Ovaj rad je licenciran pod Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International.

Zaprimljen: 19.5.2026.
Odobren za objavu: 26.10.2026.
https://doi.org/10.17559/JF-2026040000038

Izvorni znanstveni rad

ANALIZA KRETANJA PREMIJE OSIGURANJA POMOĆU MJERA NEJEDNAKOSTI U BOSNI I HERCEGOVINI

Anela Čolak[1], Nikola Papac[2], Marina Jerinić[3]
[1] Ekonomski fakultet Sveučilišta u Mostaru, Matice Hrvatske b.b., 88000 Mostar, Bosna i Hercegovina, ePošta: anela.colak@ef.sum.ba
[2] Ekonomski fakultet Sveučilišta u Mostaru, Matice Hrvatske b.b., 88000 Mostar, Bosna i Hercegovina, ePošta: nikola.papac@ef.sum.ba
[3] Ekonomski fakultet Sveučilišta u Mostaru, Matice Hrvatske b.b., 88000 Mostar, Bosna i Hercegovina, ePošta: marina.jerinic@ef.sum.ba

Sažetak: Cilj rada je prikazati promjene u raspodjeli premije osiguranja u Bosni i Hercegovini (BiH) za razdoblje od 2010. do 2024. godine. Rezultati istraživanja odnose se na određivanje oblika i jakosti konkurencije u životnim i neživotnim osiguranjima. Šest mjera koncentracije i Lorenzova krivulja opisuju različite razine konkurencije za tržište neživotnog i životnog osiguranja u BiH. Rezultati upućuju na visoku razinu konkurencije za neživotno osiguranje i slabu do umjerenu konkurenciju životnog osiguranja.
Kvadratni trend modeli za indekse koncentracije bruto premije neživotnih osiguranja statistički su značajni kod gotovo svih istaknutih mjera nejednakosti. Koncentracijski omjer C5, Herfindhal-Hirschman indeksa (HHI), Gini koeficijent (G),Rozenbluth (RI) opisani su kvadratnim trend modelom sa vodećim pozitivnim koeficijentom, a entropija prati trend model polinoma drugog stupnja sa negativnim vodećim koeficijentom. Navedeno sugerira da se u budućem razdoblju pet do deset godina očekuje blagi rast indeksa koncentracije osim entropije koja će blago padati, odnosno smanjenje broja društava.
Kretanje bruto premije životnih osiguranja oblikovano je mjerama koncentracije čiji trend modeli ne prikazuju istu monotonost. U razdoblju nakon 2025. modeli prognoziraju pad entropije, RI, G i HHI dok modeli za koncentracijski omjer C5 i HTI prognoziraju blagi rast ovih indeksa. Navedeno se uz istodobni rast ukupne premije može interpretirati kao početak procesa koncentracije tržišta osiguranja.

Ključne riječi: Bruto premija; entropija; Hall-Tideman; Herfindahl-Hirschman; predviđanje trenda; Rosenbluth

1. Uvod

Tržište osiguranja u Bosni i Hercegovini (BiH) bilježi rast od posljednjeg desetljeća prošlog stoljeća. Organizacija Bosne i Hercegovine kao države dvaju entiteta i Brčko distrikta uvjetovala je entitetski način organizacije i rada društava za osiguranje i drugih institucija vezanih za funkcioniranje tržišta osiguranja. Budući entiteti i Distrikt Brčko imaju vlastite strukture vlasti, pravila i propise to određuje dva odvojena pravna okvira za regulaciju osiguravajućih društava.

Mjerenje koncentracije tržišta je ključno za razumijevanje strukture i dinamike tržišta. Prema OECD-u razina koncentracije je mjera tržišnog udjela manjeg broj tvrtki. Mnogi autori naglašavaju važnost mjerenja koncentracije kao čimbenika koji opisuje učinkovitost različitih dionika tržišta. Mjere koncentracije tržišta daju ključne uvide u

strukturu tržišta i pomažu u donošenju odluka za održavanje zdravog konkurentskog okruženja.

Predmet i cilj rada je bruto premija osiguranja i analiza nejednakosti bruto premije društava za osiguranje u Bosni i Hercegovini u razdoblju 2010. – 2024. Cilj je izdvojiti broj osiguratelja koji su najznačajniji na tržištu osiguranja u Bosni i Hercegovini i analizirati kretanje bruto premije životnih i neživotnih osiguranja korištenjem šest mjera koncentracije i Lorenzovu krivulju.

Iz definiranog predmeta i cilja rada proizlaze polazne hipoteze rada koje se mogu definirati u obliku:

H1: Raspodjela ukupno zaračunate bruto premije osiguranja u Bosni i Hercegovini opisana je visokom razinom konkurencije.

H2: Različita je koncentracija tržišta životnih i neživotnih osiguranja u Bosni i Hercegovini.

Doprinos ovog rada ogleda se u primjeni većeg broja mjera koncentracije za analizu raspodjele bruto premije osiguranja što su značajni tržišni faktori koji pobliže opisuju tržišnu strukturu i konkurentnost tržišta osiguranja u BiH. Navedeno može pomoći u oblikovanju pravih politika za postizanje više razine učinkovitosti tržišnih sudionika.

2. Metodologija

Za testiranje postavljenih hipoteza u radu se koriste podaci o zaračunatoj bruto premiji društava za osiguranje u Bosni i Hercegovini u razdoblju 2010. – 2024. godine. Podaci o bruto premiji dostupni su na službenoj web stranici Agencije za osiguranje u BiH. Za izračun šest mjera koncentracije korišteni su sekundarni podaci iz službenih Statističkih izvješća/biltena Agencije za osiguranje u BiH. Korištene su statističke i matematičke metode u izračunu pokazatelja i analizi modela, te za grafičko i tabelarno predstavljanje podataka i rezultata, izvođenje zaključaka i tumačenje rezultata. Mjere koncentracije su analizirane pomoću Slobodnog softvera dostupnog na Wessa.net (2026) i Microsoft Excela 2016. Uz deskriptivnu statističku analizu u radu je urađena i prognostička analiza trenda mjera koncentracije, koja se temelji na regresijskoj analizi uz nezavisnu varijablu vrijeme/godina.

3. Pregled literature

Prikaz tržišta pomoću mjera koncentracije u literaturi se obrađuje s različitih aspekata vezanih za specifičnosti samog tržišta koje je predmet analize tržišne koncentracije. Postoje radovi koji mjerama koncentracije opisuju koncentriranost ili nejednakost tržišta osiguranja. Značajan broj radova donosi studije i analizu koncentracije i raspodjele drugih financijskih subjekata i financijskih varijabli vezanih za financijsko tržište na kojem djeluju. U nastavku donosimo pregled odabranih istraživanja vezanih za koncentraciju na tržištima osiguranja.

Jakovčević, Dumičić i Anđelinović (2017) analiziraju koncentraciju tržišta osiguranja u Republici Hrvatskoj do 2012. godine i ukazuju na umjerenu razinu tržišne koncentracije, opisuju ga kao malo tržište osiguranja s velikim brojem međusobno konkurentnih osiguravatelja.

Tipurić, Pejić Bach i Pavić (2008) donose studiju o koncentraciji tržišta osiguranja u odabranim tranzicijskim zemljama srednje i istočne Europe, 1998 – 2006. Rezultati ove studije ukazuju na to da su do početka 1990-ih osiguravajuća tržišta zemalja srednje i

istočne Europe u tranziciji bila vrlo koncentrirana, što znači da je na tržištu djelovalo jedno ili samo nekoliko državnih društava za osiguranje, a tržišni udio vodeće tvrtke bio je veći od 90%. Početkom devedesetih privatni ulagači su ušli u većinu gospodarskih sektora, uključujući tržište osiguranja. Ulazak novih tvrtki doveo je do smanjenja koncentracije, odnosno do povećane konkurencije.

Bauer (2012) donosi u svom radu rezultate mjerenja i prognoziranja koncentracije bruto premije u sektoru osiguranja Republike Hrvatske koji pokazuju da se događa pad koncentracije bruto premije u periodu 2002. – 2011.

Vasilev (2022) analizira koncentraciju tržišta i jačine konkurencije kasko osiguranja i osiguranja od autoodgovornosti u Bugarskoj u razdoblju 2012.-2021. i donosi zaključak da je neživotno osiguranje u Bugarskoj normalno konkurentno tržište s niskom razinom koncentracije.

3. Tržište osiguranja u Bosni i Hercegovini

Tržište osiguranja u BiH se razvija u specifičnih političkih, ekonomsko-socijalnih i regulatornih uvjeta zemlje. BiH je entitetski uređena, a entiteti (Republika Srpska i Federacija Bosne i Hercegovine) imaju vlastite regulatorne agencije za nadzor osiguranja. Za jedinstvenu primjenu zakona o osiguranju između entiteta, kao i postojanje neometane i djelotvorne suradnje između entitetskih agencija zadužena je državna Agencija za osiguranje u Bosni i Hercegovini.

U zadnjem desetljeću broj društava za osiguranje malo se mijenjao, kao što je prikazano na sljedećoj slici.

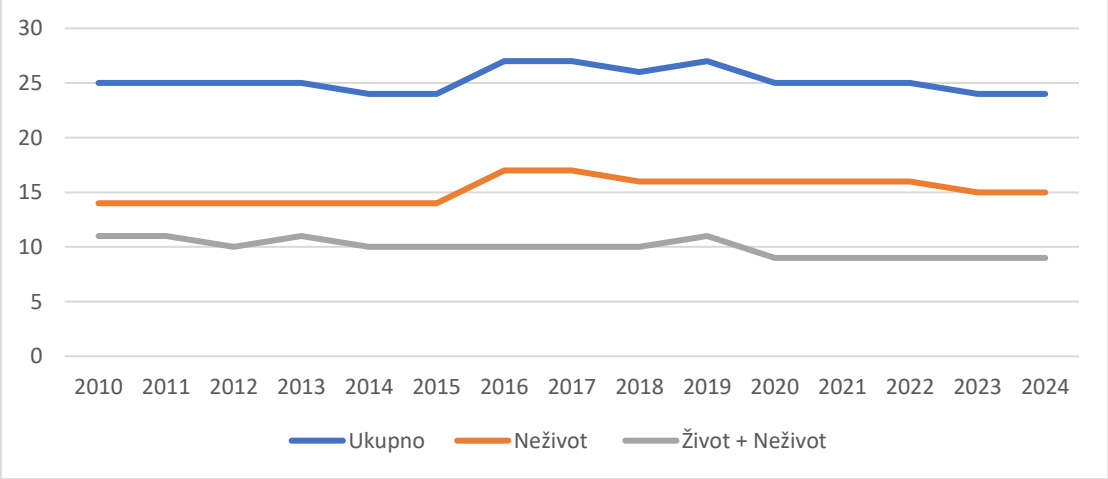

Slika 1. Kretanje broja društava za osiguranje u Bosni i Hercegovini u razdoblju 2010.-2024. godina, Statistika tržišta osiguranja BiH, Agencija za osiguranje BiH, izradili autori

Cijelo promatrano razdoblje broj društava za osiguranje je približno konstantan na razini 25 društava. Približno 60% društava se bave isključivo neživotnim osiguranjima, a oko 40% društava u svom portfelju imaju i životna i neživotna osiguranja. Početkom promatranog razdoblja ukupna aktiva društava za osiguranje bila je 3,86% ukupne aktive cijelog sektora financijskih usluga. U 2024. godini društva za osiguranje bilježe udio aktive od 5,40% u ukupnoj aktivi sektora financijskih usluga. Nominalni BDP u BiH za 2024. godinu je iznosio 53 864 milijuna KM (27 540 milijuna eura), a ukupna premija osiguranja u 2024. godini je bila 1 085 milijuna KM (555 milijuna eura) što iznosi 2,00%

BDP-a. Premija po stanovniku u BiH za 2024. godinu iznosila je 318 KM (162 eura) što je značajno manje u odnosu na razvijene zemlje zapadne Europe.

4. Mjere nejednakosti premije osiguranja

Cijelo promatrano razdoblje 2010.-2024. ukupna premija bilježi rast, a taj rast prati rast premije životnih i neživotnih osiguranja. Ukupnu bruto premiju oblikuje premija životnih i neživotnih osiguranja. U oblikovanju bruto premije neživotnih osiguranja sudjeluju sva društva, njih 25 u 2010. godini i 24 društva u 2024. godini. Za bruto premiju životnih osiguranja odgovorno je 11 društava u 2010., a 9 društava u 2024. godini. Unutar promatranog razdoblja bruto premija se kretala kako je prikazano na slici 2.

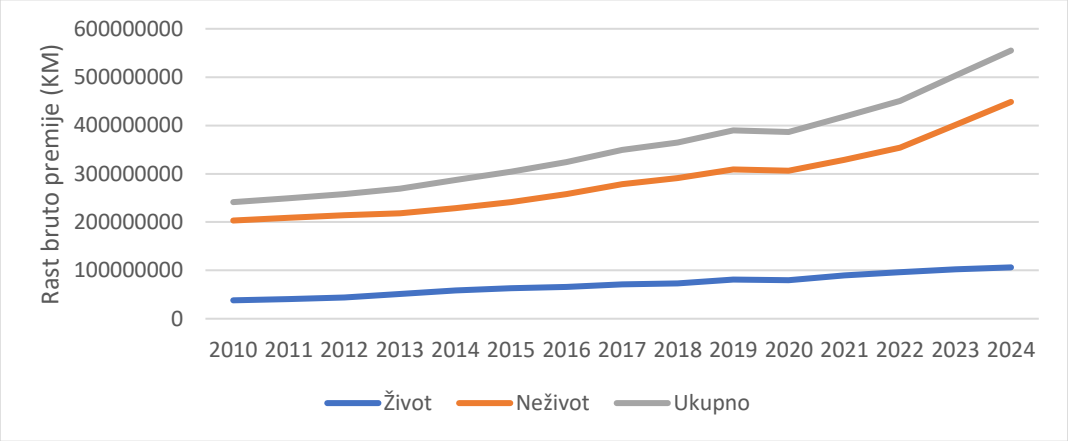

Slika 2. Kretanje ukupne bruto premije osiguranja u BiH u razdoblju 2010. – 2024. godina, Statistika tržišta osiguranja BiH, Agencija za osiguranje BiH, izradili autori

Neživotna osiguranja bilježe veći intenzitet/koeficijent rasta premije nego životna osiguranja. Udio premije neživotnih osiguranja u ukupnoj premiji se kreće u rasponu od 84,21% u 2010. do 80,86% u 2024. godini. Bruto premiji životnih osiguranja unutar ukupne premije pripada znatno manji udio od 15,79% (2010.) do 19,14% (2024.). Unutar bruto premije neživotnih osiguranja dominira premija osiguranja od autoodgovornosti s udjelom od 48,83% u 2010. do 49,42% u 2024. godini.

5. Pokazatelji kretanja premije osiguranja pomoću mjera koncentracije u Bosni i Hercegovini

Koncentracija podrazumijeva skupinu poduzeća, koja imaju zajednička obilježja, odnosno ona koja obavljaju slične ili iste poslove. Prvi činitelj koncentracije je apsolutni broj poduzeća koje čine jedno tržište. Drugi činitelj je distribucija veličina poduzeća na tržištu, kada se veličina svakog definira razmjerno i relativno u odnosu na cijelo tržište. Oba činitelja moraju se uzajamno uzimati u obzir prilikom utvrđivanja koncentracije. Može se reći kako koncentracija postoji kada jedno ili manja skupina poduzeća kontrolira tržište. (Tipurić, Kolaković, Dumičić, 2003)

Osnovna je svrha mjera koncentracije utvrditi dominira li tržištem mali broj velikih subjekata ili je tržište raspodijeljeno među većim brojem konkurenata.
Mjerenje koncentracije na tržištu osiguranja ključno je za razumijevanje njegove strukture i stupnja tržišne konkurencije. Ako se kroz promatrano razdoblje vrijednosti koncentracijskih mjera povećavaju, to obično znači jačanje tržišne koncentracije i smanjenje konkurencije. Nasuprot tome, smanjenje koncentracijskih pokazatelja

upućuje na veću tržišnu konkurenciju i ravnomjerniju raspodjelu tržišnih udjela među društvima za osiguranje.

U radu je analizirana raspodjela bruto premije osiguranja pomoću šest mjera koncentracije i Lorenzove krivulje. Analiza je provedena za tržište neživotnog i životnog osiguranja u BiH u razdoblju 2010. – 2024. godina.

U ovom radu obrađeno je 7 najpoznatijih mjera koncentracije: (1) koncentracijski omjer C5, (2) Hirschman-Herfindahlov indeks, (3) Ginijev koeficijent, (4) Lorenzovu krivulju, (5) indeks entropije, (6) Rosenbluth indeks i (7) Hall-Tideman indeks.

Koncentracijski omjer $(\boldsymbol{C_r})$ je najčešće korištena apsolutna mjera koncentracije Cr (Bahovac et al., 2016), a predstavlja udio *r* najvećih tržišnih subjekata u ukupnom broju svih subjekata na tržištu prema izdvojenom statističkom obilježju. U ovom radu koncentracijski omjer predstavlja udio odabranog broja društava za osiguranje prema bruto zaračunatoj premiji.

$$C_r = \frac{\sum_{i=1}^{r} x_i}{\sum_{i=1}^{N} x_i} \tag{1}$$

što znači da se zbroj r najvećih vrijednosti u nizu dijeli sa zbrojem svih vrijednosti niza. Vrijednosti koncentracijskog omjera su od $\frac{1}{N}$ do 1, odnosno $\frac{1}{N} \leq C_r \leq 1.$
Vrijednost omjera koncentracije (za r društava za osiguranje s najvećom bruto premijom) blizu je 0 kada na tržištu postoji veliki broj jednakih društava za osiguranje, a njegova vrijednost je 1 kada zbroj bruto premija osiguranja r subjekata s najvišim bruto premijama čini cijelo tržište osiguranja. (Jakovčević, Dumičić i Anđelinović, 2017).

Herfindal-Hirschmanov indeks (HHI) u izračun uključuje vrijednosti istaknutog statističkog obilježja kod svih sudionika analiziranog tržišta. *HHI* tržišnu koncentraciju mjeri zbrojem kvadrata tržišnih udjela svih poduzeća u nekoj industriji. Ovaj pokazatelj ima najmanje dvije prednosti nad jednostavnim pokazateljem koncentracije: (1) obuhvaća vrijednosti tržišnih udjela svih poduzeća a tržištu te (2) kvadriranjem daje veći ponder udjelima većih poduzeća. (Tipurić, Kolaković, Dumičić, 2003)

Formula za izračun indeksa je:

$$HHI = \sum_{i=1}^{N} s_i^2 \tag{2}$$

gdje je N broj društava na tržištu i s_i tržišni udjel i-tog društva.

Vrijednost HHI je prikazana pomoću nejednakosti $\frac{1}{N} \leq HHI \leq 1$. Viša vrijednost HHI ukazuje na veću koncentraciju bruto premija osiguranja. U slučaju monopola na tržištu osiguranja, njegova vrijednost je 1.
Ginijev koeficijent (G) je najzastupljenija relativna mjera koncentracije i s njim povezan grafički prikaz Lorenzova krivulja.

Suprotno određivanju koncentracijskog omjera C_r, gdje se podaci moraju urediti po veličini od najvećeg prema najmanjem, za izračun *Ginijeva koeficijenta koncentracije*, podatke treba poredati po veličini od najmanjeg prema najvećem. Za izračun koeficijenta koristi se sljedeća formula

$$G = \frac{2\sum_{i=1}^{N} i x_i - (N+1)\sum_{i=1}^{N} x_i}{N\sum_{i=1}^{N} x_i} \tag{3}$$

Vrijednosti G koeficijenta su u intervalu $0 \leq G \leq 1$. Veća vrijednost G koeficijenta znači veću koncentraciju. U slučaju maksimalne koncentracije njegova vrijednost je 1 i predstavlja maksimalnu nejednakosti tržišta.

Lorenzova krivulja se konstruira u prvom kvadrantu koordinatnog sustava. Na os apscisa nanosi se aritmetičko mjerilo za vrijednosti empirijske funkcije distribucije $F(x_i)$ prema formuli

$$F(x_i) = \frac{\sum_{j=1}^{i} p_j}{N} = \frac{i}{N} \tag{4}$$

Što je Lorenzova krivulja „udaljenija" od pravca jednolike raspodjele, to je koncentracija veća i obrnuto. (Bahovac et al., 2016)

Mjera entropije (E) je pokazatelj koji se nerijetko koristi za opisivanje koncentracije na pojedinim tržištima, a računa se prema formuli

$$E = -\sum_{i=1}^{N} s_i \log_2 s_i \tag{5}$$

Vrijednost indeksa E kreće se između 0 i $log_2 N$, što znači da nije ograničen intervalom $[0,1]$ kao većina drugih indeksa koncentracije. Vrijednost entropije i stupanj koncentracije tržišta su međusobno inverzni. Vrijednost entropije je 0 u slučaju monopola, odnosno maksimalne koncentracije, a vrijednost $log_2 N$, kada su tržišni udjeli svih društava za osiguranje jednaki, te je koncentracije najmanja.

Hall-Tidemanov indeks (HTI) i Rozenbluthov (RI) su jako slični i naglašavaju važnost apsolutnog broja društava za osiguranje pri izračunu koncentracije. HTI se računa formulom:

$$HTI = \frac{1}{2\sum_{i=1}^{N} i s_i - 1} \tag{6}$$

pri čemu se tržišni udio svakog društva s_i množi s pripadajućim rangom i , s tim da se društvu s najvećom premijom dodjeljuje rang $i = 1$, a onome s najmanjom premijom $i = N$. Vrijednosti HTI pripadaju intervalu $[0,1]$. Vrijednost približno 0 u slučaju velikog broja društava jednake veličine, a vrijednost 1 u slučaju monopola.

Glavna razlika između RI i HTI je u rangiranju društava za osiguranje pa je kod RI rang $i = 1$ pridružen društvu s najmanjom premijom, a $i = N$ društvu s najvećom premijom na tržištu.

$$RI = \frac{1}{2\sum_{i=1}^{N} i s_i - 1}, \quad RI \in [0,1] \tag{7}$$

Na vrijednost RI intenzivno utječe kretanje društava s malim iznosom bruto premije. Ako se broj društava na tržištu povećava događa se opadanje vrijednosti RI u odnosu na HTI.

6. Analiza i rezultati za tržište neživotnog osiguranja

U skupini neživotnih osiguranja u BiH razlikuje se 18 vrsta neživotnih osiguranja. Prema ukupnoj bruto premiji izdvaja se osiguranje od autoodgovornosti na koje otpada 61% ukupne premije neživotnih osiguranja.

Tablica 1. Odabrane mjere koncentracije bruto premije neživotnog osiguranja u BiH u razdoblju 2010.-2024.

	Neživotna osiguranja						
Godina	**C_5**	**HHI**	**G**	**E**	**RI**	**HTI**	**Broj društava**
2010.	0,500	0,0728	0,484	2,819	0,078	0,027	25
2011.	0,491	0,0718	0,453	2,831	0,076	0,029	24
2012.	0,463	0,0664	0,443	2,882	0,072	0,028	25
2013.	0,491	0,0712	0,422	2,832	0,075	0,031	23
2014.	0,478	0,0682	0,421	2,875	0,072	0,029	24
2015.	0,457	0,0649	0,401	2,903	0,070	0,030	24
2016.	0,433	0,0596	0,427	2,988	0,065	0,026	27
2017.	0,412	0,0563	0,395	3,028	0,061	0,027	27
2018.	0,449	0,0624	0,453	2,934	0,068	0,025	27
2019.	0,447	0,0619	0,424	2,952	0,067	0,027	26
2020.	0,448	0,0621	0,400	2,951	0,067	0,029	25
2021.	0,441	0,0603	0,388	2,969	0,065	0,029	25
2022.	0,437	0,0599	0,386	2,974	0,065	0,029	25
2023.	0,491	0,0692	0,415	2,888	0,071	0,029	24
2024.	0,496	0,0709	0,422	2,876	0,072	0,029	24

Izvor: Statistika tržišta osiguranja BiH, Agencija za osiguranje BiH, izradili autori

Prema rezultatima statističke analize za tržište neživotnog omjer koncentracije C5 iznosi 40% u 2017., a gotovo 50% u 2024. godini.

Vrijednosti HHI za neživotno osiguranje su u intervalu od 0,056 (2017.) do 0,071 (2024.) što opisuje nekoncentrirano tržište, odnosno tržište visoke razine konkurencije. Kretanje HHI ispod vrijednosti 0,1 u cijelom promatranom razdoblju opisuje fragmentiranost ukupne bruto premije neživotnih osiguranja između sve većeg broja društava za osiguranje.

Ginijev koeficijent u cijelom promatranom razdoblju ima vrijednosti manje od 0,5 što daje zaključiti da nema značajne koncentracije na tržištu neživotnog osiguranja.
Grafički promatrano G koeficijent je omjer površine koju zatvaraju krivulja jednake raspodjele i Lorenzove krivulje i površine ispod krivulje jednake raspodjele.

Vrijednosti G koeficijenta osciliraju u jako uskom numeričkom intervalu od 0,386 do 0,484 čija je širina 0,098. Približno iste vrijednosti G koeficijent u cijelom analiziranom razdoblju potvrđuje i grafički prikaz Lorenzove krivulje na slici 3.

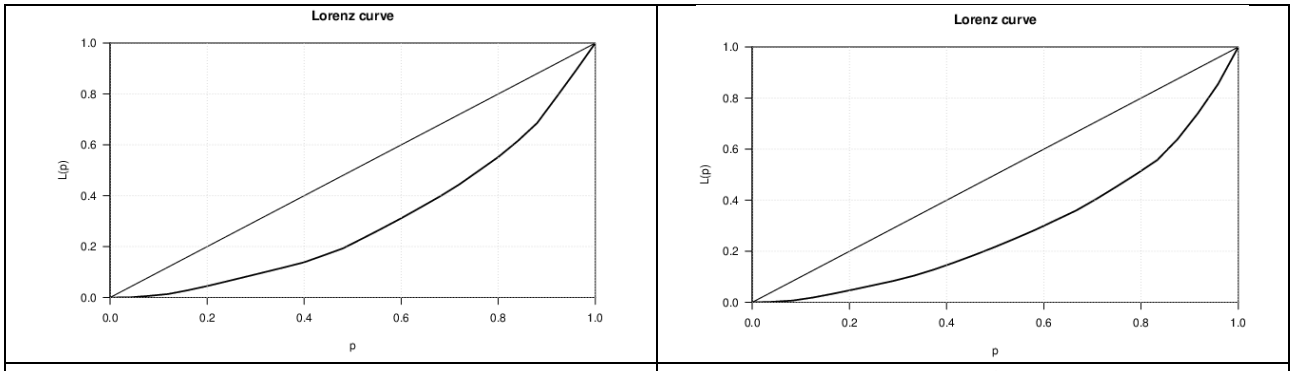

2010. 2024.

Slika 3. Lorenzova krivulja bruto premije neživotnog osiguranja u BiH za 2010. i 2024. godinu, Statistika tržišta osiguranja BiH, Agencija za osiguranje BiH, izradili autori

Na slici 3. vidljivo je kako je Lorenzova krivulja približno jednako udaljena od krivulje savršene jednakosti u 2010. kao i u 2024. godini.

U tablici 1. izračunat je RI i njegove vrijednosti osciliraju u intervalu između 0,061 (2017.) i 0,078 (2010.). U zadnjoj promatranoj godini (2024.) RI je 0,072. Izračunate vrijednosti upućuju na nisku razinu koncentracije i prema rezultatima vidljivo je da vrijednosti RI nemaju stalnu tendenciju pada ili rasta. Nadalje, HTI koncentracije je najveći u 2013. godini i iznosi 0,031, a u svim ostalim godinama analiziranog razdoblja HTI je manji i modalna vrijednost mu je 0,029 koja se pojavljuje u 7 analiziranih godina. Vrijednosti HTI približno nula ukazuju da ne postoji monopol na tržištu neživotnog osiguranja u BiH. Oba indeksa u promatranom razdoblju pokazuju nisku razinu koncentracije.

Prema definiciji Entropija ima interval vrijednosti $[0;\ 4{,}755]$ za neživotno osiguranje u BiH. Rezultati statističke analize prikazani u tablici 1. pokazuju da entropija prima vrijednosti između 2,819 (2010.) i 3,028 (2017.). Izračunata entropija premije neživotnih osiguranja prima vrijednosti približno između drugog i trećeg kvartila u intervalu vrijednosti entropije što pokazuje nisku razinu koncentracije premije, odnosno nekoncentrirano tržište neživotnog osiguranja.

7. Analiza i rezultati za tržište životnog osiguranja

Tržište životnog osiguranja je relativno malo i manje razvijeno u odnosu na zemlje Europske unije. Životno osiguranje ima u svom portfelju 9 društava za osiguranje u 2024. godini. Svih 9 društava uz životno osiguranje u portfelju imaju i neživotna osiguranja. Nijedno društvo za osiguranje u BiH ne bavi se samo životnim osiguranjem. Udio društava sa većinskim stranim kapitalom na tržištu životnog osiguranja u 2024. godini iznosi 97,99%.
Ukupna bruto zaračunata premija životnog osiguranja u 2024. godini je 19,14% ukupne premije cijelog tržišta osiguranja u BiH. Raspodjela premije opisana mjerama nejednakosti prikazana je u tablici 2. pomoću izračunatih 6 indeksa koncentracije.

Tablica 2. Odabrane mjere koncentracije bruto premije životnog osiguranja u Bosni i Hercegovini u razdoblju 2010.-2024.

	Životna osiguranja						
Godina	**C_5**	**HHI**	**G**	**E**	**RI**	**HTI**	**Broj društava**
2010.	0,875	0,1787	0,572	1,897	0,195	0,067	12
2011.	0,876	0,1817	0,538	1,885	0,197	0,067	11
2012.	0,866	0,1790	0,530	1,902	0,193	0,067	11
2013.	0,867	0,1834	0,492	1,883	0,197	0,067	10
2014.	0,854	0,1780	0,484	1,903	0,194	0,067	10
2015.	0,845	0,1723	0,465	1,935	0,187	0,068	10
2016.	0,844	0,1679	0,453	1,956	0,183	0,069	10
2017.	0,831	0,1609	0,432	1,985	0,176	0,070	10
2018.	0,857	0,1695	0,460	1,943	0,185	0,068	10
2019.	0,873	0,1705	0,466	1,925	0,187	0,068	10
2020.	0,903	0,1713	0,404	1,888	0,186	0,079	9
2021.	0,907	0,1720	0,408	1,879	0,188	0,079	9
2022.	0,902	0,1716	0,409	1,883	0,188	0,079	9
2023.	0,899	0,1322	0,417	1,882	0,190	0,078	9
2024.	0,883	0,1655	0,390	1,917	0,182	0,080	9

Izvor: Statistika tržišta osiguranja BiH, Agencija za osiguranje BiH, izradili autori

Prema rezultatima statističke analize za tržište životnog osiguranja koncentracijski omjer C5 ima vrijednost 88% u 2010., a približno istih 88% i u 2024. godini. Vrijednost koncentracijskog omjera C5 je relativno visoka za tržište životnog osiguranja tijekom cijelog promatranog razdoblja što pokazuje visoku koncentraciju bruto premije kod 5 društava.

Vrijednosti HHI za životno osiguranje su u intervalu od 0,132 (2023.) do 0,183 (2013.) što opisuje umjereno koncentrirano tržište životnog osiguranja. Kretanje HHI iznad vrijednosti 0,1 u cijelom promatranom razdoblju opisuje umjerenu koncentraciju ukupne bruto premije životnih osiguranja, odnosno nekoliko većih društava ima značajan tržišni udio, ali konkurencija još uvijek postoji.

Ginijev koeficijent u cijelom promatranom razdoblju ima trend blagog linearnog pada od vrijednosti 0,572 (2010.) do 0,390 (2024.) što daje sliku umjerene do niske razine koncentracije premije. Širina intervala vrijednosti G koeficijenta je 0,182.
Grafički prikaz G koeficijenta za životna osiguranja je Lorenzovom krivuljom na slici 4.

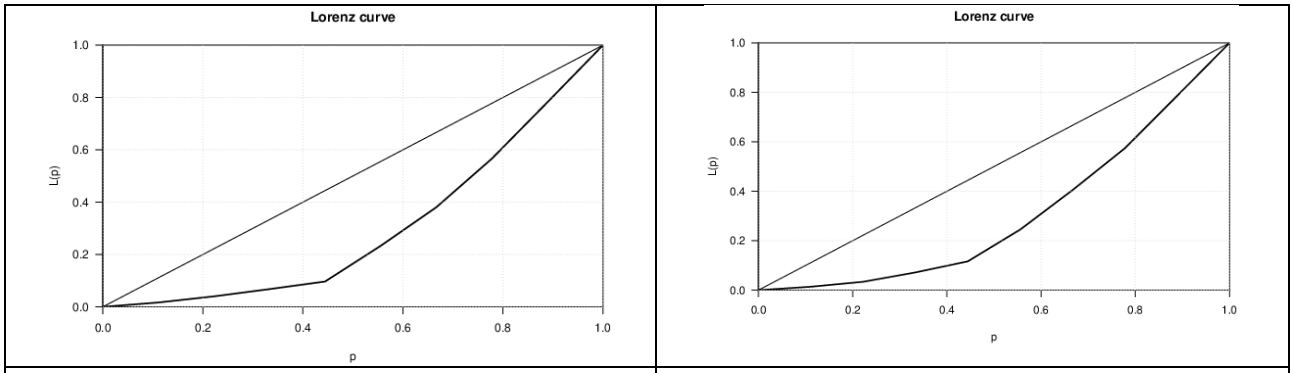

2010. 2024.

Slika 4. Lorentzova krivulja bruto premije životnog osiguranja u BiH za 2010. i 2024. godinu, Statistika tržišta osiguranja BiH, Agencija za osiguranje BiH, izradili autori

Za koeficijent G je zabilježen blagi trend pada što se uočava između dviju površina prikazanih na slici 4. Mjera površine koju omeđuje krivulja savršene jednakosti i Lorenzove krivulja za 2024. godinu je manja nego mjera površine između opisanih krivulja u 201. godini.

Za premiju životnih osiguranja RI i HTI su malo veći nego za premiju neživotnih osiguranja, ali ne značajno. Vrijednosti RI ne pokazuju niti rast niti pad nego osciliraju u jednom uskom intervalu između 0,176 i 0,197. Nasuprot RI vrijednosti HTI nalaze se u intervalu $[0{,}067;\ 0{,}080]$ i prate blagi trend rasta sa koeficijentom prosječnog rasta u iznosu 0,001 iz godine u godinu. Rast HTI pokazuje blagi rast koncentracije na tržištu životnog osiguranja, ali vrijednosti su relativno blizu nuli pa se može zaključiti da još uvijek ne postoji monopol na tržištu životnog osiguranja.

Prema definiciji E ima interval vrijednosti $[0; 3{,}5850]$ za životno osiguranje u BiH. Rezultati statističke analize prikazani u tablici 1. pokazuju da entropija prima vrijednosti između 1,879 i 1,985. Izračunata entropija premije životnih osiguranja prima vrijednosti oko sredine intervala definicijske vrijednosti entropije što opisuje tržište umjerene koncentracije premije.

8. Trend kretanja mjera koncentracije bruto premije životnih i neživotnih osiguranja u BiH u razdoblju 2010. – 2024. godina

Model trenda predstavlja analitički izraz kojim se opisuje dugoročna tendencija u razvoju istraživane pojave. U nastavku bit će prikazani polinomski trend modeli mjera nejednakosti.

Tablica 3. Prognostički trend modeli analiziranih mjera koncentracije za neživotno osiguranje u BiH

Koncentracijski omjer	$\boldsymbol{C5 = 0,001t^2 - 0,021t + 0,530}$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	0,530	0,016	33,892	$2{,}77 \cdot 10^{-13}$
$\boldsymbol{t}$	-0,021	0,004	-4,643	0,0006
$\boldsymbol{t^2}$	0,001	0,0003	4,406	0,0009
HHI	$\boldsymbol{HHI = 0,0002t^2 - 0,004t + 0,079}$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	0,079	0,003	27,802	$2{,}9 \cdot 10^{-12}$
$\boldsymbol{t}$	-0,004	0,001	-4,951	0,0003
$\boldsymbol{t^2}$	0,0002	0,00005	4,523	0,0007
Ginijev indeks	$\boldsymbol{G = 0,0006t^2 - 0,014t + 0,482}$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	0,482	0,017	27,787	$2{,}92 \cdot 10^{-12}$
$\boldsymbol{t}$	-0,014	0,005	-2,837	0,015
$\boldsymbol{t^2}$	0,0006	0,0003	2,127	0,055
RI	$\boldsymbol{RI = 0,0002t^2 - 0,004t + 0,083}$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	0,083	0,002	35,979	$1{,}36 \cdot 10^{-13}$
$\boldsymbol{t}$	-0,004	0,0007	-5,306	0,0002
$\boldsymbol{t^2}$	0,0002	$4{,}01 \cdot 10^{-5}$	4,538	0,0007
HTI	$\boldsymbol{HTI = 1,43 \cdot 10^{-5}t + 0,028}$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	0,028	0,0009	31,633	$1{,}1 \cdot 10^{-13}$
$\boldsymbol{t}$	$1{,}43 \cdot 10^{-5}$	$9{,}79 \cdot 10^{-5}$	0,146	0,886
$\boldsymbol{t^2}$	-	-	-	-

entropija (E)	$E = -0,0024t^2 + 0,045t + 2,748$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	2,748	0,034	80,378	$9{,}17 \cdot 10^{-18}$
t	0,045	0,009	4,616	0,0006
t^2	-0,0024	0,0006	-3,992	0,0018

Izvor: Statistika tržišta osiguranja BiH, Agencija za osiguranje BiH, izradili autori

Svi navedeni trend modeli imaju odgovarajuću razinu reprezentativnosti potkrijepljenu statistički značajnim koeficijente u modelima uz nezavisnu varijablu vrijeme, na razini značajnosti 5%. Trend modeli su opisani polinomom drugog stupnja ili kvadratnom funkcijom osim HTI modela koji je u obliku linearne funkcije vremena.

Tablica 4. Prognostički trend modeli analiziranih mjera koncentracije za životno osiguranje u BiH

Koncentracijski omjer	$C5 = 0,001t^2 - 0,008t + 0,882$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	0,882	0,016	55,357	$7{,}96 \cdot 10^{-16}$
t	-0,008	0,005	-1,798	0,079
t^2	0,001	0,0003	2,451	0,030
HHI	$HHI = -0,002t + 0,184$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	0,184	0,005	35,118	$2{,}8 \cdot 10^{-14}$
t	-0,002	0,0006	-3,055	0,009
t^2	-	-	-	-
Ginijev indeks	$G = -0,011t + 0,552$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	0,552	0,011	50,544	$2{,}61 \cdot 10^{-16}$
t	-0,011	0,001	-9,432	$3{,}53 \cdot 10^{-7}$
t^2	-	-	-	-
RI	$RI = -0,0008t + 0,195$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	0,195	0,003	71,656	$2{,}83 \cdot 10^{-18}$
t	-0,0008	0,0003	-2,581	0,022
t^2	-	-	-	-
HTI	$HTI = 0,001t + 0,063$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	0,063	0,0016	40,146	$5{,}11 \cdot 10^{-15}$
t	0,001	0,0002	6,211	$3{,}16 \cdot 10^{-5}$
t^2	-	-	-	-
entropija (E)	$E = -0,001t^2 + 0,016t + 1,866$			
	koeficijent	standardna greška	t-statistika	p-vrijednost
slobodni koeficijent	1,866	0,0255	73,016	$2{,}9 \cdot 10^{-17}$
t	0,016	0,0073	2,221	0,046
t^2	-0,001	0,0004	-2,317	0,039

Izvor: Statistika tržišta osiguranja BiH, Agencija za osiguranje BiH, izradili autori

Za životno osiguranje prevladavaju linearni trend modeli indeksa koncentracije. Trend model opisan polinomom drugog stupnja značajan je samo kod koncentracijskog omjera C5 i kod indeksa entropije. HHI, Ginijev koeficijent i RI opisani su linearnim trend modelima s negativnim vodećim koeficijentom što znači da ih prati padajući trend model.

Oscilacije koeficijenta entropije kako životnih tako i neživotnih osiguranja opisane su polinomom drugog stupnja sa značajnim koeficijentima u jednadžbi na razini značajnosti 5%.

9. Zaključak

Analiza koncentracije tržišta osiguranja predstavlja važan segment procjene razvijenosti i konkurentnosti sektora osiguranja. Tržište osiguranja u Bosni i Hercegovini pokazujući slabu razinu koncentracije tržišta neživotnih i slabu do umjerenu razinu koncentracije životnih osiguranja nije razvijeno kao tržite osiguranja zemlja Europske unije. Analiza pokazuje kako se radi o malom tržištu s relativno velikim brojem međusobno konkurentnih društava za osiguranje.

Istraživanje je usmjereno na analizu šest mjera koncentracije i Lorenzove krivulje neživotnog i životnog osiguranja u Bosni i Hercegovini u razdoblju od 2010. do 2024. godine. U promatranom razdoblju od 15 godina izračunate mjere nejednakosti su oblikovale šest vremenskih serija koje opisuju raspodjelu bruto premije neživotnog i životnog osiguranja. Svakoj vremenskoj seriji pridružen je statistički značajan prognostički trend model koji opisuje trend kretanja koncentracijskog indeksa u promatranih 15 godina. Izračunate mjere koncentracije opisuju tržište neživotnog osiguranja kao nekoncentrirano tržište, a životno osiguranje pokazuje blago umjerenu koncentraciju. Približno 50% bruto premije neživotnih osiguranja je koncentrirano u 5 društava. Kretanje HHI ispod vrijednosti 0,1 u cijelom promatranom razdoblju opisuje fragmentiranost ukupne bruto premije neživotnih osiguranja između sve većeg broja društava za osiguranje. Ginijev koeficijent u cijelom promatranom razdoblju ima vrijednosti manje od 0,5 što daje zaključiti da nema značajne koncentracije na tržištu neživotnog osiguranja.

U cijelom promatranom razdoblju zabilježen je rast zaračunate bruto premije. U zadnje tri analizirane godine entropija bilježi blagi pad vrijednosti što se uz istodobni rast ukupne premije može interpretirati kao početak procesa koncentracije tržišta, odnosno povećanja tržišnog udjela manjeg broja vodećih društava. U izdvojene tri godine (2022., 2023. i 2024.) ostali indeksi: C5, HHI, G, RI i HTI potvrđuju rast koncentracije pa se može zaključiti da tržište neživotnog osiguranja prolazi kroz proces u kojem vodeća društva dodatno učvršćuju svoju tržišnu poziciju. Vrijednost koncentracijskog omjera C5 je relativno visoka, na razini 88%, za tržište životnog osiguranja tijekom cijelog promatranog razdoblja što pokazuje visoku koncentraciju bruto premije kod 5 društava.

Kretanje HHI iznad vrijednosti 0,1 u cijelom promatranom razdoblju opisuje umjerenu koncentraciju ukupne bruto premije životnih osiguranja, odnosno nekoliko većih društava ima značajan tržišni udio, ali konkurencija još uvijek postoji. Izračunata entropija premije životnih osiguranja prima vrijednosti oko sredine intervala definicijske vrijednosti entropije što opisuje tržište umjerene koncentracije premije. Oscilacije koeficijenta entropije kako životnih tako i neživotnih osiguranja opisane su polinomom drugog stupnja sa značajnim koeficijentima u jednadžbi na razini značajnosti 5%.

Kratkoročna prognoza kretanja indeksa entropije prema oblikovanim trend modelima predviđa pad indeksa entropije u sljedećih 5 godina za tržište životnog i neživotnog osiguranja. To znači da se ne očekuje povećanje koncentracije premije, odnosno smanjenje broja društava. Statistička analiza mjera nejednakosti i njihovi trend modeli potvrđuju obje postavljene hipoteze.

Specifičnost tržišta osiguranja u Bosni i Hercegovini ogleda se u relativno visokoj zastupljenosti obveznih vrsta osiguranja, prvenstveno od automobilske odgovornosti. Upravo zbog dominantnosti udjela obveznih osiguranja, tržišna konkurencija se često temelji na financijskoj snazi i mogućnosti privlačenja velikog broja klijenata, a manje na diferencijaciji proizvoda. U tom slučaju najveća društva za osiguranje ostvaruju prednosti ekonomije obujma, razvijenije prodajne kanale i veću prepoznatljivost na tržištu, što im omogućuje brži rast bruto premije u odnosu na manja društva za osiguranje. Nadalje, veliki udio premije od autoodgovornosti u ukupnoj premiji i relativno mali udio životnih osiguranja su pokazatelji da osiguranje u BiH ima još dosta prostora za rast i razvoj.

10. Literatura

Agencija za osiguranje u Bosni i Hercegovini. (2010 – 2024). Godišnja izvješća, Statistika tržišta osiguranja u Bosni i Hercegovini. Sarajevo. Preuzeto s www.azobih.gov.ba

Anđelinović, M., Milec, M., Dumičić, K. (2022). Analysis of the Assets, Credits and Deposits Concentration within the Croatian Banking System based on Selected Concentration Indices. Jurnal of Central Banking Theory and Practice 1, 131-150.

Bahovac, V. et al. (2016). Statistika, *Element d.o.o., Zagreb*

Dumičić, K., Pavković, A., Akalović Antić, J. (2012). Mjere koncentracije u bankarstvu i Republici Hrvatskoj. *Zbornik Ekonomskog fakulteta u Zagrebu, 10,* 118-136.

Galetić, F., Obradović, T. (2018). Measuring Concentration of the Banking Market of the Republic of Croatia. 6th International OFEL Conference on Governance, Management and Enterpreneurship New Business Models and Institutional Enterpreneurs: Leading Disruptive Change, April 13th-14th, Dubrovnik, Croatia, Governance Research and Development Centre (CIRU), Zagre, pp. 598-625.

Halaj, G., Zochowski, D., (2009). Strateške grupe i uspješnost poslovanja banaka, Financijska teorija i praksa 33 (2), 153-186. https://hrcak.srce.hr/39903

Jakovčević, D., Dumičić, K., Anđelinović, M. (2017). Measuring recent changes of insurance gross premiums distribution using ten inequality measure: case study of Croatia, Economic Research-Ekonomska istraživanja, 30:1, 661-675.

Jishkariani, M., (2024). Herfindahl-Hirschman Indeks (HHI) of Georgia's Wholesale Electricity Market, Proceedings of IV International Scientific and Practical Conference „European congress of scientific achievements" (April 22-24), P, 146-154. https://www.researchgate.net/publication/380005874_Herfindahl-Hirschman_Index_HHI_of_Georgia's_Wholesale_Electricity_Market

Kovačević, S., Ćurić, P., Kurušić, D., (2021). Analiza tržišne koncentracije u bankarskom sektoru Republike Srpske. Financing naučni časopis za ekonomiju, 12 (4), 13-30. https://www.ceeol.com/search/article-detail?id=1062857

Kovačić, B., Opačić, R., Marohnić, L. (2012). O Ginijevu koeficijentu koncentracije, Hrvatski matematički elektronički časopis, 22 (1), 22-36. https://hrcak.srce.hr/clanak/151776

Kvalseth, T.O., (2024). Theil's Indeks of Inequality: Computation of Value-Validity Correction, Computation, 12 (12), 240. https://doi.org/10.3390/ computation12120240

Ljubaj, I. (2005). Indeksi koncentracije bankarskog sektora u Hrvatskoj. *Hrvatska narodna banka, Zagreb,* Publikacija Pregledi, P-21. preuzeto svibanj 2026., from www.hnb.hr/publikac/pregledi/p-021.pdf

Mandić, D., Duronjić, D. (2017). Analiza koncentracije bankarskog sektora Republike Srpske, Financing-naučni časopis za ekonomiju, Brčko 2, 62-67.

Mihailović, B., Simonović, Z., Paraušić, V. (2009). Entropija kao mera organizacione neefikasnosti, Industrija, 37 (3), 109-121. https://scindeks-clanci.ceon.rs/data/pdf/0350-0373/2009/0350-03730903108M.pdf

Pezer, M., Stanić, B., Perić, T., (2019). Dekompozicija Ginijevog koeficijenta nejednakosti pomoću shapleyeve vrijednosti: primjer Hrvatske, Zbornik Ekonomskog fakulteta u Zagrebu, 17 (2), 19-37. https://hrcak.srce.hr/229288

Suwinto, J., Ivy, V. (2022). The Application of Herfindahl-Hirschman Indeks in Measuring the Concentration Level of Financial-Technology Industry. Tenth International Conference on Entrepreneurship and Business Management 2021, Advances in Economics, Business and Management Research, volume 216, Atlantis Press, http://creativecommons.org/licenses/by-nc/4.0/.

Tipurić, D., Kolaković, M., Dumičić, K. (2003). Koncentracijske promjene hrvatske bankarske industrije u desetogodišnjem razdoblju (1993.-2002.). *Zbornik Ekonomskog fakulteta u Zagrebu, 1 (1),* 1-20.

Tipurić, D., Pejić, M., Pavić, T. (2008). Concentration of the insurance industry in selected transition countries of Central and Easter Europe, 1998-2006. *Post-Communist Economics, 20,* 97-118.

Vasilev, V., (2022). The market concentration and Competitive environment of casco and Motor third party liability insurance in Bulgaria, Horizons - International Scientific Journal (Series A), Vol. 31 No. 2 University "St. Kliment Ohridski" – Bitola, North Macedonia, 207-218.

Wessa.net. (2026). Contretacion-Free Statistics and Forecasting Softver (Calculators). Preuzeto veljača, 2026, from https://wessa.net/rwasp_concentration.wasp

ANALYSIS OF TRENDS IN INSURANCE PREMIUMS USING MEASURES OF INEQUALITY IN BOSNIA AND HERZEGOVINA

Anela Čolak[1], Nikola Papac[2], Marina Jerinić[3]
[1] University of Mostar, Faculty of Economics, Matice Hrvatske b.b., 88000 Mostar, Bosnia and Herzegovina, eMail: anela.colak@ef.sum.ba
[2] University of Mostar, Faculty of Economics, Matice Hrvatske b.b., 88000 Mostar, Bosnia and Herzegovina, eMail: nikola.papac@ef.sum.ba
[3] University of Mostar, Faculty of Economics, Matice Hrvatske b.b., 88000 Mostar, Bosnia and Herzegovina, eMail: marina.jerinic@ef.sum.ba

Abstract: This paper aims to present changes in the distribution of insurance premiums in Bosnia and Herzegovina (BiH) from 2010 to 2024. The research focuses on determining the form and intensity of competition in life and non-life insurance. Six concentration measures and the Lorenz curve are used to describe varying levels of competition in the non-life and life insurance markets in BiH. The findings indicate a high level of competition in non-life insurance and weak to moderate competition in life insurance. Quadratic trend models for the concentration indices of gross premiums in non-life insurance are statistically significant for almost all the examined inequality measures. The concentration ratio C5, Herfindahl-Hirschman index (HHI), Gini coefficient (G), and Rosenbluth index (RI) are described by a quadratic trend model with a positive leading coefficient, while entropy follows a second-degree polynomial trend model with a negative leading coefficient. This suggests that over the next five to ten years, a slight increase in the concentration index is expected, except for entropy, which is projected to decrease slightly, indicating a reduction in the number of companies. The movement of gross life insurance premiums is influenced by concentration measures whose trend models do not display the same monotonicity. After 2025, the models forecast a decrease in entropy, RI, G, and HHI, while the models for the concentration ratio C5 and HTI predict a slight increase in these indices. This, together with the simultaneous growth of the total premium, may be interpreted as the beginning of the concentration process in the insurance market.

Keywords: Gross premium; entropy; Hall-Tideman; Herfindahl-Hirschman; trend forecasting; Rosenbluth