

Izvorni znanstveni rad/Original scientific paper  
UDK/UDC 368.91(4-67 EU)

# Determinante potražnje za životnim osiguranjem u novim zemljama članicama Europske unije: analiza panel podataka

## Determinants of life insurance demand in new EU member states: panel data analysis

### Sažetak

U radu se proučavaju odrednice potražnje za proizvodima životnih osiguranja u trinaest zemalja Europske unije. Očekivane determinante potražnje čini šesnaest faktora koji su podijeljeni na makroekonomske, demografske, socijalne i institucionalne varijable. Osnovni je cilj rada identificirati varijable koje najbolje objašnjavaju varijacije u potražnji za životnim osiguranjem te zaključiti mogu li nositelji ekonomske politike doprinijeti razvoju tržišta životnog osiguranja. U tu se svrhu procjenjuje neuravnoteženi panel model s fiksnim efektom za razdoblje od 1995. do 2014. godine. Najznačajnijim varijablama pokazale su se makroekonomske varijable, posebice bruto domaći proizvod po stanovniku. Pri kreaciji svojih proizvoda, društva za osiguranje će trebati uzeti u obzir demografska kretanja i gospodarsko stanje u zemljama, ali kako je i analiza pokazala, uložiti napore da educiraju stanovništvo o beneficijama životnog osiguranja te o potrebi za dugoročnom štednjom.

**Cljučne riječi:** potražnja za životnim osiguranjem, nove zemlje članice Europske unije, analiza panel podataka

**JEL klasifikacija:** G22, C33, E21

### Abstract

The paper analyzes determinants of demand for life insurance products in thirteen countries of the European Union. The expected demand determinants cover sixteen factors divided into macroeconomic, demographic, social and institutional variables. The main aim of the paper is to identify the variables that best explain variations in demand for life insurance and to draw a conclusion as to whether policy makers can contribute to the development of the life insurance market. For this purpose, an unbalanced panel model with a fixed effect for the period from 1995 to 2014 was estimated. The most important variables were macroeconomic ones, especially gross domestic product per capita. Insurance companies need to take into account demographic trends and existing economic situations in the respective economies when developing their products, and as analysis indicates, they have to make efforts in educating the population concerning the benefits of life insurance and the need for long-term savings.

**Keywords:** life insurance demand, new EU Member States, panel data analysis

**JEL classification:** G22, C33, E21

### 1. Uvod

Osiguratelji života čine sve važnije financijske institucije, kako u svojstvu financijskih posrednika, tako

i kao institucionalni investitori koji potiču razvoj tržišta kapitala. Značaj osiguratelja kao financijskih posrednika raste u kontekstu suvremenih promjena koje su nebankovnim institucijama omogućile da

Doc. dr. sc. **Mihovil Andelinović**  
Ekonomski fakultet Sveučilišta u Zagrebu  
E-mail: mandelinovic@efzg.hr

Dr. sc. **Petar Mišević**  
Hrvatska gospodarska komora  
E-mail: misevic@hotmail.com

**Ana Pavković**, mag. oec.  
Ekonomski fakultet Sveučilišta u Zagrebu  
E-mail: ana.pavkovic@hotmail.com

Asst. prof. **Mihovil Andelinović**, PhD  
Faculty of Economics and Business,  
University of Zagreb  
E-mail: mandelinovic@efzg.hr

**Petar Mišević**, PhD  
Croatian Chamber of Economy  
E-mail: misevic@hotmail.com

**Ana Pavković**, mag. oec.  
Faculty of Economics and Business,  
University of Zagreb  
E-mail: ana.pavkovic@hotmail.com

Andelinović, M., Mišević, P.,  
Pavković, A.

Determinante potražnje za  
životnim osiguranjem u novim  
zemljama članicama Europske  
unije: analiza panel podataka

konkuriraju tradicionalnoj depozitnoj štednji, što u kombinaciji s demografskim promjenama otvara prostor razvoju životnog osiguranja. Međutim, nejednak razvoj osigurateljnog sektora među zemljama nameće pitanje o uzroku varijacija u potražnji za osigurateljnim proizvodima. Gospodarstva zemalja članica Europske unije su, unatoč velikim naporima uložanima u harmonizaciju ekonomskih politika i usklađivanje institucionalnih okvira, i dalje vrlo heterogena pa se tako uvelike razlikuju i nacionalni osigurateljni sektori.

Temeljni cilj ovog rada je identificirati i detaljnije analizirati odrednice potražnje za proizvodima životnog osiguranja u novim zemljama članicama Europske unije. U tu svrhu procjenjuje se neuravnoteženi panel model s fiksnim efektom za razdoblje od 1995. do 2014. godine za 13 zemalja. Očekivane determinante potražnje čini veći broj makroekonomskih, demografskih, socijalnih i institucionalnih varijabli kojima se želio obuhvatiti maksimalan broj faktora potražnje strane u modelu potrošnje životnog osiguranja. Rezultatima panel analize daje se odgovor na pitanje koje od navedenih kategorija varijabli najbolje objašnjavaju potražnju za životnim osiguranjem, a dobiveni zaključci mogu poslužiti kao potencijalna vodilja nositeljima ekonomske politike u nastojanjima da potaknu dugoročnu štednju građana te posljedično i razvoj sektora životnog osiguranja.

Osnovna je pretpostavka rada da makroekonomski čimbenici imaju najznačajniji utjecaj na kretanje potražnje za proizvodima životnog osiguranja, budući da su i prijašnja empirijska istraživanja dokazala jaku povezanost osigurateljnog tržišta s osnovnim ekonomskim čimbenicima.

Rad je strukturiran u pet poglavlja. Nakon uvodnog poglavlja, u drugom poglavlju prikazani su ključni zaključci teorijskih i empirijskih istraživanja o potražnji za životnim osiguranjem koji čine podlogu za provedbu ekonometrijske analize. U trećem poglavlju opisani su podaci i postupak provođenja empirijske analize. Četvrto poglavlje sadrži rezultate te implikacije rezultata ekonometrijske analize, a peto poglavlje predstavlja zaključak cijeloga rada.

## 2. Pregled literature

Kako teorijska, tako i empirijska istraživanja potvrđuju pozitivan utjecaj financijske razvijenosti

na razvoj gospodarskog sustava. Ward i Zurbruegg (2000.) su među prvima dokazali da pozitivna veza postoji i između osigurateljnog i gospodarskog sustava, zbog čega su istraživači usmjerili napore u analizu faktora koji mogu potaknuti razvoj ovih financijskih institucija. Identifikacijom determinanti značajnih za osigurateljni sektor, nositelji ekonomskih politika će dobiti uvid na koji način bi mogli pridonijeti financijskoj razvijenosti (Hussels, Ward i Zurbruegg, 2005.).

Empirijska istraživanja ove tematike mogu se podijeliti na mikroekonometrijska i makroekonometrijska istraživanja. Cilj mikroekonometrijskih istraživanja je objasniti proces donošenja odluke u kućanstvima o potrošnji na osigurateljne proizvode, za što se uobičajeno koriste podaci iz anketa o dohotku kućanstva. Makroekonometrijska istraživanja temelje se na analizi agregiranih makroekonomskih vremenskih serija i omogućavaju komparaciju zemalja. S obzirom da je cilj rada prepoznati signifikantne varijable na razini novih zemalja članica EU, provodi se analiza makroekonomskih podataka, a pregled literature usmjeren je na makroekonometrijska istraživanja. U nastavku su kroz pregled teorijske osnove istraživanja i potencijalnih odrednica potražnje za životnim osiguranjem prikazane relevantne studije.

### 2.1. Teorijski okvir

Začetnicima istraživanja ove tematike smatraju se Yaari (1965.) i Hakansson (1969.) koji su prvi razvili teorijski model potražnje za životnim osiguranjem. U srži tog modela je želja pojedinca da osigura dobar život svojim nasljednicima, a sebi dohodak za mirovinu. Model pretpostavlja da je potražnja za životnim osiguranjem funkcija bogatstva, očekivanog dohotka pojedinca kroz cjeloživotno razdoblje, kamatnih stopa, cijene proizvoda životnog osiguranja i pretpostavljene subjektivne diskontne stope, odnosno cijene odricanja od današnje potrošnje. Lewis (1989.) proširuje njihov model uključivanjem preferencija uzdržavanih članova i korisnika isplaćene štete po polici životnog osiguranja. On definira potražnju za životnim osiguranjem na sljedeći način:

$LD = f(p, TC, \delta, L, W),$ <p>(+) (+) (+) (-) (-)</p>	1
---	---

gdje je  $LD$  potražnja za životnim osiguranjem koja raste s vjerojatnošću smrti uzdržavatelja obitelji  $p$ , sadašnjom potrošnjom uzdržavanih i relativnom averzijom prema riziku, a pada s cijenom osiguranja koja se prikazuje kao omjer troškova i aktuarske vrijednosti police (engl. *policy loading factor*) te neto bogatstvom kućanstva.

Dakle, u teorijskim istraživanjima naglašava se značaj varijabli poput dohotka, kamatne stope, trenutne potrošnje i akumulirane štednje za potrošnju životnog osiguranja. U teorijske koncepte uključuju se također demografske i socijalne varijable. Potražnja za životnim osiguranjem raste s porastom vjerojatnosti smrti uzdržavatelja obitelji, razine sadašnje potrošnje te stupnja averzije prema riziku. Ipak, malo je dokaza o utjecaju neekonomskih i šireg skupa ekonomskih varijabli u teorijskim modelima. Outreville (1996.) je razvio model koji naglašava i stranu ponude i potražnje u procesu kupnje police osiguranja, a radi se o sljedećem modelu simultanih jednadžbi kakav je koristila Nesterova (2008.):

$Q_d = f(GDPc, P, LIFEXP, Inf, R, AD)$ $Q_s = f(P, R, FD, AD),$	2
---	---

pri čemu je  $GDPc$  BDP po stanovniku,  $P$  cijena životnog osiguranja  $LIFEXP$ , očekivani životni vijek,  $Inf$  inflacija,  $R$  realna kamatna stopa,  $FD$  financijska razvijenost, a  $AD$  ostale varijable. Budući da je na tržištu ponuda jednaka potražnji, izjednačuje se:  $Q_s = Q_d$ . No, istraživanja su pokazala da je nemoguće razlučiti između utjecaja ponude i potražnje jer podaci to ne dopuštaju (Beenstock, Dickinson i Khajuria, 1986.) pa je u radu upotrijebljena jedna verzija modela koju je predložio Outreville (1996.). U nastavku poglavlja objašnjene su varijable korištene u ovom istraživanju i zaključci o njihovom učinku na potražnju za životnim osiguranjem, temeljeni na provedenim empirijskim istraživanjima i ekonomskoj teoriji.

## 2.2. Makroekonomske varijable

Potražnja za životnim osiguranjem treba rasti s porastom dohotka zbog više razloga. Prvo, potrošnja raste s dohotkom što stvara veću osigurateljnu potražnju radi zaštite potencijala dohotka i buduće potrošnje uzdržavanih članova. Drugo, osiguranje se smatra luksuznim dobrom pa veći dohodak omogu-

ćava potrošnju radi nekih drugih motiva osim zadovoljenja elementarnih potreba (Beck i Webb, 2002.). Konačno, gledano na makro razini, prosperitetno gospodarstvo podupire rast svih gospodarskih sektora. Realni BDP po stanovniku upotrijebljen je kao aproksimacija nacionalnog dohotka u većini istraživanja te pokazuje pozitivan i signifikantan utjecaj na potražnju za životnim osiguranjem.

Realna kamatna stopa koristi se kao realni pokazatelj povrata na investirana novčana sredstva društava za osiguranje. Više realne kamatne stope povećavaju povrat na ulaganje osiguratelja, a time i njihovu profitabilnost. Također, povećava se i ponuda novčanog kapitala, što osigurateljima omogućava da odgovore na povećanu potražnju (Lenten i Rulli, 2006.). No, više kamatne stope čine alternativna ulaganja privlačnijima, što može utjecati na komponentu štednje. Osim toga, jedna od komponenti kamatne stope je premija kreditnog rizika koja varira od zemlje do zemlje pa neki autori ne zaključuju sa sigurnošću o ukupnom učinku ove varijable (Kjosevski, 2012.).

Inflacija predstavlja monetarnu disciplinu zemlje. Budući da je osiguranje života štedno-ulažacki proizvod dugoročnog horizonta, porast stope inflacije obeshrabruje ljude od štednje, a monetarna nesigurnost ima negativan učinak na osigurateljnu potražnju. Značajan i negativan utjecaj dokazali su Outreville (1996.), Ward i Zurbruegg (2002.), kao i većina kasnijih istraživanja te se i u ovom radu može očekivati negativan predznak. Jedina iznimka je istraživanje Zerriae i Noubbigha (2016.) koje govori da rast inflacije povećava potražnju za životnim osiguranjem u zemljama Bliskog istoka i Sjeverne Afrike.

Rastuća zaposlenost i sigurnost posla stvaraju poticajno okruženje za sklapanje novih policica osiguranja. S druge strane, smanjenje zaposlenosti može uzrokovati i velik broj raskida ugovora. Gledano na razini pojedinca, životno osiguranje je luksuzno dobro pa pojedinci bez stalnog izvora prihoda ili s niskom razinom dohotka neće ulagati u životno osiguranje. Dakle, stopa nezaposlenosti bi nedvojbeno trebala imati negativan efekat na potražnju za osiguranjem. Ova varijabla nije uključena u proučenim empirijskim istraživanjima.

U radu su izabrane dvije varijable kojima se želi proučiti razvijenost financijskog sustava. Financi-

Andelinović, M., Mišević, P., Pavković, A.

Determinante potražnje za životnim osiguranjem u novim zemljama članicama Europske unije: analiza panel podataka

Andelinović, M., Mišević, P.,  
Pavković, A.

Determinante potražnje za  
životnim osiguranjem u novim  
zemljama članicama Europske  
unije: analiza panel podataka

ska razvijenost odnosi se na razvijenost financijskog sustava u cjelini, dok varijabla tržište kapitala predstavlja razvijenost jednog segmenta financijskog sustava. Razvijenost financijskog sektora ogleda se u njegovoj sposobnosti da učinkovito alocira štednju od novčano suficitarnih jedinica novčano deficitarnim jedinicama, odnosno u uspješnosti financijske intermedijacije. Beck, Dermigüç-Kunt i Levine (2001.) za indikatore razvijenosti financijskog posredništva predlažu sljedeća četiri pokazatelja: omjer monetarnog agregata M2 i BDP-a, udio imovine komercijalnih banaka u imovini cjelokupnog bankarskog sektora, omjer kredita komercijalnih banaka i BDP-a, kao i omjer kredita komercijalnih banaka privatnom sektoru i BDP-a. Omjer M2 i BDP-a, odnosno omjer likvidne pasive i BDP-a (engl. *liquid liabilities to GDP*) najšire je korišteni indikator financijske razvijenosti. Monetarni agregat M2 uključuje novac te kvazinovac kojeg čine likvidna novčana sredstva koja su raspoloživa na zahtjev, ali su za razliku od komponenti novčane mase namijenjena funkciji štednje (Lovrinović i Ivanov, 2009.). Očekuje se da će učinkovit financijski sustav utjecati na povećanje povjerenja građana i ulaganje u osigurateljne proizvode. Značajka takvog sustava su i niže kamatne stope koje mogu pridonijeti kvalitetnijem ulaganju matematičke pričuve. Outreville (1996.), Ward i Zurbruegg (2002.), Sen (2008.) te Zerria i Noubigh (2016.) potvrđuju pozitivan i signifikantan utjecaj ove varijable, dok Beck i Webb (2002.) te Lorent (2010.) dolaze do istog zaključka s varijacijom ove varijable, bankovnom razvijenošću.

Razvijeno tržište kapitala bitan je preduvjet uspješnosti ulaganja društava za osiguranje budući da većinu njihove aktive čine dugoročne vrijednosnice pa njegov napredak doprinosi rastu osiguratelja. Ipak, ako se životno osiguranje gleda kao jedna od alternativa za ulaganje, raznovrsnost vrijednosnih papira i likvidnost tog tržišta učinit će investiranje u zadužnice i vlasničke vrijednosnice atraktivnijom opcijom od životnog osiguranja, što smanjuje potražnju za životnim osiguranjem radi štednje. Ova varijabla nije uključena u proučena empirijska istraživanja.

### 2.3. Demografske i socijalne varijable

Društva za osiguranje temelje aktuarske izračune cijene životnih osiguranja na očekivanom životnom vijeku pri rođenju. Općenito, pretpostavlja se da će s

dužim životnim vijekom rasti potražnja za životnim osiguranjem. Ovaj zaključak potvrdili su Beenstock, Dickinson i Khajuria (1986.), Browne i Kim (1993.), Outreville (1996.) te Ward i Zurbruegg (2002.). Štoviše, može se reći da će zemlja u kojoj je očekivani životni vijek u porastu biti atraktivnija (novim) društvima za osiguranje, budući da je to pokazatelj poboljšanja životnih uvjeta. Ipak, potrebno je naglasiti da promatranje životnog vijeka u socijalnom kontekstu može biti problematično jer je on koreliran s razinom dohotka i nacionalnim bogatstvom pa se ne može jednoznačno zaključiti da njegov porast vodi k povećanju potražnje za životnim osiguranjem (Hussels, Ward i Zurbruegg, 2005.).

Omjeri zavisnosti o radnoj populaciji se u provedenim istraživanjima tretiraju kao ključne demografske determinante potražnje za životnim osiguranjem. Matematički se omjer zavisnosti mladih prikazuje kao omjer djece mlađe od 15 godina i radne populacije (15 - 64 g.), a prema teoriji koju je razvio Lewis (1989.), veći iznos ovog indikatora utjecat će na veću potrebu za zaštitom od rizika smrti, što povećava jednu komponentu proizvoda životnog osiguranja, kako je vidljivo i u Tablici 1. Međutim, negativno će utjecati na komponente anuiteta i štednje kroz ovaj osigurateljni proizvod. Sasvim suprotno, veći omjer zavisnosti starih povećava te dvije komponente, dok osiguranje od rizika smrti uzdržavatelja obitelji tada gubi na važnosti. Rezultati istraživanja jednako su dvosmisleni kao i očekivani predznak koeficijenta uz ove varijable.

Očekivano je da će područja i zemlje s većim udjelom gradskog stanovništva u ukupnom stanovništvu imati veću potražnju za životnim osiguranjem. Iako su obiteljske veze i osjećaj solidarnosti jači u ruralnim područjima, veći broj polica životnih osiguranja sklapa se u gradovima. Razlog tome je i koncentracija potrošača, što olakšava posao prodajnim predstavnicima i smanjuje njihove troškove (Schlag, 2003.). Niži operativni troškovi i cijena svakako imaju pozitivan utjecaj na stranu ponude u modelu potrošnje životnog osiguranja, ali empirijska su istraživanja pokazala dvosmislen utjecaj varijable urbanizacija na potražnju.

Uz urbanizaciju je usko vezano i obrazovanje koje bi trebalo pozitivno korelirati s potražnjom za životnim osiguranjem, budući da obrazovani pojedinci razumiju koncept rizika i važnost dugoročne šted-

nje. Međutim, takva pretpostavka podrazumijeva da su se pojedinci susreli s osnovnim financijskim pojmovima u svome obrazovanju. Empirijska istraživanja su ponovno nesložna oko utjecaja obrazovanja na osigurateljnu potražnju pa Ward i Zurbruegg (2002.) i Kjosevski (2012.) dolaze do pozitivnog i signifikantnog rezultata, dok je kod Becka i Webba (2002.) te Sena (2008.) koeficijent negativan.

Zdravstvena potrošnja države može utjecati na potražnju za životnim osiguranjem na više načina. Budući da se ona financira iz poreznih prihoda, a porezi smanjuju raspoloživi dohodak koji se mogao potrošiti na životno osiguranje, pretpostavljeno je da će veća zdravstvena potrošnja dovesti do smanjene potražnje za životnim osiguranjem, što su dokazali Beenstock, Dickinson i Khajuria (1986.), Browne i Kim (1993.), Beck i Webb (2002.) te Ward i Zurbruegg (2002.). Također, ukoliko zdravstvenu skrb financira država, nema potrebe štiti se od rizika smrti i nedostatnog dohotka kroz sklapanje polica životnog osiguranja. S druge strane, socijalna skrb može pokazivati nacionalno bogatstvo koje je pozitivno korelirano s osiguranjem pa je i ovdje jaključak dvosmisleni efekt.

## 2.4. Institucionalne varijable

Razvoj sektora životnog osiguranja uvelike ovisi

o institucionalnom okviru i političkoj stabilnosti nacionalnog gospodarstva. Politička stabilnost, vladavina prava, kontrola korupcije i kvaliteta regulacije od presudnog su značaja pogotovo u slabije razvijenim zemljama, gdje je stabilno i sigurno poslovno okruženje nužno, ne samo za profitabilno poslovanje, već i za povjerenje građana u financijski sustav. Četiri navedene varijable izabrane su među šest indikatora Svjetske banke (engl. *World Governance Indicators, WGI*), po uzoru na prijašnja empirijska istraživanja. Iako su njihovi zaključci bili dvosmisleni, vjeruje se da bi sva četiri pokazatelja trebala imati pozitivan utjecaj na životno osiguranje.

Tablica 1. sumira donesene zaključke o utjecaju promatranih kategorija varijabli na potražnju za životnim osiguranjem, pritom razlučujući proizvod životnog osiguranja na tri komponente, po uzoru na Becka i Webba (2002.). Komponente štednje i anuiteta vezane su uz utjecaj varijable na kupnju životnog osiguranja radi ostvarenja dohotka za mirovinu i osiguranja bolje imovinske situacije uzdržavanih, dok je komponenta rizika smrtnosti vezana uz kupnju polica radi osiguranja dobiti uzdržavanih članova i nasljednika u slučaju smrti uzdržavatelja obitelji.

Andelinović, M., Mišević, P., Pavković, A.

Determinante potražnje za životnim osiguranjem u novim zemljama članicama Europske unije: analiza panel podataka

**Tablica 1.** Očekivani učinak makroekonomskih, demografskih, socijalnih i institucionalnih varijabli na potražnju za životnim osiguranjem

Varijabla	Komponenta štednje	Komponenta rizika smrtnosti	Komponenta anuiteta	Kombinirani učinak
<b>Makroekonomske varijable</b>				
Realni BDP po stanovniku	+	+	+	+
Realna kamatna stopa	+	+	+	+
Inflacija	-	-	-	-
Stopa nezaposlenosti	-	-	-	-
Financijska razvijenost	+	+	+	+
Tržište kapitala	-	Nema efekta	-	Dvosmislen
<b>Demografske varijable</b>				
Očekivani životni vijek	+	-	+	Dvosmislen
Omjer zavisnosti mladih	-	+	-	Dvosmislen
Omjer zavisnosti starih	+	-	+	Dvosmislen
Obrazovanje	+	+	+	+
Urbanizacija	+	+	+	+
<b>Socijalne varijable</b>				
Zdravstvena potrošnja	-	-	-	-
<b>Institucionalne varijable</b>				
Politička stabilnost	+	+	+	+
Vladavina prava	+	+	+	+
Kontrola korupcije	+	+	+	+
Kvaliteta regulacije	+	+	+	+

Izvor: izrada autora.

### 3. Metodologija i empirijski podaci

Determinante predstavljene u prethodnom poglavlju uzimaju se kao nezavisne varijable, dok će zavisna varijabla biti osigurateljna penetracija. Analiza se temelji na godišnjim podacima od 1995. do 2014. godine, a podaci su preuzeti većinom iz baze Svjetske banke i Swiss Rea kako je objašnjeno

i u prilogima. U analizu je uključeno svih 13 novih zemalja članica Europske unije: Bugarska, Cipar, Češka, Estonija, Hrvatska, Latvija, Litva, Mađarska, Malta, Poljska, Rumunjska, Slovačka i Slovenija. Tablica 2. daje pregled osnovnih deskriptivnih mjera za zavisnu i nezavisne varijable.

Uzevši u obzir vremensku i kros-sekcijsku dimenziju

Tablica 2. Osnovne mjere deskriptivne statistike za varijable prije transformacije

Varijabla	Aritmetička sredina	Std. dev.	Minimum	Maksimum	Broj opažanja
INS	1,048466	0,053999	0,044	6,92	260
GDP	15977,49	442,6648	5282,907	34825,62	260
INTER	4,971649	0,665689	-70,4322	93,93745	221
INFL	12,64831	5,183821	-1,418123	1058,374	260
UNEMPL	9,873913	0,293334	3,3	20,5	260
FIN	59,36609	2,516827	16,09	216,21	260
MCR	21,41057	1,341663	0,02	137,4049	255
EXP	73,84979	0,188104	66,39122	81,1	260
YOUNG	24,8897	0,266920	19,39181	37,24592	260
OLD	21,80131	0,239402	15,14199	29,76085	260
EDU	10,73961	0,083514	7,3	13,1	260
URBAN	66,1369	0,748948	49,695	95,277	260
HEALTH	6,653132	0,078575	3,219874	9,542731	247
POL	68,61328	0,991431	30,28846	99,51923	247
LAW	67,82186	0,978143	31,10048	92,87297	247
COR	65,40715	0,949690	23,90244	93,17073	247
REG	76,63742	0,731052	46,56863	93,26923	247

Izvor: izrada autora.

podataka, u radu se procjenjuje panel model, kod kojeg je zavisna varijabla osigurateljna penetracija. Statički panel proveden u ovom radu je neuravnotežen jer dio podataka nedostaje. Pri odabiru adekvatnog modela za panel analizu provedeno je nekoliko testova. F-test, pomoću kojeg se odlučuje o prikladnosti združenog modela (engl. *Pooled regression model*) ili modela s fiksnim efektom (engl. *Fixed-effects model, FE*) ukazao je na opravdanost upotrebe modela s fiksnim efektom. Isti rezultat potvrdio je Hausmanov test koji uspoređuje procijenjene koeficijente modela s fiksnim i slučajnim efektom (engl. *Random-effects model*). Ishodi testova ukazuju dakle na adekvatnost panel modela s fiksnim efektom čiji je opći oblik:

$$y_{it} = \alpha_i + \beta X_{it} + \mu_i + v_{it}$$

$$u_{it} = \mu_i + v_{it}$$

pri čemu je  $\alpha_i$  ( $i = 1, \dots, n$ ) skalar nepoznatih koeficijenata za svaku od  $n$  jedinica promatranja,  $\beta$  je  $K \times 1$ , a  $X_{it}$  je  $it$ -to opažanje uz  $K$  nezavisnu varijablu

koje je nezavisno od  $v_{it}$ , dok su  $\mu_i$  fiksni parametri koji se procjenjuju, a  $u_{it}$  greške relacije (Baltagi, 2008.).

Model sa zavisnom varijablom Osigurateljna penetracija stoga je dan kao:

$$INS_{it} = \alpha_i + \beta_1 GDP_{it} + \beta_2 INTER_{it} + \beta_3 INFL_{it} + \beta_4 UNEMPL_{it} + \beta_5 FIN_{it} + \beta_6 MCR_{it} + \beta_7 exp_{it} + \beta_8 YOUNG_{it} + \beta_9 OLD_{it} + \beta_{10} EDU_{it} + \beta_{11} URBAN_{it} + \beta_{12} HEALTH_{it} + \beta_{13} POL_{it} + \beta_{14} LAW_{it} + \beta_{15} COR_{it} + \beta_{16} REG_{it} + u_{it}$$

Prije procjene modela, provest će se Im-Pesaran-Shinov (2003.) test i prošireni Dickey-Fuller Fisherov (1999.) test jediničnog korijena za panel podatke koji su primjereni za neuravnoteženi panel model kakav se procjenjuje u ovom radu (Stata, 2016.). IPS test temeljen je na Dickey-Fullerovoj proceduri koja se provodi radi prepoznavanja problema prividne regresije. Test kombinira informacije iz vremenske i kros-sekcijske dimenzije pa je manji broj opažanja potreban kako bi test imao snagu. IPS test započinje određivanjem

zasebne ADF regresijske jednadžbe za svaku kros-sekcijsku jedinicu s individualnim efektima i bez vremenskog trenda.

$$\Delta y_{it} = \alpha_i + \rho_i y_{it-1} + \sum_{j=1}^p \beta_{ij} \Delta y_{it-j} + \varepsilon_{it}, \quad 5$$

za  $i = 1, \dots, N$  i  $t = 1, \dots, T$ .

IPS koristi odvojene testove jediničnog korijena za  $N$  kros-sekcijskih jedinica. Test je temeljen na prosjeku ADF statističkih veličina između grupa. Nakon procjene zasebnih ADF regresijskih jednadžbi, prosjek  $t$ -test veličina za  $\rho_i$  se računa:

$$\hat{t}_{\rho} = \frac{1}{N} \sum_{i=1}^N t_{ir}(\rho_i, \beta_i). \quad 6$$

$\hat{t}_{\rho}$  je nakon toga standardiziran i vidljivo je da standardizirani  $\hat{t}_{\rho}$  konvergira standardnoj normalnoj distribuciji budući da  $N$  i  $T$  teže u beskonačnost. Nulta hipoteza testa pretpostavlja da varijabla sadrži jedinični korijen. U slučaju da se nulta hipoteza testa ne može odbaciti, tj. da je varijabla u razini nestacionarna, u analizi će se koristiti diferencirane vrijednosti.

Maddala i Wu (1999.) i Choi (2001.) predstavili su verziju Fisherovog testa:

$$P = -2 \sum_{i=1}^n \ln p_i \rightarrow \chi^2(2n), \quad 7$$

koji kombinira  $p$ -vrijednosti testova jediničnog

korijena svake kros-sekcijske jedinice  $i$  kako bi testirao postoji li jedinični korijen u panelu. Choi (2001.) predlaže još dva testa osim hi-kvadrat testa, od kojih je prvi, inverzni normalni test upotrijebljen u ovom radu, a ima oblik:

$$Z = \frac{1}{\sqrt{n}} \sum_{i=1}^n \phi^{-1}(p_i), \quad 8$$

gdje je  $\phi$  standardna normalna kumulativna funkcija distribucije. Budući da je  $0 \leq p_i \leq 1$ ,  $\sum_{i=1}^n \phi^{-1}(p_i)$  je  $N(0,1)$  slučajna varijabla.

## 4. Rezultati empirijske analize

Na početku analize je potrebno ispitati stacionarnost varijabli, odnosno postojanje jediničnog korijena, a u tu svrhu provedeni su Im-Pesaran-Shinov test i ADF-Fisherov test. Kao statistička programska podrška za potrebe provođenja ekonometrijske analize korištena je Stata 13 zbog njenih brojnih mogućnosti u provedbi panel analize i uspješnosti u radu s neuravnoteženim panel modelima. U Tablici 3. predstavljeni su rezultati IPS i ADF Fisher testova jediničnog korijena za panel podatke.

Iz Tablice 3. može se iščitati da je 11 varijabli nestacionarno u razinama, dok ih je 5 stacionarno. Kako bi se riješio problem nestacionarnosti, u modelu su korištene prve diferencije tih 11 varijabli. Zbirni prikaz rezultata svih 9 procijenjenih „ugniježdenih“ modela panel analize s pripadajućim statističkim

Andelinović, M., Mišević, P., Pavković, A.

Determinante potražnje za životnim osiguranjem u novim zemljama članicama Europske unije: analiza panel podataka

Tablica 3. Rezultati testova jediničnog korijena za panel podatke

Varijabla	Im-Pesaran-Shin test	ADF-Fisher test	Red integracije
Osigurateljna penetracija	-2,6542*	-2,7723*	I(0)
Realni BDP po stanovniku	4,3900	4,8807	I(1)
Realna kamatna stopa	-5,8760*	-6,2324*	I(0)
Inflacija	-4,6426*	-5,2213*	I(0)
Stopa nezaposlenosti	-3,2711*	-3,7576*	I(0)
Financijska razvijenost	0,8273	1,0619	I(1)
Tržište kapitala	-1,7806	-0,4743	I(1)
Očekivani životni vijek	5,8440	6,1865	I(1)
Omjer zavisnosti mladih	-3,9988*	-4,3199*	I(0)
Omjer zavisnosti starih	8,2919	7,7900	I(1)
Obrazovanje	0,0819	0,1360	I(1)
Urbanizacija	-0,8629	-0,1424	I(1)
Zdravstvena potrošnja	-0,4932	-0,4337	I(1)
Politička stabilnost	-1,9790	-2,0711	I(1)
Vladavina prava	1,5933	1,8195	I(1)
Kontrola korupcije	-2,2393	-2,3123	I(1)
Kvaliteta regulacije	-0,3258	-0,2994	I(1)

Izvor: izrada autora.

Napomena: \* označava stacionarnost pri razini značajnosti 1%.

Tablica 4. Procjene panel modela za zavisnu varijablu Osigurateljna penetracija

Varijabla	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
Konstanta	0.7611 (0.1358) ***	0.8268 (0.1337) ***	0.6902 (0.1646) ***	0.8582 (0.1737) ***	2.5471 (0.2796) ***	0.9160 (0.1210) ***	0.9160 (0.1210) ***	0.9125 (0.1213) ***	0.9122 (0.210) ***
D.GDP	0.0001 (0.0000)**	0.0001 (0.0000)**	0.0001 (0.0000)	0.0001 (0.0000)**	0.0001 (0.0000)*	0.0001 (0.0000)*	0.0001 (0.0000)*	0.0001 (0.0000)*	0.0001 (0.0000)*
D.MCR	0.0045 (0.0024)*	0.0045 (0.0023)*	0.0050 (0.0025)**	0.0044 (0.00236)*	0.0055 (0.0022)**	0.0048 (0.0023)**	0.0049 (0.0023)**	0.0049 (0.0023)**	0.0049 (0.0023)**
D.OLD	0.2325 (0.1671)	0.1912 (0.1503)	0.2806 (0.1690)*	0.1896 (0.1499)	-0.0444 (0.1444)	0.1149 (0.1475)	0.1247 (0.1486)	0.1168 (0.1477)	0.1204 (0.1483)
D.URBAN	0.5541 (0.3259)*	0.5741 (0.3142)*	0.7019 (0.3306)**	0.5637 (0.3124)*	-	0.6544 (0.3224)**	0.6378 (0.3213)**	0.6348 (0.3221)*	0.6418 (0.3228)**
FIN	0.0024 (0.0018)	0.0017 (0.0018)	0.0021 (0.0024)	0.0021 (0.0017)	-	0.0012 (0.0017)	0.0012 (0.0017)	0.0012 (0.0017)	0.0012 (0.0017)
D.EXP	-0.0084 (0.0973)	-	-0.0132 (0.0943)	-	-	-	-	-	-
D.HEALTH	0.0092 (0.0878)	-	-	-	-	-	-	-	-
INFL	-0.0001 (0.0005)	-0.0001 (0.0005)	-	-	-	-	-	-	-
D.EDU	-	-0.1706 (0.2757)	-	-	-	-	-	-	-
INTER	-	-	-0.0011 (0.0046)	-	-	-	-	-	-
UNEMPL	-	-	-	-0.0065 (0.0119)	-	-	-	-	-
YOUNG	-	-	-	-	-0.0615 (0.0104) ***	-	-	-	-
D.POL	-	-	-	-	-	0.0037 (0.0053)	-	-	-
D.LAW	-	-	-	-	-	-	-0.0067 (0.0145)	-	-
D.COR	-	-	-	-	-	-	-	0.0005 (0.0089)	-
D.REG	-	-	-	-	-	-	-	-	0.0035 (0.0135)
R <sup>2</sup>	0.7146	0.7151	0.7278	0.7149	0.7469	0.7401	0.7398	0.7395	0.7396
Hausman $\rho$	0.0044	0.0000	0.0297	0.0000	0.002	0.000	0.000	0.000	0.000
Opažanja	232	242	212	242	242	229	229	229	229

Izvor: izrada autora.

Napomena: \*\*\*, \*\* i \* označavaju signifikantnost koeficijenta pri razinama značajnosti 1%, 5% i 10%. U zagradama su navedene standardne pogreške.

Budući da u Stati postoje pogreške pri izračunu koeficijenta determinacije R<sup>2</sup> kod fiksnih modela uporabom uobičajene funkcije za panele xtreg, fe, koeficijenti su dobiveni procjenom linearne regresije, uz funkciju areg, absorb().

veličinama dan je u Tablici 4.

Rezultati modela pokazuju da su četiri varijable signifikantne u modelu u kojem je zavisna varijabla osigurateljna penetracija: bruto domaći proizvod, razvijenost tržišta kapitala, omjer zavisnosti mladih i urbanizacija. Realni BDP po stanovniku ima pozitivan utjecaj na potražnju za životnim osiguranjem, kako je bez iznimke dokazano i u svim ostalim empirijskim istraživanjima. Rezultati pokazuju da će

porast BDP-a za 1% dovesti do porasta osigurateljne penetracije za 0,0001 postotnih bodova. Na rast osiguranja će također pozitivno utjecati razvijanje tržišta kapitala, što se može pripisati povećanju profitabilnosti osiguratelja života kroz bolje uvjete za ulaganje na tržištu. Veći broj gradskog stanovništva znači veći broj potencijalnih klijenata društava za osiguranje do kojih će prodajni predstavnici moći doprijeti. Jedina signifikantna negativna varijabla je omjer zavisnosti mladih koja pokazuje da će porast



broja stanovništva do 15 godina u odnosu na radnu populaciju smanjiti potražnju za životnim osiguranjem za 0,0615 postotnih bodova. To se može objasniti činjenicom da mlada populacija nema mogućnosti ni financijskih kapaciteta da ulaže u životno osiguranje.

Govoreći o varijablama koje su se pokazale kao nesig-nifikantne, većina predznaka u skladu je s očekiva-njima. Viša realna kamatna stopa pozitivno utječe na osiguranje, što znači da je prevladao efekt povećanja profitabilnosti osiguratelja u odnosu na povećanje atraktivnosti drugih alternativa za ulaganje. Inflacija i stopa nezaposlenosti negativno su korelirane s rastom osiguranja, kao i s većinom drugih makroeko-nomskih kategorija te je ovaj zaključak bio logičan. Za dvije varijable kod kojih je prepoznat dvosmislen efekt na osiguranje, omjer zavisnosti starih i očeki-vani životni vijek, pokazalo se da zemlje s većinskom starijom populacijom i nižim očekivanim vijekom ži-vota imaju veću potražnju za životnim osiguranjem te se ne može zaključiti je li prevladao motiv štednje ili zaštite od rizika smrti (vidjeti Tablicu 1.). Od ostalih varijabli vrijedi spomenuti i potrošnju države na zdravstvo za koju se pokazalo da pozitivno utječe na osiguranje. Do ovoga zaključka došli su i Beck i Webb (2002.) te Kjosovski (2012.), što znači da zdravstveno osiguranje nije supstitut životnom osiguranju.

Zanimljiv i neočekivan rezultat je negativan efekt obrazovanja na potražnju za životnim osiguranjem, ali koji ipak nije značajan. Do jednakog zaključka dolaze i Beck i Webb (2002.) te Sen (2008.). On može ukazivati na moguću neuspjeh obrazovnog sustava u financijskom opismenivanju te isticanju beneficija osiguranja života. Što se tiče institucionalnih varia-bli, nijedna se nije pokazala signifikantnom u mode-lu te su koeficijenti tri od četiri varijable pozitivni, u skladu s očekivanjima.

## 5. Zaključak

Razvijenost tržišta životnih osiguranja pokazatelj je razvijenosti financijskog sustava neke zemlje, a time i cijelog gospodarstva. Europske zemlje karakterizira trend rasta udjela životnog osiguranja u ukupnoj premiji, na račun neživotnog osiguranja, što je bio osnovni motiv analize determinanti potražnje za tom vrstom osiguranja, budući da su brojna empirijska istraživanja ukazala na potencijal osiguranja u poticanju gospodarskog

rasta. Faktori koji bi mogli utjecati na potražnju podijeljeni su u četiri kategorije: makroekonomske, demografske, socijalne i institucionalne varijable. Makroekonomske varijable predstavljaju osnovne ekonomske uvjete koji predodređuju poslovanje svih financijskih institucija te njihovu profitabilnost, pa tako i profitabilnost osiguratelja. Demografske i socijalne varijable naglašavaju važnost strukture stanovništva te ulaganja države u njeno poboljšanje, dok su institucionalne varijable vezane uz pravni i regulatorni okvir koji treba omogućavati nesmetano poslovanje društava za osiguranje. U radu je procijenjen neuravnoteženi panel model s fiksnim efektom za 13 novih zemalja članica EU u razdoblju od 1995. do 2014. godine. Model je činilo 16 nezavisnih varijabli te zavisna varijabla osigurateljna penetracija kojom se aproksimirala potražnja za životnim osiguranjem. Prema *t*-statističkim veličinama i pripadajućim *p*-vrijednostima zaključeno je da četiri varijable značajno objašnjavaju varijacije u potražnji za životnim osiguranjem. Na temelju rezultata panel analize može se zaključiti da će među analiziranim europskim zemljama veća potražnja postojati u zemljama s višim realnim bruto domaćim proizvodom po stanovniku, većim postotkom gradskog stanovništva i razvijenijim tržištem kapitala te u zemljama u kojima opada udio mladog stanovništva, a raste broj stanovništva iznad 65 godina, a sve navedeno su karakteristike svih novih zemalja članica Europske unije, što potvrđuje validnost rezultata analize. Budući da su dvije od četiri signifikantne varijable svrstane u makroekonomske faktore, potvrđuje se polazna hipoteza rada da makroekonomska situacija čini najvažniju odrednicu razvoja tržišta životnog osiguranja u analiziranim zemljama Europske unije. Društva za osiguranje trebaju pri kreaciji svojih proizvoda uzeti u obzir aktualna demografska kretanja i gospodarsko stanje u zemljama, ali i, kako je analiza pokazala, uložiti napore da educiraju stanovništvo o beneficijama životnog osiguranja te o potrebi za dugoročnom štednjom. Dugoročna štednja stanovništva jedno je od područja na kojem radi Europska komisija, a upravo za životno osiguranje kao oblik takve štednje postoji velik potencijal u novim zemljama članicama Europske unije, pod uvjetom da nositelji ekonomskih politika podupiru razvoj čimbenika koji pridonose rastu osiguranja.

Andelinović, M., Mišević, P., Pavković, A.

Determinante potražnje za životnim osiguranjem u novim zemljama članicama Europske unije: analiza panel podataka

Andelinović, M., Mišević, P.,  
Pavković, A.

Determinante potražnje za  
životnim osiguranjem u novim  
zemljama članicama Europske  
unije: analiza panel podataka

## Literatura

- Baltagi, B. H. (2008) *Econometric Analysis of Panel Data*. 4. izd. New Jersey: John Wiley & Sons, Ltd.
- Beck, T., Webb, I. (2002) Economic, Demographic and Institutional Determinants of Life Insurance Consumption across Countries. *The World Bank Economic Review*, 17 (1): 51-88.
- Beck, T., Dermigüç-Kunt, A., Levine, R. (2001) The Financial Structure Database. U: *Financial Structure and Economic Growth: A Cross-Country Comparison of Banks, Markets and Development*, Dermigüç-Kunt, A. i Levine, R. (ur.), Cambridge, MA, The MIT Press: 17-80.
- Beenstock, M., Dickinson, G., Khajuria, S. (1986) The Determinants of Life Premiums: An International Cross-Section Analysis. *Insurance: Mathematics and Economics*, 5 (4): 261-270.
- Browne, M. J., Kim, K. (1993) An International Analysis of Life Insurance Demand. *Journal of Risk and Insurance*, 60 (4): 616-634.
- Choi, I. (2001) Unit root tests for panel data. *Journal of International Money and Finance*, 20 (2): 249-272.
- Eurostat, Database. Dostupno na: <http://ec.europa.eu/eurostat/data/database> [29.12.2015.].
- Hakansson, N. H. (1969) Optimal Investment and Consumption Strategies under Risk, an Uncertain Lifetime and Insurance. *International Economic Review*, 10 (3): 443-466.
- Hussels, S., Ward, D., Z., R. (2005) Stimulating the Demand for Insurance. *Risk Management and Insurance Review*, 8 (2): 257-278.
- Im, K. S., Pesaran, M. H., Shin, Y. (2003) Testing for Unit Roots in Heterogeneous Panels. *Journal of Econometrics*, 115 (1): 53-74.
- Insurance Europe, Publications. Dostupno na: <http://www.insuranceeurope.eu/publications> [22.12.2015.].
- Kjosevski, J. (2012) The Determinants of Life Insurance Demand In Central and Southeastern Europe. *International Journal of Economics and Finance*, 4 (3): 237-247.
- Lenten, L. J. A., Rulli, D. N. (2006) A Time-Series Analysis of the Demand for Life Insurance Companies in Australia: An Unobserved Components Approach. *Australian Journal of Management*, 31 (1): 41-66.
- Lewis, F. D. (1989) Dependents and the Demand for Life Insurance. *American Economic Review*, 79 (3): 452-466.
- Lorent, B. (2010) The Link between Insurance and Banking Sectors: An International Cross-Section Analysis of Life Insurance Demand. CEB Working Paper No.10/040: 1-36.
- Lovrinović, I., Ivanov, M. (2009) *Monetarna politika*. Zagreb, RRIF plus d.o.o.
- Maddala, G. S., Wu, S. (1999) A Comparative Study of Unit Root Tests with Panel Data and A New Simple Test. *Oxford Bulletin of Economics and Statistics*, 61 (0): 631-652.
- Nesterova, D. (2008) Determinants of the Demand for Life Insurance: Evidence from Selected CIS and CEE Countries, magistarski rad National University "Kyiv-Mohyla Academy".
- Outreville, J. F. (1996) Life Insurance Markets in Developing Countries. *Journal of Risk and Insurance*, 63 (2): 263-278.
- Schlag, C. H. (2003) Determinants of demand for life insurance products – Theoretical concepts and empirical evidence. Swiss Re, Economic Research & Consulting.
- Sen, S. (2008) An Analysis of Life Insurance Demand Determinants for Selected Asian Economies and India. MSE Working Paper, 36: 1-44.
- Stata, Panel-data unit-root tests. Dostupno na: <http://www.stata.com/features/overview/panel-data-unit-root-tests/> [11.10.2016.].
- Swiss Re, Sigma: Insurance Research. Dostupno na: <http://www.swissre.com/sigma/> [20.12.2015.].

Ward, D., Zurbrugg, R. (2000) Does Insurance Promote Economic Growth? Evidence from OECD Countries. *Journal of Risk and Insurance*, 67 (4): 489-506.

World Bank, Data. Dostupno na: <http://data.worldbank.org/> [28.12.2015.].

Yaari, M. E. (1965) Uncertain Lifetime, Life Insurance and the Theory of the Consumer. *Review of Economic Studies*, 32 (2): 137-150.

Zerriaa, M., Noubigh, H. (2016.) Determinants of Life Insurance Demand in the MENA Region. *The Geneva Papers on Risk and Insurance - Issues and Practice*, 41 (3): 491-511.

Andelinović, M., Mišević, P., Pavković, A.

Determinante potražnje za životnim osiguranjem u novim zemljama članicama Europske unije: analiza panel podataka

## Prilozi

**Prilog 1.** Definicija varijabli i izvori vremenskih serija

Varijabla	Oznaka	Definicija	Razdoblje	Izvor
Osigurateljna penetracija	INS	Udio premije životnog osiguranja u BDP-u	1995. - 2014.	Swiss Re
Realni BDP po stanovniku	GDP	BDP po stanovniku izražen u dolaru po paritetu kupovne moći	1995. - 2014.	World Bank – Economy & Growth
Realna kamatna stopa	INTER	Aktivna kamatna stopa korigirana za inflaciju mjerenu BDP deflatorom	1995. - 2014.	World Bank – Financial Sector
Inflacija	INFL	Promjena opće razine cijena mjerena BDP deflatorom	1995. - 2014.	World Bank – Economy & Growth
Stopa nezaposlenosti	UNEMPL	Udio radno sposobnog stanovništva koje nema stalan posao, ali ga aktivno traži	1995. - 2014.	World Bank – Social Protection & Labor
Financijska razvijenost	FIN	Omjer monetarnog agregata M2 i BDP-a	1995. - 2014.	World Bank – Financial Sector
Tržište kapitala	MCR	Omjer tržišne kapitalizacije i BDP-a	1995. - 2014.	World Bank – Financial Sector
Očekivani životni vijek	EXP	Očekivani broj godina života pri rođenju	1995. - 2014.	World Bank – Health
Omjer zavisnosti mladih	YOUNG	Omjer stanovništva mlađeg od 15 g. i radno sposobnog stanovništva (15 - 64g.)	1995. - 2014.	World Bank – Health
Omjer zavisnosti starih	OLD	Omjer stanovništva starijeg od 64 g. i radno sposobnog stanovništva (15 - 64g.)	1995. - 2014.	World Bank – Health
Urbanizacija	URBAN	Udio gradskog u ukupnom stanovništvu	1995. - 2014.	World Bank – Urban Development
Obrazovanje	EDU	Prosječan broj godina školovanja stanovništva starijeg od 25 g.	1995. - 2014.	HDI – Education
Zdravstvena potrošnja	HEALTH	Omjer javne zdravstvene potrošnje i BDP-a	1995. - 2013.	World Bank – Health
Politička stabilnost	POL	Mjera nestabilnosti državne vlade i mogućnosti njenog rušenja, izražena u rangu percentila	1996. - 2014.	Worldwide Governance Indicators
Vladavina prava	LAW	Mjera povjerenja građana u provedbu zakona, policiju i sudstvo, izražena u rangu percentila	1996. - 2014.	Worldwide Governance Indicators
Kontrola korupcije	COR	Mjera sposobnosti za sprječavanje i borbu protiv korupcije, izražena u rangu percentila	1996. - 2014.	Worldwide Governance Indicators
Kvaliteta regulacije	REG	Mjera sposobnosti državne vlade da implementira učinkovitu regulaciju, izražena u rangu percentila	1996. - 2014.	Worldwide Governance Indicators

Napomena: U slučaju kada podaci za određene godine nisu bili dostupni u navedenim izvorima, preuzeti su sa službenih stranica Eurostata, nacionalnih zavoda za statistiku i regulatornih tijela.

Andelinović, M., Mišević, P.,  
Pavković, A.

Determinante potražnje za  
životnim osiguranjem u novim  
zemljama članicama Europske  
unije: analiza panel podataka

## Prilog 2. Korelacijska matrica

	ins	gdp	inter	infl	unempl	fin	mcr	exp	young	old	edu	urban	health	pol	law	cor	reg
ins	1,0000																
gdp	0,6277	1,000															
inter	-0,0282	-0,0925	1,0000														
infl	-0,1119	-0,1874	-0,5064	1,000													
unempl	-0,3405	-0,4378	0,1754	0,0462	1,000												
fin	0,6975	0,5343	0,0191	-0,0865	-0,3663	1,000											
mcr	0,6074	0,4536	-0,0844	-0,1234	-0,3559	0,5802	1,000										
exp	0,7763	0,8112	0,0048	-0,1567	-0,3424	0,7622	0,5203	1,000									
young	0,1353	-0,3691	0,0938	0,0384	0,0090	0,3052	0,0664	0,0006	1,000								
old	-0,3728	0,0845	-0,0643	0,0160	0,1411	-0,3655	-0,0835	-0,2422	-0,6865	1,000							
edu	-0,0932	0,3503	-0,0823	-0,1087	-0,0397	-0,2871	-0,1107	-0,0314	-0,5086	0,2207	1,000						
urban	0,4145	0,2643	-0,0917	-0,0249	-0,1803	0,5104	0,3168	0,3824	0,1314	0,0159	-0,2031	1,000					
health	0,3966	0,5272	0,0236	-0,1560	-0,1175	0,2104	0,2743	0,4520	-0,4337	0,2254	0,0269	0,2245	1,000				
pol	0,4246	0,4321	-0,1174	-0,1264	-0,2816	0,2780	0,2634	0,4260	-0,0490	-0,1692	0,0823	0,3978	0,4984	1,000			
law	0,6288	0,6747	-0,0960	-0,2137	-0,4328	0,5024	0,4091	0,6224	0,0431	-0,2091	0,2513	0,4781	0,3906	0,7060	1,000		
cor	0,6025	0,5607	-0,1077	-0,2194	-0,3357	0,4938	0,4404	0,5916	0,1181	-0,2936	0,2459	0,2928	0,3301	0,6029	0,8799	1,000	
reg	0,4232	0,5154	-0,1265	-0,2414	-0,2417	0,3000	0,2829	0,3431	0,0158	-0,1092	0,3983	0,4683	0,2323	0,4948	0,8049	0,7449	1,000

Izvor: izrada autora.