Brierov skor kao mjera kvalitete sportskog prognoziranja

Dušan Munđar[1]

Sažetak. Ljudi često precjenjuju vlastitu sposobnost procjene budućih događaja. Posebno je to izraženo u području sportskog prognoziranja i klađenja, gdje subjektivan osjećaj sigurnosti ne mora odgovarati stvarnoj uspješnosti procjene. U radu uspoređujemo prognoziranje najvjerojatnijeg događaja i prognoziranje pridruživanjem vjerojatnosti mogućim ishodima. Predstavljamo Brierov skor kao mjeru uspješnosti prognoziranja vjerojatnostima. Nadalje, pažnju usmjerujemo na kalibriranost, odnosno usklađenost relativne frekvencije pojavljivanja događaja i njemu pridružene vjerojatnosti. Za primjenu u nastavi predložena je aktivnost za provjeru sposobnosti predviđanja ishoda nogometne utakmice s ciljem mjerenja kalibriranosti i razvoja statističkog načina razmišljanja. Glavna poruka rada je da dobra prognoza nije samo pogođen ishod, nego i dobra procjena koliko je pojedini ishod bio vjerojatan.

1. Uvod

Sport je popularna aktivnost za velik dio populacije, bilo da se radi o aktivnom bavljenju sportom ili praćenju drugih kako se bave njime, posebno profesionalnih sportskih događaja. Sportsko klađenje također je relativno učestala pojava, a osobito među mlađom populacijom (Ricijaš i dr., 2016.). Prema istraživanju provedenom u radu, 12.9 % srednjoškolaca ispunjava kriterije za visoku razinu problema povezanih s kockanjem. Postavljanje realnih očekivanja pritom je od iznimne važnosti, posebno kada se mlade osobe uključuju u klađenje ili druge igre na sreću.

Upoznavanje alata za razumijevanje nesigurnosti pomaže svima, a posebno učenicima, u donošenju racionalnih životnih odluka. Ocjena uspješnosti i kalibriranosti pri prognoziranju, odnosno pri iskazivanju svojih uvjerenja, može pomoći u realnoj procjeni vlastitih sposobnosti i predstavljati zaštitu od pretjerane samouvjerenosti.

Ovim radom želi se predstaviti model provjere sposobnosti prognoziranja rezultata, pri čemu je naglasak stavljen na procjenu uspješnosti sportskog prognozira-

[1]Dušan Munđar, Veleučilište Hrvatsko zagorje Krapina

nja. U radu (Munđar, 2023b) detaljnije su prikazani način funkcioniranja klađenja te osnovni kriterij isplativosti, odnosno neisplativosti klađenja.

Ukratko, ciljevi rada su:

1. prikazati primjere prognoziranja najvjerojatnijeg ishoda i prognoziranja pridruživanjem vjerojatnosti mogućim ishodima,
2. upoznati Brierov skor kao mjeru sposobnosti prognoziranja diskretnog slučajnog ishoda,
3. razumjeti razliku između točnosti prognoziranja i usklađenosti (kalibriranosti) prognoza,
4. osvijestiti primjenu Brierovog skora kao mjere kalibriranosti prognozera,
5. predložiti nastavnu aktivnost za razvoj statističkog pristupa odlučivanju u uvjetima nesigurnosti.

Razumijevanje koncepata vjerojatnosti i statistike bitno je za donošenje odluka u svakodnevnom životu. Bolja procjena vlastitih sposobnosti prognoziranja može nam pomoći da pažnju usmjerimo na područja u kojima smo uspješniji, dok područja slabijeg razumijevanja možemo dodatno razvijati stjecanjem novih znanja ili ih izbjegavati pri donošenju odluka.

2. Natjecanja i prognoziranje ishoda

Bavljenje sportom može pružiti mnoge koristi, od održavanja zdravog načina života do pružanja prilike za druženje. Velikom broju ljudi predstavlja i profesionalni angažman. Razdoblja velikih natjecanja povećavaju interes za praćenje sportskih događaja. Praćenje sporta tada može postati i intelektualni izazov kroz analizu podataka vezanih uz klubove, igrače, natjecanja i druge povezane aspekte. Dodatni izazov predstavlja procjena pobjednika u profesionalnim sportskim nadmetanjima gdje je primarni cilj natjecatelja ostvariti pobjedu.

U radu ćemo uzeti jedan od standardnih načina označavanja ishoda nogometne utakmice, a to je: pobjeda domaće ekipe (oznaka: 1), neodlučeni rezultat (oznaka: 0 ili X) i pobjeda gostujuće ekipe (oznaka: 2).

2.1. Prognoziranje najvjerojatnijeg ishoda

Kada je potrebno prognozirati ishod utakmice, osnovni način prognoziranja jest odabir jednog od mogućih ishoda: pobjeda domaće ekipe, neriješeni rezultat ili pobjeda gostujuće ekipe. Točnost prognoziranja možemo definirati kao omjer broja točnih prognoza i ukupnog broja pokušaja. Primjerice, za posljednje kolo sezone 2025/2026 SuperSport HNL-a osoba koja bi prognozirala na način prikazan u Tablici 1. ostvarila bi uspješnost 3 / 5 = 60 %.

Tablica 1. Prikaz izračuna točnosti prognoziranja ishoda najvjerojatnijim događajem

Datum	Domaćin	Gost	Prognoza	Rezultat	Točno (DA/NE)
23. 5. 2026.	Dinamo	Lokomotiva	1	0 : 0	Ne
23. 5. 2026.	Rijeka	Gorica	1	2 : 0	Da
23. 5. 2026.	Varaždin	Istra 1961	1	2 : 0	Da
22. 5. 2026.	Hajduk	Vukovar 1991	1	6 : 3	Da
22. 5. 2026.	Osijek	Slaven Belupo	2	2 : 0	Ne
				Točnost	3 / 5

Za procjenu sposobnosti ili vještine prognoziranja mogu se koristiti i informacije koje o utakmici daje kladionica te usporediti točnost prognoza osobe s procjenom kladionice. Razumno je pretpostaviti da najmanji koeficijent pripada ishodu koji kladionica ocjenjuje najvjerojatnijim. Takvim pristupom kladionica je kao najvjerojatnije ishode procijenila pobjede domaćih ekipa i bila je u pravu u četiri od pet slučajeva, pa je njezina točnost iznosila 80 %.

Pri prognoziranju određivanjem najvjerojatnijeg ishoda primjećujemo da istu prognozu pridružujemo situacijama kada je vjerojatnost događaja 0.51, kao i situacijama u kojima je vjerojatnost 0.95, iako one ne predstavljaju jednaku razinu uvjerenja. Prognoziranje pridruživanjem vjerojatnosti, koje bi iskazivale razinu našeg uvjerenja, omogućuje preciznije izražavanje prognoze. Temom prognoziranja pridruživanjem vjerojatnosti mogućim ishodima bavimo se u sljedećem poglavlju.

2.2. Prognoziranje pridruživanjem vjerojatnosti ishodima

Naše prognoze najvjerojatnijeg ishoda temelje se na uvjerenju u ostvarenje razmatranog događaja. Ako prognoze želimo temeljiti na razini uvjerenja koju pridružujemo pojedinim mogućim ishodima, tada svakom ishodu možemo pridružiti broj koji predstavlja procjenu njegove vjerojatnosti.

Za utakmicu Dinamo : Lokomotiva odigranu 23. svibnja 2026. mogli bismo primjerice pridružiti sljedeće vjerojatnosti: za pobjedu domaće ekipe 0.80, neriješeni ishod 0.15 i za pobjedu gostujuće ekipe 0.05.

Ako se koristi prognoziranje pridruživanjem vjerojatnosti mogućim ishodima, tada točnost prognoziranja treba definirati na drugačiji način. Mjerenje uspješnosti prognoza temeljenih na pridruženim vjerojatnostima ocjenjivat ćemo Brierovim skorom koji će biti definiran u sljedećem poglavlju.

Problem točnosti prognoziranja tada poprima dodatnu dimenziju. To se jasno vidi na jednostavnom primjeru prognoziranja ishoda pri bacanju novčića. Očekivana točnost pogađanja jednaka je i za osobu koja prognozira da će u n bacanja sva-

ki put pasti pismo, kao i za osobu koja u svojim prognozama pretpostavlja da se u 50 % slučaja pojavljuje pismo, a u preostalih 50 % glava (grb). Time se pojavljuje dublje razumijevanje nesigurnosti i uočava se razlika između pogađanja i kalibriranog razmišljanja.

Pri takvom prognoziranju važno je primijetiti da osoba koja često koristi vrlo visoke vjerojatnosti, a pritom griješi, pokazuje lošu kalibriranost svojih procjena. Dobro kalibriran prognozer trebao bi događaje kojima pridružuje vjerojatnost 0,80 pogađati približno u 80 % slučajeva.

2.3. Vjerojatnosti dobivene iz koeficijenata kladionica

Kladionice navode moguće ishode sportskih i drugih događaja te im u svojim ponudama pridružuju koeficijente isplate. Koeficijent isplate ili tečaj je iznos koji se isplaćuje u slučaju ostvarenja događaja na koji je uplaćen jedinični iznos. Više o načinu izračuna isplata i mogućoj zaradi može se pronaći u radu (Munđar, 2023b). U istom radu predstavljene su takozvane neutralne vjerojatnosti ishoda.

Ukratko, za svaki od mogućih ishoda (1 – pobjeda domaće ekipe, X ili 0 – neriješeni rezultat i 2 – pobjeda gostujuće ekipe) pridruženi koeficijent ili kvota (k) pretvara se u procjenu vjerojatnosti $p = 1 / k$, čime se dobivaju neutralne vjerojatnosti.

Primjerice, koeficijenti isplate prije utakmice Dinamo : Lokomotiva koja se odigrala 23. svibnja 2026. godine u Zagrebu bili su (1.25, 5.50, 8.00). Pripadajuće neutralne vjerojatnosti događaja (1, X, 2) iskazanim koeficijentima isplate su $(n_1, n_x, n_2) =$ $= (0.800, 0.182, 0.125)$.

Budući da zbroj vjerojatnosti svih mogućih ishoda treba biti jednak jedan, neutralne vjerojatnosti potrebno je normalizirati dijeljenjem sa $s = n_1 + n_x + n_2$. Tako dobivamo implicitne vjerojatnosti ishoda $p' = n / s$.

Za promatranu utakmicu suma neutralnih vjerojatnosti je $s = 1.107$, a implicitne vjerojatnosti ishoda iznose $(p_1, p_x, p_2) = (0.723, 0.164, 0.113)$.

2.4. Procjena vjerojatnosti ishoda utakmice modelom

U radu (Munđar, 2023a) prikazane su dvije kvantitativne metode za procjenu vjerojatnosti ishoda nogometne utakmice. Prognoze se izrađuju primjenom Poissonovog i binomnog modela. Takvi modeli pri izradi prognoze ne uzimaju u obzir specifične situacije poput ozljeda ključnih igrača, važnosti utakmica, vremenskih uvjeta i sličnih čimbenika.

Poissonov model temelji se na procjeni prosječnog broja golova koje ekipa postiže tijekom jedne utakmice. Za svaku ekipu modelira se slučajan broj postignutih pogodaka, a zatim se provjerava odgovara li ostvareni par pogodaka pobjedi domaće ekipe, pobjedi gostujuće ekipe ili neriješenom ishodu. Zbrajanjem vjerojatnosti elementarnih događaja dobiva se procjena vjerojatnosti pojedinog ishoda utakmice.

Binomni model prognozira ukupan broj golova na utakmici, a zatim na temelju odnosa snage ekipa pojedine golove pripisuje jednoj od ekipa u nadmetanju. Za procjenu snage ekipe mogu se, primjerice, koristiti Pitagorini faktori, kako je prikazano u radu o procjeni očekivane uspješnosti ekipa (Munđar, 2026.).

3. Ocjena uspješnosti prognoziranja

3.1. Brierov skor

Kako bismo procijenili uspješnost prognoziranja ishoda pridruživanjem vjerojatnosti, predstavljamo mjeru Brierov skor. Brierov skor dobio je naziv prema autoru Glennu W. Brieru koji je rad (Brier, 1950.) o mogućnosti primijene skora objavio 1950. godine. Skor se izvorno koristio za procjenu točnosti vremenskih prognoza, odnosno u području meteorologije.

Najčešći oblik izračuna Brierovog skora za jedan slučajni događaj jest

$$BS = \frac{1}{N}\sum\left(f_t - o_t\right)^2 .$$

Pri tome je:

N - broj mogućih ishoda

f_t - prognozirana vjerojatnost ishoda

o_t - ostvareni ishod.

Ostvareni ishod (o_t) indikator je ostvarenja događaja (tzv. *dummy varijabla*) koja poprima vrijednost 1 ako se događaj ostvario, a 0 ako se nije ostvario. Poželjno je ostvariti što manji Brierov skor jer formula mjeri odstupanje prognoziranih vjerojatnosti od ostvarenih ishoda.

Brierov skor moguće je izračunati i za prognoziranje najvjerojatnijeg ishoda. U tom slučaju skor za jedan događaj iznosi 0 ako je ishod pogođen, odnosno (1 / N) ako je ishod promašen (npr. 1 / 3 u slučaju nogometne utakmice). U primjeru prognozi-

Tablica 2. Prikaz izračuna Brierova skora za prognoziranje ishoda događaja pridruživanjem vjerojatnosti

				Prognoza osobe			Kladionica			Brierov skor	
Datum	**Domaći**	**Gost**	**Rezultat**	**1**	**X**	**2**	**1**	**X**	**2**	**Osoba**	**Kladionica**
23. 5. 2026.	Dinamo	Lokomotiva	X	0.80	0.15	0.05	0.73	0.16	0.11	0.94	0.90
23. 5. 2026.	Rijeka	Gorica	1	0.80	0.10	0.10	0.60	0.24	0.16	0.03	0.14
23. 5. 2026.	Varaždin	Istra 1961	1	0.70	0.20	0.10	0.52	0.30	0.18	0.08	0.20
22. 5. 2026.	Hajduk	Vukovar 1991	1	0.80	0.15	0.05	0.71	0.19	0.10	0.04	0.07
22. 5. 2026.	Osijek	Slaven Belupo	1	0.30	0.30	0.40	0.41	0.29	0.30	0.41	0.29
									Prosjek	0.30	0.32

ranja više događaja prikazanom u Tablici 1. prosječni Brierov skor iznosi (1 / 3 + 0 + + 0 + 0 + 1 / 3) / 5 = 2 / 15.

Primjer izračuna Brierova skora u slučaju prognoziranja pridruživanjem vjerojatnosti mogućim ishodima prikazan je u Tablici 2. Primjer prikazuje dva slučaja: prognoziranje neke osobe i prognoziranje na temelju vjerojatnosti dobivenih iz koeficijenata kladionica.

Brierov skor za utakmicu Dinamo : Lokomotiva, izračun na temelju implicitnih vjerojatnosti dobivenih iz koeficijenata kladionica, iznosi

$$BS = \frac{1}{3}\left((0.73-0)^2 + (0.16-1)^2 + (0.11-0)^2\right) = 0.90\,.$$

Primjerice, za prognozu osobe u utakmici Varaždin : Istra 1961 dobivamo

$$BS = \frac{1}{3}\left((0.70-1)^2 + (0.20-0)^2 + (0.10-0)^2\right) = 0.08\,.$$

Prosječni Brierov skor osobe u promatranom primjeru iznosi 0,30, dok prosječni Brierov skor prognoza temeljenih na implicitnim vjerojatnostima kladionica iznosi 0,32. Na temelju dobivenih vrijednosti možemo i dati kratki vodič za interpretaciju Brierova skora, prikazan u Tablici 3.

Tablica 3. Prikaz interpretacije Brierovog skora

Brierov skor	Interpretacija
Nula	Savršena prognoza
Blizu nule	Vrlo dobra prognoza
Srednje vrijednosti	Umjerena kvaliteta prognoze
Velike vrijednosti	Loša kvaliteta prognoze

3.2. Kalibriranost prognoziranja

Provjeravanje usklađenosti pridruženih vjerojatnosti ishoda s relativnim frekvencijama pojavljivanja događaja daje nam dodatni pogled na nesigurnost. Kako bismo pojasnili koncept kalibriranosti, razmotrit ćemo ilustrativni primjer.

Primjer. Pretpostavimo da je osoba prognozirala pobjede domaće ekipe na većem broju utakmica koristeći prognozirane vjerojatnosti ishoda. U Tablici 4. prikazane su korištene vrijednosti prognoziranih vjerojatnosti te učestalost njihove primjene. Za svaki događaj evidentirano je je li se razmatrani ishod ostvario. Stupac *Ostvareno* prikazuje broj ostvarenja događaja, dok stupac *Realizirana učestalost* prikazuje omjer broja ostvarenih događaja i broja primjena pojedine prognozirane vjerojatnosti.

Tablica 4. Prikaz učestalosti korištenja i realizacije razina vjerojatnosti pri prognoziranju ishoda

Prognozirana vjerojatnost	Broj primjene	Ostvareno	Realizirana učestalost
0.1	16	2	0.125
0.2	8	3	0.375
0.3	8	4	0.500
0.4	4	2	0.500
0.5	14	10	0.714
0.6	12	9	0.750
0.7	12	9	0.750
0.8	8	6	0.750
0.9	9	8	0.889

Slika 1. prikazuje kalibracijski dijagram. Kalibracijski dijagram omogućuje vizualnu procjenu usklađenosti realizacije događaja s prognoziranim vjerojatnostima ishoda. Primjerice, točka (0.4, 0.5) na slici pokazuje da je osoba blago podcijenila sigurnost ostvarenja događaja iz te kategorije. Događaji kojima je pridružena vjerojatnost 0.4 ostvarili su se u 50 % slučajeva, odnosno u dva od četiri promatrana slučaja. Idealna situacija bila bi kada bi se točke realiziranih učestalosti nalazile na crvenoj liniji, odnosno na pravcu ($y = x$).

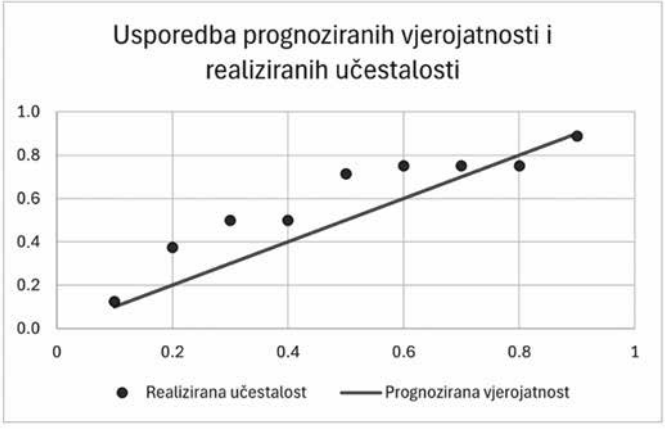

Slika 1. Dijagram kalibriranosti prognozera

Kalibriranost nam omogućuje razlikovanje prognozera koji samo povremeno pogađaju od prognozera koji dobro razumiju razinu nesigurnosti događaja. Kod dobro kalibriranih prognozera prognozirane vjerojatnosti i realizirane učestalosti međusobno su dobro usklađene, dok kod slabije kalibriranih prognozera dolazi do većih odstupanja. Sustavno pridruživanje previsokih vjerojatnosti događajima koji se

ostvaruju rjeđe od očekivanog može se interpretirati kao oblik pretjerane samouvjerenosti prognozera.

Primjerice, zamislimo dvije osobe koje prognoziraju isti događaj, pri čemu jedna ostvarenju ishoda pridružuje vjerojatnost 0.99, a druga 0.6. Obje procjenjuju da je vjerojatnije da će se događaj ostvariti nego da se neće ostvariti. Međutim, ako se događaj ne ostvari, znatno veću pogrešku napravila je osoba koja je bila gotovo potpuno uvjerena u ostvarenje toga ishoda.

Razmotrimo sada drugačiju situaciju. Pretpostavimo da dvije osobe prognoziraju ishode većeg broja događaja. Prva osoba pridružuje događajima prosječnu vjerojatnost 0.95, a druga prosječnu vjerojatnost 0.65. Ako obje osobe ostvare prosječnu točnost prognoziranja 0.6, njihova se uspješnost ne bi trebala smatrati jednakom. S obzirom na visoku razinu uvjerenosti prve osobe, od nje se očekivao znatno veći broj točnih prognoza. Prva osoba zapravo predstavlja pretjerano samouvjerenog prognozera, dok je druga osoba primjer dobro kalibriranog prognozera.

Brierov skor jedan je način mjerenja kalibriranosti prognoziranih vjerojatnosti i realiziranih učestalosti događaja. Skor ne mjeri samo broj pogodaka, nego i koliko su prognozirane vjerojatnosti bile dobro usklađene s ostvarenim ishodima. U izračunu poprima velike vrijednosti kada se često pojavljuju događaji kojima je pridružena mala vjerojatnost ili kada se rijetko ostvaruju događaji kojima je pridružena velika vjerojatnost. Na taj način Brierov skor kažnjava pretjeranu sigurnost prognozera. Kvadriranjem odstupanja između prognozirane vjerojatnosti i ostvarenog ishoda posebno se kažnjavaju vrlo samouvjerene, ali pogrešne prognoze.

Zaključujemo da je pri prognoziranju važno razlikovati točnost, kalibriranost i Brierov skor. Točnost govori o učestalosti točnih prognoza, kalibriranost pokazuje koliko su prognozirane vjerojatnosti usklađene s realizacijom događaja, dok Brierov skor jednom vrijednošću objedinjuje pogrešku prognoze i razinu sigurnosti prognozera.

3.3. Brierov skor vještine prognoziranja

Dobro je imati standardnu i lako dostupnu mjeru uspješnosti prognoziranja na temelju koje se može procijeniti kvaliteta prognoza pojedine osobe. Takvu referentnu razinu možemo dobiti iz koeficijenata kladionica. Brierov skor temeljen na implicitnim vjerojatnostima dobivenima iz koeficijenata možemo promatrati kao referentnu razinu uspješnosti ako se želimo natjecati u kvaliteti prognoziranja.

Brierov skor vještine *BSS* (eng, *Brier's Skill Score*) definiramo formulom

$$BSS = 1 - BS / BSf ,$$

pri čemu je (*BS*) Brierov skor osobe kojoj procjenjujemo uspješnost prognoziranja te (*BSf)* Brierov skor dobiven na temelju implicitnih vjerojatnosti iz koeficijenata kladionice.

U promatranom primjeru Brierov skor vještine prognoziranja osobe iznosi

$$BSS = 1 - 1.50 / 1.59 = 0.056.$$

Maksimalna vrijednost skora vještine jednaka je 1 i ostvaruje se u slučaju kada osoba sve događaje uspješno prognozira. Negativne vrijednosti pojavljuju se kada osoba ostvaruje slabiju uspješnost prognoziranja od referentne razine dobivene iz koeficijenata kladionice. U takvom slučaju teško je očekivati dugoročno uspješno klađenje s ciljem ostvarivanja pozitivnih financijskih rezultata.

4. Predložena nastavna igra

Prije odigravanja većeg broja utakmica, recimo prije utakmica koje se igraju tijekom vikenda ili prije velikog natjecanja poput svjetskog prvenstva, moguće je organizirati natjecanje u prognoziranju ishoda utakmica. Nakon odigravanja utakmica prognozirane ishode moguće je ocijeniti Brierovom skorom vještine prognoziranja te provjeriti kalibriranost prognoza. Važno je naglasiti da je primarni cilj nastavne aktivnosti razumijevanje kalibriranosti i njezina mjerenja Brierovim skorom, dok provjera točnosti prognoziranja predstavlja sporedni cilj.

Zadatak. Aktivnost se provodi u sljedećim koracima:

1) Za svaki ishod razmatrane utakmice upisuju se brojevi od 1 do 99. Brojevi predstavljaju procijenjene vjerojatnosti pobjede domaće ekipe, neriješenog rezultata i pobjede gostujuće ekipe. Primjerice, broj 32 predstavlja procijenjenu vjerojatnost ishoda od 0.32.

Napomene:

- Treći broj određuju prva dva jer njihov zbroj mora iznositi 100, odnosno zbroj vjerojatnosti svih mogućih ishoda mora biti jedan.
- Najveći broj koji se može koristiti je 98 jer svaki događaj mora imati pridruženu barem minimalnu vjerojatnost.
- Brojevi 0 i 100 ne koriste se jer predstavljaju nemoguć i siguran događaj. Definicija i nastanak takvih događaja mogu biti dobra prilika za raspravu.

2) Izradi se Tablica 5. za evidenciju prognoza i provjeru kalibriranosti sudionika nastavne aktivnosti. Tablica je slična Tablici 4. iz poglavlja o kalibriranosti, ali se razlikuje po tome što se prognozirane vrijednosti grupiraju u intervale radi dobivanja dovoljnog broja prognoza u svakoj skupini.

3) Crta se grafički prikaz pri čemu x-os predstavlja prosječnu prognoziranu vjerojatnost, a y-os realiziranu učestalost događaja. Dijagonala ($y = x$) predstavlja idealno kalibriranog prognozera.

Tablica 5. Evidencija prognoza i provjera kalibriranosti sudionika nastavne aktivnosti

Interval pripadnosti prognoziranog broja	Prosječna prognozirana vjerojatnost	Broj primjena	Ostvareno	Realizirana učestalost
[1, 9]	0.05			
[10, 19]	0.15			
…	…			
[90, 99]	0.95			

Nakon provedene analize moguće je raspraviti u kojim su slučajevima učenici bili previše samouvjereni, odnosno pridruživali veće vjerojatnosti od realiziranih učestalosti, a u kojim slučajevima previše nesigurni, odnosno pridruživali manje vrijednosti od realiziranih učestalosti. Također se može analizirati u kojim su slučajevima prognoze bile dobro kalibrirane.

Za svaku skupinu preporučljivo je imati barem deset vrijednosti, dakle ukupno približno sto prognoza. Budući da se svakoj utakmici pridružuju tri broja, za provedbu aktivnosti poželjno je odabrati barem trideset utakmica.

Ukoliko ostane dovoljno vremena i interes učenika bude prikladan, nastavnu aktivnost moguće je proširiti usporedbom individualnih rezultata s grupnim prosjekom ili implicitnim vjerojatnostima kladionice. Time se otvara prostor za raspravu, kritičko razmišljanje i usporedbu različitih pristupa prognoziranju.

5. Zaključak

Praćenje sporta i klađenje na sportske događaje privlačne su aktivnosti za velik dio mlađe populacije. Istovremeno, klađenje predstavlja prilično opasnu aktivnost, kako s financijskog tako i s psihosocijalnog aspekta. U ovom radu bavili smo se procjenom uspješnosti prognoziranja, kako prognoziranja najvjerojatnijeg ishoda, tako i prognoziranja pridruživanjem vjerojatnosti mogućim ishodima.

Budući da je predviđanje ishoda događaja svakodnevna pojava u životu čovjeka, ova tema može, kao proširenu dio gradiva iz cjeline Podatci, statistika i vjerojatnost, poslužiti učenicima srednjih škola da bolje razumiju i prilagođavaju se svijetu koji ih okružuje. Tema procjene uspješnosti prognoziranja i kalibriranosti prognoza u radu je prikazana korištenjem Brierova skora. Takav pristup mogao bi pomoći učenicima da realnije procijene vlastite sposobnosti predviđanja ishoda, čime bi igre na sreću većini učenika mogle postati manje privlačne. S druge strane, u slučaju prepoznavanja vlastitih sposobnosti, njih je moguće dodatno razvijati i usmjeravati.

Radom se naglašava razlika između prognoziranja i znanja, važnost kalibriranosti, opasnost pretjeranog samopouzdanja i korisnost statističkog razmišljanja. Važno

je istaknuti da pogođen ishod nije isto što i dobra prognoza te da je velika samouvjerenost često povezana sa slabom kalibriranošću prognoza u odnosu na realizirane učestalosti događaja.

Rad možemo zaključiti ključnom porukom: dobra prognoza nije samo pogođen ishod, nego uključuje i procjenu koliko je pojedini ishod vjerojatan.

Literatura:

1. Brier, G. W. (1950.) *Verification of Forecasts Expressed in Terms of Probability*. Monthly Weather Review. 78 (1) 1-3. https://doi.org/10.1175/1520-0493(1950)078<0001:VOFEIT>2.0.CO;2
2. Munđar, D. (2023a). *Prognoza ishoda nogometne utakmice.* Poučak 24 (94), 69-76. https://hrcak.srce.hr/clanak/446825
3. Munđar, D. (2023b). *Sportsko klađenje i Kellyjev kriterij za ulaganje.* Poučak 24 (95). 60-67. https://hrcak.srce.hr/clanak/456250
4. Munđar, D. (2026.). *Pitagorina očekivana uspješnost za ekipe SuperSport HNL lige*. Susreti 2026. Veleučilište Hrvatsko zagorje Krapina, 102-106.
5. Ricijaš, N., i dr. (2016.). *Kockanje mladih u Hrvatskoj - učestalost igranja i zastupljenost problematičnog kockanja.* Kriminologija & socijalna integracija, 24 (2), 24-47. https://doi.org/10.31299/ksi.24.2.2