1. Prikazuje vrednosti izbranih metrik branilca Liverpoola, Trenta Alexandra-Arnolda, v primerjavi z vsemi ostalimi igralci iz istega tekmovanja. Vizualizacija prikazuje kvantilne range izbranih metrik, pri čemer so upoštevana povprečja na devetdeset odigranih minut. Na primer število vseh uspešnih podaj delimo s številom odigranih minut v celotni sezoni, nato pa dobljen količnik pomnožimo z devetdeset. Tako dobimo vrednosti, ki ne favorizirajo igralcev z večjim številom odigranih minut. Da se izognemo podobni težavi v nasprotni smeri (visoke vrednosti metrik zaradi nizkih vrednosti delitelja), upoštevamo samo igralce, ki so odigrali več kot tisoč minut. Takoj je denimo mogoče videti, da gre za vsestranskega nogometaša, ki je izjemen v gradnji napadov in pripravljanju priložnosti za zadetek. Približno 95 odstotkov vseh nogometašev iz angleške prve lige z več kot tisoč odigranimi minutami je v sezoni 2022/23 zabeležilo manj ali kvečjemu enako število uspešnih podaj na devetdeset odigranih minut kot Trent Alexander-Arnold. Podobno velja recimo tudi za ključne podaje, medtem ko je denimo v pričakovanih asistencah (glej 2.1.1) opazovan igralec še toliko bolj izstopal. Pri takšnih radarjih imajo marsikdaj pripombe statistiki, saj morda malce popačijo podatke, ker ploščina radarja ni sorazmerna s pripadajočo vrednostjo. Pravilnejša alternativa je raba preprostih stolpčnih diagramov, ki pa je pri nogometnih strokovnjakih manj priljubljena (Sumpter, 2016; Uppsala Universitet, brez datuma).

Slika 1: Primerjalni radar



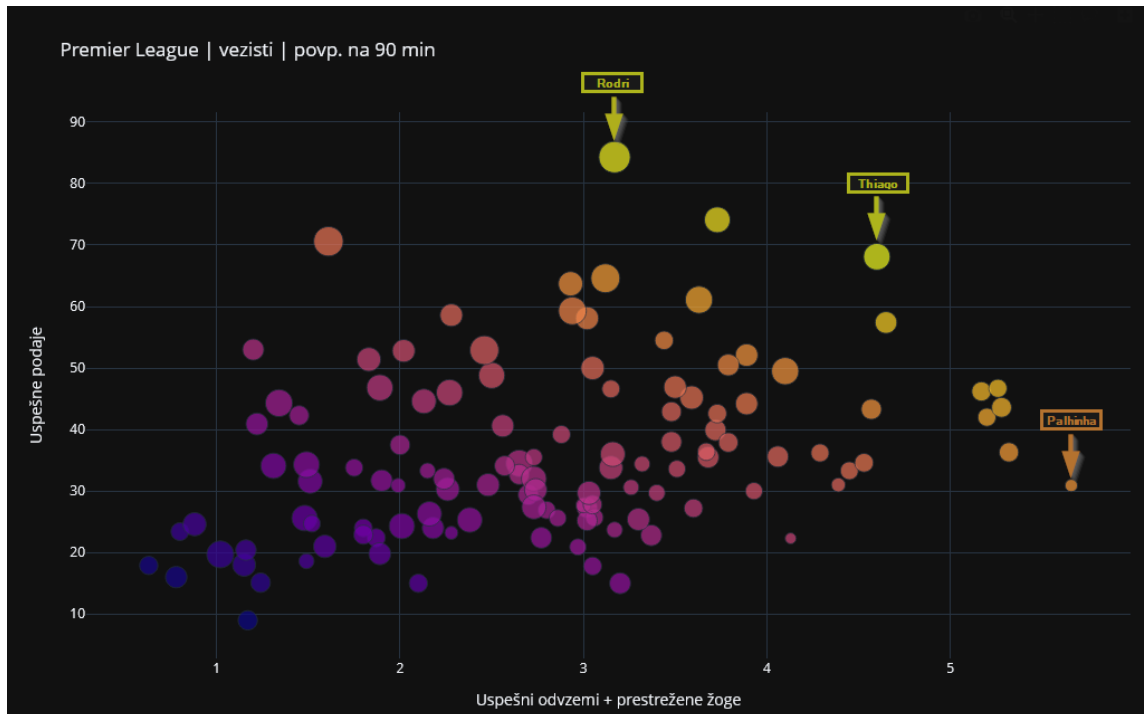
Prirejeno po Sports Reference LLC (brez datuma) in Durgapal & Rowlinson (brez datuma).

Kar se tiče težavnosti primerjave igralcev v različno kakovostnih ekipah, je ena izmed rešitev normalizacija. Logično je namreč, da bo igralec iz vodilne ekipe prvenstva kreiral več priložnosti, kar pa še ne pomeni, da je zagotovo boljši od primerljivega igralca iz zadnjevrščne ekipe. Vrednosti se prilagodijo glede na določene statistike ekipe, s katerimi površinsko opredelimo kakovost – na primer število strelav na minuto. Še ena izmed boljših metod je prilagoditev vrednosti glede na število dotikov, ki jih igralec opravi, kar je še posebej smiselno pri napadalcih. S tem lahko namreč ocenimo, koliko igralec v povprečju doda z enim dotikom (Sumpter & Andrzejewski, brez datuma; Uppsala Universitet, brez datuma).

Masovni podatki so omogočili primerjavo večjega nabora igralcev naenkrat, s čimer lahko hitro in preprosto vidimo odstopanja in posledično identificiramo zanimive igralce. Na sliki 2 je viden primer primerjave vezistov iz angleške prve nogometne lige, ki sem ga pripravil s pomočjo programskega jezika Python. Na osi x so sešteti uspešni odvzemi in prestrežene žoge, medtem ko je na osi y število uspešnih podaj. Z velikostjo krogca je določena še skupna razdalja iznosa oziroma vodenja žoge proti nasprotnikovemu голу. Uporabljene so

povprečne vrednosti na devetdeset odigranih minut, pri čemer so vključeni zgolj igralci sredine igrišča, ki so v sezoni 2022–2023 odigrali več kot tisoč minut.

Slika 2: Primerjava večjega nabora igralcev



Prirejeno po Sports Reference LLC (brez datuma).

Glede na omenjene karakteristike lahko proti zgornjemu desnemu kotu identificiramo vsestranske veziste (angl. box-to-box), ki so učinkoviti tako v obrambi, kot tudi pri gradnji napadov. Z vidika vsestranskosti lahko denimo takoj izpostavimo Thiaga Alcantaro, ki beleži skoraj sedemdeset uspešnih podaj na devetdeset odigranih minut, medtem ko v istem času v povprečju pribori več kot štiri žoge. Pri aplikaciji je ponovno treba biti zelo pozoren na kontekst. Rodri denimo igra v Manchester Cityju, ki temelji svojo igro na posesti, kar osrednjemu vezistu omogoča večje število podaj. Medtem na primer João Palhinha igra v Fulhamu, ki se več časa brani brez žoge. Posledično ima precej manj uspešnih podaj in iznosov žoge, a na drugi strani največje število odvzetih in prestreženih žog na devetdeset odigranih minut med vsemi vezisti v angleški prvoligaški konkurenci.

Podatkovni skavting lahko torej koristi v različnih korakih. Pomaga lahko denimo že pri analizi stanja trenutnega kadra, pri čemer s pomočjo analize odigranih minut, starosti, pogodbe in ostalih kazalnikov opredelimo splošne potrebe kluba pred prestopnim rokom. Temu sledi analiza večjega števila igralcev in identifikacija potencialnih kandidatov glede na določene karakteristike. V nadaljevanju se ustrezne kandidate preveri še z primerjalnimi radarji in tradicionalnim pristopom – ogled tekme, pogovor itd.

2.2.3 Naprednejši modeli ocenjevanja igralcev

Alternativen pogled ocenjuje igralce na podlagi tega, koliko in kako so prispevali k igri oziroma akcijam njihove ekipe. Pri tem je ogromno prispevala Rudd (2011), ki je z uporabo Markovske verige opredelila prispevke posameznih igralcev. Igro je razdelila na pet možnih stanj (gol, izgubljena žoga, krilo, vezna linija in kazenski prostor), pri čemer je bila v vsakem opredeljena verjetnost za prehode v druga stanja – pri голу in izgubljeni žogi se je akcija končala. Igralci so ocenjeni na podlagi tega, koliko so povišali (ali znižali) verjetnost za gol. Če je bila na primer verjetnost za gol 15 odstotkov, ko je vezist podal žogo do napadalca in povečal verjetnost na 25 odstotkov, je tako podajalec prejel 10 »točk«. Model je takrat presenetljivo visoko ocenil Jordana Hendersona, ki je kmalu zablestel v Liverpoolu (Sumpter, 2016).

Nekakšna preoblikovana različica omenjenega modela je še ena pričakovana vrednost – pričakovana nevarnost (angl. expected threat, v nadaljevanju xT). V bistvu je matematično ozadje predstavila že Rudd (2011), a je pričakovano nevarnost kot tako prvič poimenoval in predstavil Singh (brez datuma). xT temelji na nogometnem igrišču, ki je porazdeljeno na delčke mreže glede na verjetnost, da bo od tam dosežen zadetek. V splošnem je večja verjetnost bližje nasprotnikovemu голу. Če igralec poda iz kvadrata z manjšo verjetnostjo v tistega z večjo, to pomeni, da je povišal xT v korist njegove ekipe (Sumpter & Andrzejewski, brez datuma).

Na podobnem principu delujeta še dve novejši metriki z imeni xGChain in xGBuildup. Pričakovani zadetki se namreč osredotočajo na napadalce. S pričakovanimi asistencami se je dodal fokus tudi na kreativne organizatorje igre, še vedno pa v akcijah sodeluje večje število ostalih nogometašev, ki so morda s svojo podajo prispevali velik delež k zadetku (Lawrence, 2018; Sumpter & Andrzejewski, brez datuma).

xGChain deluje po relativno preprostem receptu (Lawrence, 2018):

- poiščemo vse posesti, v katerih je igralec sodeloval.
- poiščemo vse strele znotraj teh posesti.
- seštejemo vrednosti pričakovanih zadetkov (xG) vseh vključenih strelav.
- vsoto dodelimo igralcu, ne glede na to, koliko je dejansko prispeval – vsi, ki so bili vključeni, so prispevali enako.

Če na podlagi xGChain na 90 minut izračunamo Ginijeve koeficiente, nam to pove, kako zelo uravnotežena je gradnja napadov določene ekipe. Če vrednost znaša 1,0, pomeni, da je vse napade ustvaril en sam igralec brez pomoči soigralcev, medtem ko bi vrednost 0,0 pomenila, da so pri vseh napadih (isto število minut) sodelovali čisto vsi igralci. Vrednosti se gibajo nekje od 0,12 do 0,30, pri čemer so običajno nižje vrednosti prisotne pri najboljših klubih, ki imajo veliko zelo kvalitetnih igralcev in zato nihče pretirano ne izstopa.

Prej omenjen xGBuildup pri izračunih izpusti še strele in asistence, s čemer se še bolj osredotoči na dejansko gradnjo napada in da večjo vrednost igralcem, ki pri gradnji napadov sodelujejo bolj iz ozadja (Lawrence, 2018). Ob vseh navedenih rešitvah je seveda mogoče s strojnimi učenjem implementirati kakršenkoli alternativni model ocenjevanja igralcev, ki je povsem prilagojen željam organizacije.

2.3 Taktična priprava na tekme in poročila

Taktika v splošnem predstavlja skrbno planirano dejanje ali strategijo za doseganje specifičnega cilja. Pri nogometu je to največkrat zmaga na tekmi, zato je izbira prave taktike ključnega pomena pri pripravi na tekmo. Kljub izrednemu pomenu pa do nedavnega ni bilo konkretnih raziskav na to tematiko, predvsem zaradi primanjkljaja podatkov. Z nosljivimi napravami in naprednejšim beleženjem podatkov, je tudi to postalo mogoče (Rein & Memmert, 2016).

V nadaljevanju predstavim nekaj najbolj priljubljenih pristopov in vizualizacij, ki so se v zadnjem času uveljavile na področju priprave na tekmo in poročil po tekmi. Velika večina primerov v tem poglavju se nanaša na prikazane igre lastne ekipe ali nasprotnikov (angl. performance analysis), na podlagi katerih je smiselno prilagoditi pristop na tekmi.

S preprostimi vizualizacijami lahko na primer primerjamo taktiko, pristop in kvaliteto posameznih ekip. Primer je denimo primerjava ekip iz istega tekmovanja glede na hitrost napada oziroma premika proti голу na eni osi in število podaj v posameznem napadu na drugi osi. Na podoben način lahko primerjamo tudi druge metrike, vključno z ustvarjenimi priložnostmi, uspešnostjo podaj, obrambno intenziteto, postavitvijo itd. Poznavanje vedenja in načina igre lastnih in nasprotnikovih igralcev zagotovo predstavlja določeno taktično prednost. Na primer, za branilce je lahko zelo koristna informacija, če napadalec nasprotne ekipe v večini predložkov napada vratarja ali pa se giblje bolj proti bližnji oziroma oddaljeni vratnici (Van Haaren in drugi, 2019, str. 8).

Je pa na tem mestu vredno poudariti, da je pojem analitike zelo širok, možnosti pa posledično ogromno. V vsakem primeru se rešitve prilagajajo uporabniku oziroma naročniku, tudi v obliki **ad-hoc analiz** glede iskanja določenih vzorcev. Na primer, kako uspešni smo pri prekinitvah ali celo bolj specifično, kako uspešni smo pri izvajanju kotov glede na podajo - bližnja ali oddaljena vratnica, vratarjev prostor, rob kazenskega prostora (Knutson, 2017). Kot primer, Pavitt, Braines in Tomsett (2021) so v sodelovanju z lokalnim nogometnim klubom izpostavili tudi vprašanje »Od kje igralec X največkrat poda predložek pred vrata?«, kar se da v primeru pozicijskih podatkov preprosto prikazati s točkami na skici igrišča.

2.3.1 Podatki o dogodkih

Po besedah Davida Sumpterja, enega od začetnikov razvoja podatkovne analitike v evropskem nogometu, je na povečanje popularnosti analitike v nogometu vplivala predvsem dostopnost podatkov. Nekdaj so se uporabljali zgolj numerični podatki v obliki golov, strelav, posesti ipd., medtem ko se je z razvojem nosljivih naprav uveljavila tudi uporaba tako imenovanih pozicijskih (angl. positional) oziroma o podatkih o dogodkih (angl. event data), ki s pomočjo koordinat (x, y) opredelijo vsako podajo, obrambno akcijo ali strel. Za namene uporabe teh podatkov so se v nogometu uveljavile številne relativno nezahtevne vizualizacije, ki velike količine podatkov združijo v preprosto razumljive grafike. Med temi so nekateri najbolj znani primeri: zemljevidi strelav (angl. shotmaps), mreže podaj (angl. pass networks), zemljevidi aktivnosti/gibanja (angl. heatmaps) (Sumpter, 2016; Uppsala Universitet, brez datuma).

Vizualizacije lahko služijo kot orodje za analizo lastne igre oziroma igralcev, po drugi strani pa nudijo priložnost za analizo in pripravo na nasprotnika, saj na zelo enostaven način površinsko pokažejo, na čem temelji nasprotnikova igra in od kje prežijo največje nevarnosti. Omogočijo precej dober uvid v dejansko dogajanje na določeni tekmi, hkrati pa lahko kot pripomoček precej skrajšajo čas podrobne video analize. Podobni prikazi odgovarjajo na številna vprašanja trenerjev in igralcev, med katerimi so na primer Pavitt, Braines in Tomsett (2021) v sodelovanju z lokalnim nogometnim klubom Leatherhead FC izpostavili »S katerim igralcem si igralec X največkrat izmenja podajo?« in »Kdo izmed igralcev je najbolj vključen pri gradnji (proti)napadov?«

Zemljevidi strelav (angl. shot map) na primer prikazujejo pozicije strelav po nogometnem igrišču, pri čemer so običajno z velikostjo kroga prikazane vrednosti pričakovanih zadetkov. V praksi so pogosto ob premiku miške na krog na voljo tudi dodatne informacije o strelu (Knutson, 2016).

Vse bolj priljubljen je koncept mreže podaj (angl. passing network), ki v večini primerov temelji na modelu xGChain (glej 2.2.3) in na poenostavljen način prikazuje celotno napadalno strukturo določene ekipe na opazovani tekmi. Služi lahko kot analiza lastne igre, hkrati pa kot analiza nasprotnika. Ponudi namreč hiter pregled glede sistema igre, opozarja na nevarnosti in ključne igralce pri gradnji napadov. Položaj krogca na grafu predstavlja povprečno pozicijo igralca ob dotiku z žogo, medtem ko velikost krogca ponazarja število dotikov. Puščice med igralci ponazarjajo vsaj 5 podaj na relaciji in so debelejšje, če je bilo med igralcema izmenjanih večje število podaj. Ker določeni igralci velikokrat sodelujejo v gradnji napadov po celem igrišču, so lahko točke njihovih dotikov precej razpršene. To razpršenost na mreži podaj ponazarjajo majhni trikotniki ob krogcih (Lawrence, 2018; Muller, 2022).

Še globlji pogled ponuja tudi tako imenovani sonar podaj (angl. pass sonar), ki se predvidoma uporablja skupaj z mrežo podaj. Medtem ko se prej omenjene mreže podaj

osredotočajo predvsem na podaje med igralci, sonarji podaj ponudijo pogled v raznolikost, učinkovitost in smer podaj. Dolžina stolpca predstavlja frekvenco podaj v določeno smer, medtem ko barva ponazarja povprečno dolžino podaje (Pimpaud, 2019).

Pri zemljevidih aktivnosti (angl. heatmaps) so deli igrišča obarvani glede na frekvenco opazovane spremenljivke, pri čemer lahko spremljamo razne aktivnosti ekip ali posameznih igralcev. Opazujemo lahko samo gibanje igralcev, ki je recimo v primeru mrež podaj ignoriramo, ko igralec nima žoge. Tudi to je namreč lahko zelo pomembno, saj so določeni igralci večino časa brez žoge. Sicer pa so lahko na zemljevidih aktivnosti tudi druge konkretnije spremenljivke – na primer, kje so bile podaje sprejete ali iz obrambnega vidika, kje so bile žoge pridobljene (Uppsala Universitet, brez datuma; Sumpter & Andrzejewski, brez datuma). Na podoben način lahko na skici igrišča prikažemo denimo tudi šprinte, odvzete žoge, preigravanja in podobno. V vsakem primeru gre pri prikazanem za izolirane primere uporabe, ki so lahko tudi interaktivni in združeni v aplikacije.

2.3.2 Sledljivi podatki

Še naprednejši pogled od podatkov o dogodkih so tako imenovani podatki 22 igralcev (angl. 22-player data) ali sledljivi podatki (angl. tracking data), pri katerih v določenem trenutku nogometne tekme s koordinatami opisujemo aktivnost vseh igralcev na igrišču, s čimer zajamemo celoten kontekst igre. To je zelo pomembno, saj imajo denimo vrhunski napadalci lahko v več kot 90 minutah igre žogo pri sebi manj kot 90 sekund, a na igro vplivajo z neprestanimi vtekanji, pritiskom in taktičnim postavljanjem, kar ne more biti izmerjeno s preprostimi numeričnimi statistikami (Uppsala Universitet, brez datuma).

V enem od primerov uporabe takšnih podatkov je Peralta Alguacil (2019) ugotavljal, kako agresivna vtekanja napadalcev odpirajo prostor ostalim soigralcem. Realno sliko gibanja igralcev je prikazal z modelom podaj. Ob označenih črtah, ki nakazujejo dejansko izvedene podaje, model opredeljuje preostale možnosti podaje na površini nogometnega igrišča, obarvane z zeleno oziroma rdečo barvo glede na preračunane verjetnosti za uspešnost podaje.

V uporabi in razvoju so dandanes še številni zanimivi modeli, ki so za potreba magistrskega dela manj relevantni in jih bom zgolj omenil. Med drugim so največ pozornosti deležni na primer analiziranje postavljanja na igrišču (v napadu odkrivanje, v obrambi pritisk) s pomočjo Voronojevih diagramov (Efthimiou, 2021; Fonseca, Milho, Travassos & Araújo, 2012), naprednejši modeli ocenjevanja posameznih potez in prispevka igralcev (Bransen, Van Haaren & Van De Velden, 2019; Decroos, Van Haaren, Bransen & Davis, 2019), kompleksnejši taktični modeli (Beal, Chalkiadakis, Norman & Ramchurn, 2020; Llana, Madrero & Fernández, brez datuma; Roy, Robberechts & Davis, 2021), še dodatno nadgrajene pričakovane vrednosti in mnogi ad-hoc modeli po željah nogometnih klubov.

2.4 Ostali primeri uporabe

Kar se tiče telesne priprave, je analitika v športu naredila ogromen preskok z razvojem in dostopnostjo nosljivih naprav (angl. wearables). Te namreč omogočajo beleženje časa, srčnega utripa, števila vdihov, pospeška, hitrosti, pretečene razdalje itd. Vse to nam seveda lahko pomaga pri spremljanju pripravljenosti, hkrati pa opozarja na morebitno preobremenjenost. Dodatni pozitivni učinki uporabe nosljivih naprav, ki so jih izpostavili trenerji, se nanašajo na dostopnost dodatnih informacij, ki pomaga pri sprejemanju odločitev glede začetne postave in menjav – koliko časa je določen igralec sposoben opraviti na najvišji ravni. Hkrati je s temi podatki trdo delo na treningih prej opaženo in večkrat nagrajeno (De Silva in drugi, 2018; Ravindranathan in drugi, 2017). Ob optimizaciji treningov lahko podatki iz nosljivih naprav pomagajo tudi pri preprečevanju poškodb, saj lahko delujejo tudi kot nekakšen zdravstveni informacijski sistem, ki na podlagi meritev opozarja na nevarnost poškodbe. To trenerjem omogoča pripravo treningov, ki prinašajo najboljše rezultate, a hkrati ne povečujejo tveganja za poškodbe (Zadeh in drugi, 2021).

Vsekakor je glede na povečanje denarnega vložka na vseh ravneh za nogometne organizacije prav tako zanimivo **poslovno poročanje**, ki pomaga pri optimizaciji prihodkov, odhodkov, marketinga in ostalih področij. Poslovna analitika je sicer definirana kot znanost ugotavljanja pomembnih poslovnih dognanj s pomočjo matematike, statistike in strojnega učenja. Uporablja se predvsem za izboljšave na ravni zadovoljstva strank, operativnega in finančnega delovanja ter ustvarjanje konkurenčne prednosti, kar pride v poštev tudi v nogometnih organizacijah (Cao & Duan, 2017).

Za športne organizacije so pod vejo poslovne analitike ob optimizaciji prihodkov in odhodkov denimo zanimiva tudi področja določanja cen, zadrževanja kupcev sezonskih vstopnic, vključevanja navijačev, upravljanja odnosov s strankami, digitalnega marketinga in podobno (Harrison, C.K. & Bukstein, 2016). Tudi prvaki v ameriškem nogometu iz leta 2019, Kansas City Chiefs, so predstavili, kako so optimizirali svoje stroške z digitalno preobrazbo. Orodja za poročanje uporabljajo na vse več področjih, med katerimi so na primer tudi analitika socialnih omrežij in dejavnosti na dan tekme – vstopnice, parkirišča in podobno (Ragsdale & Schutte, 2022).

Prav tako si želijo nogometni klubi zmanjšati količino dolgočasnih in ponavljajočih se nalog, ki so predvsem administrativne narave. To bi namreč dopuščalo več časa za aktivnosti, s katerimi lahko delajo razliko (Plattfaut & Koch, 2021). Ob vsem naštetem športne organizacije analitiko uporabljajo tudi v namene upravljanja socialnih omrežij, odnosov s strankami, analitiko prodaje kart in klubskih artiklov, optimizacijo cen vstopnic, oblikovanje marketinških strategij in podobno (Davenport, 2014b; Watanabe, Shapiro & Drayer, 2021).

2.5 Povzetek primerov uporabe

V poglavjih od 2.1 do 2.4 sem zbral različne primere uporabe podatkovne analitike v nogometu, jih na kratko predstavil in združil v smiselne skupine. V tabeli 1 so predstavljena ključna področja uporabe, ki so relevantna za slovenski nogometni prostor. Področje poslovne analitike zaradi karakteristik sogovornikov ni bilo vključeno v empirično raziskavo.

Tabela 1: Potencialni primeri uporabe

Področje uporabe	Primeri uporabe	Viri
Iskanje talentov in skavting (angl. recruitment and scouting analysis)	<ul style="list-style-type: none"> • Identifikacija potreb in potencialnega nabora igralcev. • Primerjalni grafi. • Potrditev potencialnih okrepitev. 	Gerrard (2016); Kröckel (2019); Lawrence (2018); Leško (2019); Marshall (2021); Uppsala Universitet (brez datuma); Rudd (2011); Pavitt, Braines & Tomsett (2021); Sumpter (2016); Sumpter & Andrzejewski (brez datuma)
Taktična priprava na tekme (angl. performance analysis)	<ul style="list-style-type: none"> • Analize nasprotnikov in lastne igre. • Ad – hoc poizvedbe. • Zahtevnejši taktični modeli. 	Beal, Chalkiadakis, Norman & Ramchurn (2020); Knutson (2017); Kröckel (2019); Uppsala Universitet (brez datuma); Pavitt, Braines & Tomsett (2021); Peralta Alguacil (2019); Rein & Memmert (2016); Sumpter (2019); Sumpter & Andrzejewski (brez datuma)
Telesna priprava (angl. athlete monitoring)	<ul style="list-style-type: none"> • Uporaba nosljivih naprav in analiza podatkov o fizični pripravljenosti. 	De Silva in drugi (2018); Ravindranathan in drugi (2017); Zadeh in drugi (2021); Yang, Yuan & Yan (2021)
Poslovna analitika (angl. business analytics)	<ul style="list-style-type: none"> • Poročila in simulacije za optimizacijo prihodkov, odhodkov itd. • Dodatno: avtomatizacija ponavljajočih se nalog. 	Davenport (2014b); Harrison, C.K. & Bukstein (2016); Plattfaut & Koch, (2021); Ragsdale & Schutte (2022); Watanabe, Shapiro & Drayer (2021)

Vir: lastno delo.

3 PRIVZEMANJE PODATKOVNE ANALITIKE V NOGOMETU

Privzemanje (angl. adoption) predstavlja celoten proces od seznanjenja z neko novo tehnologijo pa vse do trenutka, ko jo začnemo uporabljati. Na privzemanje sicer vpliva veliko število dejavnikov, med katere štejemo denimo organizacijsko kulturo, interes vodstva ter razmerje med zaznanimi prednostmi in stroški. Sicer se nanaša bolj na vidik organizacije in se začne že pri samem prepoznavanju obstoja določene tehnologije ter nadaljuje z odločitvijo o uvedbi in dejansko uporabo. Glede slednje je ključnega pomena **sprejemanje** (angl. acceptance), ki se v večji meri nanaša na posameznika in se pri uporabi nove tehnologije sprašuje, kateri so dejavniki, ki bodo vplivali na to, ali bo inovacijo dejansko uporabljal (Davis, 1989; Hernandez, Jimenez & José Martín, 2009; Straub, 2009).

V teorijah modelov je v večini primerov omenjeno podjetje (angl. firm), medtem ko bom za potrebe magistrskega dela to preslikal v (nogometno) organizacijo. Prav tako se večina literature nanaša na srednja in majhna podjetja, kar v bistvu ustreza tej raziskavi in strukturi slovenskih nogometnih organizacij.

3.1 Teorija razširjanja inovacij

Glede privzemanja je zelo pomembna teorija razširjanja inovacij (angl. Diffusion of Innovation, v nadaljevanju DOI), saj proučuje dejavnike, ki vplivajo na širjenje inovacij v organizaciji in analizira izzive, s katerimi se soočamo pri uvajanju inovacij. Rogers (2003, str. 5) je razširjanje oziroma tako imenovano difuzijo definiral kot »proces, v katerem je inovacija preko različnih kanalov v nekem časovnem intervalu komunicirana med člani socialnega sistema.« Gre torej za nekakšno socialno spremembo, ki spreminja strukturo in funkcijo sistema. Razlaga, da na naklonjenost k inovacijam v organizaciji vplivajo odnos do sprememb, organizacijska kultura in značilnosti iz okolja (Rogers, 1995).

V širšem smislu je inovacija vsaka nova ideja za določeno populacijo. Rogers (2003, str. 12) je inovacijo definiral kot »idejo, prakso ali predmet, ki je zaznan kot novost s strani posameznika ali druge enote privzemanja.« Pri tem ni pomembno, da je ideja, praksa ali predmet objektivna novost, temveč to, da je zaznana kot novost. Prav tako inovacija nujno ne pomeni napredka oziroma izboljšave za posameznika. Na nagnjenost k inovacijam v organizaciji vplivajo trije ključni sklopi dejavnikov. Prvi je značilnost vodilnih in njihov odnos do sprememb, drugi predstavlja značilnosti organizacijske strukture (centralizacija, kompleksnost itd.), tretji pa zunanje značilnosti organizacije. Vse to je izjemno pomembno pri implementaciji inovacij in lahko izdatno pospeši ali zavira samo implementacijo (Rogers, 2003, str. 411; Straub, 2009).

Zavedati se moramo, da obstajajo dejavniki, ki razširjanje inovacije preprečujejo, inovacije pa se ne razširjajo same od sebe. Lep primer za to je tako imenovana »QWERTY« tipkovnica, ki jo uporabljamo še danes. Profesor Dvorak je namreč v zgodnjih štiridesetih letih prejšnjega stoletja iznašel prilagoditev postavitve tipk na tipkovnici (kasneje je

podobno alternativo predstavil še Colemak). Le ta omogoča precej bolj učinkovito rabo v primerjavi s standardno »QWERTY« tipkovnico, kar so med drugim potrdili tudi na Ameriškem državnem inštitutu za standarde in Združenju proizvajalcev opreme. Kljub vsemu pa se Dvorakova postavitve tipkovnice ni nikoli popularizirala. Prehod iz klasične na alternativno postavitve tipkovnice očitno v družbi ni vzbudil dovolj pričakovane koristi, da bi bili v zameno pripravljeni ponuditi nekaj prilagajanja in učenja (Rogers, 2003, str. 8).

Inovacija gre pred popolnim sprejetjem skozi pet faz. O **poznavanju** (angl. knowledge, tudi awareness) govorimo, ko se posameznik ali skupina zaveda, da neka inovacija obstaja, hkrati pa razume, kako v osnovi funkcionira. V fazi **ovrednotenja** (angl. evaluation, ponekod tudi persuasion) se posameznik ali skupina opredeli glede dotične inovacije glede na identifikacijo potreb in problemov. Stopnja ujemanja med inovacijo in problemi, ki jih rešuje, vpliva na **odločitev** (angl. decision), s katero sprejme oziroma zavrne inovacijo. Zavrnitev (angl. nonadoption) je lahko aktivna ali pasivna, kar pomeni, da možnost za privzemanje dejansko nikoli ni obstajala. Uporaba oziroma **implementacija** (angl. implementation) se zgodi, ko se nova ideja začne uporabljati. Temu pa sledi še **potrditev** (angl. confirmation), kjer posameznik išče povratne informacije, na podlagi katerih lahko ob negativnem odzivu spremeni svojo odločitev (Rogers, 1995, 2003). Kljub temu pa večina raziskav temelji na zgolj treh fazah – **ovrednotenje, odločitev za privzemanje in uporaba** oziroma implementacija (Puklavec, 2016; Puklavec, Oliveira & Popovič, 2017).

Rogers (2003) je prav tako definiriral pet medsebojno povezanih, a konceptualno različnih lastnosti, ki opredeljujejo potencialno privzemanje neke inovacije. **Relativna prednost** (angl. relative advantage) predstavlja dojemanje inovacije kot boljše od predhodnih. **Združljivost** (angl. compatibility) se nanaša na pričakovano ujemanje inovacije s trenutnimi vrednotami, preteklimi izkušnjami in potrebami potencialnih prevzemnikov. **Kompleksnost** (angl. complexity) se nanaša na zaznano zahtevnost razumevanja in uporabe, medtem ko se **možnost preizkusa** (angl. trailability) opredeljuje možnost preizkušanja inovacije pred samo odločitvijo. **Vidnost** (angl. observability) omenja, kako ostali v socialnem sistemu vidijo rezultate inovacije.

V primeru razširjanja prvih mobilnih telefonov je na primer relativna prednost lahko prenosljivost in neprekinjena dosegljivost. Združljivost ni bila problematična, saj so bili takoj mogoči klici tudi na stacionarne telefone, medtem ko kompleksnost ni problematična, saj je uporaba ostala praktično enaka, nove funkcionalnosti (npr. sistem kratkih sporočil) pa so bile relativno preproste. Z vidika možnosti preizkusa si je lahko vsak posameznik sposobil napraviti svojega prijatelja, hkrati pa so mnogi ponudniki v tistem času omogočali brezplačne mesečne preizkuse, s katerimi so vzpodbudili rabo. Seveda je pri mobilnih telefonih izdatno vplivala tudi vidnost, saj je mobilni telefon v svojih začetkih predstavljal statusni simbol (Rogers, 2003, str. 262-265).

Ena bolj prepoznavnih kritih teorij inovacij se nanaša predvsem na tako imenovano pro-inovacijsko pristranskost, s katero impliciramo, da mora biti inovacija sprejeta hitro in s

strani vseh članov socialnega sistema, pri tem pa ignoriramo slabe inovacije in njihove zavrnitve (Rogers, 2003, str. 106). DOI se sicer osredotoča na tehnološke dejavnike, zaradi česar ga pogosto dopolnjujemo z alternativnimi modeli (Picoto, Bélanger & Palma-dos-Reis, 2014).

3.2 Okvir tehnologija – organizacija – okolje

Razširjanje inovacij dopolnjuje okvir tehnologija – organizacija – okolje (angl. Technology-Organization-Environment Framework, v nadaljevanju TOE), ki proučuje privzemanje določene inovacije v tehnološkem in organizacijskem kontekstu ter kontekstu okolja (Tornatzky, Fleischer & Chakrabarti, 1990). Še posebej zanimiv je proces privzemanja v manjših organizacijah, kjer so velikokrat vodilni tudi sami uporabniki, kar pride v poštev tudi v konkretnem obravnavanem primeru.

Okvir TOE opredeljuje, kako kontekst organizacije vpliva na privzemanje in implementacijo inovacij. Konkretnije na to vplivajo dejavniki iz tehnološkega, organizacijskega in konteksta okolja. Okvir TOE ne predstavlja konkurenčne razlage, temveč deluje komplementarno in kot dodatna razlaga oziroma dopolni ostalim modelom privzemanja. Pretekle raziskave so denimo pokazale, da je TOE okvir skladen s teorijo DOI, kar pomeni, da ju lahko preverjeno brez težav združujemo. DOI poudari tehnološke lastnosti kot gonila za razširjanje in opisuje sam proces znotraj organizacije, medtem ko ga TOE dopolni z vključevanjem vseh notranjih in zunanjih dejavnikov, ki lahko vplivajo na privzemanje. Ob tehnoloških izpostavlja tudi organizacijske dejavnike in dejavnike iz okolja (Baker, 2012; Picoto, Bélanger & Palma-dos-Reis, 2014; Puklavec, 2016; Puklavec, Oliveira & Popovič, 2017). Kombinacija dejavnikov iz konteksta tehnologije, organizacije in okolja torej predstavljajo tako omejitve kot tudi priložnosti za tehnološke inovacije. Govora je o dejavnikih, ki vplivajo na privzemanje tehnoloških inovacij znotraj obravnavane organizacije (Tornatzky, Fleischer & Chakrabarti, 1990, str. 154).

V nadaljevanju opredelim ključne dejavnike iz tehnološkega in organizacijskega konteksta ter konteksta okolja. Glede na relativno neraziskanost obravnavanega področja so mnogi smotno privzeti iz drugih področij, pri čemer so sicer številni drugi bolj specifični dejavniki izpuščeni, ker za obravnavan primer niso relevantni.

3.2.1 Tehnološki kontekst

V tehnološki kontekst spadajo vse tehnologije, ki so relevantne za dotično organizacijo. Bodisi tiste, ki so že implementirane in se uporabljajo, bodisi tiste, ki so na voljo, a se še ne uporabljajo. Že implementirane tehnologije so pomembne, ker predstavljajo nekakšno okvirno mejo za privzemanje inovacij, ki si jih organizacija lahko v dani situaciji privošči. Na drugi strani še ne implementirane tehnologije omogočajo vpogled v to, kaj vse je mogoče in kako bi to lahko organizaciji pomagalo pri nadaljnjem razvoju (Baker, 2012). Kot prvi dejavnik je smiselno izpostaviti **relativno prednost** (angl. relative advantage), ki je

zagotovo med najpogosteje uporabljenimi dejavniki pri raziskovanju privzemanja. Predstavlja zaznavanje neposredne prednosti uporabe inovacije v primerjavi z obstoječim sistemom (Rogers, 1995, 2003). Zaznava prednosti napram obstoječemu sistemu bo spodbudila privzemanje inovacije. Pozitiven vpliv zaznane relativne prednosti naj bi bil opazen že v fazi evalvacije oziroma faze prepričanja, kjer organizacija išče razloge za izvedljivost in smiselnost privzemanja inovacije pred samo odločitvijo. Relativna prednost je pomembna tudi v kasnejših fazah privzemanja, saj vpliva na željo po dejanski uporabi. Če uporabnik ali skupina zazna prednosti napram obstoječemu sistemu, bo to spodbudilo privzemanje in samo uporabo inovacije, kar potrjujejo številne raziskave (Baker, 2012; Chen, Preston & Swink, 2015; Daradkeh, 2019; Lai, Sun & Ren, 2018; Maroufkhani, Wan Ismail & Ghobakhloo, 2020). Puklavec, Popovič in Oliveira (2017) sicer ugotavljajo, da v majhnih in srednje velikih podjetjih relativno prednost nima statistično značilnega pozitivnega vpliva na privzemanje in rabo poslovno-inteligenčnih sistemov, saj naj bi tako prevzemniki kot neprevzemniki do dobra poznali relativne prednosti novih sistemov. Vendarle bi lahko bilo v specifičnem primeru nogometnih organizacij drugače, saj predvidoma podobni sistemi niso v uporabi, hkrati pa jih odločevalci tudi pomanjkljivo poznajo.

Naslednji dejavnik je **zaznana združljivost** (angl. perceived compatibility), ki se nanaša na »ujemanje inovacije z vrednotami, preteklimi izkušnjami in potrebami potencialnih uporabnikov« (Rogers, 2003). Z drugimi besedami, gre za konsistentnost inovacije s trenutnim sistemom v organizaciji. Inovacija namreč prinaša uspeh, če jo lahko organizacija nemoteno sprejme. Organizacija bo lahko najbolj izkoristila konkurenčno prednost inovacije, če bo privzemanje potekalo gladko in v skladu z internimi vrednotami in praksami. Nezdružljiva inovacija na drugi strani je lahko za organizacijo draga in zahtevna, kar pa preprečuje pridobitev prednosti, ki jo inovacija prinaša. Tudi, če inovacijo brez težav privzamemo, lahko še vedno zahteva drugačen pristop v primerjavi s trenutno prakso, kar pomeni, da preprosta inovacija še ne pomeni višje združljivosti. Posledično lahko sklepamo, da zahtevnejše in bolj kompleksne inovacije zavirajo privzemanje (Gangwar, 2018; Awa, Ukoha & Igwe, 2017; Chen, Preston & Swink, 2015; Chong & Lim, 2022; Daradkeh, 2019; Maroufkhani, Iranmanesh & Ghobakhloo, 2023; Maroufkhani, Wan Ismail & Ghobakhloo, 2020).

Kompleksnost (angl. complexity) predstavlja »stopnjo, do katere je inovacija zaznana kot težavna za razumevanje in uporabo« (Rogers, 2003). Za uspešen proces privzemanja mora biti inovacija zaznana kot preprosta za uporabo, hkrati pa jo morajo zaposleni oziroma potencialni uporabniki dobro poznati. Prevzem nove tehnologije bo spodletel, če je implementacija zaznana kot preveč ambiciozna in zahtevna (Rogers, 1995). Tudi če gre za preprosto združljive rešitve, lahko kompleksnost zavira privzemanje z vidika dejstva, da gre za drugačen pristop kot pred implementacijo inovacije in so posledično potrebne večje prilagoditve v obstoječih procesih. Večja kompleksnost predstavlja večje tveganje v procesu privzemanja, zato po številnih raziskavah predstavlja pomemben dejavnik (Gangwar, 2018;

Chong & Lim, 2022; Daradkeh, 2019; Maroufkhani, Iranmanesh & Ghobakhloo, 2023; Maroufkhani, Wan Ismail & Ghobakhloo, 2020).

Uspešno privzemanje je prav tako bolj verjetno, če ima organizacija **možnost preizkusa** (angl. trialability), v najboljšem primeru brez stroškov oziroma druge obveze. Ta namreč omogoči boljše ovrednotenje sistema, kar je ključno za ustrežnejše zaznavanje uporabnosti in kompleksnosti ter pomaga pri prehodu iz faze implementacije v fazo uporabe (Rogers, 1995, 2003). Potencialni uporabniki si želijo preizkusiti novost, da jo lažje ocenijo. Hkrati to že v samem začetku predstavlja neke vrste izobraževanje, kar lahko občutno vpliva na končno odločitev. Če je inovacija že v samem začetku izpostavljena težavam, je bolj verjetno da bo šla hitreje in lažje skozi proces prevzemanja. Na privzemanje bo pozitivno vplivala tudi možnost začetne implementacije z manj tveganja in možnostjo nadgrajevanja ob zadovoljstvu (Baker, 2012; Chen, Preston & Swink, 2015; Chong & Lim, 2022; Daradkeh, 2019; Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid, 2020; Maroufkhani, Wan Ismail & Ghobakhloo, 2020). Pomen možnosti preizkusa se je denimo pokazal tudi pri privzemanju tehnologije Wi-Fi, kjer je bilo pri posameznikih brez brezžične naprave za eksperimentiranje opaziti občutno nižjo stopnjo privzemanja (Murphy, 2005). Medtem ko sta združljivost in kompleksnost precej konsistentna dejavnika, je možnost preizkusa kritični dejavnik, še posebej za zgodnje prevzemnike (Moghavvemi, Hakimian, Faziharudean & Feissal, 2012).

Ker podatkovna analitika v nogometu pri nas še ni uveljavljena, je na mestu tudi vprašanje glede dostopnosti relevantnih podatkov (Shet, Poddar, Wamba Samuel & Dwivedi, 2021). Za implementacijo podatkovne analitike je namreč treba imeti vzpostavljene kritične podatkovne vire, ki omogočajo zanesljiv dostop do relevantnih in kakovostnih podatkov. Če organizacija dostopa do podatkov nima, pa je to lahko zelo pomemben dejavnik, pri katerem pridejo do izraza tudi dodatni stroški. Preostali potencialni tehnološki dejavniki se nanašajo denimo še na vidnost inovacije, varnost, kvaliteto podatkov, poznavanje masovnih podatkov, dostopnost orodij za njihovo obdelavo in ostale bolj specifične dejavnike (Baig, Shuib & Yadegaridehkordi, 2019; Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid, 2020).

3.2.2 Organizacijski kontekst

Organizacijski kontekst se nanaša na vire in lastnosti organizacije, vključno s strukturo med zaposlenimi. Ob tem opredeljuje neformalne in formalne povezave ter komunikacijske procese oziroma vire znotraj organizacije (Baker, 2012, str. 3-4).

Za privzemanje je ključna **podpora (vrhnjega) managementa** (angl. top-management support), ki vpliva na pozitiven pogled glede inovacije v organizaciji. Vrhnji management se nanaša na višje odločevalce ali posameznike, ki imajo največ odgovornosti in pooblastil v procesu odločanja, medtem ko podpora pomeni njihovo pripravljenost do dodelitve virov in spodbujanja predvidenih sprememb. Če je vrhnji management optimističen glede prednosti, ki jih prinaša inovacija, je privzemanje te inovacije precej bolj verjetno. Po drugi strani, v kolikor vrhnji management ne zaznava uporabnosti in koristi inovacije, je

privzemanje manj verjetno (Gangwar, 2018; Chen, Preston & Swink, 2015; Chong & Lim, 2022; Lai, Sun & Ren, 2018; Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid, 2020; Maroufkhani, Wan Ismail & Ghobakhloo, 2020; Mneneý & Van Belle, 2016; Puklavec, Oliveira & Popovič, 2017). Po Rogers (2003) je najhitrejše privzemanje običajno posledica avtoritativnih odločitev iz vrst vrhnjega managementa.

V okviru podpore vrhnjega managementa lahko ima zelo pomemben vpliv tudi vloga projektnega vodje ali tako imenovanega **prvaka projekta** (angl. project champion). Izraz predstavlja predstavnika vodstva, ki pozna in razume prednosti podatkovne analitike za organizacijo in posledično vodi ter organizira projekt skozi faze razvoja in implementacije. Prav tako se pričakuje, da predvsem v fazi evalvacije idejo zagovarja pri ostalih predstavnikih managementa in znotraj celotne organizacije. Gre za člana vodstva, ki ob tradicionalnih nalogah opravlja tudi druge – zagotavlja motivacijo, deluje kot ambasador projekta, zagovarja njegove potrebe in jih usklajuje z vizijo organizacije ter skrbi za dobre odnose med vsemi ključnimi deležniki (Pinto & Patanakul, 2015; Pinto & Slevin, 1989). Howell in Shea (2006) opisujeta prvaka projekta kot predstavnika, ki nenehno zbira informacije, zagotavlja vire in skrbi za motiviranost projektnega tima. Po Bose in Luo (2012) prisotnost prvaka projekta predstavlja zelo pomemben dejavnik pri privzemanju informacijskih rešitev, medtem ko se odsotnost večkrat odraža v neprevzeti inovaciji. V zadnjem času se je v organizacijah uveljavile vloge digitalnih direktorjev (angl. chief digital officer) in podatkovnih direktorjev (angl. chief data officer), ki zaradi svojega tehnološkega znanja in navdušenja nad inovacijami pogosto nastopijo kot prvaki projektov. Puklavec, Popovič in Oliveira (2017) so zaznali, da je prisotnost prvaka projekta najbolj pomemben dejavnik pri privzemanju v splošnem in eden od najbolj pomembnih v prav vseh fazah privzemanja poslovnointeligenčnih sistemov v majhnih in srednje velikih podjetjih.

Podpora managementa je v večini odvisna od razpoložljivih organizacijskih virov. To poimenujemo tudi **organizacijska pripravljenost** (angl. organizational readiness), ki predstavlja razpoložljivost nujnih organizacijskih virov za privzemanje inovacije (Chen, Preston & Swink, 2015, str. 18). Gangwar (2018, str. 6) je v raziskavi o privzemanju analitike masovnih podatkov organizacijsko pripravljenost definirala kot sposobnost in pripravljenost zagotavljanja potrebnih finančnih, tehničnih ali človeških virov. V okviru organizacijske pripravljenosti je vredno izpostaviti finančni primanjkljaj in nezadostnost tehničnega znanja. Še posebej z vidika malih in srednje velikih organizacij predstavljata ključna zaviralca privzemanja inovacij, kar potrjuje več raziskav (Gangwar, 2018; Chen, Preston & Swink, 2015; Chong & Lim, 2022; Daradkeh, 2019; Lai, Sun & Ren, 2018; Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid, 2020; Maroufkhani, Wan Ismail & Ghobakhloo, 2020; Mneneý & Van Belle, 2016; Ramakrishnan, Philpott, Duan & Cao, 2017).

Kot omenjeno, razpoložljivi viri vključujejo finančna sredstva, ki opredeljujejo tudi **finančno pripravljenost** (angl. perceived financial readiness). Ta opredeljuje proračun oziroma finančne vire, ki so na voljo za implementacijo nove tehnologije ali inovacije. Organizacija bo namreč precej bolj verjetno privzela inovacijo, če je na to finančno

pripravljena. V primeru pomanjkljive pripravljenosti je uvajanje novosti skoraj nemogoče, ne glede na to, kako visoka je zaznana relativna prednost. Še posebej pri manjših podjetjih naj bi previsoki stroški predstavljali enega najpomembnejših dejavnikov pri zaviranju nadaljnjega tehnološkega razvoja organizacije (Baig, Shuib & Yadegaridehkordi, 2019; Daradkeh, 2019; Taxman, Henderson, Young & Farrell, 2012).

Ob finančnih so pomembni tudi preostali viri, ki vključujejo vso znanje in talente zaposlenih. Če viri niso zadovoljivi, bo tehnološka inovacija težko implementirana in uporabljana (Chen, Preston & Swink, 2015; Chong & Lim, 2022; Eder & Igarria, 2001), kar je predvsem z vidika zaposlenih predvidoma problematično tudi v slovenskih nogometnih organizacijah, kjer ni zaposlenih veliko inženirjev ali programerjev (Davenport, 2014b). S tega vidika je ključnega pomena **zadostnost človeških virov** (angl. adequacy of human resource), ki predpostavlja, da ima organizacija dovolj zaposlenih z ustreznim znanjem za privzemanje inovacije (Mneney & Van Belle, 2016). Lai, Sun in Ren (2018) ugotavljajo, da je zadostnost človeških virov skupaj s tehnološkimi ključnega pomena za uspešno privzemanje analitike masovnih podatkov.

Glede virov je pomembna tudi **velikost organizacije** (angl. firm size), saj je obseg virov neposredno odvisen od same velikosti organizacije (Baig, Shuib & Yadegaridehkordi, 2019). Večja organizacija ima običajno na voljo več virov, orodij in tehničnega znanja, zaradi česar si lahko privoščijo tudi večja tveganja pri sprejemanju novih inovacij. Na drugi strani imajo manjše organizacije pogosto težave s tako imenovano revščino virov (angl. resource poverty) (Welsh & White & Dowell, 1981), ki zavira eksperimentiranje in samo implementacijo inovacij. Če velikost združujemo s stroškov, lahko sklepamo, da manjše organizacije težje argumentirajo čas in vire, ki so potrebni za uspešno privzemanje inovacije (Lai, Sun & Ren, 2018).

Ustreznost organizacijskega konteksta z vidika privzemanja tehnologije ponazarja primer proizvajalca motociklov, Harley Davidsona, ki je v devetdesetih letih prejšnjega stoletja implementiral sodobno upravljanje dobavne verige. K uspešni implementaciji je namreč ogromno prispevalo učinkovito povezovanje zaposlenih iz različnih oddelkov in delovnih mest (Baker, 2012). Med preostalimi organizacijskimi dejavniki lahko omenimo še vzpostavljeno digitalno oziroma podatkovno okolje, strateško usmerjenost, management sprememb, kulturo racionalnega odločanja, nadzor nad podatki, pravno skladnost in primerna analitična orodja ter izobraževanja (Baig, Shuib & Yadegaridehkordi, 2019; Pedro, Brown & Hart, 2019; Popovič, Hackney, Coelho & Jaklič, 2012).

3.2.3 Kontekst okolja

Kontekst okolja se v splošnem nanaša na priložnosti in omejitve glede inovacij ter vključuje strukturo trga in panoge, prisotnost tehnoloških storitev in pravno-regulativno okolje (Baker, 2012, str. 5). V nadaljevanju izpostavljam pritisk konkurentov in vpliv zunanjih ponudnikov,

medtem ko so med preostalimi dejavniki iz konteksta okolja na primer še zakonodaja, podpora vlade, varnost in samo dogajanje na trgu (Baig, Shuib & Yadegaridehkordi, 2019).

Zgodnji prevzemniki predvsem v primeru uspešne implementacije vplivajo na svoje konkurente, kar spodbuja privzemanje. Čeprav je primerjanje med konkurenti prisotno praktično povsod, je v športu **pritisak konkurentov** še posebej izrazit. Subjektivno uspešnost organizacija sicer meri glede na svojo vizijo, vendarle pa je mogoče ne glede na različne vizije nogometnih klubov po koncu sezone na povsem preprost in racionalen način razvrstiti njihovo objektivno uspešnost od prvega do zadnjega. Če organizacije na tehnološkem področju ne naredijo koraka naprej, lahko precej zaostanejo za konkurenco in postanejo ranljive. Mnoge organizacije se v teh primerih zatekajo tudi k izkoriščanju zunanjih virov (angl. outsourcing), saj na tak način ostajajo konkurenčni in stroškovno učinkoviti. Veliko raziskav nakazuje, da uporaba podatkovne analitike v konkurenčnih podjetjih motivira lastnike in vrhnji management k spodbujanju uporabe poslovne inteligence in analitike tudi v njihovi organizaciji (Chong & Lim, 2022; Malladi & Krishnan, 2013; Maroufkhani, Wan Ismail & Ghobakhloo, 2020). V tem kontekstu je zanimiva izjava odločevalca iz enega največjih nemških nogometnih klubov, ki je izpostavil opažene tehnološke inovacije pri konkurentu v angleški ligi. Poudaril je, da ima Manchester City lastnega direktorja digitalnega poslovanja, kar jim občutno pomaga pri izkoriščanju prednosti tehnoloških inovacij (Plattfaut & Koch, 2021, str. 243).

Pomembno vlogo znotraj konteksta okolja imajo lahko še **zunanji ponudniki in podpora**. Več podpore namreč ne spodbuja le privzemanja, ampak tudi dejansko uporabo inovacije. Možnost uporabe obstoječe predpripravljene platforme, programov izobraževanja in tehnične podpore bo pozitivno vplivalo na privzemanje tehnologije (Gangwar, 2018; Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid, 2020; Maroufkhani, Wan Ismail & Ghobakhloo, 2020).

3.3 Modeli sprejemanja tehnologije

Samo privzemanje inovacije v organizaciji še ne pomeni, da se bo tehnologija znotraj organizacije dejansko uporabljala. Na koncu procesa privzemanja sledi še sprejemanje, ki se nanaša na samo uporabo inovacije. Pri sprejemanju gre za dokazljivo željo uporabniške skupine po uporabi informacijsko tehnologije, ki je oblikovana tako, da podpira naloge in posledično cilje skupine. V primeru odsotnosti uporabniškega sprejemanja je uspešnost novih informacijskih sistemov precej nižja. Posledično sprejemanje predstavlja ključni dejavnik za uspeh informacijskega sistema (Davis, 1993; Dillon & Morris, 1996, str. 12-13; Puklavec, Oliveira & Popovič, 2017).

Model sprejemanja tehnologije (angl. Technology Acceptance Model, v nadaljevanju TAM) je bil sicer definiran že v devetdesetih letih prejšnjega stoletja, a z nekaj nadgradnjami še vedno predstavlja temelj teorije sprejemanja, ki je uporabljen v veliki večini člankov na to tematiko. Osnova modela temelji na odnosu med dvema ključnima idejama. Prva je tako

imenovana **zaznana uporabnost** (angl. perceived usefulness, v nadaljevanju PU), pri kateri gre v bistvu za percepcijo same uporabnosti ali praktičnosti sistema, na podlagi katere bi lahko dosegli napredek v konkretni organizaciji. Definirana je kot »stopnja, do katere uporabnik verjame, da mu bo uporaba novega sistema pomagala v smislu povečane delovne uspešnosti« (Davis, 1989, str. 320). Druga ideja je **zaznana enostavnost uporabe** (angl. perceived ease of use, v nadaljevanju PEOU), ki predstavlja »stopnjo, do katere uporabnik zaznava, da bo lahko sistem uporabljal brez dodatnega napora ali težav« (Davis, 1989, str. 320). Z drugimi besedami, gre za uporabnikovo subjektivno mnenje o enostavnosti uporabe nove tehnologije. Medtem ko se PU nanaša na ekstrinzično motivacijo v smislu učinkovitosti in učinkovitosti, se PEOU osredotoča na zagotavljanje fleksibilnosti in udobja (Davis, 1989).

Učinek zunanjih spremenljivk na vedenjsko namero je pogojen z omenjenima ključnima idejama zaznane uporabnosti in enostavnosti uporabe. Zunanji dejavniki neposredno ne vplivajo na odnos ali vedenje, temveč vplivajo posredno preko PU in PEOU. Z drugimi besedami, zunanje spremenljivke oziroma dražljaji torej vplivajo na motivacijo uporabnika (PU, PEOU), ta pa preko odnosa do uporabe (angl. attitude) vpliva na dejansko uporabo (Chuttur, 2009; Davis, 1989; Mohammadi & Isanejad, 2018).

V nasprotju s prej omenjenimi modeli privzemanja je bil TAM že v začetku zasnovan na podlagi računalniške znanosti, specifično za raziskovanje privzemanja moderne tehnologije. Hkrati se od modelov DOI in TOE razlikuje, ker je osredotočen na posameznika in njegovo dejansko uporabo tehnologije. Model izpostavlja pomen posameznikovega zaznavanja določene tehnologije. Znotraj populacije namreč obstajajo skupine, ki različno dojemajo enostavnost uporabe in uporabnost inovacije. Dojemanje uporabnosti inovacije je predvidoma povezana tudi z dejstvom, kako inovativen je posameznik sam po sebi. Model izvira iz dveh sociopsiholoških modelov iz osemdesetih, in združuje teorijo načrtovanega vedenja (angl. theory of planned behaviour) in teorijo utemeljenega ukrepanja (angl. theory of reasoned action) (Straub, 2009; Venkatesh & Bala, 2008).

Model je bil kasneje razširjen in izpopolnjen v TAM2, ki vključuje dodatne spremenljivke. Socialni vpliv opredeljujeta subjektivna norma, kot sprejemanje nekih socialnih standardov in podoba kot pozitivni vpliv na status posameznika v sistemu. Kognitivni proces pa dodatno opredeljujejo relevantnost delovnega mesta, kakovost rezultata, vidnost rezultatov in zaznana enostavnost uporabe (Venkatesh & Bala, 2008). Sledil je TAM3, ki v še večji meri upošteva razlike med posamezniki. Tako so bili dodani še vplivi (Venkatesh & Bala, 2008):

- računalniške samoučinkovitosti,
- zaznavanja zunanjega nadzora,
- straha pred računalnikom,
- računalniške igrivosti,
- zaznanega uživanja ob uporabi,
- objektivne uporabnosti.

Prav tako TAM3 predpostavlja tri nove povezave, na katere vplivajo izkušnje posameznika. Te namreč vplivajo na razmerje med zaznano enostavnostjo uporabe in zaznano uporabnostjo, razmerje med strahom pred uporabo računalnika in zaznano enostavnostjo uporabe ter razmerje med zaznano enostavnostjo uporabe in vedenjsko namero uporabe (Venkatesh & Bala, 2008; Wixom & Todd, 2005).

Glede na področja so se uveljavile še številne nadgradnje z dodanimi spremenljivkami, med katerimi sta recimo tudi pričakovano tveganje (angl. perceived risk) in pa finančne stroške (angl. financial cost). Potencialni uporabniki so preprosto manj nagnjeni k tveganju ali visokim stroškom, če ne vedo prave vrednosti, ki jo tehnologija prinaša (Ben Arfi, Ben Nasr, Khvatova & Ben Zaied, 2021).

Mohammadi in Isanejad (2018) sta s pomočjo razširjenega TAM modela, ki vključuje tudi odnos (angl. attitude) in zadovoljstvo uporabnika (angl. user satisfaction), analizirala odnose med PU, PEOU in uporabo tehnoloških inovacij v športnih organizacijah. Pri tem sta upoštevala nekatere zunanje dejavnike – računalniška samoučinkovitost, strah pred tehnologijo in zaznano uživanje ob uporabi. Ugotovila sta, da imajo odnos, samoučinkovitost, zaznana uporabnost in zaznana enostavnost največji vpliv na samo uporabo tehnologije. Prav tako sta zaznala negativen vpliv straha pred tehnologijo na zaznano enostavnost uporabe in odnos ter pozitiven vpliv računalniške igrivosti na zaznano enostavnost in uporabo.

Računalniška ali tehnološka samoučinkovitost pomeni posameznikovo presojo svojih sposobnosti glede samostojnega izvajanja določenih nalog in iskanja rešitev z uporabo računalnika oziroma druge napredne tehnologije. V splošnem višji nivo tehnološke samoučinkovitosti vodi k višjemu nivoju sprejemanja informacijske tehnologije (Saade & Kira, 2009). Če posameznik zaupa v svoje sposobnosti glede uporabe informacijske tehnologije, jo bo tudi lažje razumel, kar bo povečalo možnost same uporabe. Zaznana tehnološka samoučinkovitost ima posreden in neposreden vpliv na samo uporabo informacijske tehnologije (Mohammadi & Isanejad, 2018).

Strah pred uporabo računalnika oziroma računalniška tesnoba (angl. computer anxiety) je še ena izmed zunanjih spremenljivk, ki nekoliko izgublja na veljavi z neprestano globalno digitalizacijo in tehnološkim razvojem. Sicer predstavlja strah, jezo, tesnobo, predvsem pa nelagodje, ki ga posameznik začuti, ko uporablja računalnik oziroma informacijsko tehnologijo na splošno. To se dogaja predvsem osebam, ki tehnologijo razumejo kot nevarnost (Venkatesh, 2003).

Če je ob uporabi tehnologije prisoten strah, to v večini primerov pripelje do manj učinkovite rabe tehnologije in slabšega počutja. Bolj tesnobno kot se ljudje počutijo zaradi tehnologije, slabša bo njihova zaznana stopnja enostavnosti in obratno (Mohammadi & Isanejad, 2018).

V nasprotju s strahom denimo na namero po uporabi vpliva tudi **zaznan užitek ob uporabi tehnologije**. Ta opisuje reakcijo posameznika ob uporabi tehnologije in pri tem ne upošteva

instrumentalne vrednosti, ki jo uporaba prinaša. Z drugimi besedami, ne upošteva posameznikovega zadovoljstva ob doseganju cilja z uporabo tehnologije, temveč se nanaša na uporabnikov užitek pri uporabi tehnologije kot take (Venkatesh & Bala, 2008). Po Mohammadi in Isanejad (2018) ima zaznan užitek ob uporabi tehnologije pomemben vpliv na zaznano enostavnost uporabe, zaznano uporabnost in tehnološko samoučinkovitost.

Grublješič in Jaklič (2015a) ter Grublješič in Jaklič (2015b) pri analizi sprejemanja poslovnointeligenčnih sistemov izpostavita še dve osebnostni lastnosti, ki naj bi močno vplivali na sprejemanje – **inovativnost posameznika** in **pripravljenost na spremembe**. Ker so poslovnointeligenčni sistemi definirani kot orodja za podatkovno analitiko in poročanje, ki podpira odločanje v organizacijah, lahko ugotovitve preslikamo tudi na obravnavan primer podatkovne analitike. Inovativnost je definirana kot posameznikova dovzetnost do novih sprememb, v kontekstu privzemanja pa so inovativni posamezniki velikokrat predstavljeni tudi kot zgodnji prevzemniki (angl. early adopters) (Agarwal & Prasad, 1998). Pripravljenost na spremembe pa nam pove, v kolikšni meri posameznik zazna potrebo po spremembi in hkrati verjame, da bodo imele spremembe pozitivne posledice. V nasprotnem primeru lahko spremembe povzročijo odpor, kar znižuje verjetnost uspešnega sprejemanja inovacije že v začetnih fazah privzemanja.

Z vidika vedenjskih prepričanj in stališč je pomemben socialni oziroma **družbeni vpliv** (angl. social influence), ki opredeljuje posameznikovo zaznavanje glede tega, koliko je njegova uporaba nove tehnologije ali sistema pomembna drugim (Grublješič & Jaklič, 2015a; Grublješič & Jaklič, 2015b). Posameznik bo uporabo novega sistema hitreje vpeljal v svojo rutino, če bodo njegovo uporabo promovirali in zagovarjali ljudje, ki se mu zdijo znotraj njegovega delovnega okolja pomembni. Hkrati bo uporabnik pogosteje uporabljal tehnologijo, če je mnenja, da bo to pozitivno vplivalo na njegovo podobo ali položaj v družbi oziroma organizaciji (Venkatesh & Bala, 2008).

Naslednji potencialni dejavnik se nanaša na **predstavljalnost rezultatov** (angl. result demonstrability), ki predstavlja prepričanje posameznika glede oprijemljivosti, vidnosti in možnosti sporočanja rezultatov, pridobljenih s pomočjo sistema ali inovacije. Ker so koristi poslovne inteligence oziroma analitike bolj dolgoročne in tesno povezane z uspešnostjo organizacije, so uporabniki bolj naklonjeni k uporabi, če so rezultati dejansko vidni in prepoznani znotraj organizacije. Tako predstavljalnost rezultatov, kot tudi družbeni vpliv sta tesno povezana z posameznikovim miselnim procesom nekega vedenja (Grublješič, Coelho & Jaklič, 2014; Grublješič & Jaklič, 2015b; Venkatesh, 2003; Venkatesh & Bala, 2008).

Zaradi vpliva odnosa na namero po uporabi informacijske tehnologije, Mohammadi in Isanejad (2018) predlagata organizacijam, da ne pozabljajo na zagotavljanje pozitivnega odnosa za informacijsko tehnologijo v splošnem. To se bo namreč zagotovo obrestovalo v uspešnejšem procesu sprejemanja.

3.4 Primerjava modelov in združevanje

Izmed najbolj uveljavljenih modelov privzemanja in sprejemanja sta DOI in TOE ustrezna za privzemanje na ravni organizacije. Ko govorimo o privzemanju specifično določene inovacije, je treba združevati modele privzemanja z namenom po doseganju bolj izčrpnega vpogleda v koncept privzemanja (Puklavec, Oliveira & Popovič, 2017). Modela TOE in DOI lahko kot omenjeno preverjeno obravnavamo skupaj (Oliveira & Martins, 2010; Picoto, Bélanger & Palma-dos-Reis, 2014; Puklavec, 2016), sam pa sem v raziskavo vključil še TAM, ker gre pri privzemanju v športnih organizacijah za specifičen primer.

Wang in drugi (2011) ugotavljajo, da sta zaznana uporabnost (sprejemanje) in relativna prednost (privzemanje) nadomestljivi v primeru, ko je obravnavana tehnologija ali inovacija edina oziroma prva razpoložljiva za potencialne privzemnike, kar je v našem primeru relevantno. Prav tako sta večjih organizacijah razdelitev vlog in proces privzemanja precej bolj kompleksna, medtem ko so v obravnavanem primeru v večini primerov odločevalci in uporabniki celo iste osebe, v skrajnem primeru pa so zelo tesno povezani. Ob navedeni specifikah lažje združujemo dejavnike privzemanja in sprejemanja.

V tabeli 2 predstavim dejavnike privzemanja, ki so relevantni za obravnavan primer in vključeni v empirično raziskavo. Ker je privzemanje podatkovne analitike v športu specifično in neraziskano področje, je bilo treba literaturo privzeti in smiselno aplicirati iz podobnih področij (poslovnointeligenčni sistemi, analitika v drugih panogah, itd.).

Tabela 2: Potencialno pomembni dejavniki privzemanja

Tehnološki dejavniki	Viri
Relativna prednost (zaznana uporabnost)	Gangwar (2018); Chen, Preston & Swink (2015); Daradkeh (2019); Lai, Sun & Ren (2018); Maroufkhani, Wan Ismail & Ghobakhloo (2020)
Kompleksnost (zaznana enostavnost uporabe)	Gangwar (2018); Daradkeh (2019); Chong & Lim (2022); Maroufkhani, Wan Ismail & Ghobakhloo (2020); Maroufkhani, Iranmanesh & Ghobakhloo (2023); Verma & Bhattacharyya (2017)
Združljivost	Gangwar (2018); Chen, Preston & Swink (2015); Chong & Lim (2022); Daradkeh, (2019); Maroufkhani, Wan Ismail & Ghobakhloo (2020); Maroufkhani, Iranmanesh & Ghobakhloo (2023); Verma & Bhattacharyya (2017)
Možnost preizkusa	Chen, Preston & Swink (2015); Chong & Lim (2022); Daradkeh, (2019); Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid (2020); Maroufkhani, Wan Ismail & Ghobakhloo (2020)

se nadaljuje

Tabela 2: Potencialno pomembni dejavniki privzemanja (nad.)

Organizacijski dejavniki	Viri
Podpora vrhnjega managementa	Gangwar (2018); Chen, Preston & Swink (2015); Chong & Lim (2022); Lai, Sun & Ren (2018); Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid (2020); Maroufkhani, Wan Ismail & Ghobakhloo (2020); Mneney & Van Belle (2016); Puklavec (2016); Puklavec, Oliveira & Popovič (2017); Verma & Bhattacharyya (2017)
Prvak projekta	Bose & Luo (2012); Pinto & Patankul (2015); Puklavec, Oliveira & Popovič (2017); Puklavec (2016)
Organizacijska pripravljenost	Gangwar (2018); Chen, Preston & Swink (2015); Chong & Lim (2022); Dardakeh (2019); Lai, Sun & Ren (2018); Maroufkhani, Tseng, in drugi (2020); Maroufkhani, Wan Ismail & Ghobakhloo (2020); Mneney & Van Belle (2016); Shet, Poddar, Wamba Samuel & Dwivedi (2021); Ramakrishnan, Philpott, Duan & Cao (2017)
Dejavniki okolja	
Pritisk konkurentov	Chong & Lim (2022); Malladi & Krishnan (2013); Maroufkhani, Wan Ismail & Ghobakhloo (2020)
Zunanji ponudniki in podpora	Gangwar (2018); Chong & Lim (2022), Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid (2020); Maroufkhani, Wan Ismail & Ghobakhloo (2020)

Vir: lastno delo.

Prav tako sem identificiral potencialno pomembne dejavnike sprejemanja podatkovne analitike v Sloveniji. V tabeli 3 so predstavljeni dejavniki, ki sem jih na podlagi pregleda literature in relevantnosti vključil v empirično raziskavo.

Tabela 3: Potencialno pomembni dejavniki sprejemanja

Dejavniki sprejemanja	Viri
Tehnološka samoučinkovitost	Mohammadi & Isanejad (2018); Viswanath Venkatesh & Bala (2008); Saade & Kira (2009)
Zaznan užitek ob uporabi tehnologije	Mohammadi & Isanejad (2018); Viswanath Venkatesh & Bala (2008)
Inovativnost posameznika	Agarwal & Prasad (1998); Grublješič & Jaklič (2015a, 2015b)

se nadaljuje

Tabela 3: Potencialno pomembni dejavniki sprejemanja (nad.)

Dejavniki sprejemanja	Viri
Posameznikova pripravljenost na spremembe	Grublješič & Jaklič (2015a, 2015b)
Predstavljaljivost rezultatov	Grublješič & Jaklič (2015a); Grublješič, Coelho & Jaklič (2014); Viswanath Venkatesh & Bala (2008)
Družbeni vpliv	Grublješič & Jaklič (2015a, 2015b); Grublješič, Coelho & Jaklič (2014); Viswanath Venkatesh & Bala (2008)

Vir: lastno delo.

4 EMPIRIČNA RAZISKAVA UPORABE PODATKOVNE ANALITIKE V SLOVENSkih NOGOMETNIH ORGANIZACIJAH

4.1 Načrt raziskave in metodologija

Za potrebe magistrskega dela sem izvedel kvalitativno raziskavo v obliki polstrukturiranih globinskih intervjujev s predstavniki slovenskih prvoligaških nogometnih klubov. Bistvena značilnost polstrukturiranega intervjuja je, da ima raziskovalec vnaprej pripravljena vprašanja, največkrat v obliki opornih točk, ki so okvirne in raziskovalcu nudijo orientacijo pri izvedbi. V razliki s strukturiranim je bistvenega pomena, da raziskovalec z intervjuvancem vzpostavi določen odnos in izvedbo izpelje preko dialoga oziroma pogovora. To omogoči raziskovalcu, da pridobi poglobljen pogled, intervjuvanec pa lahko slikovito predstavi svoje izkušnje in mnenje (Banjac, 2020, str. 76-77).

Potrebne podatke sem pridobil s vprašalnikom, ki sem ga izoblikoval sam s pomočjo pregleda obstoječe literature, pri čemer sem se osredotočil na teoretične modele DOI, TOE in TAM ter identificirane primere uporabe podatkovne analitike v nogometu. Vprašalnik obsega šestnajst vprašanj odprtega tipa, pripadajoča podvprašanja in oporne točke. Vprašanja sem razdelil na tri večje sklope – trenutno uporabo, privzemanje in sprejemanje. Zaporedje vprašanj in podvprašanj sem pripravil smiselno glede na opravljen pregled literature, nato pa jih prilagajal sproti glede na pretekle intervjuje. Najprej sem ugotavljal, če je analitika na kakršenkoli način že v uporabi. V nadaljevanju sem vprašanja in pogovor obrnil na način, ki mi je pomagal na podlagi prej identificiranih dejavnikov privzemanja oceniti, kateri so dejansko ključni za to, da je podatkovna analitika v slovenskem nogometu v uporabi oziroma se ne uporablja.

Za kvalitativno metodo raziskovanja sem se odločil, ker preučujem nek poglobljen uvid v percepcijo, stališča, želje in pričakovanja posameznikov, pri čemer so lahko pri intervjujih vprašanja kompleksnejša in sproti prilagojena glede na odgovore respondenta. Tako ali tako

pa bi bilo glede na preučevano populacijo neizvedljivo dobiti primerno velik vzorec za izvedbo ankete. Zelo pomemben razlog za izbiro intervjuja je bila tudi možnost prilagodljivosti poteka pogovora posamezniku (Bregar, Ograjenšek & Bavdaž, 2005).

Za pomoč pri izvedbi intervjujev sem s posebnim dopisom zaprosil Nogometno zvezo Slovenije, ki je zagotovila pomoč pri izvedbi intervjujev. Kontaktna oseba (g. Čepelnik) mi je zagotovil kontakte predstavnikov prvoligaških klubov, ki so me nato usmerili na pravo osebo znotraj kluba. Vzorec v raziskavi je bil določen z namenskim vzorčenjem (Gantar & Vogrinc, 2008), saj sva skupaj z g. Čepelnikom sogovornike izbrala glede na dostopnost in namensko glede na položaj in stanje organizacije. Izvedel sem šest polstrukturiranih intervjujev, kjer je šlo pri vseh intervjujih za predstavnika analitike v šestih slovenskih prvoligaških nogometnih klubih. V dveh primerih je šlo za glavna trenerja, v ostalih pa za ostale člane strokovnega štaba (tj. pomočnike trenerja), ki so v določenem klubu zadolženi za analitiko. Glede na pooblastila so vloge precej raznolike glede na klub, a sem bolj ali manj posredno zajel poglede tako glavnega trenerja in celotnega strokovnega štaba kot tudi vodstva. Prvi izmed intervjujev je bil pilotni intervju, na podlagi katerega sem naredil še nekaj prilagoditev pri izvedbi in podvprašanjih.

V povprečju so bili intervjuji dolgi v povprečju okoli 60 minut. Izvajal sem jih s pomočjo predpripravljenih opornih točk, zato je bil tok načeloma pri vseh podoben, vendarle pa sem potek intervjuja sproti prilagajal glede na izkušnje, znanja in odgovore sogovornika. Ob teoriji privzemanja in sprejemanja sem pripravil tudi določene primere uporabe (poglavje 2), ki so mi olajšale predstavitev potencialne uporabe. Nekatere primere sem izbrskal na spletu, druge pa izdelal sam s pomočjo programskega jezika Python in knjižnic `plotly` (`express`) ter `mplsoccer`.

Zaradi varovanja podatkov so polna imena sogovornikov zakrita. Glavni trenerji so v rezultatih označeni z G_, medtem ko imajo pomočniki trenerjev in kondicijski trenerji oznako P_. V tabeli 4 so predstavljene ključne značilnosti sogovornikov v empirični raziskavi.

Tabela 4: Demografski podatki sogovornikov

Oseba	Spol	Delovno mesto	Starost	Uvrstitev na polovici sezone 22/23
GA	Moški	Glavni trener	30–40	4–7
PB	Moški	Pomočnik trenerja (analitik)	20–30	1–3
PC	Moški	Pomočnik trenerja (analitik)	30–40	1–3
PD	Moški	Kondicijski trener (analitik)	30–40	4–7
PE	Moški	Pomočnik trenerja (analitik)	20–30	4–7
GF	Moški	Glavni trener	50+	8–10

Vir: lastno delo.

4.2 Rezultati in ključne ugotovitve

V prvem delu so bila vprašanja vezana na **trenutno uporabo analitike** po posameznih področjih, pri čemer sem preverjal tudi **združljivost** inovacije z obstoječim sistemom. Glede trenutne uporabe podatkovne analitike so prav vsi sodelujoči v začetku omenili uporabo predpripravljenih poročil s platforme InStat, ki jih uporabljajo predvsem za taktično pripravo v smislu analize lastne igre oziroma nasprotnika. Teh poročil se sicer nekateri poslužujejo bolj, drugi manj, vsekakor pa je večina sodelujočih poudarila, da kot osnovo za taktično pripravo uporabljajo video posnetke, podatkovna poročila pa le kot dodatno gradivo, s katerim podkrepijo dejstva, ki so jih identificirali na videu. Vse skupaj potem skrčijo in na čim bolj enostaven način predajo igralcem.

Prav tako so vsi sogovorniki kot primer uporabe v njihovih klubih izpostavili analitiko fizičnih podatkov, ki jih analizirajo preko platforme gpexe. Na podlagi teh podatkov lahko predvsem kondicijski trenerji analizirajo pretečene kilometre, šprinte in hitrosti, pri tem pa uravnavajo obremenitev (angl. load) – zmanjšujejo obremenitev, če je nekdo pretekel preveč, ali naložijo dodatno delo oziroma suh trening tistim, ki so na treningu naredili premalo.

Ob taktični in telesni pripravi so sodelujoči izpostavili še uporabo podatkovne analitike za pomoč pri skavtingu. PC omenja, da igralce ob spremljanju v živo ocenijo s točkovnimi ocenami po področjih, kar jim omogoči okviren vpogled v kvalitete igralca. Dobljene ocene potem primerjajo s številkami iz InStat poročil. GA je omenil, da pripravljajo določene formule za posamezno igralno mesto (npr. hočemo igralca, ki je podoben X in ima veliko y ter z), ki potem na podlagi določenih koeficientov prikaže najbolj primerne igralce. Zaradi tega lahko potem na primer podrobneje opazujejo le pet igralcev namesto desetih. Izpostavil je še, da analitični skavting zelo podpira trenutni športni direktor, kar je precej pospešilo razvoj in hkrati že prineslo prve rezultate v obliki konkretnega zaslužka ob prodaji igralcev.

PD pove, da so z vidika skavtinga začeli spremljati podatke, a je za večji projekt zmanjkalo volje in časa. Temu se pridružuje GF, ki je v preteklih obdobjih sam poskušal pridobiti koristne informacije iz baze podatkov, a mu je za konkretnejši otipljiv projekt zmanjkalo časa in tehničnega znanja. Hkrati je podvomil v konsistentnost podatkov, saj so ti večkrat pokazali drugačno sliko, kot jo je sam videl na tekmi. Kar se tiče samostojnega razvoja analitike, je ravno GA omenil, da so začeli z letošnjo sezono graditi tudi lastni skavting model, ki ga planirajo dokončno implementirati v poletnem prestopnem roku, medtem ko je oseba PB poudarila, da analitike ob njegovem prihodu v klub še ni bilo, zdaj pa se uporaba povečuje iz dneva v dan. Kot je omenil, sam opaža, da mu podatkovna analitika precej pomaga kot nek dodatek k video analizi, ki jo pripravlja tedensko. PE je dodatno izpostavil uporabo analitike pri operativnih zadevah oziroma tudi tako imenovano analitiko socialnih omrežij, pri čemer je izpostavil pomen spodbujanja vključevanja navijačev (angl. fan engagement) v slovenskem nogometu.

Je pa na tem mestu smiselno izpostaviti, da si nobeden izmed klubov grafik ali drugih naprednejših podatkovnih rešitev ne pripravlja sam s pomočjo programskih jezikov ali drugih orodij za vizualizacijo. Grafično je zgolj tisto, kar pripravi InStat, sicer pa gre bolj za neko tabelarno uporabo.

Predstavljene grafične rešitve so bile vseč vsem sodelujočim, ki so prav tako izpostavili **uporabnost** rešitev. V največji meri je sogovornikom zanimiva uporaba v skavtingu, ki jo na nek posplošen (tabelaričen) način že uporabljajo v polovici (treh) sodelujočih klubih. GA je dodal, da so takšni grafični prikazi zagotovo neka nadgradnja, ker so trenerji vizualni tipi in to vsekakor bolj bode v oči in je zelo pregledno. Ob tem je dodal, da »so podatki v skavtingu zagotovo naslednja velika novost (angl. the next big thing).« Kot zelo zanimive je označil tudi predstavljene ad-hoc analize, ki si jih prav tako želi v klubu, a z analitiko še niso tako daleč. Ob tem je izpostavil še dejstvo, da morda analitika malenkost zaostaja, ker so zaenkrat v klubu še vedno v ospredju bolj osnovne stvari v smislu prehrane in profesionalizma.

Glede skavtinga je PC omenil tudi, da po njegovem mnenju idealen postopek vključuje tudi podatkovno analizo, pri čemer grejo igralci skozi »prvo sito«. GF so bili grafični prikazi prav tako zelo zanimivi, saj je med drugim dejal tudi: »To, da se vrže noter parametre in ti vrne primerne igralce [...] to bi bilo zlata vredno. Jaz sem imel vedno sto igralcev, ki sem jih gledal, pa sem se zato čisto zgubil.« Je pa izpostavil tudi pomislek, ki se veže direktno na slovensko ligo, saj velikokrat ne iščejo med najboljšimi igralci na prostoru (tj. tistimi, ki jih izpostavi grafični prikaz), temveč med tistimi, ki »še niso zgubili volje in jim lahko ponudimo profesionalno pogodbo.« Zanimiv pomislek glede uporabnosti skavtinga je izpostavil tudi PE, ki omenja, da je uporabnost sicer nedvomna in vseč tudi vodilnim v klubu, a je načeloma uporaba najbolj smiselna nekje od enega do dveh mesecev pred vsakim prestopnim rokom, kar znaša nekje tri do štiri mesece na leto.

Podoben pozitiven odziv je možno opaziti glede podatkovne analitike za taktično pripravo. PB je denimo izpostavil, da je ta v veliko pomoč, ker jo lahko združuje s tem, kar vidi na videu ali sami tekmi, medtem ko je PC izpostavil prednost predstavljenih grafik kot nekaj, kar omogoča zelo hiter vpogled v določene vzorce in posledično olajša ter skrajša delo. GF vidi korist v preprostih primerjalnih grafih, ki na primer pokažejo razliko v stilu igre po premoru ali menjavi trenerja, pri čemer seveda ni časa naenkrat pogledati več tekem vseh klubov.

Na drugi strani je PD izpostavil, da so vse predstavljene stvari zagotovo zelo koristne in uporabne, vendar pa do ključne uporabnosti takšnih prikazov pridemo šele, ko razumemo kontekst. Po njegovih besedah je kontekst »glavna umetnost podatkovne analitike v nogometu.« Hkrati izpostavlja, da je nogomet na koncu »živa igra«, kar pomeni, da ti v konkretnem trenutku težav na igrišču grafike težko pomagajo. Podobno razmišljanje je izpostavil tudi PE, ki je dejal, da je »na koncu vseeno igrišče glavni pokazatelj« ter da lahko imaš z vidika analitike vse mogoče analitične rešitve pa ti ne bodo pomagale, če jih ne boš

znal prenesti na igralce. Glede skavtinga poudarja, da je ključno združevati skavting v živo s podatki in ne uporabljati le enega ali drugega.

Analitiko telesne priprave sicer klubi v večini primerov že uporabljajo, je pa glede same uporabnosti priprave GA izpostavil, da kaj več od analize treninga oziroma obremenitve verjetno niti ne bi bilo smiselno. Na primer na sami tekmi po njegovih besedah »[...] nekoga, ki je lider ne boš dal ven, ker ti pokaže, da je utrujen [...], je treba vseeno uporabiti kmečko pamet.«

Sogovornik PE je znanje in razumevanje podatkov izpostavil kot ključno oviro za nadaljnjo uporabo, pri čemer je dejal, da »[...] nič ne koristijo ne statistika, ne videi, če tega ne znaš na pravi način uporabiti, kar je tudi največji izziv analitikov v slovenskem nogometu.« PD je omenil, da so tudi zahtevnejši primeri uporabni, vendar bi v Sloveniji potrebovali ljudi (tj. analitike), ki bi se pretežno ukvarjali z aplikacijo in prezentacijo podobnih analitičnih rešitev. Trenutno se sami skušajo izogibati poplavi podatkov in temu, da imajo podatke z nekim razlogom in ne zgolj »zato, ker je fajn«. V podobni smeri je razmišljal tudi GF: »gora podatkov sama po sebi čisto nič ne pomeni; treba je stvari interpretirati.«

GA je hitro zavrnil, da bi bil razumevanje podatkovno-analitične rešitve **prekompleksno** za slovenski nogometni prostor. Pri tem se je naslonil na dejstvo, da to uporablja iz dneva v dan vse več evropskih klubov, tudi manjših, pri čemer je izpostavil danski Midtjylland. Ob tem je dodal: »Veliki evropski klubi so vedno postavljali trende – se pravi, če so oni to sprejeli in oni to že nekaj časa delajo, potem bodo temu zagotovo sledili tudi ostali.« PC je prav tako zavrnil težavo kompleksnosti in pri tem izpostavil, kako njegovi nadrejeni raje vidijo agregirane podatke, s katerimi si lažje pomagajo. Tudi ostali sogovorniki niso imeli težav z razumevanjem predstavljenih rešitev.

Pomislek glede kompleksnosti je izpostavil PB, ki je z navdušenjem potrdil uporabnost, a ob tem povedal, da je lahko tega v našem okolju hitro preveč: »Mi imamo okoli dvajset minut dolgo predstavitev in igralcem je že to včasih preveč« ter opozoril, da se je treba zelo potruditi pri predstavitvi, saj je treba ugotovitve prikazati na čim bolj enostaven način. Pri tem je dodal, da je razumevanje zelo raznoliko od igralca do igralca – medtem ko so nekateri zelo zainteresirani, je treba drugim po besedah PB zadeve »dobesedno narisati.«

Kar se tiče dostopnosti podatkov in zunanjih ponudnikov, je načeloma pri vseh sogovornikih zgodba enaka, saj gre za kolektivne pogodbe. Vsi sogovorniki so izpostavili, da imajo dostop do podatkov preko platforme InStat (podatki o dogodkih) in gpexe (fizični podatki). GA je omenil, da gre v primeru InStata za poročila dolga okoli petnajst listov, na katerih so določene metrike (število dobljenih dvobojev, točnih podaj itd.), kar služi kot dodatno gradivo temu, kar predstavijo igralcem. Na tem mestu je bil zanimiv tudi pomislek GF, ki je izpostavil, da je ob preizkušanju podatkov naletel na razlike med videnim in podatki: »Ko sem imel občutek, da je fant odlično odigral, je bil po InStatu slab in obratno [...], kot da obstaja segment igre, ki ga računalnik ne zajame. No, ali pa zgolj pri nas to še ni tako daleč.«

Glede **možnosti preizkusa** so bili vsi sogovorniki zelo skladni, saj so se strinjali s tem, da bi z veseljem preizkusili kakršnokoli novo stvar v smeri analitike. Ob tem je na primer PE izpostavil, da bi ob takem preizkusu konkretno videl, koliko časa ti stvar vzame in koliko od tega dobiš. Po njegovih besedah je pri takih zadevah »še vedno prisoten strah [...], če pa probaš, vidiš da gre, se precej lažje odločiš.« Večina sodelujočih je prav tako omenila, da so v določenem obdobju imeli dostop do različnih platform (Comparisonator, Dribblab), ki so omogočile dodatno analizo in so bile po njihovem mnenju zelo uporabne.

Podobno sklepčni so bili sogovorniki tudi glede **pritiska konkurentov**, ki načeloma naj ne bi vplival na uporabo same analitike, saj se raje odločajo na podlagi lastnih potreb in tega, kaj bi konkretno koristilo njihovem klubu. PB, PC in PE so sicer omenili, da so redno v stiku z ljudmi s podobnimi zadolžitvami iz nekaterih drugih klubov. Tako vsaj približno vedo, kaj in kako počnejo konkurenti, a po njihovih besedah to ne vpliva na uporabo podatkovne analitike v njihovih organizacijah.

PB in PC sta omenila, da bi se sicer še več posluževali analitike, a so **stroški** podatkovnih platform zelo visoki. PC meni, da bi bile vse platforme, ki bi jih želel uporabljati občutno predrage za slovenski klub, saj »bi mesečno plačevali več tisoč evrov, če bi imel vse, kar si želim.« Pri tem meni, da bi lahko v tej smeri pomagala Nogometna zveza Slovenije, ki bi lahko po njegovih besedah pospešila napredek. Kar se tiče izzivov s proračunom, je PC izpostavil še eno problematiko – »V Sloveniji imamo denar, ni pa interesa.« ter dodal, da je v večini slovenskih mest navijačem 10 € previsoka cena vstopnice, pri čemer se nasloni na skrajni primer angleškega nogometa, kjer bodo navijači za tekmo svojega najljubšega kluba brez pomisleka porabili svoje zadnje prihranke. Tudi GA, PD in GF so omenili, da jim nadaljnjo rabo omejuje proračun. To se v konkretnem primeru pozna predvsem pri omejitvah glede strokovnega kadra, kjer bi koristila dodatna oseba. GA je omenil, da se zaradi manjše proračunske stiske z vidika analitike lotevajo stvari, ki ne zahtevajo večjih dodatnih stroškov, temveč iščejo poti, ki bi lahko imele pozitiven vpliv na proračun. Tudi PD in GF sta omenila, da nadaljnjo rabo omejuje proračun. To se v konkretnem primeru pozna predvsem pri omejitvah glede strokovnega kadra, kjer bi koristila dodatna oseba. V tej smeri je denimo zanimiv analitični skavting. PB izpostavlja, da je skavting s podatkovno analitiko zelo zanimiv tudi z vidika, ker zagotovo omogoča nek prihranek z vidika manjšega števila potovanj in podobno. Zanimivo mnenje je podal PE, ki pravi, da v njihovi organizaciji ni tolikšen problem to, da si nečesa ne bi morali privoščiti, temveč je večje vprašanje, ali to želijo oziroma ali bodo to dejansko uporabljali.

GA meni, da tudi na ravni organizacije uporabljajo racionalni pristop, pri čemer si pomagajo s podatki, ki pa niso zadnji odločevalec (angl. decision-maker). Uporabo tehnologije v organizaciji je ponazoril tudi z uporabo platforme Sportimus (pregled treningov, prisotnosti) v nogometni šoli. PC omenja, da vodstvo vsako odločitev večkrat »preračuna«, predvsem pa se pri sprejemanju odločitev osredotoča na združevanje podatkov in občutka. PE pove, da številke v organizaciji kot celoti sicer niso glavni dejavnik pri odločanju, a zagotovo pridejo v obzir oziroma »so na mizi«, kar pred leti ni bilo samoumevno. Tudi PD omeni, da

organizacija upošteva podatke, a ne sprejema končnih odločitev samo zato, ker bi tako pokazal graf.

Glede **podpore managementa** je mnenje sogovornikov zelo podobno, saj vsi menijo, kako je vodstvo pripravljeno sodelovati in vlagati v tehnološko naprednejše tehnološke vire in ljudi, v kolikor je to možno argumentirati. Na tem mestu je GA omenil, da vodstvo vedno prisluhne, a nikakor ne želi določenih stvari samo zato, ker so popularne. Ob tem je povedal, da si skupaj z vodstvom želijo koristiti analitiko ravno zato, ker so finančno manj konkurenčni, hkrati pa želijo svoje mlade igralce pripravljati tudi na ta vidik višjega nivoja nogometa – »podatki jih v prihodnje čakajo«. Tudi PB je povedal, da športni direktor in lastnik nikoli nista zavrnila prošnje, če je bila ta lepo predstavljena in argumentirana. PD se pridružuje in pravi, da je organizacija pripravljena, v kolikor proračun to zdrži in bi novost argumentirano koristila. Mimogrede so sogovorniki omenili še uporabo drugih tehnoloških pripomočkov v obliki naprednih kamer in dronov.

Ob podpori managementa je za uporabo analitike ključnega pomena tudi **miselnost glavnega trenerja**, pri čemer je ključna razlika med tradicionalnim in modernejšim pogledom na nogomet. PB sicer pove, da je vesel, kako je njihov kader naklonjen analitiki, a hkrati opozori, da imajo nekateri trenerji odpor že do same video analize, kaj šele do podatkov oziroma števil. Meni, da bo marsikatera ovira odpravljena, »ko ljudje analitikom ne bodo rekli snemalci, ampak trenerji.« Po besedah PD je »nogomet največji biznis na svetu,« v katerem imajo najuspešnejši ljudje ob sebi največje strokovnjake v določeni stvari. Omeni, da imajo dandanes tudi trenerji iz »stare jugo šole« za sabo najboljše analitike oziroma pomočnike. Ob tem predstavi pogled na razmerje med tradicionalnim in modernim pristopom glavnih trenerjev v Sloveniji: »Nekdaj je bilo tradicionalnega jugo šmeka preveč, kar je stroka zavračala in spodbujala zgolj strokoven pogled, kar pa tudi ni najboljše.« Po njegovem mnenju se gre v te stvari preveč enoznačno v smislu »jaz bom moderen trener in bom imel prenosnik na treningu ali pa jaz bom star, izkušen trener pa rabim samo klobučke in žoge,« medtem ko je najboljša izbira pravo ravnotežje. Tudi PE izpostavlja pomen pristopa glavnega trenerja, kar se je pokazalo tudi konkretno v organizaciji, ko se je pristop do analitike zelo spremenil z odhodom prejšnjega in prihodom novega trenerja. Kar se tiče pristopa v Sloveniji, opaza vedno bolj očiteno val mlajših trenerjev in drugih sodelavcev, ki postajajo vedno bolj odprti za spremembe, ker opazijo določene stvari na najvišjih nivojih. Meni, da je le vprašanje časa, kdaj bodo trenerji z bolj tradicionalnim pristopom v manjšini.

Glede **organizacijske pripravljenosti** so po besedah sogovornikov s tehnološkega vidika klubi načeloma pripravljeni, medtem ko je več težav opaznih pri ljudeh. Zgolj polovica sogovornikov je povedala, da imajo v klubu osebo, ki se večinsko ukvarja z analitiko. PD je izpostavil, da trenerji v Sloveniji sledijo trendom, a jim vključno s strokovnih štabom zmanjka časa ali energije za kvalitetno obdelavo podatkov. Po njegovih besedah bo moral v strokovnem štabu vsakega kluba biti slej ko prej še analitik, ki bo to bral in apliciral, predvsem pa se bo ukvarjal izključno s tem področjem – »Če ni aplikacije podatkov, ki se

potem uporabi na igrišču [...], potem je to brez veze [...], je samo okrasek.« Trenutno je po njegovem mnenju vzrok za **kadrovsko stisko** predvsem finančne narave.

GA je prav tako izpostavil kadrovsko stisko, saj ima relativno maloštevilen strokovni kader malo časa za analizo ob napornem tekmovalnem ritmu sreda–sobota, medtem ko je tudi PE izpostavil, kako imajo veliki evropski klubi v nasprotju s slovenskimi klubi ločene oddelke za analitiko, ki štejejo po več kot deset redno zaposlenih. PB je izpostavil tudi, da klubi na Balkanu v podatkovni analitiki in nasploh sprejemanju inovacij v nogometu precej zaostajajo. Ob tem izpostavi, kako je vesel, da se v njegovi organizaciji pomena analitikov zavedajo, medtem ko marsikje drugje to počnejo kar glavni trenerji. Tudi GF omenja, da bi bilo zelo dobro imeti ob sebi nekoga (op. a. analitika), ki bi razumel njegov način dela in ostale specifike – »Če je sodelovanje utečeno, potem je to vse zelo preprosto.« Zdaj določene ugotovitve video analiz predstavljajo bolj površinsko na skupnih sestankih, ker ni časa za individualizacijo. Kot glavno oviro nadaljnjega razvoja analitike izpostavi dejstvo, da v Sloveniji nihče od trenerjev razen Matjaža Keka (op. a. selektor slovenske reprezentance) nima svoje ekipe, ki jo vzame povsod s seboj. Tega bi si sam sicer zelo želel, a izpostavi problematiko financ, pri čemer so si recimo v konkretni organizaciji trenutno delo zastavili tako, da »preživijo« in ne ustvarjajo dodatnih stroškov.

GA je izpostavil svoj pozitiven **odnos do računalnikov** in tehnologije nasploh, pri čemer je omenil, da večino stvari želi najprej poskusiti sam. PB je povedal, da nikoli ni bil pretirano računalniški tip, a vedno v koraku s časom. Poudari, da se je veliko stvari naučil tudi odkar opravlja novo funkcijo pomočnika trenerja v kontekstu analitika. PD pravi, da se vključno z ožjimi sodelavci vsaj za nogometno okolje znajdejo s tehnologijo, ker so mlad in »moderen« kader. Prav tako pa je sam kljub bolj konservativnemu in pazljivemu karakterju vedno pripravljen preizkusiti novosti. Kljub temu ponovno poudarja, da je treba analitiko uporabljati v skladu s kontekstom in ne zato »ker je to moderno in ker sem videl, da ima to tudi tisti pomočnik od Chelsea.« Tudi PC, PE in GF se vključno s svojimi sodelavci za potrebe svojega dela znajdejo z računalniki.

Kar se tiče sprememb, so v večini primerov sogovorniki potrdili pripravljenost in željo po spremembah. GA je izpostavil, da sicer zahteva red in disciplino, kar se pogosto povezuje z neko rutino, a je sicer pripravljen na spremembe, ki jih narekuje okolje. Glede tega je povedal: »Če gredo vsi v eno smer, nisem jaz trmast pa bom rekel, da smo 20 let nazaj pa to delali drugače [...]; glede analitike je zadeva ušla iz aladinove lampice.« Kot glavno gonilo napredka analitike je izpostavil dejstvo, da se največ napak dela na čustveni ravni, kar lahko preprečimo z digitalizacijo in implementacijo vsesplošnega merjenja. PE izpostavlja, kako si zelo želi sprememb, saj so po njegovem mnenju nujne, če želi napredovati, kar preslika tudi na klub, v katerem deluje.

GA je na tem mestu na slikovit način izpostavil tudi samo **predstavljenost** rezultatov: »Najbolj me zmoti, ko se nekdo popraska po glavi in reče, kako se mu približno zdi, da je pred štirinajstimi dnevi nekaj bilo tako in tako – od tega napredka ne bo!« PC meni, da s

podatki bolj slikovito predstavi rezultate in ugotovitve vodstvu, pri čemer pa bi bilo še precej lažje, če bi imel na voljo tudi naprednejše grafične prikaze. Pomen predstavljalosti izpostavljata tudi PB in PE, ki menita, da je učinkovita predstavitev ključna za promocijo podatkovne analitike znotraj organizacije. PC izpostavi, da se v splošnem še vedno »prodaja precej megle,« vse pogosteje pa se dogaja, da jih nekdo s podatki povezi, saj tudi v nogometu konkretne številke pridobivajo na veljavi. Prav tako meni, da imajo glede trenerskega posla veliko prednost tisti, ki so imeli dobro igralsko kariero, pri čemer izpostavi, da gre trend v evropskem nogometu v drugo smer – primer Julian Nagelsmann (op. a. svetovno znan glavni trener, ki je profesionalno kariero kot nogometaš zaključil pri dvajsetih letih). Na to se je navezal tudi GF, ki je mnenja, da se da dandanes v nogometnem svetu biti zelo uspešen tudi brez igralskih izkušenj, če si priden, učljiv in pripravljen slediti trendom, kjer je podatkovna analitika zagotovo med najpomembnejšimi.

5 DISKUSIJA

Prva ugotovitev je dejstvo, da vsi sodelujoči klubi vsaj okvirno poznajo pristope podatkovne analitike v nogometu. Pri tem je ključen kolektivni dostop do poročil InStat, ki zagotovo spodbuja analitičen pogled, saj večina klubov vsaj pregleda dobljena poročila. Nekateri jih uporabljajo tedensko, medtem ko drugim preprosto zmanjka časa in volje. Na tem mestu pa se je treba zavedati, da so ta poročila vzorčna in seveda ne nudijo polnega izkoriščanja podatkovne analitike.

Večina sogovornikov je med trenutnimi in želenimi primeri uporabe v njihovih organizacijah izpostavila ravno skavting (Gerrard, 2016; Kröckel, 2019; Pavitt, Braines & Tomsett, 2021; Rudd, 2011; Sumpter, 2016, Sumpter & Andrzejewski, brez datuma), taktično pripravo (Kröckel, 2019; Pavitt, Braines & Tomsett, 2021; Peralta Alguacil, 2019; Rein & Memmert, 2016; Sumpter, 2019) in telesno pripravo (De Silva in drugi, 2018; Ravindranathan in drugi, 2017; Yang, Yuan & Yan, 2021; Zadeh in drugi, 2021), kar povsem sovпада s področji, ki sem jih definiral v poglavju 2. Z vidika taktične priprave so sogovorniki izpostavljali združljivost podatkovne analitike z video analizo, kar je lahko v veliko pomoč. Korist vidijo tudi v preprosti primerjalnih grafih (ekip, igralcev), ki ustvarijo neko sliko, ko ni časa za podrobnejšo analizo. V večini primerov se za taktično pripravo primarno uporablja video analiza. Glede telesne priprave sodelujoči niso imeli posebnega mnenja, saj se ta izvaja v domeni kondicijski trenerjev, hkrati pa po mnenju večine uporaba pustih podatkov na tem področju zadovoljuje potrebe. Medtem ko večina zaenkrat zgolj pregleda pripravljena poročila s strani InStat, se nekateri klubi že v začetni fazi razvoja lastnih modelov za skavting v obliki preprostih tabelaričnih rešitev, ki so že prinesle prve rezultate v obliki dobičkonosnega kadrovanja. To rezultira v vidnem entuziazmu in motivaciji za naprej.

Trenutno se v slovenskem prostoru podatkovna analitike glede na ugotovitve iz raziskave največ uporablja ravno v namene skavtinga. Najverjetnejša razlaga za to je dejstvo, da organizacije nekakšne individualizirane metrike po igralnih mestih prejmejo s strani InStata,

pri čemer je že to samo po sebi dovolj za preprosto različico podatkovnega skavtinga. Na tem mestu je zelo pozitivna ugotovitev iz raziskave to, da sogovorniki sami poudarjajo, kako tem poročilom in podatkom nasploh ne gre zgolj slepo verjeti, temveč jih je treba združevati s tradicionalnim pristopom v smislu mnenj strokovnjakov in ogleda tekem ter videov. Vsekakor pa je pri skavtingu v slovenskem prostoru še vedno mogoče opaziti močan vpliv tradicionalnosti. Zdi se namreč, da na odločitev glede igralskih okrepitev namesto podatkov v največji meri vplivajo predlogi bivših uspešnih nogometašev in prepričevanja uveljavljenih nogometnih zastopnikov.

Osebnostno se mi zdi ključnega pomena vsaj poskusiti z razvojem podatkovne analitike, saj v primeru iz raziskave zaenkrat še niso imeli dodatnih stroškov, medtem ko jim je analitika ponudila priložnost v boju proti stagnaciji. Naprednejših grafičnih prikazov in taktičnih rešitev, definiranih v omenjenem poglavju, zaenkrat še ne uporabljajo, je pa nekako mogoče opaziti vsaj zametke predstavljenih možnosti uporabe. Prav tako je opaziti, da sogovorniki zadeve poznajo, kar pomeni, da so čez fazo poznavanja, ki opredeljuje razumevanje in poznavanje osnovnih funkcionalnosti inovacije.

Glede same uporabnosti je bila ob izpostavljenih treh nogometnih področjih s strani sogovornikov omenjena še analitika socialnih omrežij oziroma digitalni marketing, kar kot koristno prikazujejo tudi strokovni prispevki (Ragsdale & Schutte, 2022; Watanabe, Shapiro & Drayer, 2021).

5.1 Dejavniki privzemanja

Za analizo zaznane uporabnosti oziroma **relativne prednosti** sem na podlagi kratke predstavitve o potencialnih primerih uporabe ugotovil, da v splošnem te zadeve sodelujoči že poznajo, predvsem pa se zavedajo koristi, ki jih obstoječe podatkovne rešitve prinašajo v nogometne organizacije. Tako se denimo v nekaj klubih sicer na bolj trivialen način pomagajo pri iskanju novih talentov z združevanjem podatkovnega in tradicionalnega skavtinga. Kot predpisuje Sumpter (2016), združujejo pozitivne lastnosti obeh pristopov ter s pomočjo določenih predpisanih parametrov v obliki numeričnih vrednosti (dobljeni dvoboji, uspešnost podaj, pričakovane vrednosti itd.) identificirajo nabor potencialnih okrepitev, ki jih kasneje pogledajo še v živo. Sogovorniki so omenili prednosti tako imenovane metode lijaka, ki vključuje korake podatkovnega skavtinga, video skavtinga in skavtinga v živo. Če igralec pride skozi vsa tri sita, sledita še kontakt in pogajanje.

Vsaj okvirno sogovorniki poznajo večino predstavljenih grafičnih prikazov in zahtevnejših rešitev, do katerih pa v praksi še niso prišli. Tudi zaznana uporabnost oziroma percepcija praktičnosti inovacije je na zelo visokem nivoju, saj je bilo praktično pri vseh sogovornikih opaziti navdušenje ob pogovoru o potencialnih rešitvah na vseh področjih.

Puklavec, Oliveira in Popovič (2017) ugotavljajo, da relativna prednost nima značilnega vpliva na privzemanje in rabo tehnološke inovacije (poslovnointeligenčnih sistemov), saj

tako neprizemniki kot prizemniki prednosti dobro poznajo, ker gre za uveljavljeno inovacijo. Poznavanje možnosti in relativne prednosti podatkovne analitike je v slovenskem nogometu sicer nad pričakovanji, saj so sodelujoči namreč v splošnem poznajo tako prednosti kot tudi potencialne rešitve podatkovne analitike. Kljub temu pa je glede na ugotovitve iz raziskave relativna prednost oziroma zaznana uporabnost še vedno pomemben dejavnik privzemanja. Vendarle gre pri podatkovni analitiki na področju nogometa za precej manj uveljavljeno tehnologijo, kar je še posebej značilno za slovenski nogometni prostor.

Eden izmed sogovornikov je kot osnovno motivacijo za privzemanje in uporabo podatkovne analitike izpostavil finančno nekonkurenčnost. Želijo si alternativnega pristopa, s katerim bi v primerjavi s konkurenco nadoknaditi primanjkljaj denarja. Pri tem gre seveda za osnovno idejo podatkovne analitike v športu, saj se je začela razvijati na podlagi identične športne ekonomije, ki narekuje učinkovito izkoriščanje (manjšega) proračuna. Iz ideje športne ekonomije se je vse skupaj namreč začelo v ameriškem nogometu in nadaljevalo do neverjetnih uspehov Midtyllanda in Brentforda, ki so jih večkrat izpostavili sogovorniki (Hellier, 2021; Wigmore, 2018). Ob tem je uporaba podatkov koristna tudi z vidika razvoja igralcev. Večina klubov v Sloveniji preživi z razvojem in prodajo igralcev, zato je to ključnega pomena. Ker je podatkovne analitike v nogometu vse več in je prisotna v vse večjem številu nogometnih klubov, so izkušnje igralcev v analitičnem okolju lahko zlata vredne, čeprav bodo verjetno zelo kmalu postale del obvezne nogometne izobrazbe.

Vendarle pa so sogovorniki izpostavili nekaj pomislekov. Nogomet je namreč kljub vsemu živa igra, ki se dogaja na igrišču, kjer je treba v času tekme hitro in nenadno sprejemati zelo pomembne odločitve, pri čemer razne vizualizacije in podobno naenkrat postanejo manj koristne. Prav tako rešitve izgubijo na uporabnosti, če jih uporabljamo izolirano, saj več sogovornikov kot najpomembnejši del podatkovne analitike v nogometu izpostavi pomen konteksta, ki ga kot ključnega omenjajo tudi opazni predstavniki podatkovne analitike v evropskem nogometu (Sumpter & Andrzejewski, brez datuma; Uppsala Universitet, brez datuma). Sogovorniki menijo, da je podatkovno analitiko obvezno treba združiti z načinom igre, hkrati pa jo uporabljati z razlogom in ne samo zato, ker je moderno.

Na drugi strani je zanimiv pomislek, ki je zelo specifičen za Slovenijo kot nogometno okolje, saj v literaturi še ni bil izpostavljen. Eden izmed sogovornikov je namreč na primeru skavtinga izpostavil, da so vse te rešitve sicer zelo zanimive, a v Sloveniji manj uporabne. Medtem ko je lahko iskanje najboljših igralcev po določenih parametrih v teoriji zelo koristno (ožji izbor igralcev) predvsem nižje situiranim klubom v Sloveniji ne koristi prav dosti. Ti namreč novih igralcev ne iščejo med statistično najboljšimi v določeni regiji, temveč tistimi, ki morda sploh ne dobijo priložnosti za igro. Na tem mestu je smiselno izpostaviti tudi problematiko manjšega bazena igralcev v okolju, pri čemer so izstopajoči hitro prepoznani. Gre za specifično težavo v obravnavanem okolju, saj bi lahko načeloma slovenski klubi glede na kvaliteto morebitne podcenjene igralce iskale v nižjih okoliških ligah (Slovenija, Hrvaška, Avstrija), kjer pa tudi dostopnost in razpoložljivost podatkov zaenkrat še nista na najvišji ravni.

Več raziskav (Gangwar, 2018; Chen, Preston & Swink, 2015; Chong & Lim, 2022; Grublješič & Jaklič, 2015a, 2015b; Maroufkhani, Iranmanesh & Ghobakhloo, 2023; Maroufkhani, Wan Ismail & Ghobakhloo, 2020; Verma & Bhattacharyya, 2017) ugotavlja ključen pomen **združljivosti** za privzemanje podatkovne analitike, kar lahko identificiram tudi v raziskavi. Sogovorniki so namreč na vseh področjih izpostavljali pomen kompatibilnosti novega sistema z obstoječim, saj podatkovno analitiko vidijo kot zelo smiselno in uporaben dodatek k trenutnemu sistemu, nikakor pa ne kot popolno nadomestilo. Pri skavtingu bi si tako denimo olajšali delo (ožji izbor igralcev), hkrati pa dobili dodatno potrditev ugotovitev in bolj objektivno mnenje, medtem ko je pri taktični pripravi podatkovna analitika koristna kot dopolnitev k obstoječi video analizi ter v skrajnem primeru časovne stiske tudi kot njena nadomestitev. Glede telesne priprave trenutni sistem prav tako ostaja enak, podatkovna analitika pa v tem primeru omogoča optimizacijo trenažnega procesa. V vseh primerih uporabe gre torej za pripomoček, saj gre vendarle za »živo igro« in so določeni procesi v nogometu nenadomestljivi in relativno rigidni. Maroufkhani, Tseng, Iranmanesh, Ismail in Khalid (2020) ugotavljajo, da v srednjih in malih podjetjih združljivost ne vpliva na privzemanje analitike in pri tem predvidevajo, da majhnost organizacij omogoča večjo fleksibilnost podjetja in zato predstavlja manjšo oviro pri prilagoditvi obstoječih praks ter posledično privzemanju inovacije. To pa ne drži za privzemanje podatkovne analitike v slovenskem nogometu, saj se v tem primeru organizacije namreč nikakor ne bodo posluževale inovacije, če ne bo sledila obstoječemu sistemu. Od podatkovne analitike si želijo podpore pri že ustaljenih procesih, kar priporočajo tudi strokovnjaki (Gerrard, 2016; Sumpter, 2016; Uppsala Universitet, brez datuma). Pri taktični pripravi to torej pomeni dodaten material za analizo in hiter vpogled v vzorce, pri telesni pripravi dodatne informacije za optimizacijo trenažnega procesa, medtem ko pri skavtingu lažjo identifikacijo potencialnih okrepitev in možnost dodatnega preverjanja. Združljivost s tega vidika predstavlja ključen dejavnik privzemanja podatkovne analitike v nogometu.

Rogers (2003) je izpostavil, da bo privzemanje nove tehnologije ali sistema neuspešno, če bo zaznано kot preveč ambiciozno ali zahtevno. Negativen vpliv **kompleksnosti** z vidika spremenjenih procesov, potrebe po novem znanju in razumevanja inovacije so v zadnjem času potrdile številne raziskave (Gangwar, 2018; Chong & Lim, 2022; Daradkeh, 2019; Maroufkhani, Iranmanesh & Ghobakhloo, 2023; Maroufkhani, Wan Ismail & Ghobakhloo, 2020; Verma & Bhattacharyya, 2017). Predstavljene rešitve sodelujoči načeloma razumejo kot razumljive in enostavne, tudi za akterje iz slovenskega nogometnega prostora. Hkrati gre po besedah enega izmed sogovornikov za zadevo, ki bo preprosto postala stalnica, ker jo veliki evropski klubi, ki postavljajo standarde, dlje časa uspešno uporabljajo. Zato je treba tudi morebiten visok nivo zahtevnosti in učenja slej kot prej premostiti pa četudi z okrepljenim kadrom ali obsežnejšimi izobraževanji. Morda so nekatere stvari nerazumljive za igralce, a je ravno to morda premostljivo z bolj vizualnimi prikazi, ki se zaenkrat še ne uporabljajo toliko oziroma sploh ne. Kljub temu pa je eden izmed sodelujočih izpostavil, da bi v Sloveniji potrebovali ljudi, ki bi se ukvarjali izključno z aplikacijo in prezentacijo analitičnih rešitev.

Vendar kompleksnost v našem primeru še zdaleč ni enoznačna. Končne rešitve in grafike so uporabnikom zelo razumljive, saj za njihovo uporabo ni pretirane spremembe v procesih ali novih znanjih niso potrebne. Trenutno lahko sklepamo, da je dejavnik v nasprotju z omenjenimi raziskavami manj pomemben, a je razlog za to v trenutnem pristopu. Kompleksnost lahko namreč dojemamo tudi v primeru, ko bi si rešitve pripravili sami, kot to počnejo tudi v največjih evropskih klubih (Lichtenthaler, 2020; Uppsala Universitet, brez datuma). V tem primeru bi verjetno prišlo do večjega vpliva, saj je predvidoma prisoten primanjkljaj tehničnega znanja, saj v slovenskih klubih tudi za analitiko skrbijo pretežno nogometni strokovnjaki.

Za ustrežnejše zaznavanje uporabnosti in kompleksnosti v okviru ovrednotenja sistema (Rogers, 2003) je pomembna **možnost preizkusa**, ki lahko pospeši prehod iz faze implementacije v fazo uporabe. Poskusna verzija (angl. trial) omogoči organizaciji, da oceni koristi in morebitne negotovosti tehnologije, zato je ključnega pomena za proces privzemanja (Gangwar, 2018; Chen, Preston & Swink, 2015; Chong & Lim, 2022; Daradkeh, 2019; Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid, 2020; Maroufkhani, Wan Ismail & Ghobakhloo, 2020), kar potrjuje tudi raziskava. Sogovorniki so zelo naklonjeni preizkusu novosti in so temu vedno pripravljene posvetiti svoje razpoložljive vire. Izpostavili so pomen preizkusa neke nove tehnologije kot sredstvo, na podlagi katerega lažje oceniš, koliko ti bo tehnologija koristila in koliko si pripravljen za njo plačati. Mnogi so denimo omenili tudi, da so že imeli možnost preizkusa (Driblab, Comparisonator), pri čemer so bile izkušnje večinoma izrazito pozitivne, a se sodelovanje ni nadaljevalo izključno zaradi stroškov.

Ravno v tej smeri se lahko navežemo na **organizacijsko pripravljenost**, ki predstavlja zadostnost virov v organizaciji za privzete inovacije (Tornatzky, Fleischer & Chakrabarti, 1990). V okviru organizacijske pripravljenosti pa raziskave izpostavljajo dejavnik zaznane **finančne pripravljenosti** kot enega ključnih zaviralcev privzemanja tehnoloških inovacij (Daradkeh, 2019; Taxman, Henderson, Young & Farrell, 2012). Tudi sogovorniki so kot eno največjih ovir omenjali stroške raznih platform, ki zagotavljajo podatkovne rešitve, zaradi česar lahko to označimo kot zelo pomemben dejavnik privzemanja v našem kontekstu. Finančna pripravljenost je sicer ključni dejavnik tudi v drugih panogah, a je še posebej specifičen za slovenski nogometni prostor. Vložki v nogometnem svetu postajajo izredno visoki, medtem ko proračuni slovenskih klubov, razen izjem s tujimi vlagatelji, ostajajo nespremenjeni. Pri tem je zaskrbljujoča tudi nizka obiskanost tekem, ki jo je izpostavil tudi sogovornik v raziskavi. V sezoni 2021/22 je znašala 1021 obiskovalcev po tekmi, brez dveh najbolj obiskanih (Maribor, Mura) pa povprečno število obiskovalcev pade na nekaj več kot 600 (Nogometna zveza Slovenije, brez datuma).

Ena izmed možnosti za premostitev te ovire je še bolj obsežna pomoč nogometne zveze, medtem ko je druga, ki se je lotevajo mnogi manjši evropski klubi (Švedska, Gruzija), ravno vključevanje bolj tehnično naravnane osebja, ki z relativno preprostim znanjem programiranja omogoči dostop do preprostih podatkovnih rešitev. Dandanes je namreč kot

posledica navdušenja nad podatki v športu na spletu na voljo ogromno število vadnic, programskih knjižnic in druge literature, ki omogoča relativno preprost samostojen razvoj podatkovnih rešitev za podatkovno analitiko v nogometu.

Seveda je treba na tem mestu ohraniti »nogometne« analitike. Še vedno gre namreč za zelo pomembna specifična znanja, ki so vsekakor potrebna in koristna pri sami aplikaciji analitičnih ugotovitev na igrišče. Treba je namreč biti pozoren na poenostavitev ugotovitev v predstavlljivo in razumljivo obliko, ki je še posebej pomembna v športu, kjer lahko nastanejo velike razlike v razumevanju in tehničnem znanju. Ravno zato so ključnega pomena ljudje, ki lahko delujejo kot prevajalci med nogometom in podatkovnimi rešitvami.

Takšni »nogometni« analitiki so po Sormaz (2023) imenovani analitiki za pripravo (angl. performance analyst), medtem ko lahko za interni razvoj rešitev poskrbijo podatkovni znanstveniki (angl. data scientist). Ključnega pomena je povezava med obema vlogama, medtem ko lahko obe vlogi opravlja tudi ista oseba. Z vidika podatkovne analitike v nogometu je sicer zelo specifičen tudi širši krog vpletenih ljudi. Treba je namreč biti pozoren na različne nivoje znanja in udobja pri delu s podatki pri sodelovanju z športnim direktorjem, glavnim trenerjem, trenerji, analitiki, skavti itd.

Ob finančnih sredstvih je v okviru organizacijske pripravljenosti ključnega pomena tudi **zadostnost človeških virov**, ki predpostavlja ravno vire v obliki zaposlenih z ustreznim znanjem za implementacijo in uporabo inovacije. Vpliv tega dejavnika ob privzemanju analitike masovnih podatkov ugotavlja več raziskav (Chen, Preston & Swink, 2015; Lai, Sun & Ren, 2018; Mneney & Van Belle, 2016; Taxman, Henderson, Young & Farrell, 2012), medtem ko je še posebej zanimiv za slovenske športne organizacije, kjer je že v splošnem manjše število zaposlenih, še posebej redki pa so programerji ali inženirji (Davenport, 2014b). Tudi po LaValle, Lesser, Shockley, Hopkins in Kruschwitz (2011) so največje ovire privzemanja podatkovne analitike v pomanjkanju potrebnih znanj za obdelavo ali pripravo podatkov znotraj organizacije, pomanjkljivem razumevanju, kako in kje bo analitika sploh izboljšala delovanje, ali zgolj zavračanje analitičnega potenciala. V raziskavi je bil dejavnik (ne)zadostnosti človeških virov zelo prisoten. Kar se tiče organizacijske pripravljenosti, ni bilo izpostavljenih ovir glede tehnoloških virov, medtem ko je več sogovornikov omenilo problematiko kadrovskega primanjkljaja. Po ugotovitvah iz raziskave ima pomemben vpliv na privzemanje podatkovne analitike tudi velikost organizacije, ki je neposredno povezana z obsegom virov (Baig, Shuib & Yadegaridehkordi, 2019) in v bistvu predstavlja izziv za vse slovenske nogometne organizacije, ki se zaradi tega srečujejo z revščino virov (Welsh, White & Dowell, 1982).

Tudi Davenport (2014b) izpostavlja, da gre pri športnih organizacijah za relativno majhne organizacije, ki večino svojih prihodkov namenijo za igralce, medtem ko denimo za analitiko ostajajo le drobtinice. V Sloveniji je ta problematika še bolj pereča, saj imajo športne organizacije po pravilu maloštevilčen kader, zaradi česar pogosto preprosto zmanjka časa za analitiko. Prav tako imajo zaradi manjših proračunov organizacij zelo redki trenerji možnost

s seboj pripeljati strokovne ekipe, kar bi z vidika podobne miselnosti in utečenosti zagotovo olajšalo uporabo analitike. Zaradi prej omenjenih specifičnih karakteristik nogometnih organizacij so pogosti izzivi, ko organizacija in glavni trener drugače vidita ali cenita analitiko, kar bi bilo vsekakor lažje premostiti, če bi imel trener za seboj dobro vpeljana ekipo, ki ima do analitike enako stališče kot glavni trener. Kot omenjeno, posledično manjka tudi bolj tehnično usmerjenega kadra, ki bi lahko omogočil ugodnejšo vzpostavitev podatkovne analitike. Govora je torej o dejavniku, ki je sicer pomemben tudi v ostalih panogah in v primeru drugih tehnoloških inovacij, a je v primeru slovenskega nogometa še posebej izrazit. V večini organizacij se namreč ustvari nekakšen začaran krog, ko organizaciji primanjkuje kadra ali znanja vendar nima finančnih zmogljivosti za kadrovanje. Glede na vse zapisano je dejavnik zadostnega kadra ključen za privzemanje podatkovne analitike v slovenskem nogometu.

Puklavec, Oliveira in Popovič (2017) sicer ugotavljajo, da je za privzemanje poslovno-inteligenčnih sistemov v majhnih in srednje velikih organizacijah dejavnik organizacijske pripravljenosti pomemben samo v fazah ovrednotenja in odločitve za privzemanje, medtem ko je pri podatkovni analitiki v slovenskem nogometu dejavnik pomemben tudi glede same uporabe. Izzivi z vidika financ in kadrovskega primanjkljaja v slovenskem nogometu namreč predstavljajo specifično problematiko, ki je pomembna v vseh treh fazah privzemanja.

Iz omenjenih razlogov organizacije svojo analitično moč iščejo v širšem ekosistemu. Tako so denimo pri ameriški košarkarski organizaciji Orlando Magic sklenili dogovor z Walt Disney Co., ki je v zameno za promocijo ponudil pomoč svojega močnega analitskega oddelka (Davenport, 2014b).

Tudi razpoložljivost virov pa ni dovolj, če privzemanja inovacije ne **podpira management**, ki posledično privzemanju ne nameni virov (Tornatzky, Fleischer & Chakrabarti, 1990), kar potrjujejo številne raziskave (Gangwar, 2018; Baig, Shuib & Yadegaridehkordi, 2019; Chen, Preston & Swink, 2015; Chong & Lim, 2022; Lai, Sun & Ren, 2018; Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid, 2020; Maroufkhani, Wan Ismail & Ghobakhloo, 2020; Mneney & Van Belle, 2016; Puklavec, Oliveira & Popovič, 2017). Po ugotovitvah iz raziskave sklepam, da je dejavnik v slovenskih nogometnih organizacijah sicer pomemben, a precej konsistenten in zato predvidoma ne predstavljata konkretne ovire ali izrazito pomembne spremenljivke pri privzemanju. Novosti in inovacije so namreč ob dobri predstavitvi v prav vseh klubih toplo sprejete, kar lahko pripišemo trendom v največjih evropskih klubih, po katerih se vodilni neprestano zgledujejo. Težava nastane, če se novosti in tehnologija v organizaciji kopičijo, a se dejansko ne uporabljajo.

Na tem mestu je pomemben tako imenovan **prvak projekta**, ki kot član vodstva zagovarja inovacijo v fazi evalvacije in tudi kasneje. Velik vpliv tega dejavnika je potrdilo več raziskav (Bose & Luo, 2012; J. K. Pinto & Patanakul, 2015), medtem ko Puklavec, Popovič in Oliveira (2017) zaznavajo prisotnost prvaka projekta kot najbolj pomemben dejavnik v vseh

fazah privzemanja poslovnointeligentnih sistemov, kar lahko glede na rezultate raziskave prenesemo tudi na podatkovno analitiko v slovenskem nogometnem prostoru. V primeru, kjer je bilo očitno zaznati prisotnost prvaka projekta (konkretno športni direktor), so nad potencialom podatkovne analitike navdušeni, hkrati pa so že zabeležili prve uspehe v obliki zaslužka od prodaje igralcev, ki jih je našel podatkovni model. Tudi na podlagi lastnih izkušenj menim, da je dejavnik prvaka projekta ključnega pomena pri razvoju in implementaciji, saj sem tudi ob svojem delu sodeloval v primeru, ko sta bila razvoj in implementacija projekta občutno bolj učinkovita in uspešna, ker je bil kot vodja vključen član uprave.

Čeprav je največkrat predstavnik prvaka projekta nekdo na vodstvenih položajih, bi lahko v prenesenem pomenu kot prvaka projekta razumeli tudi glavnega trenerja. Ob podpori managementa je namreč glede same uporabe podatkovne analitike ključna tudi miselnost glavnega trenerja. Ravno na tem mestu pa pridemo do stičišča med privzemanjem in sprejemanjem, kjer je meja v obravnavanem primeru nogometa močno zabrisana. Uporaba analitike se v določeni organizaciji težje ohrani predvsem pa stabilno vzpostavi, če se ob menjavi trenerja interes in odnos do podatkovne analitike povsem spremenita, kar je kot oviro izpostavil tudi eden izmed sogovornikov. Čeprav si v zadnjem času po svetu tudi najbolj tradicionalno naravnani glavni trenerji vse več pomagajo s podatki, to za slovenski prostor še ne velja, saj imamo po ugotovitvah iz raziskave preveč enoznačno razlikovanje med tradicionalnimi in modernimi trenerji, pri čemer je zagotovo najboljša kombinacija obojega.

Vpliv pogostih menjav ključnih kadrov za razvoj analitike (glavni trener, športni direktor) lahko po Mohammadi in Isanejad (2018) organizacija zmanjša z zagotavljanjem splošnega pozitivnega odnosa glede informacijske tehnologije, kar bo pozitivno vplivalo na sprejemanje zaradi vpliva na namero po uporabi informacijske tehnologije. Na ta način lahko organizacija doseže večjo stabilnost ne glede na številne spremembe.

Z vidika okolja je za obravnavan primer specifičen tudi vidik **zunanjih ponudnikov ali podpore**, ki vključuje izobraževanja, tehnično pomoč in uporabo predpripravljenih platform. Pomembnost dejavnika ugotavlja več raziskovalcev (Gangwar, 2018; Chong & Lim, 2022; Maroufkhani, Tseng, Iranmanesh, Ismail & Khalid, 2020; Maroufkhani, Wan Ismail & Ghobakhloo, 2020). V tem trenutku se zdi, da je uporaba podatkovne analitike v slovenskih organizacijah namreč odvisna predvsem od tega, kar je na voljo v obliki neke pripravljene platforme. Kljub temu lahko glede na mnenja sogovornikov sklepam, da dejavnik zunanjih ponudnikov in podpore ni pretirano pomemben. Razlog za to je dejstvo, da podatkovne platforme sogovornikom ne zagotavljajo izobraževanj ali tehnične podpore, kar kot ključno izpostavljajo Maroufkhani, Tseng, Iranmanesh, Ismail in Khalid (2020). Hkrati se lahko na tem mestu navežemo na možnost lastnega razvoja s pomočjo tehnično naravnanih analitikov, pri čemer je pomen dejavnika predvidoma še manj občuten.

Mnogi strokovnjaki izpostavljajo **pritisek konkurentov**, saj naj bi na privzemanje analitike ali ostalih naprednih tehnoloških rešitev stimulatивно vplivala njihova uporaba v konkurenčnih podjetjih (Gangwar, 2018; Chong & Lim, 2022; Maroufkhani, Wan Ismail & Ghobakhloo, 2020). Vendarle pa vsaj zaenkrat pritisek konkurentov v slovenskem prostoru deluje kot manj pomemben dejavnik, kar ob analizi privzemanja analitike masovnih podatkov ugotavljajo tudi Maroufkhani, Tseng, Iranmanesh, Ismail in Khalid (2020). Sogovorniki sicer spremljajo uporabo analitike pri konkurentih, a jih to načeloma dodatno ne motivira glede samo uvajanje podatkovne analitike. Vsi sogovorniki namreč zagotavljajo, da ne bodo uporabljali določene rešitve samo zato, ker jo uporablja tudi njihov konkurent, temveč se bodo pri izbiri tehnologije zanašali zgolj na svoje lastne potrebe. Sicer bi lahko sklepali, da gre pri manjšem pomenu pritiska konkurentov za specifično privzemanja v športu, a je po drugi strani potencialen razlog za ugotovitve dejstvo, da sogovorniki pri konkurentih še niso opazili kakšnih opaznih uspehov podatkovne analitike.

5.2 Dejavniki sprejemanja

Dejanska uporaba tehnološke inovacije je odvisna tudi od odnosa posameznika do tehnologije oziroma tehnološkega napredka, kar opredeljujejo denimo tehnološka samoučinkovitost, zaznan užitek ob uporabi tehnologije, inovativnost posameznika ali posameznikova pripravljenost za spremembe (Mohammadi & Isanejad, 2018; Venkatesh & Bala, 2008). Tehnološka samoučinkovitost v zadnjem času podobno kot strah pred uporabo računalnikov precej izgublja na pomenu zaradi neprestanega tehnološkega napredka in vsesplošne digitalizacije, kar je bilo opaziti tudi v sami raziskavi. Glede na ugotovitve bi lahko podobno sklepali tudi za posameznikovo pripravljenost na spremembe, kar pa je v bistvu v nasprotju z ugotovitvami Grublješič in Jaklič (2015a), ki ugotavljata pomemben vpliv. Kot vzrok bi navedel dejstvo, da je kljub dinamičnosti strogo poslovnih panog, ta v nogometu še toliko večja. Sestava ekip in strokovnih kadrov se nenehno spreminja, medtem ko se ključne odločitve in prilagajanja izvajajo tudi med samo tekmo. Ob tem je tudi tehnološki napredek v nekaj letih od omenjene raziskave dodatno spremenil okolje, v katerem pripravljenost na spremembe postaja nekako samoumevna. Tudi sogovorniki se zavedajo, da je treba slediti trendom, ki jih postavljajo najboljši evropski klub in zato menijo, da zaradi narave dela preprosto morajo biti pripravljeni na spremembe. Vsi sogovorniki prav tako nedvomno podpirajo tehnološki razvoj in menijo, da je uporaba tehnologije nujna za napredek, hkrati pa njeno uporabo spodbujajo v vseh pogledih in vsekakor tudi na ravni organizacije. V splošnem v raziskavi glede samoučinkovitosti in pripravljenosti na spremembe ni bilo opaziti večjih razlik med sogovorniki.

Na drugi strani lahko **inovativnost posameznika** in **zaznan užitek ob uporabi tehnologije** občutno spodbudita samo uporabo podatkovne analitike, še posebej, če je mogoče omenjeni lastnosti opaziti pri glavnem trenerju. Čeprav je tudi v poslovnem svetu opaziti vpliv obeh dejavnikov (Grublješič & Jaklič, 2015b; Venkatesh & Bala, 2008), sta glede na ugotovitve iz raziskave in moje mnenje še toliko bolj opazna v slovenskem športu. Medtem ko se je v

večjih poslovnih panogah (proizvodnja, trgovina, energetika) napredna raba računalnikov v različne namene povsem standardizirala, so zaenkrat v nogometu inovativni pristopi z uporabo računalnika še vedno v manjšini. S tega vidika lahko stopnja navdušenja posameznika zelo vpliva na samo uporabo. V tem primeru gre za dejavnika, ki lahko občutno vplivata na samo uporabo podatkovne analitike.

Metem ko so pri operativnih sistemih rezultati uporabe vidni takoj, je v primeru podatkovne analitike na predstavljen način zelo pomembno, da ob zaznavi uspešnosti (relativna prednost, zaznana uporabnost) občutijo tudi družbeni vpliv. Če torej uporabniki zaznavajo koristi svoji podobi, hkrati pa so rezultati uporabe vidni in tudi dokazljivi, bo uporaba analitike postala bolj vpeta v njihova vsakodnevna opravila (Grublješič & Jaklič, 2015a). V splošnem bi moral **družbeni vpliv** tudi v nogometu vplivati na uporabo podatkovne analitike, kar se predvidoma že dogaja drugje po svetu. Kljub temu pa v Sloveniji glede na ugotovitve iz intervjujev še ni tako. Najbolj cenjena so mnenja nekdanjih vrhunskih nogometašev, ki prevladajo četudi podatki morda govorijo drugače. Hkrati mnogi strokovnjaki analitikov v slovenskem nogometu denimo še vedno ne dojemajo kot sestavni del strokovnega kadra. Ravno to je verjetno tudi glavni razlog za manjši pomen dejavnika v času raziskave. Vendarle pa se v zadnjem času stvari opazno premikajo naprej, pri čemer tudi analitiki, predvsem pa uporaba podatkov v nogometu na sploh, pridobivajo na podobi, kar bo predvidoma dodatno spodbudilo samo uporabo.

Na tem mestu je smiselno izpostaviti tudi pomen **predstavljenosti**. Grublješič in Jaklič (2015a) sicer dejavnik predstavljenosti opisujeta kot manj pomemben, medtem ko po ugotovitvah iz raziskave deluje kot potencialno pomemben faktor pri sprejemanju podatkovne analitike, saj so sogovorniki sami od sebe kot pozitivno lastnost podatkovne analitike izpostavili dejstvo, da lažje in predvsem bolj učinkovito predstavijo rezultate in svoje ugotovitve. Posledično prav to predstavlja pozitiven odnos in motivacijo za nadgradnjo »tabelarične« analitike ter uporabo predstavljenih grafičnih rešitev. Sklepam, da je predstavljenost v nogometu in športu pomembna predvsem zaradi zagotavljanja konkretnih rezultatov in števil, ki nekako testirajo tradicionalni pristop, od katerega nekateri pomembni akterji še vedno ne odstopajo.

5.3 Ključni dejavniki in predlogi

Glede na zapisano so lahko od primera do primera pomembni številni različni dejavniki, med katerimi so bolj pomembni denimo relativna prednost, združljivost, možnost preizkusa, prisotnost prvaka projekta, organizacijska pripravljenost, velikost organizacije, zaznan užitek ob uporabi tehnologije, inovativnost posameznika in predstavljenost rezultatov. Ključni dejavniki privzemanja podatkovne analitike v slovenskem nogometu so predstavljeni v tabeli 5.

Tabela 5: Tabelarični povzetek pomembnosti dejavnikov privzemanja

Dejavnik	Vpliv (ugotovitve raziskave)
Tehnološki dejavniki	
Relativna prednost (zaznana uporabnost)	+
Kompleksnost (zaznana enostavnost uporabe)	+o
Združljivost	++
Možnost preizkusa	+
Organizacijski dejavniki	
Podpora vrhnjega managementa	+o
Prvak projekta	++
Organizacijska pripravljenost	++
Dejavniki okolja	
Pritisk konkurentov	o
Zunanji ponudniki in podpora	+o
Sprejemanje	
Tehnološka samoučinkovitost	o
Zazan užitek ob uporabi tehnologije	+
Inovativnost posameznika	+
Posameznikova pripravljenost na spremembe	o
Predstavljenost rezultatov	+
Družbeni vpliv	+o

Legenda: ++ – ključen dejavnik, + – pomemben dejavnik, +o – relevanten dejavnik, o – nepomemben dejavnik

Vir: lastno delo.

Zelo pomembna značilnost privzemanja podatkovne analitike v nogometu je dejstvo, da so odločevalci in uporabniki v večini primerov iste osebe. S tega vidika je ključen dejavnik tako imenovan prvak projekta, ki ga kot enega najpomembnejših izpostavljajo tudi Puklavec, Popovič in Oliveira (2017). Prvak projekta je sicer kot zelo pomemben dejavnik identificiran v mnogih raziskavah glede privzemanja podatkovne analitike in sorodnih področij, a je zaradi omenjene specifičnosti v obravnavanem primeru še toliko bolj zanimiv. Medtem ko je tudi naklonjenost k podatkom s strani športnega direktorja faktor v privzemanju, je vpliv dejavnika še večji, če v vlogo prvaka projekta postavimo glavnega trenerja, saj je od njegove miselnosti in navdušenja nad podatki zelo odvisna dejanska uporaba podatkovne analitike. V kolikor bo glavni trener kot prvak projekta želel uporabljati podatkovno analitiko, bo to zelo pripomoglo k samemu privzemanju in uporabi.

Kar se tiče športnega dela, sta običajno najpomembnejša športni direktor in glavni trener, pri čemer je razdelitev vlog in organizacijska struktura zelo raznolika in odvisna od kluba do kluba. Ravno s tega vidika je morda malce težje opredeliti in oceniti vpliv odločevalcev. Medtem ko je na drugih področjih vpliv odločevalcev precej pomemben, gre v

obravnavanem primeru vsaj zaenkrat zgolj za odobritev določenih zadev, pri čemer pretirano ne pospešujejo ali zavirajo privzemanja in uporabe. Morda se bo to spremenilo v prihodnosti, ko bodo predvidoma tudi slovenske nogometne organizacije sledile največjim evropskim klubom, ki so v zadnjem času že vzpostavili nekakšne analitične oddelke. Pri tem je zaključna faza privzemanja, ki opredeljuje samo uporabo, seveda še vedno odvisna predvsem od glavnega trenerja in strokovnega štaba, a bo predvidoma tudi vodstvo izbiralo takšen strokovni kader, ki ustreza njihovim podatkovno-analitičnim nazorom. S tega vidika bi lahko bila potencialna možnost za premostitev ovire nenehnih sprememb v konkretnem vključevanju mlajših selekcij. Trenutno se namreč vse skupaj preveč veže zgolj na prvo ekipo, medtem ko bi lahko klubi začeli z vzpostavljanjem željenega sistema že na ravni kadetskih in mladinskih ekip, kjer je načeloma manj sprememb v strokovnem kadru in posledično pristopu. S tem bi lahko zastavili bolj konsistentno delo z vidika celotne organizacije – tudi iz analitičnega vidika.

Odvisnost od pristopa trenerja pa je posebej problematična zaradi izredno dinamičnega okolja. V zadnjem času so se morale organizacije v praktično vseh panogah prilagoditi na hitro in fleksibilno okolje, medtem ko so nenehne spremembe in prilagoditve v nogometu stalnica že od nekdaj. Glavni trenerji, igralci in ostali strokovni delavci namreč zelo pogosto menjavajo klube, kar pogosto predstavlja izziv zaradi raznolikih pristopov in razmišljanja. S tega vidika je glede na ugotovitve iz raziskave tudi pripravljenost na spremembe precej manj pomembna kot na drugih področjih. Medtem ko je v tujini olajševalna okoliščina dejstvo, da ima večina glavnih trenerjev strokovne ekipe, ki jih vzame s seboj, v Sloveniji to vsaj zaenkrat še ne velja.

Ravno s tega razloga je kot ključna dejavnika smiselno izpostaviti finančno pripravljenost in zadostnost človeških virov v okviru dejavnika organizacijske pripravljenosti, saj lahko kot največji oviri za bolj intenzivno in napredno rabo podatkovne analitike na podlagi empirične raziskave izpostavimo stroške in kadrovske stisko. Pri stroških so sogovorniki izpostavili cene platform s podatkovnimi rešitvami, medtem ko imajo glede kadra občutek, da manjka nekdo, ki bi se ukvarjal le s podatki in njihovo aplikacijo. Seveda sta omenjena dejavnika tesno povezana, saj je kader v športnih organizacijah odvisen predvsem od proračuna. Oba dejavnika v drugih panogah ali v nogometno uspešnejših državah sicer predstavljata težavo, a ne tako zelo perečo kot v Sloveniji, kjer pravzaprav sestavljata začaran krog. Zaradi manjšega interesa navijačev v slovenskem prostoru so tudi proračuni nižji, kar onemogoča zadostnost kadra oziroma kadrovanje po željah trenerja, medtem ko to zavira napredek na več področjih. To pa preko rezultatov vodi nazaj do manjšega interesa. Dodatno oviro predstavlja še majhnost organizacij in tako imenovana revščina virov.

Na tem mestu lahko morda pomaga tudi alternativen pristop k podatkovni analitiki. Ključnega pomena je namreč zavedanje, da lahko tudi sama uporaba analitike s pomočjo vpogledov v vzorce in skrajšanih seznamov potencialnih okrepitev zmanjša težave glede razpoložljivih virov v smislu časa in denarja (Sumpter, 2016).

V skladu z raziskovalnim vprašanjem »Kako povečati smiselno in koristno uporabo podatkovne analitike v nogometu v Sloveniji?« sem na podlagi analize dejavnikov privzemanja in sprejemanja pripravil nekaj konkretnih predlogov oziroma aplikacije v prakso. Prvi predlog se nanaša na to, kar so izpostavili tudi sogovorniki, ki bi morda glede na cene podatkovnih rešitev iz znanih platform pričakovali večjo podporo s strani Nogometne zveze Slovenije. Cena je namreč zagotovo ugodnejša, če se dostope zagotovi na višji ravni.

Alternativno se mnogi evropski klubi namesto dragih platform obračajo proti lastnemu razvoju analitike. V tej smeri pridemo sicer do druge ključne ovire v obliki kadrovske stiske, ki je v primerjavi s stroški glede na ugotovitve iz raziskave in moje mnenje lažje premostljiva. Slovenske nogometne organizacije si sicer ne morejo kar naenkrat privoščiti profesionalnih analitikov. Ker pa je navdušenje nad podatkovno analitiko v nogometu pri mladih ogromno, je denimo vredno razmisliti o neplačanem pripravništvu, ki organizaciji omogoči poskus razvoja lastne analitike, medtem ko sodelujočim ponudi izkušnje, prisotnost v prvoligaškem nogometu in morebiti še kakšne malenkosti v smislu vstopnic ali klubske opreme. Smiselnost predloga so v letošnjem letu potrdili pri gruzijskem prvoligašu FC Dinamo Tbilisi, kjer so s pomočjo neplačanega pripravništva v klubu oblikovali celoten oddelek analitike na daljavo, ki šteje deset članov. Gre za najrazličnejše profile navdušencev iz celotnega sveta, od študentov do redno zaposlenih. V zelo kratkem času je prostovoljni oddelek za klub pripravili razne grafike (radarje, zemljevide podaj) in poročila, ki so prilagojena glede na zahteve in ključne kazalnike uspešnosti znotraj organizacije.

Podobna možnost je sodelovanje z univerzo ali določenimi fakultetami (računalništvo, elektrotehnika, ekonomija, fakulteta za šport, ekonomija ipd.), kjer bi potencialno lahko zainteresirani študentje v okviru določenega izbirnega predmeta ali projekta dobili priložnost za sodelovanje z nogometnim klubom. Vsaj zaenkrat je namreč smiselno razmišljati zgolj o relativno preprostih rešitvah v smislu deskriptivne in diagnostične analitike, ki jih je ob številnih vadnicah in programskih knjižnicah lahko implementira nekdo z zelo osnovnim znanjem programskih jezikov (na primer Python ali R) ali orodij za vizualizacijo, kar je lahko zaključeno v okviru enega semestra.

Še ena izmed možnosti v tej smeri se nanaša na širši ekosistem organizacije, ki ga kot zelo pomembnega omenja že Davenport (2014b). Marsikateri slovenski nogometni prvoligaš ima namreč sponzorje z močnimi podatkovnimi oddelki, ki bi jih lahko ob primernem dogovoru izkoristili, tako kot so to storili na relaciji Orlando Magic–Walt Disney Co. V začetku je to predstavljalo začasno pomoč, ki je kasneje NBA ekipi omogočila, da je vzpostavila lastno ekipo analitikov – vključno z nekaterimi prihodi s strani Disneyja.

Vsi predlogi se z razlogom nanašajo na neke vrste priložnostno delo, saj bi bilo smiselno z morebitnim razvojem začeti postopoma. Prav tako je eden od sogovornikov omenil, da bi predstavljene rešitve v okviru skavtinga potrebovali predvidoma le dva meseca na leto – pred prestopnimi roki. Zaradi tega verjetno vsaj na začetku niti ni smiselno razmišljati o

redno zaposlenem podatkovnem analitiku. Kot omenjeno, pa nikakor ne smemo pri vsem tem pozabiti na »nogometne« analitike, ki ugotovitve aplicirajo in spravijo na igrišče, kar je na koncu najpomembnejše.

Če se navežem še na izpostavljen dejavnik miselnosti glavnih trenerjev, bi zagotovo koristila določena izobraževanja v smeri koristi in potenciala podatkovne analitike v nogometu. Sam sem v okviru raziskave sicer govoril z glavnimi trenerji, ki to že poznajo, a glede na ugotovitve iz raziskave v slovenskem prostoru deluje še precej strokovnih delavcev, ki podatke zavračajo. Posredno lahko na tak način ob samem poznavanju potencialnih prednosti spodbudimo tudi samo inovativnost posameznikov, kar glede na ugotovitve iz raziskave prav tako opazno vpliva na samo uporabo.

Na tem mestu je smiselno izpostaviti še eno specifično lastnost slovenskega nogometnega prostora, ki predstavlja dodaten izziv. Sogovorniki so v raziskavi izpostavili, da se prvoligaški klubi v Sloveniji v veliki meri ukvarjajo z osnovnimi stvarmi v smislu profesionalizma, pravilne prehrane in počitka, pri čemer posledično zmanjka prostora za naprednejše zadeve. Kljub temu sogovorniki izpostavljajo, da bo tudi to treba vključiti, saj denimo podatki postajajo ključni del nogometne izobrazbe. S tega vidika je denimo ključno vključevanje taktične analitike. Na tem mestu je treba strukturirati in analitiko prilagoditi v kontekstu vzpostavljenega modela igre, saj se šele takrat vidi, kdo in kdaj deluje skladno z navodili. Na podlagi pridobljenih informacij se igralci lažje učijo in izboljšujejo svojo igro. Vse to je zelo pomembno, ker slovenski klubi v veliki meri živijo od ustvarjanja in prodaje mladih igralcev.

V kontekstu privzemanja podatkovne analitike v ostalih panogah so v raziskavah izpostavljeni še nekateri drugi dejavniki, ki jih nisem presodil kot relevantne, prav tako pa se niso pojavili med intervjuji. Tako je denimo manj pomembna vidnost (angl. observability). Podatkovna analitika v nogometu namreč praviloma vedno deluje skupaj s tradicionalnim pristopom, kar pomeni, da so neposredni rezultati podatkovne analitike navzven precej težko opredeljivi. Prav tako so manj pomembni dejavniki glede upravljanja podatkov, vzpostavljenega podatkovnega okolja, saj se organizacije v Sloveniji (še) ne ukvarjajo z lastnim zbiranjem in shranjevanjem podatkov. Če ugotovitve preslikamo še na ostale športe, je pomembnost dejavnikov v slovenskem prostoru predvidoma zelo podobna, zlasti v ekipnih športih. V širšem okolju velja prepričanje, da je nogomet z vidika analitike v primerjavi z ostalimi športi na splošno zaostajal zaradi dolge zgodovine, ki je nekako zadržala tradicionalen pristop (Kuper & Szymanski, 2009). Kljub temu mislim, da v našem prostoru to ni zgolj specifična nogometa in je na območju bivše Jugoslavije tako tudi v ostalih športih. Ravno tradicionalni pristop pri večjem deležu strokovnjakov v slovenskem okolju, ki ga omenjajo sogovorniki, je zagotovo eden od razlogov, da se podatkovna analitika v prostoru bivše Jugoslavije še ni uveljavila. To posledično vpliva na pomen nekaterih obravnavanih dejavnikov, vključno z družbenim vplivom, ki je na primer precej bolj pomemben v državah, kjer so podatki v nogometu bolj priljubljeni in uveljavljeni.

SKLEP

Nogomet je iz športne rekreacije prerasel v panogo, ki iz leta v leto ustvarja ogromne vsote denarja. Posledično morajo biti tudi v športu organizacije inovativne in pozorne na vsako priložnost, s katero lahko postanejo boljše od konkurence. Ena izmed teh priložnost se zagotovo nanaša na uporabo podatkovne analitike. Dandanes jo zato že uporabljajo številne nogometne organizacije po vsem svetu – bodisi za doseganje konkurenčne prednosti na igrišču, bodisi za bolj učinkovit izkoristek proračuna in posledično možnost konkuriranja finančno bolje situiranim organizacijam.

Ker so indici v Sloveniji kljub temu kazali na manj intenzivno rabo podatkovno analitike, sem v sklopu magistrskega dela pripravil pregled literature in izluščil smiselne primere uporabe. Z empirično raziskavo sem preveril trenutno stanje uporabe podatkovne analitike v slovenskem nogometu, pri čemer sem se osredotočil na identifikacijo in analizo dejavnikov privzemanja, ki vplivajo na uporabo podatkovne analitike.

Na podlagi empirične raziskave ugotavljam, da je uporaba podatkovne analitike v nogometu v Sloveniji v bistvu prisotna, a je v večini primerov zaenkrat še bolj v smislu delnega vključevanja predpripravljenih poročil s strani ponudnika podatkov v obstoječe procese ali analize surovih podatkov glede telesne priprave, medtem ko se redki lotevajo samostojnega razvoja preprostejših modelov za skavting. Ključne značilnosti, ki vplivajo na pomen dejavnikov privzemanja podatkovne analitike v slovenskem nogometu, se nanašajo predvsem na majhnost organizacij s skromnimi proračuni. Potencialni uporabniki podatkovne analitike (glavni trenerji) v večini primerov nastopajo tudi v vlogi odločevalcev, pri čemer stabilnost otežujejo nenehne menjave klubov. Sicer je opaziti vpliv mnogih dejavnikov privzemanja in sprejemanja, a lahko glede na ugotovitve raziskave posebej izpostavim finančno pripravljenost in zadostnost človeških virov v okviru organizacijske pripravljenosti, združljivost ter dejavnik prvaka projekta, v vlogo katerega lahko postavimo glavnega trenerja.

Predlogi za aplikacijo ugotovitev v prakso se nanašajo predvsem na možnost samostojnega razvoja analitike na podlagi pripravništev ali vključevanja širšega ekosistema v smislu fakultet in sponzorjev. Ob tem je vredno omeniti še morebitno finančno pomoč s strani ključnih akterjev in organizacijo delavnic za osveščenost udeležencev.

Namen magistrskega dela, ki sem ga opredelil kot povečanje oziroma spodbuditev uporabe podatkovne analitike v nogometu v Sloveniji, je bil dosežen, saj smo s sogovorniki ob identifikaciji pomembnih dejavnikov privzemanja v večini primerov zelo konkretno govorili o smiselni uporabi analitike, kjer smo izpostavili številne uporabne prakse. Zelo spodbudno je tudi dejstvo, da je več sogovornikov izpostavilo močno željo po nadaljnji implementaciji podatkovne analitike v prihodnje, pri čemer bo v pomoč magistrsko delo oziroma ključne ugotovitve, ki iz dela izhajajo.

Glavni teoretični prispevek magistrskega dela je doprinos k razumevanju privzemanja in sprejemanja podatkovne analitike v specifičnem kontekstu nogometa v Sloveniji. Praktični prispevek sestavljajo pripravljene predloge za povečanje smiselne in koristne uporabe podatkovne analitike v slovenskem nogometu ter opravljena prva raziskava na to tematiko v našem prostoru. Ta lahko služi kot uvodno preverjanje stanja uporabe analitike v širšem kontekstu in hkrati kot spodbuda za nadaljnje raziskovanje na tem področju. V prihodnje bi bilo smiselno še podrobneje preučiti posamezne segmente, v okviru katerih lahko podatkovna analitika pripomore k boljšemu delovanju organizacij v slovenskem nogometu.

Predvsem je smiselno poglobiti empirično raziskavo z s podrobnejšo analizo dejavnikov in večjim vzorcem. Sam sem imel v vzorcu glavne trenerje in pomočnike trenerjev, ki imajo največ stika s samo analitiko. V večjih evropskih klubih, kjer imajo vzpostavljene analitične oddelke, so zato odgovorni najrazličnejši profili. Ravno zato bi bilo morda smiselno razširiti vzorec sogovornikov še na športne direktorje in ostale ključne akterje.

V prihodnosti bi se bilo smiselno osredotočiti tudi na problematiko morebitnega prikrivanja neuporabe. Kljub temu, da imajo recimo klubi pogodbe z InStat, ki jim pripravljajo obsežna poročila, je vprašanje, ali to dejansko preučijo, predvsem pa aplicirajo v trenajžni proces. Do neke mere sem bil na to posebej pozoren, saj smo to z mentorjema izpostavili pri zastavljanju izvedbe, a sem mnenja, da je v prihodnjih raziskavah treba še bolj prodreti v globino tega problema. Ena izmed omejitev raziskave je bila tudi sama izvedba intervjujev, saj sem glede uporabe analitike pred samo izvedbo raziskave dobil zelo različne informacije, kar je ob neizkušenosti s kvalitativnimi raziskavami predstavljalo izziv pri pripravi na intervjuje. Hkrati so bili moji sogovorniki po izkušnjah precej različni. Sicer sem sproti prilagajal vprašanja in poskušal iz vsakega intervjuja pridobiti čim več, a verjamem, da bi lahko vprašanja zastavil na še boljši način in posledično dobil še boljše podatke.

Šport v Sloveniji od nekdaj presega pričakovanja glede na razpoložljive vire. Verjamem, da bo v prihodnje to uspelo tudi nogometu, pri čemer mislim, da lahko ob ustreznih strateških ciljih in vzajemnem sodelovanju ključnih akterjev zelo pomembno vlogo odigra tudi učinkovitejše izkoriščanje razpoložljivih podatkov. Dragocenost informacij in pomen podatkovne analitike so v zadnjem času spoznala tudi največja slovenska podjetja, zaradi česar so njihovi analitični oddelki vse večji. Podatkovna analitika se v slovenskem prostoru intenzivno uporablja v najrazličnejših panogah, vse od pivovarstva do energetike. Vsaj zaenkrat pa v tem segmentu zaostaja šport, kjer je podatkovni potencial prav tako ogromen. Kot je dejal Rory Campbell, tedaj vodilni analitik West Ham Uniteda: »[...] ne glede na to, ali gre za poker, ekonomijo, stave ali nogomet, pomembno je uporabiti vse možne informacije, ki so potrebne za sprejemanje pravih odločitev pod pritiskom [...]« (Sumpter, 2016).

LITERATURA IN VIRI

1. Agarwal, R. & Prasad, J. (1998). A Conceptual and Operational Definition of Personal Innovativeness in the Domain of Information Technology. *Information Systems Research*, 9(2), 204–215.
2. Ajah, I. A. & Nweke, H. F. (2019). Big Data and Business Analytics: Trends, Platforms, Success Factors and Applications. *Big Data and Cognitive Computing*, 3(2), 32.
3. Alsunaidi, S. J., Almuhaideb, A. M., Ibrahim, N. M., Shaikh, F. S., Alqudaihi, K. S., Alhaidari, F. A., Khan, I. U., Aslam, N. & Alshahrani, M. S. (2021). Applications of Big Data Analytics to Control COVID-19 Pandemic. *Sensors*, 21(7), 2282.
4. Anderson, C. & Sally, D. (2013). *The Numbers Game: Why Everything You Know About Football is Wrong*. London: Penguin Books Limited.
5. Arthur, L. (2013). *Big Data Marketing: Engage Your Customers More Effectively and Drive Value*. New Jersey: Wiley.
6. Awa, H. O., Ukoha, O. & Igwe, S. (2017). Revisiting technology-organization-environment (T-O-E) theory for enriched applicability. *The Bottom Line*, 30(1), 2–22.
7. Bai, Z. & Bai, X. (2021). Sports Big Data: Management, Analysis, Applications, and Challenges. *Complexity*, 2021, 1–11.
8. Baig, M. I., Shuib, L. & Yadegaridehkordi, E. (2019). Big data adoption: State of the art and research challenges. *Information Processing & Management*, 56(6), 102095.
9. Baker, J. (2012). The Technology–Organization–Environment Framework. V Dwivedi, Y., Wade, M. & Schneberger, S. (ur.), *Information Systems Theory* (str. 231–245). New York: Springer.
10. Banjac, M. (2020). *Uvod v kvalitativne metode zbiranja podatkov: opazovanje, intervju in fokusna skupina*. Ljubljana: Založba FDV.
11. Batorfy, A. (2020, 24. februar). *Three Sportviz Inventions By a Hungarian Newspaper* [objava na blogu]. Pridobljeno 11. oktobra 2022 iz <https://medium.com/nightingale/three-sportviz-inventions-by-a-hungarian-newspaper-b5c0df489d6c>
12. Beal, R., Chalkiadakis, G., Norman, T. J. & Ramchurn, S. D. (2020). Optimising game tactics for football. *Proceedings of the 19th International Conference on Autonomous Agents and Multiagent Systems*, 141-149.
13. Ben Arfi, W., Ben Nasr, I., Khvatova, T. & Ben Zaied, Y. (2021). Understanding acceptance of eHealthcare by IoT natives and IoT immigrants: An integrated model of UTAUT, perceived risk, and financial cost. *Technological Forecasting and Social Change*, 163, 120437.
14. Bornn, L., Cervone, D. & Fernandez, J. (2018). Soccer analytics: Unravelling the complexity of “the beautiful game.” *Significance*, 15(3), 26–29.
15. Bose, R. & Luo, R. (2012). Green IT adoption: A process management approach. *International Journal of Accounting & Information Management*, 20, 63–77.
16. Bransen, L., Van Haaren, J. & Van De Velden, M. (2019). Measuring soccer players' contributions to chance creation by valuing their passes. *Journal of Quantitative Analysis*

- in Sports*, 15(2), 97–116.
17. Brechot, M. & Flepp, R. (2020). Dealing With Randomness in Match Outcomes: How to Rethink Performance Evaluation in European Club Football Using Expected Goals. *Journal of Sports Economics*, 21(4), 335–362.
 18. Bregar, L., Ograjenšek, I. & Bavdaž, M. (2005). *Metode raziskovalnega dela za ekonomiste: izbrane teme*. Ljubljana: Ekonomska fakulteta.
 19. Cao, G. & Duan, Y. (2017). How do top- and bottom-performing companies differ in using business analytics? *Journal of Enterprise Information Management*, 30(6), 874–892.
 20. Cervone, H. F. (2016). Organizational considerations initiating a big data and analytics implementation. *Digital Library Perspectives*, 32(3), 137–141.
 21. Chen, D., Preston, D. & Swink, M. (2015). How the Use of Big Data Analytics Affects Value Creation in Supply Chain Management. *Journal of Management Information Systems*, 32(4), 4–39.
 22. Chong, L. Y. & Lim, T. S. (2022). Pull and Push Factors of Data Analytics Adoption and Its Mediating Role on Operational Performance. *Sustainability*, 14(12), 7316.
 23. Chuttur, M. (2009). Overview of the Technology Acceptance Model: Origins, Developments and Future Directions. *Sprouts: Working Papers on Information Systems*, 9(37), 9–37.
 24. Daradkeh, M. K. (2019). Determinants of visual analytics adoption in organizations: Knowledge discovery through content analysis of online evaluation reviews. *Information Technology & People*, 32(3), 668–695.
 25. Davenport, T. H. (2014a). Analytics in Sports: The New Science of Winning. *International Institute for Analytics*, 2, 1–28.
 26. Davenport, T. H. (2014b). What businesses can learn from sports analytics. *MIT Sloan Management Review*, 55(4), 10–13.
 27. Davis, F. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly: Management Information Systems*, 13(3), 319–339.
 28. Davis, F. D. (1993). User acceptance of information technology: system characteristics, user perceptions and behavioral impacts. *International Journal of Man-Machine Studies*, 38(3), 475–487.
 29. Davis, J. & Robberechts, P. (2020, 1. julij). *How data quality affects xG* [objava na blogu]. Pridobljeno 4. januarja 2022 iz <https://dtai.cs.kuleuven.be/sports/blog/how-data-quality-affects-xg>
 30. De Silva, D., Caine, M., Skinner, J., Dogan, S., Kondo, A., Peter, T., Axtell, E., Birnie, M. & Smith, B. (2018). Player Tracking Data Analytics as a Tool for Physical Performance Management in Football: A Case Study from Chelsea Football Club Academy. *Sports*, 6, 130.
 31. Decroos, T., Van Haaren, J., Bransen, L. & Davis, J. (2019). Actions speak louder than goals: Valuing player actions in soccer. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1851–1861.

32. Dillon, A. & Morris, M. (1996). User Acceptance of Information Technology: Theories and Models. *Annual Review of Information Science and Technology*, 31.
33. Durgapal, A. & Rowlinson, A. (brez datuma). *mplsoccer*. Pridobljeno 11. aprila 2023 iz <https://mplsoccer.readthedocs.io/en/latest/index.html>
34. Eder, L. B. & Igarria, M. (2001). Determinants of intranet diffusion and infusion. *Omega*, 29(3), 233–242.
35. Efthimiou, C. J. (2021). The voronoi diagram in soccer: a theoretical study to measure dominance space. *ArXiv Preprint ArXiv:2107.05714*.
36. FC PYTHON. (brez datuma). *FC Python*. Pridobljeno 4. januarja 2023 iz <https://fcpython.com/>
37. Fonseca, S., Milho, J., Travassos, B. & Araújo, D. (2012). Spatial dynamics of team sports exposed by Voronoi diagrams. *Human Movement Science*, 31(6), 1652–1659.
38. Football Philosophy. (brez datuma). *xG | Encyclopedia*. Pridobljeno 4. januarja 2023 iz <https://footballphilosophy.org/encyclopedia/xg/>
39. Fosso Wamba, S., Akter, S., Edwards, A., Chopin, G., Gnanzou, D. (2014). How ‘big data’ can make big impact: Findings from a systematic review and a longitudinal case study. *International Journal of Production Economics*, 165, 234–246.
40. Foster, G., O’Reilly, N. & Naidu, Z. (2021). Playing-Side Analytics in Team Sports: Multiple Directions, Opportunities, and Challenges. *Frontiers in Sports and Active Living*, 3.
41. Freeman, L. (2019). The Impact of Analytics in Professional Baseball: How Long Before Performance Improves. *MWAIS 2019 Proceedings*, 7.
42. Gangwar, H. (2018). Understanding the determinants of big data adoption in India: An analysis of the manufacturing and services sectors. In *Information Resources Management Journal*, 31(4), 1–22.
43. Gantar, B. & Vogrinc, J. (2008). *Kvalitativno raziskovanje na pedagoškem področju*. Ljubljana: Pedagoška fakulteta.
44. Gartner. (brez datuma). *What Is Data and Analytics?* Pridobljeno 11. oktobra 2022 iz <https://www.gartner.com/en/topics/data-and-analytics>
45. Gavião, L. O., Sant’Anna, A. P., Alves Lima, G. B. & de Almada Garcia, P. A. (2020). Evaluation of soccer players under the Moneyball concept. *Journal of Sports Sciences*, 38(11–12), 1221–1247.
46. Gerrard, B. (2016). The Role of Analytics in Assessing Playing Talent. V Baker, J., Copley S., Schorer J. & Wattier N. (ur.), *Routledge Handbook of Talent Identification and Development in Sport* (str. 423–431). London: Routledge.
47. Grublješič, T. & Jaklič, J. (2015a). Business Intelligence Acceptance: The Prominence of Organizational Factors. *Information Systems Management*, 32(4), 299–315.
48. Grublješič, T. & Jaklič, J. (2015b). Conceptualization of the Business Intelligence Extended Use Model. *Journal of Computer Information Systems*, 55(3), 72–82.
49. Grublješič, T., Coelho, P. & Jaklič, J. (2014). The importance and impact of determinants influencing business intelligence systems embeddedness. *Issues in Information Systems*, 15, 106–217.

50. Harper, J. (2021, 5. marec). *Data experts are becoming football's best signings*. Pridobljeno 11. oktobra 2022 iz <https://www.bbc.co.uk/news/business-56164159>
51. Harrison, C.K. & Bukstein, S. (2016). *Sport Business Analytics: Using Data to Increase Revenue and Improve Operational Efficiency* (1. izd.). New York: Auerbach Publications.
52. Hellier, D. (2021). *Big Data Model Helps Local London Team Win Soccer's Richest Game*. Pridobljeno 12. oktobra 2022 iz <https://www.bloomberg.com/news/articles/2021-05-28/big-data-model-takes-local-london-team-to-soccer-s-richest-game#xj4y7vzkg>
53. Hernandez, B., Jimenez, J. & José Martín, M. (2009). Adoption vs acceptance of e-commerce: two different decisions. *European Journal of Marketing*, 43(9/10), 1232–1245.
54. Howell, J. & Shea, C. (2006). Effects of Champion Behavior, Team Potency, and External Communication Activities on Predicting Team Performance. *Group & Organization Management*, 31, 180–211.
55. Kayser, V., Nehrke, B. & Zubovic, D. (2018). Data Science as an Innovation Challenge: From Big Data to Value Proposition. *Technology Innovation Management Review*, 8(3), 16–25.
56. Kenton, W. (brez datuma). *Expected Value Definition, Formula, and Examples*. Pridobljeno 6. decembra 2022 iz <https://www.investopedia.com/terms/e/expected-value.asp>
57. Kiron, D. (2013). Organizational Alignment is Key to Big Data Success. *MIT Sloan Management Review*, 54(3).
58. Klee, S., Janson, A. & Leimeister, J. M. (2021). How Data Analytics Competencies Can Foster Business Value— A Systematic Review and Way Forward. *Information Systems Management*, 38(3), 200–217.
59. Knutson, T. (2016, 25. marec). *Design Diary – MK Shot Maps*. Pridobljeno 22. septembra 2022 iz <https://statsbomb.com/articles/soccer/design-diary-mk-shot-maps/>
60. Knutson, T. (2017, 22. februar). *Changing How the World Thinks About Set Pieces*. Pridobljeno 21. septembra 2022 iz <https://statsbomb.com/articles/soccer/changing-how-the-world-thinks-about-set-pieces/>
61. Kröckel, P. (2019). *Big Data Event Analytics in Football for Tactical Decision Support* (doktorska disertacija). Erlangen-Nürnberg: Friedrich-Alexander-Universität.
62. Kuper, S. & Szymanski, S. (2009). *Soccernomics: why England loses, why Germany and Brazil win, and why the US, Japan, Australia, Turkey--and even Iraq--are destined to become the kings of the world's most popular sport*. New York: Nation Books.
63. Lai, Y., Sun, H. & Ren, J. (2018). Understanding the determinants of big data analytics (BDA) adoption in logistics and supply chain management: An empirical investigation. *The International Journal of Logistics Management*, 29(2), 676-703.
64. LaValle, S., Lesser, E., Shockley, R., Hopkins, M. S. & Kruschwitz, N. (2011). Big Data, Analytics and the Path From Insights to Value. *MIT Sloan Management Review*, 52(2), 21–32.
65. Lawrence, T. (2018, 30. avgust). *Introducing xGChain and xGBuildup*. Pridobljeno 5.

- decembra 2022 iz <https://statsbomb.com/articles/soccer/introducing-xgchain-and-xgbuildup/>
66. Leško, L. (2019). Špijunaža i Business Intelligence u sportu. *Business Excellence*, 13(1), 181–195.
 67. Lewis, M. (2004). *Moneyball: The Art of Winning an Unfair Game*. New York: WW Norton.
 68. Lichtenthaler, U. (2020). Mixing data analytics with intuition: Liverpool Football Club scores with integrated intelligence. *Journal of Business Strategy*, 43(1), 10–16.
 69. Lindbergh, B. & Arthur, B. (2016, 26. april). *Statheads Are The Best Free Agent Bargains In Baseball*. Pridobljeno 22. oktobra 2022 iz <https://fivethirtyeight.com/features/statheads-are-the-best-free-agent-bargains-in-baseball/>
 70. Llana, S., Madrero, P. & Fernández, J. (brez datuma). *The right place at the right time: Advanced off-ball metrics for exploiting an opponent's spatial weaknesses in soccer*. Pridobljeno 29. septembra 2022 iz <https://www.sloansportsconference.com/research-papers/the-right-place-at-the-right-time-advanced-off-ball-metrics-for-exploiting-an-opponents-spatial-weaknesses-in-soccer>
 71. Malladi, S. & Krishnan, M. S. (2013). Determinants of usage variations of business intelligence & analytics in organizations – An empirical analysis. *International Conference on Information Systems (ICIS 2013): Reshaping Society Through Information Systems Design*, 2, 1102–1123.
 72. Manohar, P. (2020). *Impact of Adopting Big Data Analytics on Strategic Decisions: A Delphi Study Using the Technology–Organization–Environment (TOE) Framework* (doktorska disertacija). Ann Arbor: Capella University.
 73. MarketsandMarkets. (2022). *Sports Analytics Market worth \$8.4 billion by 2026*. Pridobljeno 2. maja 2023 iz <https://www.marketsandmarkets.com/PressReleases/sports-analytics.asp>
 74. Maroufkhani, P., Iranmanesh, M. & Ghobakhloo, M. (2023). Determinants of big data analytics adoption in small and medium-sized enterprises (SMEs). *Industrial Management & Data Systems*, 123(1), 278–301.
 75. Maroufkhani, P., Tseng, M. L., Iranmanesh, M., Ismail, W. K. W. & Khalid, H. (2020). Big data analytics adoption: Determinants and performances among small to medium-sized enterprises. *International Journal of Information Management*, 54, 102190.
 76. Maroufkhani, P., Wan Ismail, W. K. & Ghobakhloo, M. (2020). Big data analytics adoption model for small and medium enterprises. *Journal of Science and Technology Policy Management*, 11(2), 171–201.
 77. Mikalef, P., Pappas, I. O., Krogstie, J. & Giannakos, M. (2018). Big data analytics capabilities: a systematic literature review and research agenda. *Information Systems and E-Business Management*, 16(3), 547–578.
 78. Mnene, J. & Van Belle, J.-P. (2016). Big Data capabilities and readiness of South African retail organisations. *2016 6th International Conference - Cloud System and Big Data Engineering (Confluence)*, 279–286.

79. Moghavvemi, S., Hakimian, F., Faziharudean, T. & Feissal, T. (2012). Competitive advantages through IT innovation adoption by SMEs. *Social Technologies*, 2(1), 24-39.
80. Mohammadi, S. & Isanejad, O. (2018). Presentation of the Extended Technology Acceptance Model in Sports Organizations. *Annals of Applied Sport Science*, 6, 75-86.
81. Muller, J. (2022, 7. junij). *How each Premier League team pass*. Pridobljeno 30. januarja 2023 iz <https://theathletic.com/3346644/2022/06/07/premier-league-pass-networks/>
82. Murphy, E. (2005). Issues in the adoption of broadband-enabled learning. *British Journal of Educational Technology*, 36(3), 525-536.
83. Nakagawara, R. (2020, 14. maj). *Intro to {polite} Web Scraping of Soccer Data with R!* Pridobljeno 13. marca 2023 iz <https://ryo-n7.github.io/2020-05-14-webscrape-soccer-data-with-R/>
84. Nogometna zveza Slovenije. (brez datuma). *Statistika - Prva liga Telemach 21/22*. Pridobljeno 31. februarja 2023 iz <https://www.prvaliga.si/tekmovanja/?action=statistika>
85. Oliveira, T. & Martins, M. F. (2010). Information technology adoption models at Firm Level: Review of literature. *4th European Conference on Information Management and Evaluation, ECIME 2010*, 14, 312-322.
86. Opta Analyst. (2017, 25. julij). *Opta Expected Goals* [Youtube]. Pridobljeno 22. septembra 2022 iz <https://www.youtube.com/watch?v=w7zPZsLGK18>
87. Pagano, A. M. & Liotine, M. (2020). *Technology in Supply Chain Management and Logistics*. Amsterdam: Elsevier.
88. Pavitt, J., Braines, D. & Tomsett, R. (2021). Cognitive Analysis in Sports: Supporting Match Analysis and Scouting through Artificial Intelligence. *Applied AI Letters*, 2(1).
89. Pedro, J., Brown, I. & Hart, M. (2019). Capabilities and Readiness for Big Data Analytics. *Procedia Computer Science*, 164, 3-10.
90. Peralta Alguacil, F. J. (2019). *Modelling the Collective Movement of Football Players* (magistrsko delo). Uppsala: Uppsala Universitet.
91. Picoto, W. N., Bélanger, F. & Palma-dos-Reis, A. (2014). An organizational perspective on m-business: usage factors and value determination. *European Journal of Information Systems*, 23(5), 571-592.
92. Pimpaud, B. (2019, 16. avgust). *PassSonar: Visualizing Player Interactions in Soccer Analytics* [objava na blogu]. Pridobljeno 12. oktobra 2022 iz <https://medium.com/nightingale/passsonar-visualizing-player-interactions-in-soccer-analytics-7708e1d94afc>
93. Pinto, J. & Slevin, D. P. (1989). The project champion: key to implementation success. *Project Management Journal*, 20(4), 15-20.
94. Pinto, J. K. & Patanakul, P. (2015). When narcissism drives project champions: A review and research agenda. *International Journal of Project Management*, 33(5), 1180-1190.
95. Plattfaut, R. & Koch, J. (2021). Preserving the legacy – Why do professional soccer clubs (not) adopt innovative process technologies? A grounded theory study. *Journal of Business Research*, 136, 237-250.
96. Pollard, R. (2002). Charles Reep (1904-2002): pioneer of notational and performance analysis in football. *Journal of Sports Sciences*, 20(10), 853-855.

97. Popovič, A., Hackney, R., Coelho, P. S. & Jaklič, J. (2012). Towards business intelligence systems success: Effects of maturity and culture on analytical decision making. *Decision Support Systems*, 54(1), 729–739.
98. Puklavec, B. (2016). *Adoption of business intelligence systems: empirical insights from small and medium enterprises: doctoral dissertation* (doktorska disertacija). Ljubljana: Univerza v Ljubljani.
99. Puklavec, B., Oliveira, T. & Popovič, A. (2017). Understanding the determinants of business intelligence system adoption stages: An empirical study of SMEs. *Industrial Management & Data Systems*, 118(1), 236–261.
100. Ragsdale, M. & Schutte, A. (2022). *Championing Digital Transformation with Dash* [Webinar]. Pridobljeno 5. septembra 2022 iz <https://go.plotly.com/digital-transformation>
101. Ramakrishnan, R., Philpott, E., Duan, Y. & Cao, G. (2017). Adoption of business analytics and impact on performance: a qualitative study in retail. *Production Planning & Control*, 28, 985–998.
102. Rathke, A. (2017). An examination of expected goals and shot efficiency in soccer. *Journal of Human Sport and Exercise*, 12(Proc2), 514–529.
103. Ravindranathan, S., Ardakani, H. D., Pimental, A., Lee, J., Care, N. & Clark, J. F. (2017). Performance monitoring of soccer players using physiological signals and predictive analytics. *NSF I/UCRC for Intelligent Maintenance Systems (IMS)*, 1–11.
104. Rein, R. & Memmert, D. (2016). Big data and tactical analysis in elite soccer: future challenges and opportunities for sports science. *SpringerPlus*, 5(1), 1410.
105. Rogers, E. M. (1995). *Diffusion of Innovations* (4. izd). New York: The Free Press.
106. Rogers, E. M. (2003). *Diffusion of Innovations* (5. izd). New York: The Free Press.
107. Roth, W. S. & Matherne, B. P. (2021). Using Moneyball to Introduce Students to Data Analytics: Illustrating the Data Analytics Life Cycle. *INFORMS Transactions on Education*.
108. Roy, M. Van, Robberechts, P. & Davis, J. (2021). *Optimally Disrupting Opponent Build-ups*. Pridobljeno 20. februarja 2023 iz <http://statsbomb.com/wp-content/uploads/2021/11/DTAI-Research-Paper.pdf>
109. Rudd, S. (2011). *A Framework for Tactical Analysis and Individual Offensive Production Assessment in Soccer Using Markov Chains*. Pridobljeno 7. oktobra 2022 iz <http://nessis.org/nessis11/rudd.pdf>
110. Saade, R. & Kira, D. (2009). Computer Anxiety in E-Learning: The Effect of Computer Self-Efficacy. *Journal of Information Technology Education: Research*, 8(1), 177-191
111. Saha, K. (2019). Analytics and Big Data: Emerging trends and their impact on our lives. *Journal of Public Affairs*, 19(4), 1944.
112. Sharma, H. (2021, 4. avgust). *Swimming-Aussies' dive into »data lake« brings success in Tokyo pool*. Pridobljeno 13. maja 2022 iz <https://www.reuters.com/lifestyle/sports/swimming-aussies-dive-into-data-lake-brings-success-tokyo-pool-2021-08-04/>

113. Shet, S. V., Poddar, T., Wamba Samuel, F. & Dwivedi, Y. K. (2021). Examining the determinants of successful adoption of data analytics in human resource management – A framework for implications. *Journal of Business Research*, 131, 311–326.
114. Shields, B. (2018). Integrating Analytics in Your Organization: Lessons From the Sports Industry. *MIT Sloan Management Review*, 59(2), 108–115.
115. Singh, K. (brez datuma). *Introducing Expected Threat (xT)*. Pridobljeno 11. septembra 2022 iz <https://karun.in/blog/expected-threat.html>.
116. Sormaz, M. (2023, 7. april). *Building a data analytics department*. Pridobljeno 30. aprila 2023 iz <https://trainingground.guru/articles/mladen-sormaz-building-a-data-analytics-department>
117. Sports Reference LLC. (brez datuma). *2022-2023 Premier League Stats (fbref)*. Pridobljeno 12. maja 2023 iz <https://fbref.com/en/comps/9/stats/Premier-League-Stats>
118. Straub, E. T. (2009). Understanding Technology Adoption: Theory and Future Directions for Informal Learning. *Review of Educational Research*, 79(2), 625–649.
119. Sumpter, D. & Andrzejewski, A. (brez datuma). *Soccermatics Course*. Pridobljeno 15. septembra 2022 iz <https://soccermatics.readthedocs.io/en/latest/index.html>
120. Sumpter, D. (2016). *Soccermatics : mathematical adventures in the beautiful game*. London: Bloomsbury Publishing Plc.
121. Sumpter, D. (2019). *What do you need to learn to work in football analytics?* Pridobljeno 11. oktobra 2022 iz <https://barcainnovationhub.com/what-do-you-need-to-learn-to-work-in-football-analytics/>
122. Szymanski, S. (2020). Sport Analytics: Science or Alchemy? *Kinesiology Review*, 9(1), 57–63.
123. Taxman, F., Henderson, C., Young, D. & Farrell, J. (2012). The Impact of Training Interventions on Organizational Readiness to Support Innovations in Juvenile Justice Offices. *Administration and Policy in Mental Health*, 41(2), 177–188.
124. Tornatzky, L. G., Fleischer, M. & Chakrabarti, A. K. (1990). *The processes of technological innovation*. Lexington: Lexington Books.
125. Transfermarkt. (2020, 5. april). *Pass completion rates: PSG dominate top 20 - Otamendi best in Premier League with 92.4%*. Pridobljeno 15. oktobra 2022 iz <https://www.transfermarkt.com/pass-completion-rates-psg-dominate-top-20-otamendi-best-in-premier-league-with-92-4-/view/news/358096>
126. Understat. (brez datuma). *Son Heung-min*. Pridobljeno 11. oktobra 2022 iz <https://understat.com/player/453>
127. University of Akron. (brez datuma). *The Bachelor of Science in Sport Analytics*. Pridobljeno 10. septembra 2022 iz <https://www.uakron.edu/cba/undergraduate/majors/sport-analytics-major>
128. University of Bath. (2022). *Descriptive, predictive and prescriptive: three types of business analytics*. Pridobljeno 30. aprila 2022 iz <https://online.bath.ac.uk/content/descriptive-predictive-and-prescriptive-three-types-business-analytics>
129. Uppsala Universitet. (brez datuma). *Mathematical Modelling of Football*.

- Pridobljeno 10. marca 2022 iz <https://uppsala.instructure.com/courses/28112>
130. Van Haaren, J., Robberechts, P., Decroos, T., Bransen, L., Davis, J., Ric, A. & Peláez, R. (2019). Analysing Performance and Playing Style using Ball Event Data. V Ric, A. & Peláez, R. (ur.), *Football Analytics: Now and Beyond. A deep dive into the current state of advanced data analytics* (str. 36–47). Barça Innovation Hub.
 131. Venkatesh, V. & Bala, H. (2008). Technology Acceptance Model 3 and a Research Agenda on Interventions. *Decision Sciences*, 39(2), 273–315.
 132. Venkatesh, V. (2003). User acceptance of information technology: Toward a unified view. *MIS quarterly : management information systems*, 27(3), 425–478.
 133. Venkatesh, V., Thong, J. Y. L. & Xu, X. (2012). Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology. *MIS Quarterly*, 36(1), 157–178.
 134. Verma, S. & Bhattacharyya, S. S. (2017). Perceived strategic value-based adoption of Big Data Analytics in emerging economy. *Journal of Enterprise Information Management*, 30(3), 354–382.
 135. Wamba, S. F., Gunasekaran, A., Akter, S., Ren, S. J., Dubey, R. & Childe, S. J. (2017). Big data analytics and firm performance: Effects of dynamic capabilities. *Journal of Business Research*, 7(1), 356–365.
 136. Wang, Y., Meister, D. & Wang, Y. (2011). Reexamining Relative Advantage and Perceived Usefulness: An Empirical Study. *IJICTE*, 7, 46–59.
 137. Watanabe, N. M., Shapiro, S. & Drayer, J. (2021). Big Data and Analytics in Sport Management. *Journal of Sport Management*, 35(3), 197–202.
 138. Welsh, J. A., White, J. F. & Dowell, P. (1982). A Small Business is not a Little Big Business. *Harvard Business Review*, 59(4), 18–32.
 139. Whitmore, J. (2021a, 24. marec). *What Are Expected Assists (xA)?* Pridobljeno 12. aprila 2023 iz <https://theanalyst.com/eu/2021/03/what-are-expected-assists-xa/>
 140. Whitmore, J. (2021b, 23. junij). *What Are Expected Goals on Target (xGOT)?* Pridobljeno 12. aprila 2023 iz <https://theanalyst.com/eu/2021/06/what-are-expected-goals-on-target-xgot/>
 141. Wigmore, T. (2018, 4. julij). *Brentford's Moneyball Way To Beat Football Teams With Huge Budgets*. Pridobljeno 13. maja 2022 iz <https://bleacherreport.com/articles/2718752-brentfords-moneyball-way-to-beat-football-teams-with-huge-budgets>
 142. Wixom, B. & Todd, P. (2005). A Theoretical Integration of User Satisfaction and Technology Acceptance. *Information Systems Research*, 16(1), 85–102.
 143. Wyscout (brez datuma). *xG | Glossary*. Pridobljeno 16. maja 2023 iz <https://dataglossary.wyscout.com/xg/>
 144. Yang, T., Yuan, G. & Yan, J. (2021). Health Analysis of Footballer Using Big Data and Deep Learning. *Scientific Programming*, 2021.
 145. Zadeh, A., Taylor, D., Bertso, M., Tillman, T., Nosoudi, N. & Bruce, S. (2021). Predicting Sports Injuries with Wearable Technology and Data Analysis. *Information Systems Frontiers*, 23(4), 1023–1037.