https://doi.org/10.63356/stes.soc.2026.003 УДК 368.91:368.2.026.4(497.6)

PRIMJENA DETERMINISTIČKIH MODELA U ŽIVOTNOM OSIGURANJU RADI ZADOVOLJENJA ZAHTJEVA SOLVENCY II

Autor: RADA ŠORMAZ ĐAKOVIĆ
e-mail: rada.sormaz7@gmail.com
Mentor: prof. dr Bojan Baškot
Ekonomski fakultet Univerziteta u Banjoj Luci

Uvod: Solvency II postavlja visoke zahtjeve u pogledu procjene rizika, kapitalne adekvatnosti i solventnosti osiguravajućih društava. Deterministički modeli predstavljaju tradicionalne aktuarske alate koji, uprkos ograničenjima u obuhvatanju neizvjesnosti i ekstremnih događaja, mogu imati značajnu praktičnu vrijednost u procjeni rizika životnog osiguranja.

Cilj: Cilj istraživanja je ispitati mogućnosti i ograničenja primjene determinističkih modela u procjeni solventnosti društava za životno osiguranje i utvrditi njihovu adekvatnost u odnosu na zahtjeve Solvency II.

Materijal i metode: Istraživanje je zasnovano na kombinaciji kvalitativnih i kvantitativnih metoda. Empirijska analiza obuhvata četiri osiguravajuća društva iz Bosne i Hercegovine i Hrvatske u periodu 2014–2023, odnosno 40 opservacija. Formiran je kvazi-panel skup podataka, a uticaj primjene determinističkih modela, kamatnih stopa, promjena smrtnosti i regulatornog okruženja na solventnost analiziran je primjenom kombinovanog pooled OLS regresionog modela. Dodatno su primijenjene scenarijske analize i pseudo-stohastički scenariji radi sagledavanja osjetljivosti rezultata na promjene ključnih parametara.

Rezultati: Zajednički pooled OLS model pokazuje statistički značajnu pozitivnu povezanost između primjene determinističkih modela i solventnosti, kao i statistički značajne razlike povezane sa pripadnošću zemlji, dok kamatna stopa i promjena smrtnosti nisu statistički značajne u zajedničkom modelu. Analize pojedinačnih društava ukazuju na heterogenost rezultata. Dodatna bootstrap i pseudo-stohastička analiza omogućavaju sagledavanje stabilnosti procijenjenih parametara i osjetljivosti solventnosti na promjene ključnih pretpostavki.

Zaključak: Deterministički modeli mogu predstavljati koristan i transparentan alat za procjenu solventnosti, posebno u uslovima ograničene dostupnosti podataka. Međutim, sami po sebi nisu dovoljni za potpuno ispunjenje zahtjeva Solvency II. Njihovo kombinovanje sa pseudo-stohastičkim scenarijima može predstavljati prelazni metodološki korak ka složenijim stohastičkim modelima i potpunijoj kvantifikaciji rizika.

Ključne riječi: Solvency II; životno osiguranje; deterministički modeli; solventnost; kvazi-panel podaci; pooled OLS; pseudo-stohastički scenariji

UVOD

Životno osiguranje predstavlja specifičan segment tržišta osiguranja zbog dugoročnog karaktera ugovornih obaveza i izražene zavisnosti finansijskih rezultata od demografskih, aktuarskih i ekonomskih pretpostavki. Procjena budućih novčanih tokova, smrtnosti i dugovječnosti osiguranika, kretanja kamatnih stopa i adekvatnosti raspoloživog kapitala neposredno utiče na sposobnost osiguravajućeg društva da dugoročno izvršava preuzete obaveze. Zbog toga izbor odgovarajućeg modela za procjenu rizika i solventnosti ima

značaj, ne samo sa stanovišta poslovanja pojedinačnog društva, već i sa stanovišta zaštite osiguranika i stabilnosti tržišta osiguranja (Dickson et al., 2013; Promislow, 2015).

Regulatorni okvir Solvency II dodatno je naglasio potrebu za povezivanjem visine potrebnog kapitala sa stvarnim profilom rizika osiguravajućeg društva. Za razliku od pristupa koji se dominantno oslanjaju na statičke pokazatelje kapitalne adekvatnosti, Solvency II polazi od identifikacije, mjerenja i upravljanja rizicima kojima je društvo izloženo. Takav koncept zahtijeva sagledavanje ne samo očekivanih vrijednosti, već i mogućih nepovoljnih odstupanja od očekivanih kretanja, što je posebno značajno kod dugoročnih obaveza karakterističnih za životno osiguranje (European Commission, 2009; EIOPA, 2021).

U aktuarskoj praksi za procjenu budućih kretanja tradicionalno se koriste deterministički modeli, kod kojih se vrijednosti ključnih parametara definišu unaprijed, a budući ishodi procjenjuju na osnovu zadatih pretpostavki. Njihova prednost ogleda se u relativnoj jednostavnosti primjene, transparentnosti, razumljivosti rezultata i nižim zahtjevima u pogledu podataka i računarskih resursa. Ove karakteristike mogu biti naročito značajne kod manjih osiguravajućih društava, jednostavnijih i homogenijih portfolija, kao i na tržištima na kojima postoje ograničenja u dostupnosti i kvalitetu podataka. U ovom radu je praktična primjenjivost determinističkih modela vezana za jednostavnije i homogene portfolije sa nižim stepenom volatilnosti (Baškot, 2012; Šain, 2009).

U kontekstu životnog osiguranja poseban značaj imaju modeli kojima se analiziraju promjene smrtnosti i dugovječnosti. Lee-Carter i Cohort pristupi omogućavaju sagledavanje dugoročnih demografskih kretanja i njihovih efekata na obaveze osiguravača. Promjene očekivanog trajanja života, zajedno sa kretanjem kamatnih stopa, mogu značajno uticati na sadašnju vrijednost budućih obaveza, visinu tehničkih rezervi i solventnost društva. Zbog toga determinističko modeliranje ovih veličina može pružiti korisnu osnovu za projekcije i analizu osjetljivosti, posebno kada je potrebno brzo i transparentno procijeniti efekte promjene pojedinačnih pretpostavki (Lee & Carter, 1992; Lee, 2000).

Međutim, upravo karakteristike koje determinističke modele čine jednostavnim predstavljaju i njihovo osnovno ograničenje. Budući da se zasnivaju na unaprijed definisanim vrijednostima parametara, oni ne obuhvataju u potpunosti neizvjesnost budućih kretanja, distribuciju mogućih ishoda niti vjerovatnoću pojave ekstremnih događaja. Solvency II, nasuprot tome, zahtijeva pristup u kojem je kvantifikacija rizika povezana sa mogućim nepovoljnim odstupanjima i kapitalom potrebnim za njihovo pokriće. Zbog toga deterministička procjena, posmatrana izolovano, ne može pružiti isti nivo informacija o riziku kao stohastički pristup. Ovo ograničenje posebno je povezano sa nemogućnošću determinističkih modela da u potpunosti obuhvate volatilnost i ekstremne rizike relevantne za procjenu solventnosti (European Commission, 2009; European Insurance and Occupational Pensions Authority [EIOPA], 2021).

Stohastički modeli omogućavaju modeliranje velikog broja mogućih budućih putanja i procjenu distribucije rezultata, čime pružaju širu osnovu za kvantifikaciju rizika. Njihova primjena, međutim, zahtijeva kvalitetne i dovoljno duge vremenske serije, adekvatne statističke pretpostavke, odgovarajuće računarske kapacitete i stručne resurse. Navedeni zahtjevi mogu predstavljati ograničenje za manja tržišta osiguranja i društva koja raspolažu relativno ograničenim istorijskim podacima. Problem izbora modela zbog toga se ne svodi isključivo na izbor između jednostavnijeg i složenijeg pristupa, već na pitanje koliko određeni metod, u konkretnim uslovima, može pružiti relevantne informacije za procjenu i upravljanje rizikom (Macdonald et al., 2018).

U istraživanjima sa ograničenim uzorkom bootstrap metoda omogućava dodatno sagledavanje stabilnosti procijenjenih regresionih parametara, dok Monte Carlo simulacije predstavljaju razvijeniji stohastički pristup modeliranju neizvjesnosti budućih ishoda (Anderson et al., 2007; Davison & Hinkley, 1997). U ovom istraživanju primijenjen je pojednostavljeni pseudo-stohastički scenario-grid, kojim se deterministička procjena

proširuje unaprijed definisanim kombinacijama ulaznih parametara, bez sprovođenja pune Monte Carlo simulacije.Ovo pitanje posebno je značajno u kontekstu tržišta Bosne i Hercegovine i njegovog približavanja evropskom regulatornom okviru. Uključivanje društava iz Republike Hrvatske u istraživanje omogućava sagledavanje rezultata u različitim regulatornim uslovima, budući da Hrvatska kao članica Evropske unije primjenjuje Solvency II, dok tržište Bosne i Hercegovine karakteriše drugačiji stepen regulatornog razvoja i harmonizacije. U osnovnom istraživanju zbog toga su obuhvaćena društva iz obje zemlje, čime je omogućeno poređenje u heterogenom tržišnom i regulatornom okruženju (Imamović, 2022; Pavlović, 2023).

Polazeći od navedenog, osnovni istraživački problem ovog rada odnosi se na pitanje u kojoj mjeri deterministički modeli mogu pružiti relevantne informacije za procjenu solventnosti životnih osiguravajućih društava u kontekstu zahtjeva Solvency II i na koji način se njihova ograničenja mogu ublažiti primjenom scenarijskog, odnosno pseudo-stohastičkog pristupa. Ovo pitanje dobija dodatni značaj u uslovima ograničene dostupnosti podataka i heterogenog regulatornog okruženja, kakav karakteriše posmatrana tržišta Bosne i Hercegovine i Hrvatske.

Osnovni cilj istraživanja jeste ispitati mogućnosti i ograničenja primjene determinističkih modela u procjeni solventnosti životnih osiguravajućih društava. Posebna pažnja usmjerena je na odnos između primjene determinističkih modela i pokazatelja solventnosti, uz istovremeno sagledavanje uticaja kamatnih stopa, promjena smrtnosti i razlika u regulatornom okruženju. Empirijska osnova istraživanja obuhvata četiri osiguravajuća društva iz Bosne i Hercegovine i Hrvatske u periodu 2014–2023. godine, odnosno ukupno 40 posmatranja, dok se metodološki pristup zasniva na kvazi-panel strukturi podataka i primjeni *pooled OLS* regresionog modela.

Polazna hipoteza istraživanja jeste da deterministički modeli mogu imati praktičnu primjenjivost u procjeni solventnosti, naročito u jednostavnijim i homogenijim portfolijima sa nižim stepenom volatilnosti, ali sami po sebi nisu dovoljni za potpuno ispunjavanje zahtjeva Solvency II. Njihova analitička i operativna vrijednost može biti unaprijeđena primjenom pseudo-stohastičkih scenarija, koji omogućavaju bolju aproksimaciju rizika i mogu predstavljati prelazni korak prema potpunijem stohastičkom modeliranju. Ovakvo definisanje hipoteze ujedno uzima u obzir mogućnost da na malom i heterogenom uzorku statistička veza između same primjene determinističkih modela i solventnosti ne mora biti snažna, odnosno statistički značajna.

Naučni doprinos istraživanja ogleda se prvenstveno u povezivanju determinističkog modeliranja, empirijske procjene solventnosti i pseudo-stohastičkog scenarijskog pristupa u uslovima ograničenog i heterogenog uzorka. Umjesto posmatranja determinističkih i stohastičkih modela kao međusobno isključivih pristupa, istraživanje razmatra mogućnost postepenog metodološkog proširenja jednostavnijeg determinističkog okvira. Poseban doprinos predstavlja primjena takvog pristupa u lokalnom i regionalnom kontekstu, u kojem raspoloživost podataka, veličina tržišta i regulatorne razlike ograničavaju mogućnost neposrednog prenošenja složenijih modela razvijenih za veća i razvijenija tržišta.

Praktični značaj istraživanja proizlazi iz mogućnosti korišćenja jednostavnijih i transparentnijih modela za interne analize, projekcije i testiranje osjetljivosti, uz jasno prepoznavanje njihovih ograničenja. Takav pristup ne podrazumijeva zamjenu stohastičke kvantifikacije rizika determinističkim modelima, već određivanje područja u kojem deterministički modeli mogu imati pomoćnu analitičku vrijednost. Time se nastoji uspostaviti ravnoteža između regulatornih zahtjeva, metodološke pouzdanosti i praktičnih mogućnosti njihove primjene u konkretnim tržišnim uslovima.

MATERIJALI I METODE

Empirijsko istraživanje zasnovano je na podacima četiri osiguravajuća društva koja posluju na tržištima Bosne i Hercegovine i Republike Hrvatske. Uzorak obuhvata Sarajevo osiguranje i Wiener osiguranje iz Bosne i Hercegovine, te Agram Life i Allianz iz Republike Hrvatske. Posmatrani period obuhvata deset godina, od 2014. do 2023. godine, tako da je formiran uravnotežen kvazi-panel sa ukupno 40 opservacija. Uključivanje društava sa dva tržišta omogućilo je istovremeno sagledavanje vremenske i međudruštvene dimenzije podataka, kao i razlika koje proizlaze iz specifičnosti regulatornog okruženja.

Podaci korišćeni u istraživanju zasnovani su na javno dostupnim finansijskim izvještajima posmatranih osiguravajućih društava, publikacijama nadzornih institucija i standardizovanim statističkim pokazateljima relevantnim za aktuarske i finansijske procjene. Finansijski i tehnički parametri prikupljeni su iz godišnjih izvještaja društava i izvora nadzornih institucija, nakon čega su strukturirani u oblik pogodan za ekonometrijsku analizu. Kontinuitet serija provjeren je za cijeli posmatrani period, pri čemu u formiranom skupu podataka nisu identifikovani nedostajući podaci.

Osnovu empirijskog pristupa predstavlja ispitivanje odnosa između pokazatelja solventnosti i odabranih faktora za koje se pretpostavlja da mogu uticati na njegovu vrijednost. Zavisna varijabla Y predstavlja koeficijent solventnosti osiguravajućeg društva, odnosno odnos raspoloživih vlastitih sredstava i regulatorno zahtijevanog solventnosnog kapitala (SCR), izražen kao količnik. Kao objašnjavajuće varijable korišćeni su nivo primjene determinističkih modela ($\mathbf{X}_1$), kamatna stopa ($\mathbf{X}_2$), godišnja promjena smrtnosti ($\mathbf{X}_3$) i *dummy* varijabla zemlje ($\mathbf{X}_4$).

Varijabla X_1 operacionalizovana je kao pokazatelj nivoa primjene determinističkih modela. U osnovnom skupu podataka vrijednost 0 označava period bez primjene modela, dok vrijednost 1 označava njihovu primjenu. U scenarijskom dijelu istraživanja korišćena je i vrijednost 0,5, koja predstavlja djelimičnu primjenu modela. Ovakva operacionalizacija omogućava uključivanje kvalitativne promjene u metodologiji procjene u kvantitativni model, ali istovremeno predstavlja pojednostavljenje stvarnog nivoa integracije aktuarskih modela u poslovne procese društva. Zbog toga se rezultati povezani sa ovom varijablom tumače uz odgovarajući metodološki oprez.

Varijabla X_2 predstavlja kamatnu stopu izraženu u procentima i uključena je zbog značaja diskontovanja budućih obaveza u životnom osiguranju. Promjene kamatnih stopa utiču na sadašnju vrijednost dugoročnih obaveza, zbog čega predstavljaju relevantan finansijski faktor u analizi solventnosti. U posmatranom periodu, ova varijabla istovremeno odražava dugoročnu promjenu kamatnog okruženja na analiziranim tržištima.

Varijabla X_3 predstavlja godišnju promjenu smrtnosti izraženu u procentima. Uključivanjem ove varijable nastoji se obuhvatiti biometrijska komponenta rizika karakteristična za životno osiguranje. Vrijednosti mogu biti pozitivne ili negativne, u zavisnosti od smjera godišnje promjene smrtnosti. Time se u model istovremeno uključuju finansijski i demografski faktori koji mogu biti povezani sa promjenama solventnosti.

Posebna kontrolna varijabla X_4 uvedena je radi razlikovanja regulatornog i tržišnog okruženja u kojem posluju posmatrana društva. Definisana je kao binarna *dummy* varijabla, pri čemu vrijednost 0 označava Bosnu i Hercegovinu, a vrijednost 1 Republiku Hrvatsku. Njeno uključivanje omogućava kontrolu sistemskih razlika između dva tržišta, posebno imajući u vidu da hrvatska društva od 2016. godine posluju u okviru pune primjene Solvency II, dok je regulatorno okruženje u Bosni i Hercegovini drugačije. Definicija, uloga i način operacionalizacije varijabli korišćenih u empirijskoj analizi prikazani su u Tabeli 1.

Osnovni ekonometrijski model može se prikazati u opštem obliku:

$$Y_{it} = \beta_0 + \beta_1 X_{1it} + \beta_2 X_{2it} + \beta_3 X_{3it} + \beta_4 X_{4it} + \varepsilon_{it} \quad (1)$$

gdje Y_{it} predstavlja pokazatelj solventnosti društva *i* u godini *t*, β_0 konstantu modela, $\beta_1 - \beta_4$ koeficijente uz odgovarajuće objašnjavajuće varijable, a ε_{it} slučajnu grešku.

S obzirom na to da mali broj posmatranih društava i relativno kratak vremenski period, u empirijskoj analizi primijenjen je pooled OLS pristup sa robusnim standardnim greškama. Ovakav izbor omogućava zajedničku procjenu raspoloživih opservacija, dok je heterogenost između dva tržišna okruženja djelimično obuhvaćena uključivanjem dummy varijable zemlje. Pored zajedničkog modela, procijenjeni su i zasebni regresioni modeli za svako osiguravajuće društvo, čime je omogućeno dodatno sagledavanje razlika u smjeru i intenzitetu povezanosti posmatranih varijabli sa solventnošću.

Pored zajedničkog regresionog modela, izvršena je i analiza na nivou pojedinačnih društava radi sagledavanja specifičnosti odnosa između solventnosti i odabranih faktora. Ovaj dio istraživanja ima dopunsku funkciju: zajednički model koristi se za procjenu prosječnih odnosa u cijelom uzorku, dok pojedinačne analize omogućavaju provjeru u kojoj mjeri se ti odnosi razlikuju između društava. Na taj način izbjegava se zaključivanje isključivo na osnovu agregatnog rezultata u uslovima relativno heterogenog uzorka.

S obzirom na to da je ograničen broj opservacija, osnovna regresiona analiza dopunjena je bootstrap metodom radi dodatne provjere stabilnosti procijenjenih parametara. Primjena ove metode posebno je značajna u uslovima malog uzorka, kakav je prisutan u ovom istraživanju, jer omogućava da se pouzdanost regresionih procjena sagleda i kroz njihovu empirijsku varijabilnost, a ne samo na osnovu rezultata dobijenih iz početnog uzorka. Na taj način bootstrap predstavlja dopunu osnovnoj regresionoj analizi i omogućava detaljnije sagledavanje neizvjesnosti povezane sa procijenjenim koeficijentima.

Bootstrap analiza zasnovana je na sedam replikacija. Imajući u vidu ograničen broj ponavljanja, dobijene bootstrap percentile i intervale treba tumačiti prvenstveno deskriptivno, kao dopunsku provjeru stabilnosti procijenjenih parametara, a ne kao osnov za snažnu statističku inferenciju.

Za razumijevanje pozicije pseudo-stohastičkog pristupa potrebno je napraviti razliku u odnosu na punu Monte Carlo simulaciju.

U ovom istraživanju, međutim, nije primijenjena puna Monte Carlo simulacija sa eksplicitno definisanim distribucijama svih ulaznih varijabli i velikim brojem slučajno generisanih putanja. Umjesto toga, zadržana je struktura prethodno procijenjenih regresionih modela, dok je neizvjesnost budućih ishoda uvedena kroz ograničen skup unaprijed definisanih varijacija ključnih ulaznih parametara. Takav pristup u radu je označen kao pseudo-stohastički, jer zadržava transparentnost i relativnu jednostavnost determinističkog scenarijskog pristupa, ali omogućava da se rezultat više ne posmatra isključivo kroz jednu tačkastu projekciju, već kroz raspon mogućih scenarijskih ishoda.

Radi proširenja determinističkog pristupa, u završnoj fazi empirijske analize primijenjeni su pseudo-stohastički scenariji. Njihova svrha je uvođenje elementa neizvjesnosti bez promjene osnovne strukture procijenjenog regresionog modela. Umjesto jedne tačkaste projekcije, ključne ulazne varijable variraju kroz unaprijed definisan skup vrijednosti, čime se formira ograničena mreža scenarija (scenario-grid).

Za 2024. godinu definisana su tri stanja ključnih ulaza: nivo primjene determinističkog modela (X_1), kamatna stopa (X_2) i promjena smrtnosti (X_3). Za svaku kombinaciju ulaznih vrijednosti procjenjuje se odgovarajuća vrijednost pokazatelja solventnosti korišćenjem prethodno procijenjenih regresionih koeficijenata. Iz tako formiranog skupa ishoda određuju se percentili P5, P25, P50, P75 i P95, pri čemu P50 predstavlja medijalnu projekciju, dok rasponi P25–P75 i P5–P95 pružaju informacije o užem i širem rasponu mogućih rezultata.

Istraživanje je organizovano kroz četiri međusobno povezana analitička koraka: (1) zajedničku pooled OLS procjenu, (2) regresione analize pojedinačnih društava, (3) bootstrap provjeru stabilnosti procijenjenih parametara i (4) pseudo-stohastičku scenarijsku analizu osjetljivosti budućih ishoda. Operacionalizacija varijabli korišćenih u empirijskom modelu prikazana je u Tabeli 1.

Tabela 1: Operacionalizacija Y, X_1–X_4

Oznaka	Varijabla	Uloga u modelu	Način mjerenja / kodiranja
Y	Koeficijent solventnosti	Zavisna varijabla	Pokazatelj solventnosti osiguravajućeg društva
X1	Primjena deterministiških modela	Nezavisna varijabla	0 = bez primjene; 1 = primjena*
X2	Kamatna stopa	Nezavisna varijabla	Kamatna stopa izražena u %
X3	Promjena smrtnosti	Nezavisna varijabla	Godišnja promjena smrtnosti izražena u %
X4	Zemlja	Kontrolna dummy varijabla	0 = Bosna i Hercegovina; 1 = Hrvatska

REZULTATI

Empirijska analiza sprovedena je kroz četiri međusobno povezana analitička koraka. Najprije je procijenjen zajednički pooled OLS model, nakon čega su analizirani pojedinačni regresioni modeli četiri osiguravajuća društva. Stabilnost procijenjenih parametara dodatno je razmotrena residual bootstrap postupkom, dok je u završnom koraku primijenjena pseudo-stohastička scenarijska analiza radi sagledavanja osjetljivosti procijenjene solventnosti na promjene ključnih ulaznih pretpostavki. Na nivou zajedničkog uzorka procijenjena je sljedeća regresiona funkcija:

$$\widehat{Y} = 1{,}327 + 0{,}291X_1 + 0{,}049X_2 + 0{,}008X_3 - 0{,}405X_4 \qquad (2)$$

gdje X_1 predstavlja primjenu deterministiških modela, X_2 kamatnu stopu, X_3 promjenu smrtnosti, a X_4 dummy varijablu zemlje, pri čemu vrijednost 0 označava Bosnu i Hercegovinu, a vrijednost 1 Hrvatsku.

Rezultati pokazuju da koeficijent uz varijablu primjene deterministiških modela X_1 iznosi 0,2915 i statistički je značajan (t=3,0997; p=0,00381). Interval pouzdanosti od 95% kreće se od 0,1006 do 0,4824 i ne obuhvata nulu. U okviru procijenjenog modela, prelazak sa vrijednosti 0 na 1 za X_1 povezan je sa prosječnim povećanjem pokazatelja solventnosti za približno 0,291 jedinicu, uz ostale varijable nepromijenjene. Ovaj rezultat predstavlja najvažniji empirijski nalaz zajedničkog modela, jer pokazuje statistički potvrđenu pozitivnu povezanost između primjene deterministiških modela i solventnosti u posmatranom uzorku.

Koeficijent uz kamatnu stopu X_2 takođe je pozitivan i iznosi 0,0489, ali nije statistički značajan (t=1,2897; p=0,2056). Njegov 95% interval pouzdanosti obuhvata nulu (od –0,0281 do 0,1258). Slično tome, koeficijent uz promjenu smrtnosti X_3 iznosi 0,0078 i nije statistički značajan (t=1,1772; p=0,2471). Prema tome, na osnovu ovog uzorka ne može se potvrditi statistički značajan samostalan odnos kamatne stope i promjene smrtnosti sa solventnošću nakon kontrole ostalih varijabli.

Posebno izražen rezultat dobijen je za *dummy* varijablu zemlje X_4. Koeficijent iznosi –0,4052 i visoko je statistički značajan (t=–7,9353; p<0,001), uz 95% interval pouzdanosti od –0,5089 do –0,3015. Budući da je Bosna i Hercegovina kodirana vrijednošću 0, a Hrvatska vrijednošću 1, rezultat pokazuje da je, uz ostale faktore nepromijenjene, procijenjeni pokazatelj solventnosti hrvatskih društava u analiziranom uzorku u prosjeku niži za približno 0,405 jedinica. Ovaj koeficijent treba tumačiti kao razliku povezanu sa

pripadnošću zemlji u okviru konkretnog modela, a ne kao izolovani efekat regulatornog režima, jer varijabla zemlje može obuhvatati i druge tržišne i institucionalne razlike između dva posmatrana tržišta.

Objašnjavajuća moć zajedničkog modela je relativno visoka. Koeficijent determinacije iznosi $R^2 = 0.6871$, odnosno uključene varijable objašnjavaju približno 68,7% varijacije pokazatelja solventnosti u posmatranom uzorku. Standardna greška regresije iznosi 0,1579, dok je vrijednost F-statistike 19,21. Prema rezultatima, model je kao cjelina statistički značajan. Rezultati zajedničkog pooled OLS modela prikazani su u Tabeli 2.

Tabela 2. Rezultati zajedničkog pooled OLS modela

Varijabla	Koeficijent β	Standardna greška	t-statistika	p-vrijednost	95% CI
Konstanta	1.3268	0,1689	7.8559	<0,001	[0,9839; 1,6696]
X1 – deterministički	0,2915	0,0940	3.0997	0,0038	[0,1006; 0,4824]
X2 – kamatna stopa	0,0489	0,0379	1.2897	0,2056	[−0,0281; 0,1258]
X3 – promjena smrt	0,0078	0,0066	1.1772	0,2471	[−0,0057; 0,0213]
X4 – zemlja	−0,4052	0,0511	−7,9353	<0,001	[−0,5089; −0,3015]

Rezultati zajedničkog modela, međutim, predstavljaju prosječne odnose za četiri društva i dva različita tržišna i regulatorna okruženja. Zbog toga su dodatno analizirani rezultati pojedinačnih društava, koji pokazuju da jačina i smjer procijenjenih odnosa nisu jednaki u cijelom uzorku.

Kod Sarajevo osiguranja procijenjena je regresiona funkcija:

$$\hat{Y} = 4{,}03388 - 0{,}14135X_1 - 0{,}77318X_2 - 0{,}02977X_3 \qquad (3)$$

Model ima visoku objašnjavajuću moć, sa $R^2 = 0{,}9211$ i prilagođenim $R^2 = 0{,}8817$. F-statistika iznosi 23,364 uz pripadajuću p-vrijednost 0,00104, što pokazuje statističku značajnost modela kao cjeline. Od pojedinačnih varijabli posebno se izdvaja kamatna stopa, čiji koeficijent iznosi –0,77318 uz p-vrijednost 0,001807. Nasuprot tome, koeficijent uz primjenu determinističkog modela iznosi –0,14135 (p=0,283128), dok koeficijent uz promjenu smrtnosti iznosi –0,02977 (p=0,591824). Prema tome, u ovom pojedinačnom modelu nije utvrđena statistička značajnost posljednje dvije varijable na nivou od 5%.

Kretanje koeficijenta solventnosti Sarajevo osiguranja tokom posmatranog perioda prikazano je na Grafikonu 1. Uočljiv je opšti rast pokazatelja solventnosti, uz manja odstupanja u pojedinim godinama i blagi pad u 2023. godini. [Grafikon 1 ovdje]

Rezultati za Wiener osiguranje pokazuju nešto drugačiju strukturu. Kod Wiener osiguranja procijenjena je regresiona funkcija:

$$\widehat{Y_w} = 1{,}42114 + 0{,}25469X_1 + 0{,}02251X_2 + 0{,}15335X_3 \qquad (4)$$

Koeficijent determinacije iznosi $R^2 = 0{,}7153$, dok je model kao cjelina statistički značajan (F=5,026; p=0,04472). Procijenjeni koeficijent uz primjenu determinističkih modela pozitivan je i iznosi 0,2547, ali nije statistički značajan na nivou od 5% (p=0,1830). Koeficijent uz kamatnu stopu iznosi 0,0225 (p=0,9163), dok je koeficijent uz promjenu smrtnosti 0,1534, sa p-vrijednošću 0,0843. Posljednji rezultat ukazuje na izraženiji odnos u odnosu na ostale objašnjavajuće varijable, ali takođe ne dostiže prag statističke značajnosti od 5%.

Kod Agram Life osiguranja dobijena je funkcija:

$$\widehat{Y_{ag}} = 1{,}355 + 0{,}023X_1 - 0{,}011X_2 - 0{,}003X_3 \quad (5)$$

Koeficijent determinacije iznosi $R^2 = 0{,}4476$, a prilagođeni $R^2 = 0{,}1713$. F-statistika iznosi 1,6203 uz p-vrijednost 0,2811, tako da model kao cjelina nije statistički značajan na nivou od 5%. Pozitivan koeficijent uz X_1 iznosi 0,0231, ali je njegova p-vrijednost 0,7503. Ni kamatna stopa (p=0,5850) ni promjena smrtnosti (p=0,4203) nisu statistički značajne u ovom pojedinačnom modelu.

Slična ograničenja uočavaju se kod Allianz Hrvatska. Kod Allianz osiguranja je dobijena sljedeća funkcija:

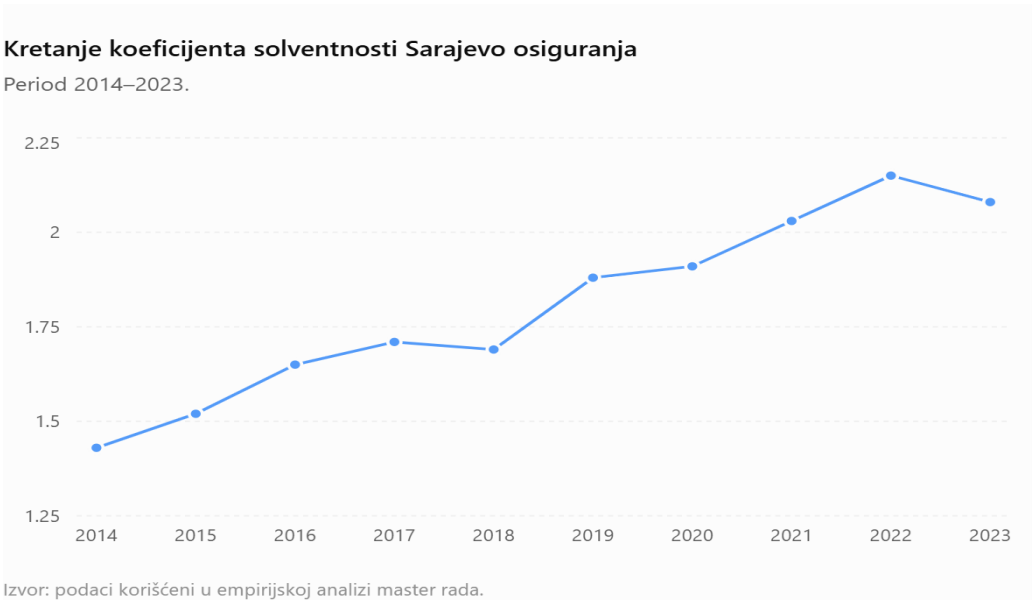
$$\widehat{Y_{al}} = 1{,}2383 + 0{,}0046X_1 - 0{,}0036X_2 - 0{,}0007X_3 \quad (6)$$

Model objašnjava približno 33,6% varijacije solventnosti R^2=0,336, dok prilagođeni koeficijent determinacije iznosi svega 0,0045. F-statistika iznosi 1,0136 uz p-vrijednost 0,4497. Koeficijent uz primjenu deterministčkih modela je pozitivan (0,0046), ali nije statistički značajan (p=0,8438). Isto važi za kamatnu stopu (–0,0036; p=0,5997) i promjenu smrtnosti (–0,0007; p=0,5338). Uporedni pregled procijenjenih koeficijenata i statističke značajnosti pojedinačnih modela dat je u Tabeli 3.

Društvo	β1 – X1	p(X1)	β2 – X2	p(X2)	β3 – X3	p(X3)	R^2	p(F)
Sarajevo osiguranje	–0,1414	0,2831	–0,7732	0,0018	–0,0298	0,5918	0,9211	0,0010
Wiener osiguranje	0,2547	0,1830	0,0225	0,9163	0,1534	0,0843	0,7153	0,0447
Agram Life	0,0231	0,7503	–0,0116	0,5850	–0,0028	0,4203	0,4476	0,2811
Allianz Hrvatska	0,0046	0,8438	–0,0036	0,5997	–0,0007	0,5338	0,3363	0,4497

Tabela 3. Uporedni rezultati pojedinačnih regresionih modela

Heterogenost procijenjene povezanosti primjene deterministčkih modela sa solventnošću dodatno je vidljiva na Grafikonu 2. Koeficijent uz X_1 negativan je kod Sarajevo osiguranja, a pozitivan kod preostala tri društva, pri čemu nijedan pojedinačni koeficijent



Izvor: podaci korišćeni u empirijskoj analizi master rada.

Grafikon 2: Koeficijent uz primjenu deterministčkih modela (X1) po društvima

nije statistički značajan na nivou od 5%.

Poređenje pojedinačnih regresija, dakle, pokazuje izraženu heterogenost rezultata. Objašnjavajuća moć modela kreće se od 33,6% kod Allianz Hrvatska do 92,1% kod Sarajevo osiguranja. Još važnije, efekat varijable X_1 nije jednoznačan: koeficijent je negativan kod Sarajevo osiguranja, a pozitivan kod Wiener, Agram Life i Allianz osiguranja, ali ni u jednom od četiri pojedinačna modela nije statistički značajan na nivou od 5%. Ovakav nalaz je posebno važan za dalje tumačenje rezultata i biće detaljnije razmotren u poglavlju Diskusija.

Zbog ograničenog broja opservacija u pojedinačnim regresionim modelima, rezultati su dodatno analizirani primjenom residual bootstrap metode. Cilj ove analize bio je da se ispita stabilnost procijenjenih regresionih koeficijenata pri ponovljenom uzorkovanju reziduala i da se utvrdi u kojoj mjeri zaključci izvedeni iz osnovnih regresionih modela zavise od strukture raspoloživog uzorka. Bootstrap rezultati stoga predstavljaju dopunu, a ne zamjenu za rezultate osnovne regresione analize.

Kod Sarajevo osiguranja bootstrap analiza ukazuje na različit stepen stabilnosti procijenjenih parametara. Dok osnovni regresioni model za X_1 daje negativan koeficijent, bootstrap medijan ovog parametra je pozitivan, a empirijski 95% interval obuhvata nulu. Zbog toga bootstrap rezultati ne potvrđuju stabilnost smjera veze između X_1 i solventnosti. Kod X_2 empirijski bootstrap interval ne obuhvata nulu, dok intervali za X_1 i X_3 obuhvataju nultu vrijednost. Imajući u vidu ograničen broj bootstrap replikacija, ove rezultate treba tumačiti prvenstveno kao deskriptivni pokazatelj stabilnosti procijenjenih parametara, a ne kao osnov za snažnu statističku inferenciju.

Za Wiener osiguranje osnovni regresioni model pokazao je pozitivan koeficijent uz X_1, ali nijedna pojedinačna objašnjavajuća varijabla nije bila statistički značajna na nivou od 5%. Bootstrap analiza u ovom slučaju dodatno ukazuje na potrebu razlikovanja smjera procijenjene veze od njene statističke preciznosti. Pozitivan pravac veze između X_1 i solventnosti može se uočiti i u ponovljenim procjenama, ali varijabilnost bootstrap rezultata pokazuje da zaključak o veličini i pouzdanosti ovog efekta treba donositi oprezno. Slično se odnosi i na promjenu smrtnosti (X_3), koja je u osnovnoj regresiji pokazivala izraženiji pozitivan koeficijent i bila bliža statističkoj značajnosti od ostalih objašnjavajućih varijabli, ali bez dovoljne empirijske osnove da bi se njen efekat smatrao stabilno utvrđenim.

Kod Agram Life osiguranja osnovni regresioni model imao je nižu objašnjavajuću snagu, a model kao cjelina nije bio statistički značajan. Nijedan pojedinačni regresioni koeficijent nije pokazao statističku značajnost na nivou od 5%. Bootstrap rezultati potvrđuju relativnu stabilnost centralnih vrijednosti pojedinih procjena, ali istovremeno ukazuju na ograničenu statističku preciznost usljed malog uzorka i relativno male varijabilnosti posmatranih ulaznih varijabli. Posebno je kod promjene smrtnosti (X_3) zabilježena veoma mala centralna vrijednost bootstrap procjene, dok raspon dobijenih vrijednosti obuhvata i pozitivne i negativne vrijednosti. Slična neizvjesnost prisutna je i kod ostalih objašnjavajućih varijabli. Zbog toga se bootstrap rezultat za Agram Life prije može tumačiti kao potvrda potrebe za oprezom u interpretaciji osnovnog regresionog modela nego kao potvrda snažnog i jednoznačnog uticaja pojedinačnih faktora.

Rezultati za Allianz Hrvatska takođe ukazuju na relativno ograničenu varijabilnost procijenjenih vrijednosti, ali uz slabu statističku snagu pojedinačnih regresionih koeficijenata. Osnovni model imao je najnižu objašnjavajuću snagu među posmatranim društvima i nije bio statistički značajan kao cjelina, dok X_1, X_2 i X_3 pojedinačno nisu bili statistički značajni. Bootstrap analiza u takvim okolnostima ne mijenja osnovni zaključak regresione analize: relativna stabilnost određenog predznaka ili centralne vrijednosti koeficijenta nije sama po sebi dovoljna da se zaključi da postoji statistički pouzdana veza sa solventnošću. Rezultati prije ukazuju na relativnu stabilnost solventnosti ovog društva u posmatranom periodu i na ograničenu sposobnost raspoloživih objašnjavajućih varijabli da objasne njene promjene. Uporedni prikaz ključnih rezultata bootstrap analize za sva četiri osiguravajuća društva dat

je u Tabeli 4.

Tabela 4. Uporedni rezultati bootstrap analize regresionih koeficijenata po osiguravajućim društvima

Osiguravajuće društvo	Koeficijent	Bootstrap medijan	Donja granica 95% CI (2,5%)	Gornja granica 95% CI (97,5%)	Ocjena rezultata
Sarajevo osiguranje	β1 (X1)	0,07484	−0,04022	0,13960	interval obuhvata 0
	β2 (X2)	0,09165	0,00691	0,25218	interval ne obuhvata 0
	β3 (X3)	0,00909	−0,03674	0,06937	interval obuhvata 0
Wiener osiguranje	β1 (X1)	0,32399	0,06819	0,38984	interval ne obuhvata 0
	β2 (X2)	0,15154	−0,23925	0,26060	interval obuhvata 0
	β3 (X3)	0,11694	0,08499	0,27881	interval ne obuhvata 0
Agram Life	β1 (X1)	0,01777	−0,12029	0,07670	interval obuhvata 0
	β2 (X2)	−0,00202	−0,02930	0,01817	interval obuhvata 0
	β3 (X3)	−0,00125	−0,00446	0,00381	interval obuhvata 0
Allianz Hrvatska	β1 (X1)	0,00589	−0,02636	0,04335	interval obuhvata 0
	β2 (X2)	0,00136	−0,00761	0,01246	interval obuhvata 0
	β3 (X3)	0,00049	−0,00132	0,00250	interval obuhvata 0

Posmatrani zajedno, bootstrap rezultati pokazuju da stabilnost procijenjenih parametara nije jednaka kod svih društava niti kod svih objašnjavajućih varijabli. To je u skladu sa rezultatima pojedinačnih regresionih modela, koji su već pokazali značajnu heterogenost između četiri analizirana osiguravača. Posebno je važno da bootstrap analiza ne daje osnov za zaključak da je koeficijent uz X_1 statistički značajan kod svakog pojedinačnog društva. Naprotiv, ona pokazuje da se smjer i centralna vrijednost pojedinih procjena mogu održavati kroz ponovljena uzorkovanja, dok njihova statistička preciznost ostaje ograničena. Time se dodatno potvrđuje opravdanost razlikovanja rezultata zajedničkog pooled modela, u kojem je X_1 statistički značajan, od rezultata pojedinačnih društava, kod kojih takva značajnost nije utvrđena.

Drugi dio empirijske analize odnosio se na proširenje tačkastih deterministčkih procjena pomoću pseudo-stohastičkih scenarija. Za različite nivoe primjene modela i vrijednosti kamatnih stopa generisani su alternativni ishodi, iz kojih su određeni percentili P5, P25, P50, P75 i P95. Time je omogućeno sagledavanje, ne samo centralne procjene solventnosti, već i raspona rezultata koji nastaju usljed promjene ulaznih pretpostavki.

Kod Sarajevo osiguranja scenarijska analiza pokazuje relativno širok raspon rezultata. Pri vrijednosti X_1=0 medijalna vrijednost P50 iznosi 2,2794, dok pri djelimičnoj primjeni X_1=0,5 pada na 2,2087, a pri potpunoj primjeni X_1=1 na 2,1380. Raspon P95–P5 iznosi približno 0,4871, dok interkvartilni raspon P75–P25 iznosi 0,2706. Rezultati tako zadržavaju negativan smjer koeficijenta uz X_1 dobijen u pojedinačnoj regresiji Sarajevo osiguranja.

Kod Wiener osiguranja obrazac je suprotan. Medijalna procjena P50 raste sa 1,3502 bez primjene modela, preko 1,4776 kod djelimične primjene, do 1,6049 kod potpune primjene. Istovremeno je raspon P95–P5 približno 0,0142, a P75–P25 oko 0,0079, što pokazuje znatno manju varijaciju scenarijskih rezultata nego kod Sarajevo osiguranja.

Pseudo-stohastički rezultati za hrvatska društva takođe pokazuju relativno uske raspone. Kod Agram Life povećanje X_1 sa 0 na 1 povećava centralnu procjenu sa približno 1,328–1,336 na približno 1,351–1,359, zavisno od posmatrane kamatne stope i percentila. Kod Allianz Hrvatska promjene su još manje: P50 raste sa 1,2356 pri X_1=0, preko 1,2379 pri X_1=0,5, do 1,2402 pri X_1=1 dok P95–P5 iznosi svega oko 0,0023.

Scenarijska analiza time potvrđuje da se osjetljivost procijenjene solventnosti znatno razlikuje između posmatranih društava. Sarajevo osiguranje pokazuje najveći raspon između donjih i gornjih percentila, dok su kod Wiener, Agram Life i naročito Allianz Hrvatska intervali znatno uži. Istovremeno se razlikuje i smjer promjene povezane sa X_1: kod Sarajevo osiguranja procijenjena solventnost opada sa povećanjem nivoa primjene determinističkog modela, dok kod ostala tri društva raste. Ovi rezultati pokazuju zašto zaključivanje samo na osnovu jedne determinističke tačkaste procjene ili jednog društva može biti ograničeno.

DISKUSIJA

Rezultati zajedničkog pooled OLS modela ukazuju na statistički značajnu pozitivnu povezanost između primjene determinističkih modela i solventnosti, ali njihovo tumačenje zahtijeva uvažavanje heterogenosti posmatranih društava i ograničenja uzorka. Ipak, navedeni rezultat ne treba interpretirati kao dokaz da sama primjena determinističkog modela uzrokuje povećanje solventnosti. Varijabla X_1 predstavlja pojednostavljenu operacionalizaciju nivoa primjene modela, dok na stvarnu solventnost utiče znatno širi skup faktora koji nisu obuhvaćeni specifikacijom. Zbog toga rezultat prvenstveno pokazuje postojanje statistički značajne povezanosti u analiziranom kvazi-panel uzorku, a ne izolovani kauzalni efekat determinističkog modeliranja.

Rezultati pojedinačnih regresija dodatno potvrđuju heterogenost posmatranih društava: koeficijent uz X1 nije statistički značajan ni u jednom pojedinačnom modelu, a njegov predznak razlikuje se između društava. Ove razlike mogu biti povezane sa karakteristikama portfolija, kapitalne pozicije i tržišnog okruženja, ali raspoloživi podaci ne omogućavaju precizno izdvajanje njihovih pojedinačnih uticaja. Značajan rezultat zajedničkog modela predstavlja i varijabla zemlje. Negativan i statistički značajan koeficijent X_4 ukazuje na postojanje sistematske razlike u pokazatelju solventnosti između društava iz Bosne i Hercegovine i Hrvatske u posmatranom uzorku. Međutim, ovu razliku nije opravdano pripisati isključivo regulatornom okviru. Varijabla zemlje istovremeno može obuhvatati razlike u strukturi tržišta, portfoliju, kapitalnoj poziciji, poslovnim praksama i drugim institucionalnim karakteristikama koje nisu posebno uključene u model. Regulatorna heterogenost je ipak relevantna za interpretaciju, budući da Hrvatska primjenjuje Solvency II kao članica Evropske unije, dok se društva iz Bosne i Hercegovine posmatraju u drugačijem regulatornom okruženju.

Kamatna stopa X_2 i promjena smrtnosti X_3 u zajedničkom modelu nisu statistički značajne na nivou od 5%. To ne znači da kamatni i biometrijski rizik nisu relevantni za životno osiguranje, već samo da u konkretnoj specifikaciji i posmatranom uzorku nije utvrđen njihov statistički značajan samostalan odnos sa pokazateljem solventnosti nakon kontrole ostalih uključenih varijabli. Posebno je ilustrativan rezultat Sarajevo osiguranja, gdje je kamatna stopa statistički značajna i ima snažan negativan koeficijent. Time se ponovo pokazuje da agregirani rezultat može prikriti specifične obrasce pojedinačnih društava.

Dobijeni rezultati mogu se posmatrati u širem kontekstu aktuarske literature koja ukazuje na potrebu istovremenog uvažavanja praktične vrijednosti determinističkih projekcija i ograničenja koja proizlaze iz njihove nemogućnosti da u potpunosti obuhvate neizvjesnost budućih kretanja. Lee i Carter (1992), kroz modeliranje mortaliteta pomoću vremenski promjenjive komponente, pokazali su značaj sistematskog povezivanja istorijskih obrazaca smrtnosti sa projekcijama budućih kretanja, dok Lee (2000) dodatno razmatra mogućnosti proširenja i primjene ovog pristupa. Iako predmet ovog istraživanja nije neposredno procjenjivanje Lee-Carter modela, rezultati koji pokazuju različitu osjetljivost solventnosti na promjene ulaznih pretpostavki podržavaju širi zaključak da

tačkasta projekcija ne daje potpunu informaciju o neizvjesnosti budućih ishoda. Zbog toga determinističke procjene imaju značajnu analitičku vrijednost, ali ih je potrebno posmatrati zajedno sa analizom osjetljivosti i mogućih odstupanja od baznih pretpostavki (Lee & Carter, 1992; Lee, 2000).

Slična metodološka poruka prisutna je i u savremenoj aktuarskoj literaturi. Dickson et al. (2013) naglašavaju značaj modeliranja životnih osiguranja u uslovima neizvjesnosti i potrebu adekvatnog vrednovanja rizika koji proizlaze iz dugoročnosti ugovora, dok Macdonald et al. (2018) detaljno razmatraju mortalitet kao stohastički fenomen i ograničenja oslanjanja na jednu očekivanu putanju njegovog budućeg kretanja. U tom kontekstu, činjenica da promjena smrtnosti u zajedničkom modelu ovog istraživanja nije statistički značajna ne znači da mortalitetni rizik nema aktuarski značaj. Rezultat prije pokazuje da, u raspoloživom uzorku i uz primijenjenu specifikaciju modela, nije utvrđena dovoljno snažna neposredna povezanost godišnje promjene smrtnosti sa posmatranim pokazateljem solventnosti. Ovo razlikovanje je posebno važno kod životnog osiguranja, gdje se efekti promjena mortaliteta mogu ispoljavati tokom dužeg perioda i kroz interakciju sa strukturom portfolija, rezervama i drugim faktorima.

Rezultate treba posmatrati i u kontekstu regulatorne logike Solvency II. Ovaj okvir polazi od pristupa zasnovanog na riziku i zahtijeva da procjena kapitalne adekvatnosti bude povezana sa stvarnim profilom rizika osiguravača, zbog čega jedna centralna projekcija nije dovoljna za potpuno sagledavanje mogućih nepovoljnih ishoda (European Commission, 2009; EIOPA, 2021). Rezultati ovog istraživanja nisu u suprotnosti sa takvim pristupom. Statistički značajna pozitivna povezanost X1 i solventnosti u zajedničkom modelu pokazuje da primjena determinističkih modela može imati praktičnu informativnu vrijednost, ali heterogenost pojedinačnih regresija istovremeno pokazuje da se njihov doprinos ne može generalizovati na sva društva. Pseudo-stohastička scenarijska analiza zbog toga ne predstavlja alternativu punom stohastičkom modeliranju zahtijevanom u odgovarajućim segmentima Solvency II okvira, već dopunski analitički instrument kojim se transparentno prikazuje osjetljivost procijenjene solventnosti na promjene ključnih pretpostavki.

Ovakav zaključak ima poseban značaj u kontekstu tržišta Bosne i Hercegovine i drugih tržišta sa ograničenijim podacima i različitim stepenom regulatornog razvoja. Domaća i regionalna literatura ukazuje na značaj postepenog usklađivanja prakse osiguranja sa zahtjevima Solvency II, uz uvažavanje institucionalnih i tržišnih specifičnosti (Baškot, 2012; Imamović, 2022; Pavlović, 2023). Rezultati ovog istraživanja dodatno ukazuju da se metodološki razvoj ne mora posmatrati kao izbor između jednostavnog determinističkog i potpuno stohastičkog pristupa. Za društva koja raspolažu kraćim vremenskim serijama i ograničenim analitičkim resursima moguće je postepeno proširivati osnovni deterministički okvir provjerom stabilnosti parametara i scenarijskom analizom osjetljivosti. Takav pristup ne uklanja potrebu za razvijenijim stohastičkim modeliranjem, ali može predstavljati praktičan međukorak u unapređenju procjene rizika i razvoju analitičkih kapaciteta.

Pseudo-stohastička scenarijska analiza dodatno ukazuje na različitu osjetljivost solventnosti posmatranih društava na promjene ulaznih pretpostavki. Njena praktična vrijednost ogleda se u proširenju determinističke tačkaste procjene i transparentnom prikazu raspona scenarijskih ishoda, posebno u uslovima ograničenih podataka i analitičkih resursa. Ipak, dobijene percentile treba tumačiti kao pokazatelje osjetljivosti, a ne kao probabilističke mjere rizika karakteristične za potpuno stohastičko modeliranje. Posmatrani zajedno, regresioni i scenarijski rezultati pružaju podršku centralnoj hipotezi istraživanja, ali zahtijevaju njeno nijansirano tumačenje. Statistički značajan pozitivan koeficijent X_1 u zajedničkom modelu pokazuje da deterministički pristup ima empirijski mjerljivu povezanost sa solventnošću u posmatranom uzorku. Istovremeno, odsustvo statističke značajnosti X_1 u pojedinačnim modelima i različiti rezultati scenarijske analize pokazuju da se njegova praktična vrijednost ne može posmatrati nezavisno od karakteristika konkretnog društva.

Stoga rezultati ne opravdavaju zaključak da deterministički modeli mogu zamijeniti stohastičko modeliranje u okviru Solvency II. Njihova vrijednost je prije svega u transparentnosti, jednostavnijoj implementaciji, analizi osjetljivosti i mogućnosti primjene u okolnostima u kojima su podaci ili resursi ograničeni. U kombinaciji sa stresnim i pseudo-stohastičkim scenarijima njihova analitička vrijednost se povećava, jer omogućavaju da se tačkasta procjena proširi rasponom alternativnih ishoda. Ovakvo pozicioniranje determinističkih modela odgovara osnovnoj postavci istraživanja prema kojoj oni mogu imati praktičnu i operativnu vrijednost, ali sami po sebi nisu dovoljni za potpuno obuhvatanje rizika koje zahtijeva Solvency II.

Važno ograničenje istraživanja predstavlja veličina uzorka. Četiri društva i desetogodišnji period daju ukupno 40 opservacija, što omogućava sprovođenje zajedničke regresione analize, ali ograničava mogućnost generalizacije rezultata. Posebno su pojedinačne regresije, sa deset opservacija i tri objašnjavajuće varijable, osjetljive na mali broj stepeni slobode. Zbog toga statističku neznačajnost pojedinih koeficijenata nije opravdano automatski tumačiti kao odsustvo ekonomskog odnosa.

Dodatno ograničenje predstavlja način operacionalizacije primjene determinističkih modela. Varijabla X_1 nužno pojednostavljuje kompleksan proces primjene aktuarskih metoda i ne može obuhvatiti razlike u kvalitetu modela, stepenu integracije u upravljanje rizicima, parametrizaciji i načinu na koji pojedinačna društva koriste rezultate modeliranja. Takođe, *dummy* varijabla zemlje kontroliše dio razlika između tržišta, ali ne omogućava njihovo razlaganje na pojedinačne regulatorne, institucionalne i poslovne faktore. Zbog navedenog, rezultate treba interpretirati prvenstveno u granicama analiziranog uzorka.

Uprkos ograničenjima, istraživanje pruža empirijsku osnovu za povezivanje determinističkog modeliranja, solventnosti i scenarijske analize na primjeru životnih osiguravajućih društava iz dva različita tržišna okruženja. Posebna vrijednost pristupa ogleda se u kombinovanju zajedničke regresione procjene, analize pojedinačnih društava i pseudo-stohastičkih scenarija. Time se deterministički model ne posmatra samo kao izolovana metoda za dobijanje jedne vrijednosti, već kao polazna osnova za analizu osjetljivosti i postepeno uključivanje neizvjesnosti u procjenu solventnosti.

ZAKLJUČCI

Istraživanje je sprovedeno sa ciljem da se ispita u kojoj mjeri deterministički modeli mogu pružiti relevantne informacije za procjenu solventnosti životnih osiguravajućih društava i kakva je njihova primjenjivost u kontekstu zahtjeva Solvency II. Analiza je obuhvatila četiri osiguravajuća društva iz Bosne i Hercegovine i Hrvatske u periodu 2014–2023. godine, pri čemu je kombinovanjem zajedničkog regresionog modela, pojedinačnih analiza društava i pseudo-stohastičkih scenarija omogućeno sagledavanje kako prosječnih odnosa u uzorku, tako i heterogenosti između pojedinačnih osiguravača.

Rezultati zajedničkog pooled OLS modela pokazuju statistički značajnu pozitivnu povezanost između primjene determinističkih modela i solventnosti. Koeficijent uz varijablu X_1 iznosi 0,2915, uz p-vrijednost 0,00381, dok model objašnjava približno 68,7% varijacije pokazatelja solventnosti. Model je statistički značajan i kao cjelina. Nasuprot tome, kamatna stopa i promjena smrtnosti u zajedničkom modelu nisu pokazale statistički značajan samostalan odnos sa solventnošću. Statistički značajna varijabla zemlje ukazuje i na postojanje razlika između dva posmatrana tržišna okruženja, ali se ovaj rezultat ne može pripisati isključivo regulatornom okviru, jer varijabla zemlje obuhvata i druge tržišne i institucionalne specifičnosti.

Rezultati pojedinačnih društava istovremeno pokazuju da odnos između primjene determinističkih modela i solventnosti nije homogen. Varijabla X_1 nije statistički značajna

na nivou od 5% ni u jednom od četiri pojedinačna modela, a razlikuje se i smjer procijenjenih koeficijenata. Ovakav nalaz ukazuje da značajan rezultat zajedničkog modela treba posmatrati kao rezultat karakterističan za objedinjeni uzorak, a ne kao dokaz jednakog efekta determinističkih modela kod svakog osiguravajućeg društva. Razlike među društvima istovremeno potvrđuju značaj njihovih specifičnih poslovnih, tržišnih i kapitalnih karakteristika za procjenu solventnosti.

Pseudo-stohastička scenarijska analiza dodatno je pokazala da se osjetljivost procijenjene solventnosti razlikuje među analiziranim društvima. Najizraženiji raspon scenarijskih rezultata zabilježen je kod Sarajevo osiguranja, dok su kod Wiener, Agram Life i posebno Allianz Hrvatska dobijeni uži intervali. Primjena scenarija omogućila je da se deterministička tačkasta procjena proširi rasponom mogućih rezultata i time jasnije prikaže osjetljivost modela na promjene odabranih ulaznih pretpostavki.

Na osnovu rezultata može se zaključiti da je osnovna hipoteza istraživanja podržana. Deterministički modeli imaju praktičnu i analitičku vrijednost u procjeni solventnosti, što dodatno potvrđuje statistički značajna pozitivna povezanost X_1 i solventnosti u zajedničkom modelu. Međutim, njihova primjena sama po sebi nije dovoljna za potpuno obuhvatanje neizvjesnosti i distribucije rizika koje zahtijeva Solvency II. Ovakav zaključak odgovara osnovnoj postavci rada prema kojoj deterministički modeli mogu imati praktičnu primjenu, ali njihova puna vrijednost dolazi do izražaja kada se dopune scenarijskim i razvijenijim stohastičkim pristupima.

U tom kontekstu, pseudo-stohastički pristup može se posmatrati kao koristan metodološki most između determinističkog i potpunog stohastičkog modeliranja. Njegova prednost je mogućnost da se uz relativno jednostavnu metodologiju ispita osjetljivost rezultata i prikaže raspon alternativnih ishoda. Istovremeno, takav pristup ne predstavlja zamjenu za punu stohastičku analizu, jer se zasniva na unaprijed definisanim scenarijima i ne generiše kompletnu distribuciju mogućih ishoda. Ova razlika je posebno važna sa stanovišta Solvency II, gdje procjena kapitalne adekvatnosti zahtijeva sagledavanje neizvjesnosti i nepovoljnih, uključujući ekstremne, ishode. U izvornom istraživanju pseudo-stohastički scenariji upravo su postavljeni kao prelazni metodološki korak prema složenijim stohastičkim metodama.

Praktična vrijednost determinističkih modela zbog toga se prvenstveno može prepoznati u njihovoj jednostavnosti, transparentnosti i relativno manjim zahtjevima u pogledu podataka i analitičkih resursa. Oni mogu biti korisni za osnovne procjene, analizu osjetljivosti i interno upravljanje rizicima, naročito u uslovima ograničene dostupnosti podataka. Njihovu primjenu, međutim, treba prilagoditi karakteristikama konkretnog portfolija i dopunjavati scenarijskim ili stohastičkim metodama kada je potrebno obuhvatiti širi spektar rizika.

Buduća istraživanja trebalo bi usmjeriti na proširenje broja osiguravajućih društava i vremenskog horizonta, detaljniju operacionalizaciju nivoa primjene aktuarskih modela i uključivanje dodatnih finansijskih, biometrijskih i tržišnih faktora. Posebno značajan pravac predstavlja poređenje determinističkih rezultata sa rezultatima punih stohastičkih simulacija na istom skupu podataka. Time bi bilo moguće preciznije utvrditi u kojim uslovima jednostavniji modeli pružaju dovoljno pouzdane informacije, a u kojim je neophodan prelazak na složenije metode procjene rizika.

U konačnom, rezultati istraživanja ne upućuju na potrebu napuštanja determinističkih modela, već na njihovo odgovarajuće pozicioniranje unutar šireg sistema upravljanja rizicima. Njihova najveća vrijednost nije u zamjeni stohastičkog modeliranja, već u pružanju transparentne i operativno primjenjive osnove koja se može proširivati analizom scenarija i naprednijim metodama. Na taj način deterministički modeli mogu predstavljati praktičnu polaznu tačku za postepeno unapređenje procjene solventnosti i približavanje zahtjevima Solvency II, posebno u tržišnim okruženjima u kojima su raspoloživost podataka i ana-

litički resursi ograničeni.

LITERATURA

Anderson, L. H., Martinson, C. B., Hall, M. K., & Duncan, G. I. (2007). *Critical review of stochastic simulation literature and applications for health actuaries*. Society of Actuaries.

Baškot, B. (2012). *Modeli životnog osiguranja u uslovima konzistentnog tržišta*. Ekonomski fakultet, Univerzitet u Nišu.

Davison, A. C., & Hinkley, D. V. (1997). *Bootstrap methods and their application*. Cambridge University Press.

Dickson, D. C. M., Hardy, M. R., & Waters, H. R. (2013). *Actuarial mathematics for life contingent risks*. Cambridge University Press.

European Commission. (2009). *Directive 2009/138/EC of the European Parliament and of the Council of 25 November 2009 on the taking-up and pursuit of the business of insurance and reinsurance (Solvency II).*

European Insurance and Occupational Pensions Authority. (2021). *Review of Solvency II: A balanced update.*

European Insurance and Occupational Pensions Authority. (n.d.). *Peer review on the supervision of stochastic valuation under Solvency II.*

Imamović, E. (2022). *Spremnost BiH na uvođenje Evropske direktive Solvency II*. Adriatic osiguranje.

Lee, R. D. (2000). The Lee-Carter method for forecasting mortality, with various extensions and applications. *North American Actuarial Journal, 4*.

Lee, R. D., & Carter, L. R. (1992). Modeling and forecasting U.S. mortality. *Journal of the American Statistical Association*.

Macdonald, A. S., Richards, S. J., & Currie, I. D. (2018). *Modelling mortality with actuarial applications*. Cambridge University Press.

Pavlović, R. B. (2023). *Upravljanje rizikom solventnosti životnih osiguravača* [Doktorska disertacija, Ekonomski fakultet Univerziteta u Beogradu].

Promislow, S. D. (2015). *Fundamentals of actuarial mathematics*. York University.

Šain, Ž. (2009). *Aktuarski modeli životnog osiguranja*. Ekonomski fakultet Univerziteta u Sarajevu.

THE APPLICATION OF DETERMINISTIC MODELS IN LIFE INSURANCE FOR COMPLIANCE WITH SOLVENCY II REQUIREMENTS

Author: Rada Šormaz Đaković
e-mail: rada.sormazdjakovic7@gmail.com
Mentor: Assoc. Prof. Bojan Baškot, PhD
Faculty of Economics, University of Banja Luka

Introduction: Solvency II imposes high requirements regarding risk assessment, capital adequacy and the solvency of insurance companies. Deterministic models are traditional actuarial tools which, despite their limitations in capturing uncertainty and extreme events, may have significant practical value in life insurance risk assessment.

Aim: The aim of this research is to examine the possibilities and limitations of deterministic models in assessing the solvency of life insurance companies and to determine their adequacy in relation to Solvency II requirements.

Material and Methods: The research combines qualitative and quantitative methods. Empirical analysis covers four insurance companies from Bosnia and Herzegovina and Croatia from 2014–2023, comprising 40 observations. A quasi-panel dataset was constructed, while the effects of deterministic model application, interest rates, mortality changes and the regulatory environment on solvency were analysed using a pooled OLS regression model. Scenario analyses and pseudo-stochastic scenarios were additionally applied to assess the sensitivity of the results to changes in key parameters.

Results: The pooled OLS model indicates a statistically significant positive association between the application of deterministic models and solvency, as well as statistically significant differences associated with the country in which the insurer operates, while the interest rate and changes in mortality are not statistically significant in the pooled model. The analyses of individual insurance companies indicate heterogeneity in the results. Additional bootstrap and pseudo-stochastic analyses provide further insight into the stability of the estimated parameters and the sensitivity of solvency to changes in key assumptions.

Conclusion: Deterministic models can provide a useful and transparent tool for solvency assessment, particularly when data availability is limited. However, they are not sufficient on their own to fully meet Solvency II requirements. Their combination with pseudo-stochastic scenarios may provide a transitional methodological step towards more complex stochastic models and more comprehensive risk quantification.

Keywords: Solvency II; life insurance; deterministic models; solvency; quasi-panel data; pooled OLS; pseudo-stochastic scenarios