

Michael Faulend*

UDK 336.711.61 (497.5)
JEL Classification G 21, G 22, G 28
Pregledni članak

DO KOJEG IZNOSA OSIGURAVATI ŠTEDNE ULOGE U HRVATSKOJ?

Određivanje visine iznosa do kojeg se osiguravaju štedni uložci (limit), jedno je od ključnih pitanja pri formuliranju sustava osiguranja štednih uloga. Jedino pravilno postavljen limit omogućuje uspješno ispunjavanje ciljeva samog sustava osiguranja i minimizaciju problema moralnog hazarda, negativne popratne pojave koje neumoljivo koegzistiraju sa svakim sustavom osiguranja štednih uloga. U tom se smislu postavlja pitanje: koliko je postojeći limit u Hrvatskoj (100.000 kuna) "dobar"? i hoće li promjena toga limita na 20.000 € (približno 150.000 kuna) prilikom ulaska u EU imati kakve posljedice? Radi odgovora na ta pitanja, u radu se nastoji naći svojevrsan optimalni limit za Hrvatsku. Pritom se koristi ekonometrijskom analizom podataka za široki skup zemalja koje posjeduju sustav osiguranja štednih uloga. Neovisno o ekonometrijskoj analizi, analizira se struktura štednih uloga po bankama u Hrvatskoj. Navedena dva, međusobno neovisna puta dovode do gotovo istih rezultata na osnovi kojih se može zaključiti da trenutno postojeći limit od 100.000 kuna nije značajno viši od optimalnoga, ali bi eventualna promjena limita na 150.000 kuna mogla narušiti kvalitetu ispunjavanja ciljeva sustava osiguranja štednih uloga, tj. pridonijeti smanjenju stabilnosti financijskoga sustava u srednjem roku.

Ključne riječi: osiguranje štednih uloga, optimalna visina osiguranja štednih uloga - limit, bankovni sustav

* M. Faulend, mr. sc., savjetnik u Direkciji istraživanja Hrvatske narodne banke. Članak primljen u uredništvo: 17. 12. 2003. Izneseni stavovi su osobni stavovi autora i ne odražavaju bezuvjetno stavove HNB, niti obvezuju spomenutu instituciju.

Uvod¹

Sustav osiguranja štednih uloga (*engl. deposit insurance, deposit protection ili deposit-guarantee*), pored institucija središnje banke² i supervizije bankovnog sustava, u današnje je vrijeme važan stup sigurnosti većine razvijenijih financijskih sustava. Njegova je osnovna ideja preko zaštite malih štediša smanjiti opasnost “navale” štediša na banke i tako pridonijeti stabilnosti financijskog sustava. Ovisno o uspjehu ispunjavanja toga zadatka, dobro formirani sustav osiguranja štednih uloga promiče povjerenje u financijske institucije, ohrabruje štednju, promičući tako rast financijskih institucija i opći gospodarski rast.

Bitno je naglasiti, međutim, da će samo dobro formirani sustav osiguranja moći uspješno izvršavati najprije spomenuto. Pritom se dobro formiranim sustavom osiguranja smatra sustav koji minimizira tri problema (moralni hazard, negativnu selekciju i principal-agent problem), a koji neizbježno koegzistiraju sa samim sustavom osiguranja štednih uloga (Garcia, 1996). Budući da je osnovni cilj rada naći svojevrsnu optimalnu visinu do koje bi valjalo osiguravati štedne uloge (limit)³, upravo se problem moralnog hazarda našao u fokusu ovog rada. Naime, do razvitka problema moralnog hazarda dolazi u slučaju previsoko određenog limita, kada se štedišama umanjuje poticaj za praćenjem banaka, a banke se osjećaju sigurnije u svojim poslovnim aktivnostima, što vodi rizičnijem poslovanju banaka i potencijalno, smanjenju stabilnosti bankovnog sustava u cjelini.

Rad daje odgovor na važna pitanja: koliko je postojeći limit u Hrvatskoj (100.000 kuna) “dobar”, u smislu da minimizira problem moralnog hazarda i pridonosi stabilnosti bankovnog sustava u srednjem roku? i hoće li promjena postojećeg limita na 20.000 € (otprilike 150.000 kuna) prilikom ulaska u EU imati kakve posljedice za naš bankovni sustav? Osim doprinosa koji rad daje u sferi utvrđivanja optimalnog limita, rad iznosi sugestije za poboljšanjem postojećeg sustava osiguranja štednih uloga radi dodatnoga umanjivanja problema moralnog hazarda. Osim toga, za potrebe stvaranja što kvalitetnije pregovaračke pozicije prilikom ulaska u EU, a kada je riječ o prilagodbi na viši limit, rad iznosi sugestiju za uvođenje sustavnog praćenja distribucije štednih uloga u Hrvatskoj.

¹ Ovaj se rad najvećim dijelom zasniva na autorovom magistarskom radu (“Osiguranje štednih uloga”). Autor se posebno želi zahvaliti dr. Evanu Kraftu za izuzetno korisne komentare i sugestije. Odgovornost za sve preostale pogreške preuzima autor.

² Ovdje se specifično pod institucijom središnje banke podrazumijeva njezina funkcija pozajmljivača u prijeko potrebi (*engl. lender of last resort*).

Problem moralnog hazarda i načini njegova suzbijanja

Uz negativnu selekciju, problem moralnog hazarda najprepoznatljiviji je problem koji inducira postojanje sustava osiguranja štednih uloga. On izvire iz fundamentalne dileme bilo kojeg sustava osiguranja štednih uloga, a ta je da sustav osiguranja ne može štiti štediše od propasti banke uzrokovane nelikvidnošću, a da pritom ne štiti štediše od propasti banke uzrokovane vođenjem loše kreditne politike (Carisano, 1992.). Moralni hazard ne ogleda se samo u iskrivljanju ponašanja štediša, koji zbog sustava osiguranja postaju manje oprezni pri odabiru banaka⁴. On se ogleda i u iskrivljenom ponašanju vlasnika i rukovodstva banke. Naime, postojanje sustava osiguranja potiče bankare na poduzimanje većeg rizika⁵, jer im smanjuje strah od potencijalne navale deponentata. Zanimljiva su razmišljanja da uz bankare i štediše postoje i neke druge grupacije, ponašanje kojih može biti pod utjecajem moralnog hazarda, a koji proizlazi iz postojanja sustava osiguranja štednih uloga (Kane, 1995.). Dobar su primjer takvih grupacija npr., supervizori⁶ i političari⁷. Premda navedena razmišljanja nisu nezasnovana, potrebno je naglasiti da glavnina negativnih posljedica moralnog hazarda proistječe iz iskrivljenog ponašanja štediša i bankara. Stoga je korisno promotriti načine koji mogu biti ugrađeni u sam sustav osiguranja, a koji smanjuju neželjeno ponašanje štediša i bankara.

U uvodu ovoga rada spomenuto je da će moralni hazard biti to veći, što je i limit veći; a zato što se problematici određivanja visine limita posvećuje puna pažnja u narednom dijelu rada, ovdje je mjesto gdje se mora upozoriti na potankosti koje relativiziraju pojam visine limita. Istovremeno, u ovom dijelu valja ukazati na mišljenja na koja se nailazi u literaturi, a koja se odnose općenito na suzbijanje problema moralnog hazarda.

Relativizacija pojma visine limita proizlazi iz zakona kojim se točno određuje osigurava li se pojedini štedni ulog (depozit) ili štediša (deponent). Valja primijetiti da je limit, zapravo, (potencijalno) mnogo veći u sustavu u kojem je osiguran po-

³ Korisno je dodatno pojasniti pojam "svojevrsno optimalne visine limita". Naime, u tehničkom smislu, u radu se ne optimiziraju neke funkcije, rezultat čega bi bio izračun optimalnog limita, već se u većoj ili manjoj mjeri sofisticiranim metodama nastoji naći visina limita koja bi bila najprihvatljivija, tj. koja bi sadržala svojstva optimalnosti u smislu umanjivanja problema moralnog hazarda.

⁴ Uz to, deponenti nemaju ni poticaj premještati svoja sredstva u kvalitetnije banke.

⁵ Bilo povećanjem rizičnih ulaganja, bilo smanjenjem kapitala i rezerve likvidnosti.

⁶ Zbog činjenice da postoji sustav osiguranja štednih uloga, supervizori mogu postati inertni pri određivanju mjera za loše banke (u svrhu njihovog poboljšanja), jer ne postoji prijetnja tržišta.

⁷ Političari, zbog postojanja sustava osiguranja štednih uloga, imaju veći prostor za provođenje politike odugovlačenja rješavanja problematičnih banaka. Naravno, politiku odugovlačenja provode čineći pritisak na superviziju.

jedini štedni ulog, nego u sustavu u kojem je osiguran pojedini deponent. Naime, neka je limit, primjerice, 100 jedinica. U slučaju da deponent u banci ima deset računa, na svakom pojedinom računu po 100 jedinica, njemu će svih 1000 jedinica biti osigurano. U suprotnom slučaju, u kojem se osigurava pojedini deponent, deponent će imati samo 100 osiguranih jedinica (bez obzira na broj računa u toj banci). No, kada bi deponent raspodijelio sredstva u deset banaka, polaganjem od po 100 jedinica u svaku banku, opet bi svih 1000 jedinica bilo osigurano. Važno je uočiti da je u prvom slučaju, premda je limit 100, efektivan limit neizmjeran; a u drugom je slučaju efektivan limit, premda još uvijek veliki, ipak konačan broj (jednak je umnošku broja banaka i zadanoga limita). U okviru relativizacije pojma visine limita valja spomenuti i problem "cijepanja" depozita koji se javio u jeku bankovne krize u Hrvatskoj kao posljedica zakonskih manjkavosti, a koji je praktički učinio odluku o osiguranju štednih uloga do 100.000 kuna bespredmetnom. Ova kratka digresija ukazuje na potrebu za adekvatnim popratnim zakonodavnim okvirom (u ovom slučaju - Zakon o bankama) da bi zakonom određeni limit istovremeno bio i efektivan limit.

U današnje vrijeme gotovo svaki sustav osiguranja štednih uloga osigurava štedne uloge na principu deponenta⁸. Iznimka su jedino filipinski sustav i sustav Dominikanske Republike, koji još uvijek osiguravaju štedne uloge po principu pojedinog štednog uloga. Budući da efektiva visina osiguranja (limita) i u slučaju osiguranja "po deponentu" može biti prilično visoka, pojedine zemlje ugrađuju različite klauzule radi smanjivanja efektivnog limita. Možda je najbolji primjer primjer čileanskog sustava, prema kojem se limit osiguranja veže uz ukupnu ušteđevinu u cjelokupnom bankovnom sustavu, a uz to postoji i klauzula tzv. koosiguranja. Klauzula koosiguranja podrazumijeva obvezu osiguravatelja da isplati osiguraniku (štediši) samo jedan postotak (zakonom propisan) njegovih osiguranih sredstava u slučaju propasti banke. U Čileu, npr., koosiguranje vrijedi za štedne uloge, pa se u slučaju propasti banke isplaćuje 90% iznosa osiguranih sredstava (do limita), a za transakcijske račune ne postoji limit, pa se sredstva s tih računa isplaćuju u cijelosti⁹. Koosiguranjem se jedan dio troška prebacuje na deponenta, te se na taj način daju poticaji deponentima da prate banke u koje ulažu sredstva. Valja spomenuti da postoje različite varijacije klauzule koosiguranja. Tako, npr., možda najčešći oblici koosiguranja osiguravaju u cijelosti štedne uloge do nekog "niskog" limita, a iznad toga limita - do nekog "višeg" limita, osiguravaju određeni postotak¹⁰. Zanimljivo

⁸ To, međutim, nije bio slučaj prije nekoliko godina, na što, uostalom, ukazuje posljednje istraživanje (Garcia, 1999.), a u odnosu na prijašnja istraživanja (Kyei, 1995.).

⁹ Očita je namjera čileanske institucije osiguranja štednih uloga da primarno štiti platni sustav, pa tek onda štediše.

¹⁰ Istraživanje (Garcia, 1999.) pokazuje da ukupno 16 od 68 zemalja ima ugrađenu klauzulu koosiguranja.

je još se na trenutak osvrnuti na čileanski sustav koji je jedinstven po tome što u slučaju štednje osigurava ukupnu štednju u cjelokupnom sustavu do propisanog limita. Takav pristup obeshrabljuje deponente da diversificiraju rizik i rasprše sredstva u više banaka¹¹. No, takav sustav istovremeno efektivnu visinu osiguranja (limit) izjednačuje sa stvarnom (zakonski propisanom) visinom osiguranja štednih uloga. Značajno je dodati da čileanski sustav ima ugrađenu i vremensku dimenziju, jer po isteku svake kalendarske godine svaki stanovnik dobiva pravo na ponovno osiguranje, bez obzira je li u prethodnoj godini “iskoristio” osiguranje ili nije.

Osiguranje štednih uloga do određenoga limita i uvođenje klauzule koosiguranja najčešći su načini sprečavanja ili bolje rečeno umanjivanja problema moralnog hazarda¹². Postoje i drugi oblici klauzula, poput, npr., klauzule koja isključuje depozite s kamatnjakom većim od referentne stope¹³ iz sustava osiguranja, kao što je to slučaj u Argentini i Francuskoj (Kyei, 1995). Ipak, ugrađivanje različitih klauzula, definiranje točno određenih vrsta depozita i grupacija deponenata može biti također od koristi pri reduciranju moralnog hazarda. Valja podsjetiti na osnovnu funkciju sustava osiguranja štednih uloga – to je zaštita malih (nesofisticiranih) deponenata. U tom je smislu sasvim logično isključivanje međubankovnih računa, računa vlasnika i rukovodstva banke te s njima povezanih osoba. Vlasnici tih računa veoma dobro poznaju ili barem imaju mogućnost spoznati kvalitetu institucije u koju polažu novac, pa prema tome nikako ne pripadaju grupaciji nesofisticiranih deponenata. Ovdje je važno pridodati da se iz sustava moraju izuzeti i svi računi koji glase na donosioca (tzv. računi na šifru ili zaporku), jer u suprotnome nije moguće provoditi “politiku” limita po deponentu. Također je poželjno izdvojiti i depozite s neprimjereno visokim kamatnjakom, jer će se na taj način onemogućiti “kockarski” pothvati slabijih banaka.

Istraživanje (Garcia, 1999) pokazuje da 45 od 68 zemalja (sustava) isključuju međubankovne račune iz sustava osiguranja. Svega 10 zemalja zaštićuje sve vrste depozita. Čak 62 zemlje¹⁴ ne pokrivaju štedne uloge u cijelosti (postoji limit), od

¹¹ Time se gubi jedna od funkcija postojanja institucije osiguranja štednih uloga – poboljšanje konkurencije među bankama.

¹² Ovdje valja ukazati i na alternativni pristup koji preko svojeg općeg djelovanja na tržišnu disciplinu djeluje i na umanjivanje problema moralnog hazarda. Radi se o pristupu predočavanja informacija o bankama javnosti (Folkerts-Landau i Lindgren, 1997). Ovisno o količini predočenih informacija, javnost (mali deponenti) može u većoj ili manjoj mjeri ocijeniti rizik pojedine banke, pa stoga može i participirati u eventualnim gubicima depozita.

¹³ Takva klauzula proistječe iz iskustva da lošije banke često nude neprimjereno visoke pasivne kamate.

¹⁴ Preostalih se šest zemalja, relativno nedavno, suočilo s problemima u bankovnom sustavu, pa je puno osiguranje štednih uloga bila jedna od mjera (privremena) za povećanje povjerenja u bankovni sustav.

čega njih 16 imaju i ugrađenu klauzulu koosiguranja. Sve to ukazuje da brojne zemlje pokušavaju u praksi umanjiti problem moralnog hazarda koji neupitno koegzistira sa sustavom osiguranja štednih uloga.

Povuče li se ovdje paralela s postojećim hrvatskim sustavom osiguranja štednih uloga¹⁵, može se primijetiti da se hrvatski sustav neznatno koristi pozitivnim iskustvima drugih zemalja. Apstrahirajući pitanje limita, on u sebi ne sadrži klauzulu koosiguranja, a ni niz drugih osigurača. On tek ističe da štedni ulozi članova Uprave i Nadzornog odbora banke i štedionice nisu osigurani u banci ili štedionici u kojoj obavljaju funkciju člana Uprave ili Nadzornog odbora. Sve to nedvosmisleno pokazuje da postoji veliki prostor za poboljšanje našeg sustava osiguranja štednih uloga, i to kada je riječ o načinima umanjivanja problema moralnog hazarda. No, prije nego što se na osnovi izloženoga eksplicitno iznesu određene sugestije, valja analizirati središnji element - limit.

Optimalna visina limita

Pravilno utvrđivanje limita jedan je od najkontroverznijih problema s kojim se susreće svaki sustav osiguranja štednih uloga. Utvrđivanje limita, dakako, veže se uz “pokrivene” račune i institucije, jer u slučaju propasti “pokrivene” institucije, deponent ima pravo na isplatu osiguranih sredstava samo uz uvjet da su njegova sredstva bila položena na “pokrivenu” vrstu depozitnog računa. O samoj politici utvrđivanja limita ili davanja preporuka za utvrđivanje limita, aktualna je literatura prilično skromna i nailazi se tek na dvije sugestije (Garcia, 1996; Garcia 1999). Prema jednoj bi sugestiji limit morao biti jedan do dva puta veći od BDP zemlje po stanovniku, a druga sugestija ukazuje na potrebu analiziranja distribucije štednih uloga u bankovnom sustavu zemlje. Prema toj je sugestiji limit potrebno odrediti kod onog iznosa koji “pokriva” približno osamdesetak posto agregiranih štednih uloga¹⁶ i dvadesetak posto iznosa ukupne štednje. Obje se sugestije mogu svrstati u tzv. vrstu metoda “palca” ili “osjećaja”, koje općenito daju okvirnu procjenu.

¹⁵ Narodne novine, različiti brojevi.

¹⁶ Ovdje se pod osamdesetak posto agregiranih štednih uloga podrazumijeva “pokrivenost” osamdesetak posto fizičkih osoba (npr. za slučaj Hrvatske), gdje se za svaku pojedinačnu fizičku osobu agregiraju svi njeni depoziti u jednoj banci ili štedionici, pa se tako dobivaju pojedinačni agregirani štedni ulozi.

Analiza visine limita po zemljama

Slijedom prve sugestije veoma je jednostavno izračunati granice unutar kojih bi se morao nalaziti optimalni limit za Hrvatsku. Budući da je Garcia svoje zaključke izvela na osnovi istraživanja provedenoga u godini 1998.¹⁷, bitno je samo znati hrvatski BDP po stanovniku i prosječni tečaj hrvatske kune za USD iz te iste godine 1998. Hrvatski BDP po stanovniku u 1998. iznosio je 4.834 USD, a za američki je dolar valjalo izdvojiti 6,36 kuna (prosječan tečaj). U kunskoj protuvrijednosti vrijednost jednog BDP po stanovniku bila je ekvivalentna iznosu od 30.744,24 kuna, a dvostruka je vrijednost iznosila 61.488,48 kuna. Dakle, prema prvoj sugestiji, optimalni iznos do kojeg bi valjalo osiguravati štedne uloge u Hrvatskoj morao bi se nalaziti unutar intervala od 30 do 60 tisuća kuna. Budući da se referentne vrijednosti odnose na godinu 1998., ispravno bi bilo korigirati ih za stopu inflacije. No, to će se učiniti nešto poslije. Ovdje valja primijetiti da je izračunani interval prilično širok, pa je u tome smislu neprecizan. Dodatno, dobra je strana te metode njezina jednostavnost i veoma laka primjenljivost na svaku zemlju, a njezina je mana osjetljivost na fluktuacije USD.

Kod potonjega, postoji jedna sretna (ili bar olakotna) okolnost. Jasno je da se podacima iz godine 1998. koristilo zbog toga što je tada provedeno i istraživanje, ali je stvar slučajnosti to što je istraživanje provedeno upravo u godini 1998., kada je tečaj USD u odnosu na tadašnje DM (koji je bitan za Hrvatsku) ostvario neku vrstu uobičajenog pariteta, i to u odnosu na razdoblje 1990.-2000. Naime, fluktuacije USD u odnosu na DM u tome su razdoblju varirale od 1,40 do 1,95 DM za USD. U godini 1998. prosječan odnos DM i USD kretao se u granicama 1,65 do 1,75 DM za USD. Stoga je razumljiva tvrdnja da je u toj godini (1998.) tečaj (DEM/USD) poprimio neku vrstu središnjeg pariteta koji ima analitičku vjerodostojnost u primjeni. Poznato je, dakako, da je nakon 2000. (pa do 2003.) USD naglo iskočio iz "uobičajenog" intervala. Vjerojatno je to dijelom bio odraz procesa zamjene u eur, pa je to razdoblje dobro isključiti iz razmatranja. Konačno, značajno je da se već od 2003. USD definitivno vratio u "uobičajeni" interval, a trenutno (studeni 2003.) je na razini 1,70 DM¹⁸, pa postoje argumentirani analitički razlozi koji govore u prilog korištenju podataka iz 1998.

Valja spomenuti da se, premda Garcia u svojem istraživanju nije potkrijepila svoje preporuke ekonometrijskom analizom, preporuka o određivanju limita u razini jednog do dva BDP po stanovniku veoma vjerojatno ipak zasniva na jednostavnoj linearnoj regresiji, a koja se može provesti na podacima prikupljenima u istraživa-

¹⁷ To je najsvježija (praktično jedina) baza podataka o karakteristikama sustava osiguranja štednih uloga po zemljama.

¹⁸ Ako se u obzir uzme paritet USD - euro, pa potom postojeći paritet eur - DM.

nju¹⁹. U tablici 1 prikazane su ocijenjene vrijednosti parametara za dvije jednadžbe. U obje je jednadžbe zavisna varijabla COV (limit), a glavna je eksplanatorna varijabla - BDP po glavi stanovnika. Osnovna je razlika između jednadžbe 1. i jednadžbe 2. u tome što su u jednadžbu 2., uz osnovnu ekplanatornu varijablu, uključene još dvije dummy varijable za dvije zemlje (Norvešku i Italiju), kojih vrijednosti limita značajno odstupaju od vrijednosti ostalih zemalja. Uključivanjem dummy varijabli (u drugoj jednadžbi) stupanj objašnjenosti zavisne varijable mjeren R-kvadratom znatno se poboljšava i dostiže veoma visokih 85%, što ukazuje da nezavisna varijabla BDP po stanovniku veoma dobro objašnjava osnovnu pojavu (limit).

Tablica 1.

REZULTATI REGRESIJE - A

| | Jednadžba 1 | Jednadžba 2 |
|----------------------------|---------------------|---------------------|
| | Zavisna var. COV | Zavisna var. COV |
| BDPpc | 1,816 | 1,183 |
| t - statistika | 6,537 | 8,986 |
| p(t>t _α) | 0,000 | 0,000 |
| DUM_Norveška | | 221.883 |
| t - statistika | | 14,063 |
| p(t>t _α) | | 0,000 |
| DUM_Italija | | 100.547 |
| t - statistika | | 6,523 |
| p(t>t _α) | | 0,000 |
| R-kvadrat | 0,256 | 0,855 |
| R-kvadrat, kor. | 0,256 | 0,850 |
| S.E. regresije | 33.806 | 15.171 |
| Broj opažanja | 59 | 59 |
| Ocjena za HR (kune) | 55.829 | 36.369 |
| donja granica (-1s.e.) | -159.177 | -60.119 |
| gornja granica (+1s.e.) | 270.835 | 132.856 |

¹⁹ Misli se na istraživanje koje je Garcia provela godine 1998. i koje je objavila 1999. (Garcia, 1999.). Valja biti svjestan manjkavosti podataka koji ulaze u regresiju, pa uzevši to u obzir, valja biti oprezan pri donošenju eventualnih zaključaka zasnovanih na rezultatima regresije. Radi se, naime, o nemogućnosti kvantificiranja klauzule koosiguranja kod podataka o visini limita, ali i o problemu obuhvata, jer različiti sustavi osiguranja štite različite vrste računa.

Valja primijetiti, što je važnije, da su ocijenjeni parametri u obje jednadžbe izrazito signifikantni i da parametar uz varijablu BDP po stanovniku poprima vrijednosti između 1,2 i 1,8. Takav rezultat u cijelosti odgovara prije spomenutim preporukama koje sugeriraju utvrđivanje limita na razini jednog do dva BDP po stanovniku. Ipak je potrebno naglasiti da spomenuta preporuka, zasnovana na prikazanim regresijskim jednadžbama, ima određena statistička ograničenja. Pod tim se prije svega misli na veličinu standardne greške regresije koja u slučaju prve jednadžbe iznosi gotovo 34 tisuće USD. Premda je u drugoj jednadžbi veličina greške prepolovljena, ona još uvijek iznosi neprihvatljivo visokih 15 tisuća USD. Posljedica veoma visokih pogrešaka regresije jesu široki intervali procjene. Tako se, npr., u slučaju druge (pouzdanije) jednadžbe granice procjene intervala za Hrvatsku kreću od - 60 do 133 tisuće kuna.

Prikazane dvije regresijske jednadžbe potiču na razmišljanje o uključivanju dodatnih nezavisnih (eksplanatornih) varijabli, a koje bi poboljšale statistička svojstva regresije i proširile horizonte razmišljanja. Naime, uz BDP po stanovniku sigurno postoje i druge varijable koje mogu objasniti postojeće razlike u visini limita među zemljama. Budući da je poznato kako zemlje pribjegavaju povećanju limita kada postoje financijski problemi (kriza), jedna bi od potencijalnih varijabli koja bi mogla dodatno objasniti promatranu pojavu morala biti varijabla koja bi mjerila intenzitet financijskih kriza. Postoji nekoliko radova u kojima su se autori bavili istraživanjem financijskih kriza u različitim zemljama u proteklih dvadesetak godina (Caprio i Klingebiel, 1996.; Demirguc-Kunt i Detragiache, 1998.; Dziobek i Pazarbasioglu, 1997.; Kaminsky i Reinhart, 1996.; Lindgren, Garcia i Saal, 1996.; Frydl, 1999.). Među različitim autorima postoji veće ili manje (ovisno o slučaju) slaganje o tome kada je kriza u nekoj zemlji započela i koliko je trajala. No, samo Lindgren, Garcia i Saal u svojem istraživanju uz dužinu trajanja krize daju i varijablu koja označuje intenzitet krize, s time da ta varijabla praktički poprima binarne vrijednosti 1 (mala kriza) ili 2 (velika kriza). Ni u jednom od radova autori nisu izložili neku vrstu integralne varijable koja bi sveobuhvatno opisivala intenzitet financijske krize. Drugim riječima, autori nisu predložili varijablu koja bi u sebi sadržala i dužinu trajanja krize i intenzitet krize. Kada bi takva varijabla postojala, mogla bi se uključiti u regresiju kao eksplanatorna varijabla koja bi objašnjavala visinu limita. Stoga je prvi zadatak bio konstruirati svojevrstan indeks financijske krize koji bi sadržao i dužinu, ali i intenzitet krize. Uz pomoć podataka koje su iznijele različite skupine autora o financijskim krizama, izrađena je tablica s ulaznim podacima (vidjeti prilog - tablicu A) kojima su se potom koristili pri izračunu indeksa financijske krize. Valja spomenuti da je indeks u osnovi izračunan za svaku zemlju na način da se dužini krize pridavala važnost 0,3 (ponder), a intenzitetu krize pridavana je važnost 0,7. Tako dobijeni indeksi financijske krize uključili su se, uz varijablu BDP po stanovniku, u regresiju. Razlika je u odnosu na prije provedenu regresiju i u to što se ovoga puta umjesto nominalnih vrijednosti BDP po

stanovniku i COV (visine limita) uzimaju njihove logaritamske vrijednosti koje ne mijenjaju smisao, a daju pouzdanije i statistički vjerodostojnije rezultate. U tablici 2 prikazani su rezultati provedene regresije pošto je uključena varijabla financijske krize. Jednadžba 3. pokazuje rezultate prve provedene regresije koja ne uključuje ni jednu dummy varijablu.

Tablica 2.

REZULTATI REGRESIJE - B

| | Jednadžba 3 | Jednadžba 4 |
|----------------------------|-----------------------|-----------------------|
| | Zavisna var. LnCOV | Zavisna var. LnCOV |
| CONST | 2,151 | 2,535 |
| t - statistika | 2,903 | 4,110 |
| p($t > t_u$) | 0,005 | 0,000 |
| LnBDPpc | 0,768 | 0,716 |
| t - statistika | 9,700 | 10,947 |
| p($t > t_u$) | 0,000 | 0,000 |
| FinCri-Index | 0,221 | 0,281 |
| t - statistika | 1,837 | 2,792 |
| p($t > t_u$) | 0,072 | 0,007 |
| DUM_Makedonija | | -2,988 |
| t - statistika | | -3,896 |
| p($t > t_u$) | | 0,000 |
| DUM_Oman | | 2,084 |
| t - statistika | | 2,655 |
| p($t > t_u$) | | 0,010 |
| DUM_Ukrajina | | -2,386 |
| t - statistika | | -3,099 |
| p($t > t_u$) | | 0,003 |
| R-kvadrat | 0,627 | 0,767 |
| R-kvadrat, kor. | 0,614 | 0,744 |
| S.E. regresije | 0,929 | 0,756 |
| F - statistika | 47,08 | 34,80 |
| p($F > F_u$) | 0,000 | 0,000 |
| Broj opažanja | 59 | 59 |
| Ocjena za HR (kune) | 49.772 | 50.797 |
| donja granica (-1s.e.) | 19.653 | 23.857 |
| gornja granica (+1s.e.) | 126.047 | 108.159 |

Pokazalo se da je varijabla financijske krize već i u ovako “nepročišćenoj” formi statistički signifikantna na razini manjoj od 10%. Predznak ispred ocijenjenog parametra indeksa financijske krize pozitivan je, a to odgovara pretpostavci da će zemlja s relativno većim financijskim problemima pribjegavati i utvrđivanju nešto viših limita, a to radi povećanja povjerenja u financijski sustav. Uz to su ostale varijable (konstanta i BDP po stanovniku) izrazito statistički signifikantne. Značajno je da R-kvadrat iznosi više od 60 %, ali je isto tako važno da se standardna greška regresije smanjila, što se može vidjeti iz procijenjenog intervala za slučaj Hrvatske. Također je zanimljivo primijetiti ocijenjenu veličinu za Hrvatsku. Naime, na osnovi vrijednosti parametara iz treće jednadžbe u Hrvatskoj bi limit morao biti određen na razini od 50 tisuća kuna. Takva se ocjena ne razlikuje bitno od ocjena iz prve dvije regresijske jednadžbe, ali je statistički pouzdanija, na što, uostalom, ukazuje i interval procjene.

Jednadžba 4. ne razlikuje se bitno od prethodne treće jednadžbe. Može se primijetiti da se statistička svojstva poboljšavaju pošto su uključene tri dummy varijable (tri zemlje čije proporcije visine limita u odnosu na BDP po stanovniku i indeks financijske krize najviše odstupaju od prosjeka). Statistička signifikantnost novouvedene varijable financijske krize postaje signifikantna na razini od 1%, R-kvadrat iznosi veoma visokih 75 %, a standardna je greška regresije dodatno smanjena. Značajno je da se ocijenjena vrijednost u slučaju četvrte jednadžbe neznatno razlikuje od prethodne i iznosi 51 tisuću kuna. Još se uvijek kao glavna zamjerka regresijskim rezultatima može navesti prilično širok interval procjene. No, zbog veoma velikoga broja različitih zemalja koje su uključene u regresiju (59 zemalja), standardna je greška, koja se kreće u nominalnim granicama od 4 do 9 tisuća USD u slučaju Hrvatske (ovisno o tome radi li se o donjoj ili o gornjoj granici procjene), u potpunosti razumljiva.

U nastojanju da se dodatno proširi broj eksplanatornih varijabli, pokušalo se vidjeti može li neka varijabla institucionalnog karaktera, poput indeksa korupcije, pomoći pri objašnjenju osnovne pojave. Naime, osnovna je ideja da će u zemlji u kojoj postoji povoljnije institucionalno okruženje (manja korupcija kao “proxy” varijabla) postojati općenito veća razina povjerenja u različite institucije zbog njihova kvalitetnijega rada. Kvalitetniji rad institucija implicira primjerice kvalitetniji rad supervizije bankovnog sustava²⁰ ili, pak, kvalitetnije funkcioniranje pravosuđa. U takvom okruženju, u kojem institucije u prosjeku kvalitetnije funkcioniraju, javnost će osjećati relativnu sigurnost u zaštiti njihova privatnoga vlasništva, to će omogućiti regulatornom tijelu da utvrdi relativno nižu visinu do koje će se osiguravati štedni ulogi (limit), a da se pritom ne naruši povjerenje javnosti.

²⁰ Bitno je skrenuti pozornost na važnu vezu između kvalitetnog rada supervizije banaka i rizičnosti poslovanja banaka. Naime, u sustavu relativno slabije supervizije, banke će moći poslovati relativno rizičnije bez straha da će supervizori “kazniti” takvo poslovanje. To, dakako, predstavlja veoma dobar primjer moralnog hazarda na strani bankara.

Uključenje varijable indeksa korupcije na neki je način delikatno zato što je varijabla indeksa korupcije kolinearna s varijablom BDP po stanovniku. To znači da između razine razvijenosti zemlje (mjerene pokazateljem BDP po stanovniku) i razine korupcije (mjerene indeksom korupcije²¹) postoji signifikantna pozitivna statistička veza²², koja pokazuje da će razvijenija zemlja biti manje podložna korupciji. Da bi se izbjegao statistički problem multikolinearnosti među nezavisnim varijablama, rješenje je transformirati zavisnu varijablu, uzevši za zavisnu varijablu omjer visine do kojeg se osiguravaju štedni ulozi i BDP po stanovniku. Time su na desnoj strani jednadžbe preostale dvije nezavisne varijable - indeks financijske krize i indeks korupcije. U tablici 3 prikazani su rezultati provedenih regresija uz pomoć transformirane zavisne varijable. U načelu ne postoje bitne razlike među jednadžbama 5, 6 i 7, osim što te jednadžbe sadrže veći broj dummy varijabli koje (uvjetno) poboljšavaju statistička svojstva ocijenjenih parametara.

²¹ Indeksi korupcije preuzeti su od međunarodne nevladine organizacije Transparency International koja svake godine objavljuje rang listu tj. ljestvicu na kojoj su poredane zemlje po veličini indeksa percepcije korupcije.

²² Valja pojasniti da do pozitivne veze dolazi zbog činjenice da Transparency International rangira korumpiranost zemlje ocjenom od 1 do 10, gdje ocjena 10 označuje totalno nepostojanje korupcije. Stoga, veći indeks percepcije korupcije podrazumijeva nižu razinu korumpiranosti unutar zemlje.

Tablica 3.

REZULTATI REGRESIJE - C

| | Jednadžba 5 | Jednadžba 6 | Jednadžba 7 |
|----------------------------|-------------------------------|-------------------------------|-------------------------------|
| | Zavisna var. Ln(COV/BDPpc) | Zavisna var. Ln(COV/BDPpc) | Zavisna var. Ln(COV/BDPpc) |
| CONST | 0,370 | 0,684 | 1,016 |
| t - statistika | 0,949 | 2,087 | 3,714 |
| p($t > t_u$) | 0,348 | 0,043 | 0,001 |
| FinCri-Index | 0,310 | 0,307 | 0,251 |
| t - statistika | 2,532 | 3,046 | 3,018 |
| p($t > t_u$) | 0,015 | 0,004 | 0,005 |
| Korupcija | -0,091 | -0,129 | -0,162 |
| t - statistika | -1,845 | -3,115 | -4,763 |
| p($t > t_u$) | 0,072 | 0,003 | 0,000 |
| DUM_Makedonija | | -2,791 | -2,901 |
| t - statistika | | -3,870 | -5,051 |
| p($t > t_u$) | | 0,000 | 0,000 |
| DUM_Ukrajina | | -2,172 | -2,311 |
| t - statistika | | -2,994 | -4,000 |
| p($t > t_u$) | | 0,005 | 0,000 |
| DUM_Latvija | | | -1,987 |
| t - statistika | | | -3,459 |
| p($t > t_u$) | | | 0,001 |
| DUM_Estonija | | | -1,622 |
| t - statistika | | | -2,838 |
| p($t > t_u$) | | | 0,007 |
| DUM_Norveška | | | 1,620 |
| t - statistika | | | 2,685 |
| p($t > t_u$) | | | 0,011 |
| R-kvadrat | 0,201 | 0,484 | 0,697 |
| R-kvadrat, kor. | 0,164 | 0,435 | 0,642 |
| S.E. regresije | 0,861 | 0,708 | 0,563 |
| F - statistika | 5,528 | 9,841 | 12,789 |
| p($F > F_u$) | 0,007 | 0,000 | 0,000 |
| Broj opažanja | 47 | 47 | 47 |
| Ocjena za HR (kune) | 52.904 | 65.117 | 76.898 |
| donja granica (-1s.e.) | 22.374 | 32.081 | 43.782 |
| gornja granica (+1s.e.) | 125.093 | 132.169 | 135.060 |

Važno je primijetiti da se već u prvoj prikazanoj (petoj) jednadžbi varijabla indeksa korupcije pokazuje kao statistički signifikantna na razini nižoj od 10 %, a varijabla indeksa financijske krize praktički je signifikantna na razini od 1 %. Jedini značajniji problem jest (početna) statistička nesignifikantnost konstantnog člana, no ona se poboljšava dodavanjem dummy varijabli. Predznaci koji stoje ispred ocijenjenog parametra indeksa korupcije negativni su, a to znači da će manje korumpirana zemlja (viši indeks percepcije korupcije) imati potrebu za utvrđivanjem nižeg omjera limita u odnosu na BDP po stanovniku. Time se potvrđuje prije spomenuta tvrdnja koja povezuje pojavu korupcije s općim institucionalnim okruženjem i visinom do koje se osiguravaju štedni ulazi. O predznacima koji stoje ispred ocijenjenih parametara indeksa financijske krize može se reći da su oni očekivano pozitivni (kao i u prethodnom slučaju). Zanimljivo je, međutim, uočiti da se ocijenjene vrijednosti visine limita za slučaj Hrvatske prilično razlikuju od jednadžbe 5 do jednadžbe 7. Uključivanjem većeg broja dummy varijabli (R-kvadrat se povećava sa dvadesetak na šezdesetak posto) ocijenjena se visina limita povećava sa 53 na 77 tisuća kuna, pri čemu je standardna greška prilično statična i kreće se kao i u prethodnom slučaju u rasponu od 4 do 9 tisuća USD.

Kratak bi zaključak, nakon uključivanja dodatne objašnjavajuće varijable, bio da uključivanje dodatne varijable nije povećalo statističku pouzdanost intervala procjene, ali je pokazalo da na visinu limita ne utječu samo tehnicističke varijable poput BDP po stanovniku i intenziteta financijske krize, već da na visinu limita utječu i varijable institucionalnog karaktera poput indeksa korupcije. Dodatni bi zaključak bio da provođenje ekonometrijske analize nad podacima širokog kruga zemalja ne može dati veoma precizan odgovor o utvrđivanju optimalne visine limita. Kao što se pokazalo u slučaju Hrvatske, ocijenjene se vrijednosti limita kreću u rasponu od 50 do 75 tisuća kuna²³, s time da se donja granica intervala procjene nalazi na otprilike 20 tisuća kuna, a gornja se nalazi na otprilike 130 tisuća kuna. Premda se ocijenjene vrijednosti čine razumno visokima, granice su intervala procjene neprimjereno široke (zbog razumljivih razloga). Stoga je praktična primjena tih rezultata analitički upitna. Ipak, iz svega se ovoga naziru kriteriji o kojima bi se definitivno moralo voditi računa pri utvrđivanju visine limita, a to su: BDP po stanovniku, intenzitet prethodnih financijskih kriza, i neka vrsta varijable koja bi opisivala kvalitetu funkcioniranja institucija (poput indeksa korupcije).

²³ Te se vrijednosti dodatno mogu korigirati za stopu inflacije u proteklih pet godina. U tom slučaju, granice intervala iznose 60 do 90 tisuća kuna. Do sličnih granica intervala dolazi se i ako se regresijske jednadžbe osvježe novijim vrijednostima za BDP i indeksom percepcije korupcije (62 do 85 tisuća kuna). No, korekcija za nove vrijednosti BDP i indeksa percepcije korupcije vjerojatno je manje ispravna u tehničkom smislu od korekcije za stopu inflacije. To je tako zbog činjenice da su se te vrijednosti (BDP i indeks percepcije korupcije) mijenjale u tijeku proteklih 5 godina i u drugim zemljama, a ne samo u Hrvatskoj. Prema tome, bilo bi jedino ispravno ponovno ocijeniti regresijske jednadžbe, a to nije moguće, jer ne postoji svježija baza podataka s iznosima limita po zemljama.

Analiza distribucije štednih uloga

Preostaje razmotriti preporuku koja ukazuje na potrebu analiziranja distribucije štednih uloga u bankovnom sustavu. Valja podsjetiti da je prema toj sugestiji limit potrebno odrediti kod onog iznosa koji "pokriva" približno osamdesetak posto agregiranih štednih uloga²⁴ i dvadesetak posto iznosa ukupne štednje. Preduvjet je za provođenje takve analize posjedovati podatke o distribuciji štednih uloga po bankama, odnosno na agregatnoj razini za cjelokupan bankovni sustav. Nažalost, u slučaju Hrvatske, zbog neraspoloživosti podataka o distribuciji depozita, čini se da provođenje takve analize nije moguće. Ipak, budući da je Državna agencija za osiguranje štednih uloga i sanaciju banaka u procesu isplate osiguranih štednih uloga kreirala bazu podataka o štednim ulozima za propale banke (radi se o 10 banaka²⁵) za potrebe kompenzacije štetiša, moguće je na osnovi tih podataka aproksimirati distribuciju štednih uloga na razini cjelokupnog sustava. Naravno, uz pretpostavku da se prosječne vrijednosti distribucije za propalih deset banaka poistovjete s prosječnim vrijednostima distribucije za cjelokupan bankovni sustav. U procesu izrade distribucije, koristila se podacima o broju štednih uloga (broju JMBG)²⁶ i o visini iznosa na tim računima, i to tako da su oni razvrstani u razrede od po 10.000 kuna (grafikon 1.)²⁷. Iznimka je prvi razred, odnosno drugi razred, gdje su razdvojeni štedni ulozci do 100 kuna, da bi se pokazao veoma veliki broj otvorenih računa s minimalnim iznosom sredstava. Veliki je broj takvih računa (gotovo jedna trećina) u najvećoj mjeri posljedica neprimjerene politike banaka u zatvaranju "mrtvih" računa. Zbog analitičkih će razloga biti važno isključiti te račune iz analize. Također, valja primijetiti kako je na grafikonu prikazana distribucija do 90.000 kuna, pa je tako izuzet posljednji razred od 90 do 100 tisuća kuna (a koji potpada pod osiguranje). Razlog je tome neprimjereno veliki porast količine JMBG i iznosa sredstava na tim računima, a to je odraz cijepanja "velikih" depozita na depozite od po 100 tisuća kuna. Na tu činjenicu ukazuju podaci, ali i anegdotalni izvori,

²⁴ Ovdje se pod osamdesetak posto agregiranih štednih uloga podrazumijeva "pokrivenost" osamdesetak posto fizičkih osoba (npr. za slučaj Hrvatske), gdje se za svaku pojedinačnu fizičku osobu agregiraju svi njeni depoziti u jednoj banci ili štedionici pa se tako dobivaju pojedinačni agregirani štedni ulozci.

²⁵ Županijska banka, Gradska banka, Glumina banka, Komercijalna banka, Ilirija banka, Neretvansko-gospodarska banka, Promdei banka, Hrvatska gospodarska banka, Agroobrtnička banka i Trgovačko-turistička banka.


²⁶ Broj štednih uloga, zapravo, označuje broj jedinstvenih matičnih brojeva građana, zato što se svi računi pojedinog građanina (JMBG) agregiraju u jedan račun s agregatnim iznosom sredstava. Pritom je važno naglasiti da se agregiranje obavlja na razini pojedine banke.

²⁷ Autor se zahvaljuje mr. Đurđici Ognjenović (DAB) za svesrdnu pomoć pri ustupanju i prikupljanju potrebnih podataka.

pa je opravdano pretpostaviti da je distribucija u tom “najvišem” razredu, zbog objektivnih okolnosti, iskrivljena. Izuzimanjem “najvišeg” razreda pretpostavlja se da je distribucija štednih uloga do 90 tisuća kuna “neporemećena” i da odgovara distribuciji u ostalim bankama.

Grafikon 1.

PROCJENJENA DISTRIBUCIJA DEPOZITA



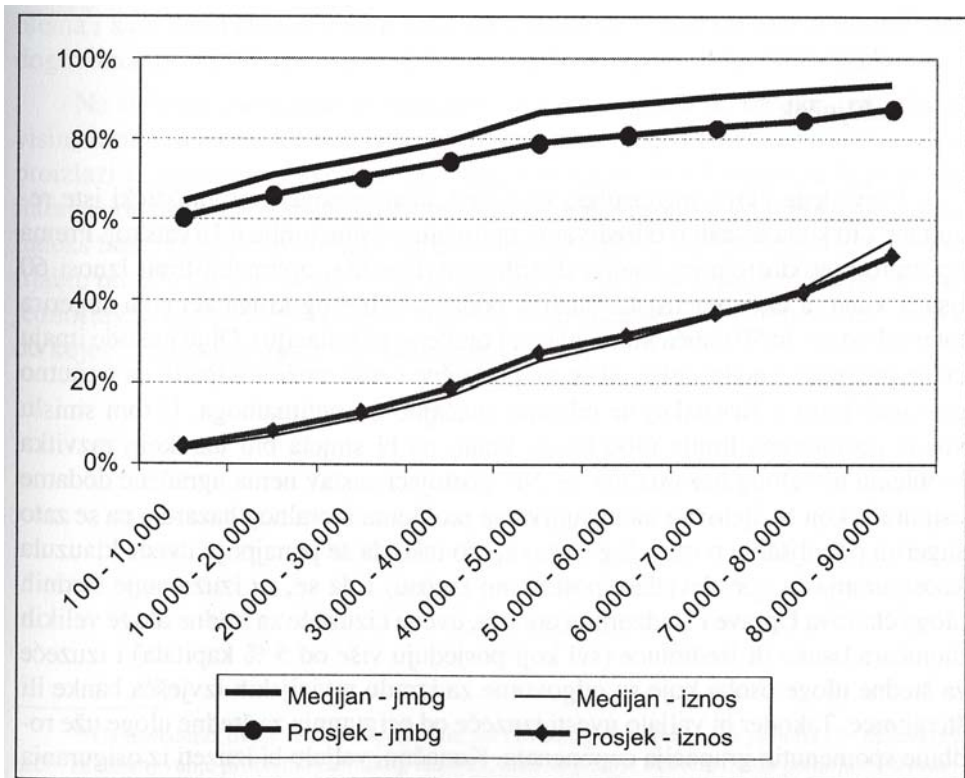
Izvor: Državna agencija za osiguranje štednih uloga i sanaciju banaka

Iz procijenjene distribucije depozita, kakva je prikazana na grafikonu 1., proizlazi da se dvadesetak posto od ukupnoga iznosa štednih uloga pokriva, ako

se štedni ulozu osiguravaju u iznosu od 40 tisuća kuna. Zaključak o visini limita, slijedom preporuke o pokrivanju osamdesetak posto računa (JMBG) nije toliko jednoznačan zato što se krivulje prosjeka i medijana ne poklapaju kao u slučaju iznosa osiguranih štednih uloga. Primjećuje se da medijalna vrijednost količine JMBG dostiže osamdesetak posto već kod pokrića od 10 tisuća kuna, a prosječna vrijednost dostiže tu razinu tek pri pokriću od 40 tisuća kuna. Već je ukazano na problematiku velikog broja računa (JMBG) s neznatnim sredstvima koji mogu poremetiti zaključke, pa su zato na grafikonu 2. iz distribucije izdvojeni računi na kojima "leži" manje od 100 kuna i dobijena je tzv. prilagođena distribucija depozita. Prema takvoj prilagođenoj distribuciji osiguranje štednih uloga u iznosu od 40 do 50 tisuća kuna pokriva približno osamdeset posto računa (JMBG) ovisno o tome uzimaju li se u obzir medijalne ili prosječne vrijednosti. Istovremeno je prijašnji rezultat o pokrivenosti dvadeset posto iznosa ostao nepromijenjen.

Grafikon 2.

PROCJENJENA PRILAGOĐENA DISTRIBUCIJA DEPOZITA



Izvor: Državna agencija za osiguranje štednih uloga i sanaciju banaka

Na osnovi prikazanih distribucija čini se da bi u Hrvatskoj štedne uloge valjalo osiguravati do maksimalnog iznosa od 50 tisuća kuna. Zanimljivo je da je nekoliko regresija prikazanih u okviru ekonometrijske analize pokazalo isti rezultat. No, problem je bio pouzdanost takve ocjene zbog prilično širokog intervala procjene. Valja istaknuti da bi rezultati analize distribucije depozita morali imati veću težinu, tj. vjerodostojnost i da ekonometrijska analiza može samo pojačati uvjerenje u kvalitetu rezultata dobijenih analizom distribucije depozita. Pritom, valja imati na umu ograničenja izloženih rezultata analize distribucije depozita. Uz činjenicu da je za aproksimaciju distribucije na razini cjelokupnog bankovnog sustava uzeta samo raspoloživa distribucija 10 propalih banaka i uz činjenicu da se podaci odnose na godinu 1998., odnosno 1999., valja imati na umu da je 2001. došlo do značajnoga rasta štednje u bankovnom sustavu, a to se tumači procesom zamjene DM u euro. Taj je efekt nesumnjivo promijenio dotadašnju strukturu štednih uloga (pomaknuvši distribuciju na više). Sve u svemu, zbog postojećih je ograničenja, jedino moguće spomenutu procijenjenu vrijednost (50.000 kuna) korigirati za iznos rasta cijena u proteklih pet godina. Tako korigirana procijenjena vrijednost iznosila bi 60.000 kuna.

Zaključak

Provedene dvije, međusobno neovisne, analize sugeriraju praktički iste rezultate, i to kada se radi o određivanju optimalne visine limita u Hrvatskoj. Prema općenito vjerodostojnijoj analizi distribucije depozita, optimalni limit iznosi 60 tisuća kuna, a ekonometrijska analiza podataka širokog kruga zemalja sugerira interval od 60 do 90 tisuća kuna (nakon korekcije za inflaciju). Obje metode imaju svoje prednosti i nedostatke, ali se za praktične svrhe može zaključiti da trenutno postojeći limit u Hrvatskoj ne odstupa značajno od optimalnoga. U tom smislu visina postojećega limita (100 tisuća kuna) ne bi smjela biti uzrokom razvitka problema moralnog hazarda *per se*. No, postojeći sustav nema ugrađene dodatne osigurače koji bi djelovali na umanjivanje problema moralnog hazarda, pa se zato sugerira poboljšanje postojećeg sustava, i to tako da se ponajprije uvede klauzula koosiguranja (u npr. devedesetpostotnom iznosu) i da se, uz izuzimanje štednih uloga članova Uprave i Nadzornog odbora, uvede i izuzeće za štedne uloge velikih dioničara banke ili štedionice (svi koji posjeduju više od 5 % kapitala) i izuzeće za štedne uloge osoba koje su odgovorne za izradu revizijskih izvješća banke ili štedionice. Također bi valjalo uvesti izuzeće od osiguranja za štedne uloge uže rodbine spomenutih grupacija deponentata. Konačno, valjalo bi izuzeti iz osiguranja i sve štedne uloge za koje su deponenti sebi, na individualnoj osnovi, priskrbili takve kamatne stope i općenito financijske ustupke koji su pridonijeli pogoršanju

financijske pozicije banke ili štedionice o kojima je riječ²⁸. Uključivanjem tih dodatnih izuzeća, koja su usklađena s Naputkom EU²⁹, problem moralnog hazarda bio bi bitno smanjen.

Izvan okvira umanjivanja problema moralnog hazarda, sugerira se statističko praćenje kretanja distribucije depozita u hrvatskom bankovnom sustavu. Takvo bi praćenje morala provoditi Državna agencija za osiguranje štednih uloga i sanaciju banaka, i to barem jednom godišnje. Preporučila bi se slična izrada distribucije, kao što je prikazana na grafikonima 1. i 2., uz napomenu da bi bilo potrebno “produžiti” distribuciju do iznosa od 200.000 kuna. Razlog zbog kojeg se preporučuje praćenje distribucije do 200.000 kuna vezan je uz budući pristup Hrvatske Europskoj uniji. Naime, u trenutku kada Hrvatska postane punopravna članica EU, ona će morati preuzeti EU propise o osiguranju štednih uloga, a to za visinu limita znači osiguravati štedne uloge do minimalnog iznosa od 20.000 eura (približno 150.000). Zbog postojećih saznanja (tj. analize provedene u ovom radu) uvođenje tako visokoga limita značilo bi praktično stopostotno osiguranje svih štednih uloga, s potencijalno negativnim posljedicama za stabilnost financijskoga sustava. Tako bi, poznavanje distribucije depozita do 200.000 kuna omogućilo kvalitetnu ocjenu veličine problema i kvalitetnu pregovaračku poziciju, o kojoj će ponajviše ovisiti mogućnost dogovora o prilagodbi (tj. tranzicijskom razdoblju) na viši limit (150.000 kuna).

Na svršetku, nevezano uz doprinos rada na području utvrđivanja optimalne visine limita za Hrvatsku, valja ukazati na još jedan njegov praktičan doprinos. On proizlazi iz ekonometrijske analize, odnosno iz provedenih regresija koje imaju internacionalni karakter. Budući da su se kriterijalne varijable (BDP po stanovniku, indeks financijske krize i indeks korupcije) pokazale kao solidne ekplanatorne varijable pri određivanju visine optimalnog limita, bilo koja zemlja može na veoma jednostavan način (uvrstavanjem vrijednosti) izračunati optimalnu visinu iznosa do kojeg bi morala osiguravati štedne uloge.

²⁸ Uz navedeno, ovdje se može spomenuti još i uvođenje diferenciranih premija kao indirektan način za umanjivanje problema moralnog hazarda, iako se pitanje diferenciranih premija u literaturi najčešće dovodi u izravnu vezu s umanjivanjem problema negativne selekcije.

²⁹ Directive 94/19/EC.

LITERATURA

1. Caprio, Jr.G. i D.Klingebiel (1996). "Bank Insolvencies: Cross Country Experience", Working Paper 1620, World Bank.
2. Carisano, R. (1992). *Deposit Insurance: Theory, Policy and Evidence*. Dartmouth Publishing Company Limited, England.
3. Demirguc-Kunt, A. i E.Detragiache (1998). "The Determinants of Banking Crises in Developing and Developed Countries", IMF Staff Papers, Vol.45, No.1, (Washington: International Monetary Fund).
4. Dziobek, C. i C.Pazarbasioglu (1997). "Lessons from Systemic Bank Restructuring: A Survey of 24 Countries", IMF Working Paper, Br.97/161, (Washington: International Monetary Fund).
5. Folkerts-Landau, D. i C.J.Lindgren sa suradnicima (1997). "Towards a Framework for Financial Stability", Mimeo (Washington: International Monetary Fund).
6. Frydl, E.J. (1999). "The Length and Cost of Banking Crises", IMF Working Paper, Br.99/30 (Washington: International Monetary Fund).
7. Garcia, G. (1996). "Deposit Insurance: Obtaining the Benefits and Avoiding the Pitfalls", IMF Working Paper, Br.96/83 (Washington: International Monetary Fund).
8. Garcia, G. (1999). "Deposit Insurance: A Survey of Actual and Best Practices", IMF Working Paper, Br.99/54 (Washington: International Monetary Fund).
9. Kaminsky, G.L. i C.M.Reinhart (1996). "The Twin Crises: The Causes of Banking and Balance-of-Payments Problems", International Finance Discussion Paper, Br.544, Board of Governors of the Federal Reserve System, ožujak 1996.
10. Kyei, A. (1995). "Deposit Protection Arrangements: A Survey", IMF Working Paper, Br.95/134 (Washington: International Monetary Fund).
11. Lindgren, C.J., G.Garcia i M.Saal (1996). "Bank Soundness and Macroeconomic Policy", Mimeo (Washington: International Monetary Fund).
12. Transparency International (TI) - Corruption Perception Index 1999, <http://www.transparency.de/documents/cpi>.

PRAVNI IZVORI

1. Directive 94/19/EC of the European Parliament and of the Council of 30 May 1994 on deposit-guarantee schemes, Official Journal L 135, 31/05/1994, str.5-14.
2. Narodne novine (1994). *Zakon o državnoj agenciji za osiguranje štednih uloga i sanaciju banaka*. NN 44/94
3. Narodne novine (1997). *Pravilnik o osiguranju štednih uloga*. NN 65/97
4. Narodne novine (1997). *Odluka o visini osiguranih štednih uloga od 20. lipnja 1997*. NN 65/97
5. Narodne novine (1998). *Odluka o datumu početka osiguranja štednih uloga*. NN 4/98.
6. Narodne novine (1998). *Odluka o visini osiguranih štednih uloga*. NN 88/98.
7. Narodne novine (1998). *Pravilnik o izmjenama i dopunama Pravilnika o osiguranju štednih uloga*. NN 105/98.
8. Narodne novine (1998). *Zakon o bankama*. NN 161/98.
9. Narodne novine (2000). *Odluka o proglašenju zakona o izmjeni zakona o državnoj agenciji za osiguranje štednih uloga i sanaciju banaka*. NN 35/00.

- PRILOG -

Tablica A.

INDEKS FINANCIJSKE KRIZE, INDEKS KORUPCIJE
I BDP PO STANOVNIKU

| Zemlja | Indeks Financijske krize | Uk. broj god. trajanja krize | Tip (suma) | Broj kriza | Indeks korupcije (1999.) | BDP po osobi (USD, 1998.) |
|--------------------------|--------------------------------|---------------------------------------|---------------|---------------|--------------------------------|---------------------------------|
| 1. ARGENTINA | 2,00 | 6 | 6 | 3 | 3,00 | 8.254 |
| 2. AUSTRIJA | 0,00 | 0 | 0 | 0 | 7,60 | 26.101 |
| 3. BAHRAIN | 0,00 | 0 | 0 | 0 | | 9.560 |
| 4. BANGLADEŠ | 1,60 | 3 | 1 | 1 | | 265 |
| 5. BELGIJA | 0,00 | 0 | 0 | 0 | 5,30 | 24.505 |
| 6. BRAZIL | 1,15 | 3 | 2 | 2 | 4,10 | 4.869 |
| 7. BUGARSKA | 2,30 | 3 | 2 | 1 | 3,30 | 1.486 |
| 8. KAMERUN | 2,90 | 5 | 2 | 1 | 1,50 | 664 |
| 9. KANADA | 1,60 | 3 | 1 | 1 | 9,20 | 20.143 |
| 10. CEN. AFRIČKA REP. | 2,40 | 9 | 3 | 2 | | 302 |
| 11. ČAD | 1,95 | 6 | 3 | 2 | | 192 |
| 12. ČILE | 2,30 | 3 | 2 | 1 | 6,90 | 4.930 |
| 13. KOLUMBIJA | 1,90 | 4 | 1 | 1 | 2,90 | 2.427 |
| 14. KONGO, REP. | 1,80 | 5 | 3 | 2 | | 699 |
| 15. HRVATSKA | 1,35 | 2 | 3 | 2 | 2,70 | 4.834 |
| 16. ČEŠKA REP. | 1,30 | 2 | 1 | 1 | 4,60 | 5.414 |
| 17. DANSKA | 2,50 | 6 | 1 | 1 | 10,00 | 32.774 |
| 18. DOMINIKANSKA REP. | 1,90 | 4 | 1 | 1 | | 1.956 |
| 19. EKVADOR | 1,30 | 2 | 1 | 1 | 2,40 | 1.621 |
| 20. EL SALVADOR | 1,00 | 1 | 1 | 1 | 3,90 | 1.986 |
| 21. EKV. GVINEJA | 1,65 | 4 | 3 | 2 | | 1.290 |
| 22. ESTONIJA | 2,30 | 3 | 2 | 1 | 5,70 | 3.589 |
| 23. FINSKA | 2,60 | 4 | 2 | 1 | 9,80 | 25.133 |
| 24. FRANCUSKA | 2,20 | 5 | 1 | 1 | 6,60 | 24.579 |
| 25. GABON | 1,30 | 2 | 1 | 1 | | 3.921 |
| 26. NJEMAČKA | 1,90 | 4 | 1 | 1 | 8,00 | 26.215 |
| 27. GRČKA | 2,20 | 5 | 1 | 1 | 4,90 | 11.538 |
| 28. MAĐARSKA | 2,50 | 6 | 1 | 1 | 5,20 | 4.654 |
| 29. ISLAND | 1,15 | 3 | 2 | 2 | 9,20 | 30.137 |
| 30. INDIJA | 2,20 | 5 | 1 | 1 | 2,90 | 440 |

| | | | | | | |
|--------------------------|------|----|---|---|------|--------|
| 31. IRSKA | 1,00 | 1 | 1 | 1 | 7,70 | 24.163 |
| 32. ITALIJA | 2,50 | 6 | 1 | 1 | 4,70 | 20.679 |
| 33. JAMAJKA | 1,30 | 2 | 1 | 1 | 3,80 | 2.773 |
| 34. JAPAN | 1,60 | 3 | 1 | 1 | 6,00 | 30.124 |
| 35. KENIJA | 1,40 | 7 | 3 | 3 | 2,00 | 395 |
| 36. KOREJA | 1,30 | 2 | 1 | 1 | 3,80 | 6.829 |
| 37. LATVIJA | 1,70 | 1 | 2 | 1 | 3,40 | 2.483 |
| 38. LIBANON | 1,60 | 3 | 1 | 1 | | 5.401 |
| 39. LITVA | 2,00 | 2 | 2 | 1 | 3,80 | 2.905 |
| 40. LUKSEMBURG | 0,00 | 0 | 0 | 0 | 8,80 | 42.650 |
| 41. MAKEDONIJA | 2,00 | 2 | 2 | 1 | 3,30 | 1.246 |
| 42. MEKSIKO | 1,85 | 3 | 4 | 2 | 3,40 | 4.328 |
| 43. NIZOZEMSKA | 0,00 | 0 | 0 | 0 | 9,00 | 24.129 |
| 44. NIGERIJA | 2,25 | 8 | 3 | 2 | 1,60 | 389 |
| 45. NORVEŠKA | 3,50 | 7 | 2 | 1 | 8,90 | 32.911 |
| 46. OMAN | 0,00 | 0 | 0 | 0 | | 6.224 |
| 47. PERU | 3,10 | 8 | 1 | 1 | 4,50 | 2.299 |
| 48. FILIPINI | 3,50 | 7 | 2 | 1 | 3,60 | 872 |
| 49. POLJSKA | 1,60 | 3 | 1 | 1 | 4,20 | 4.113 |
| 50. PORTUGAL | 2,80 | 7 | 1 | 1 | 6,70 | 10.718 |
| 51. RUMUNJSKA | 1,90 | 4 | 1 | 1 | 3,30 | 1.844 |
| 52. SLOVAČKA REP. | 2,20 | 5 | 1 | 1 | 3,70 | 3.954 |
| 53. ŠPANJOLSKA | 4,10 | 9 | 2 | 1 | 6,60 | 14.052 |
| 54. SRI LANKA | 2,20 | 5 | 1 | 1 | | 840 |
| 55. ŠVEDSKA | 2,60 | 4 | 2 | 1 | 9,40 | 26.866 |
| 56. ŠVICARSKA | 0,00 | 0 | 0 | 0 | 8,90 | 36.950 |
| 57. TANZANIJA | 1,35 | 2 | 3 | 2 | 1,90 | 250 |
| 58. TRINIDAD I TOBAGO | 3,70 | 10 | 1 | 1 | | 4.737 |
| 59. TURSKA | 1,47 | 3 | 5 | 3 | 3,60 | 3.121 |
| 60. UGANDA | 2,20 | 5 | 1 | 1 | 2,20 | 322 |
| 61. UKRAJINA | 1,90 | 4 | 1 | 1 | 2,60 | 864 |
| 62. VELIKA BRITANIJA | 0,00 | 0 | 0 | 0 | 8,60 | 24.119 |
| 63. SAD | 4,60 | 13 | 1 | 1 | 7,50 | 32.489 |
| 64. VENEZUELA | 2,00 | 2 | 2 | 1 | 2,60 | 4.072 |

Izvori: Izračun autora (na osnovi Frydl, 1999.), Transparency International i International Monetary Fund (International Financial Statistics).

WHAT SHOULD BE APPROPRIATE COVERAGE LEVEL OF DEPOSITS IN CROATIA?

Summary

In the process of formulating a deposit insurance scheme, one of the key issues is to determine the level of coverage. Correctly determined coverage would help to fulfill the aims of the deposit insurance scheme itself and to minimise the moral hazard problem, a negative externality which inevitably coexists with any deposit insurance scheme. In this regard, an important question is how appropriate is the existing coverage level in Croatia (100.000 kuna). Also, one can ask whether an increase to 20.000 € (or approximately to 150.000 kuna), when entering the EU, would cause any problems. To answer these questions, this paper tries to establish the most appropriate coverage level for Croatia. There are two approaches used in the paper. The econometric one analyses data for a large sample of countries with deposit insurance schemes. Independently, the second approach analyses the structure of deposits at banks in Croatia. Both approaches lead to virtually the same results. On this basis, it can be concluded that current coverage in Croatia (100.000 kuna) is not significantly higher than the most appropriate (optimal). However, an increase in coverage to 150.000 kuna could potentially harm the deposit insurance scheme and consequently decrease the stability of the Croatian banking system in the mid-term.

Key words: deposit insurance, coverage, banking system