

IZVORNI ZNANSTVENI RADOVI

*Amina Ahec-Šonje**

UDK 336.711.6

Izvorni znanstveni rad

**ANALIZA OSJETLJIVOSTI BANKARSKOG SUSTAVA-
PRIMJENA “SIGNALNE” METODE**

Ovaj je rad pokušaj detaljne analize makroekonomske i financijske pozadine posljednje bankarske krize u Hrvatskoj koja je započela u proljeće godine 1998. Polazeći od postojećih teorijskih objašnjenja uzročnika bankarskih kriza, testira se mogućnost korištenja nove analitičke i prognostičke metode - signalne metode, u izgradnji prvog domaćeg sustava indikatora za rano upozorenje bankarskih poremećaja. Sustavi signalnih indikatora omogućuju kontinuirano praćenje razine osjetljivosti bankarskog tržišta i u kombinaciji s ostalim analitičkim metodama mogu predstavljati značajan izvor informacija monetarnim i ekonomskim vlastima o stupnju financijske stabilnosti u zemlji. Ovaj rad prikazuje početak ozbiljnog istraživačkog poduhvata kojem je krajnji cilj izgraditi efikasan i dinamički sustav za rano upozorenje bankarskih kriza u Hrvatskoj.

Uvod

U vrijeme visokog stupnja regulacije financijskih i bankarskih tržišta u tijeku sedamdesetih godina 20. stoljeća svijet se uglavnom suočavao s pojavom valutnih kriza različitog intenziteta, uz zanemariv broj ozbiljnijih bankarskih poremećaja. Jačanje procesa financijske deregulacije povećalo je osjetljivost financijskih sustava, što je u osamdesetima, a osobito u devedesetima rezultiralo sve češćom pojavom poremećaja u bankarskom sektoru. Nerijetko su bankarske krize završavale i s ozbiljnijim valutnim poremećajima, i to uglavnom u zemljama u razvoju i u tržištima u nastajanju u kojima se proces financijske liberalizacije i deregulacije odvijao unutar slabog i nerazvijenog institucionalnog okvira.

* A. Ahec-Šonje, doktor znanosti, viši asistent u Ekonomskom institutu, Zagreb. Članak primljen u uredništvu: 3. 10. 2002.

Bankarska kriza pojam je kojim se opisuje ili bankrot pojedinačne banke ili kolaps cijelog bankarskog sustava. U ekonomskoj se literaturi pojmom bankarska kriza ipak češće koristi za opisivanje sustavnih kriznih epizoda koje dovode do kolapsa velikih banaka ili većeg broja banaka sa značajnim udjelom u ukupnoj bankarskoj aktivi.

Snažna financijska liberalizacija, povezivanje financijskih tržišta, tranzicijski proces u tržištima u nastajanju, slobodniji protok kapitala, i val poremećaja koji su zahvatili istočnu i jugoistočnu Aziju u kasnim devedesetima, upozoravaju na visoke ekonomske i socijalne troškove poremećaja u bankarskom sustavu.

Velika depresija 1929. bila je “velika” zbog toga što su pad cijena na tržištima kapitala i recesija uzdrmali ukupan američki financijski sustav. Promašeni zajmovi i navala štediša na banke stvorili su probleme u bilancama banaka, propast banaka blokirala je kreditne kanale prema stanovništvu i poduzećima, došlo je do smanjenja proizvodnje i osobne potrošnje, a to sve zajedno čini obilježje ozbiljne ekonomske kontrakcije - depresije. U takvim uvjetima ekonomija nije mogla oživjeti bez državne intervencije sa ciljem stabiliziranja bankarskog i financijskog sustava. Radilo se o klasičnom cikličkom obrascu nastanka snažne ekonomske krize koju je dodatno pothranila bankarska kriza. Stoga je slom bankarskog sustava zapravo onaj čimbenik koji odvaja ekonomsku depresiju od obične recesije.¹

U mnogim su zemljama već nakon Drugog svjetskog rata zbog straha od pojave sličnih kriza uslijedila čvršća financijska regulacija i kontrola kapitalnih tokova. Svijet je gotovo tri desetljeća bio pošteđen ozbiljnijih sustavnih poremećaja u bankarstvu.² Deregulacijom i postepenim ukidanjem kapitalnih ograničenja u osamdesetim i devedesetim godinama, raste i osjetljivost bankarskih sustava, premda financijska liberalizacija može biti potreban, ali ne i dovoljan uvjet za pojavu bankarske krize. Financijska se liberalizacija i nestabilnost bankarskih sustava često smatraju jednim od ključnih uzročnika izraženijih cikličkih oscilacija u devedesetima. Primjerice, financijska liberalizacija prethodila je dužničkoj krizi u Latinskoj Americi godine 1982., koju su popratili ozbiljni bankarski poremećaji. Oni su, pak, rezultirali snažnom kreditnom kontrakcijom i slijedom toga općom ekonomskom stagnacijom³. No, u literaturi se mogu naći i suprotna objašnjenja,

¹ Kindleberger (1996) smatra da su financijske krize usko povezane s poslovnim ciklusima, i da izbijaju na samome vrhu (peak) ekonomskog ciklusa, pojačavajući cikličku kontrakciju.

² Bordo i Eichengreen (1999) na uzorku dvadesetak zemalja (razvijenih i tržišta u nastajanju) identificirali su u razdoblju 1945-1971 samo jednu ozbiljniju bankarsku krizu, i to u Brazilu godine 1963.

³ Udio depozita u bruto domaćem proizvodu zemalja Latinske Amerike tako je tijekom krize pao čak ispod 20%.

prema njima ozbiljne recesije, bez obzira što ih je potaklo, mogu biti uzročnikom učestale pojave bankarskih poremećaja i kriza.⁴

Uzroci i posljedice bankarskih kriza – teorijska pozadina

Dosadašnje je iskustvo pokazalo da sa svakom novom kriznom epizodom u bankarstvu dolazi do proširenja liste potencijalnih uzročnika tih poremećaja. Usprkos mnoštvu provedenih istraživanja, konsenzusa među ekonomistima oko šire liste uzročnika bankarskih kriza još uvijek nema. Razlog je tome što se parcijalno analiziraju pojedinačne krizne epizode, testiraju se ponekad sasvim različite liste varijabli utjecaja, polazi se od različitih uzoraka (jedni ispituju zbivanja u razvijenim tržišnim ekonomijama, drugi u tržištima u nastajanju, treći polaze od kombiniranog uzorka), koriste se različite metode i tehnike mjerenja utjecaja potencijalnih uzročnika. Logična posljedica te istraživačke rascjepkanosti jest nepostojanje zaokruženih teorijskih objašnjenja bankarskih kriza, i izostanak jedinstvene klasifikacije kriza po vrstama i vremenu njihova izbijanja (*timing* kriza).

Identifikacija bankarskih kriza

Za razliku od valutnih kriza, bankarske je krize teže identificirati konkretnim statističkim podatkom. Teško je predvidjeti i “datum” navale na bankarske šaltere, a kada do nje i dođe, već je ugrožena kvaliteta ukupne bankarske aktive. Identifikaciju pogoršanja kvalitete ukupne aktive bankarskoga sektora uvijek otežava nedostatak adekvatnih direktnih tržišnih pokazatelja vrijednosti imovine banaka. To se može smatrati značajnim ograničenjem, jer su dosadašnji problemi bili često povezani sa zakašnjelom intervencijom vlasti na pogoršane uvjete u bankarstvu, nerješavanjem problema “u hodu”, i zbog zanemarivanja razine osjetljivosti strukture bankarskog sektora na poremećaje.

Početak bankarske krize najčešće označuju neki od specifičnih događaja kao što su, npr., navala štediša na banke i drastično smanjenje ukupnih bankarskih depozita, propadanje i zatvaranje pojedinih banaka, preuzimanje banaka, proširenje vladine pomoći u saniranju banaka, porast udjela loše aktive koja ne donosi očekivani prinos (više od 10% ukupne bankarske imovine), porast gubitaka po

⁴ Debatu među ekonomistima o smjeru kauzalnosti između bankarskih poremećaja i poslovnih ciklusa opisuju Gorton (1991.) i Calomiris i Gorton (1991.).

plasmanima. Vrhunac bankarske krize obilježava zatvaranje većeg broja banaka s visokim udjelom u ukupnoj aktivni bankarskog sustava ili intervenciji ekonomskih vlasti provedbom programa sanacije banaka.

Dok je kod valutnih kriza lako utvrditi krizni događaj, primjerice, jednostavnim izračunavanjem indeksa pritiska na deviznom tržištu⁵, konstrukcija indikatora bankarske krize gotovo je nemoguća zbog pojave problema asimetričnih informacija, i zbog problema dostupnosti stvarnih podataka o gubicima po plasmanima.

Posljedica je toga da u literaturi još uvijek ne postoji konsenzus o definiranju sustavne bankarske krize, ne postoji jedinstveni kriterij prema kojem se neka kriza može proglasiti sustavnom. Primjerice, Caprio i Klingebiel, (1996.a, 1996.b) predlažu jednostavan kriterij utvrđivanja datuma početka krize koji kombinira podatke o gubicima po plasmanima i kvalitativne pokazatelje o "zdravlju" bankarske aktive, a potom se od eksperata traži stručna prosudba radi li se zaista o krizi ili ne.⁶ Demirguc-Knut i Detragiache (1997.) za identifikaciju kriza koriste se s nekoliko kriterija: udio gubitaka po plasmanima u ukupnoj bankarskoj aktivni premašuje 10%, trošak sanacije banaka prelazi 2% BDP, poremećaj se manifestira tako da država preuzimanjem banke, zatim navala štediša na šaltere ili signali poput zamrzavanja depozita i produženih praznika u bankama. Lindren, Garcia i Saal (1996.), i Kaminsky i Reinhart (1996.) utvrđuju početak sustavnih bankarskih kriza identificiranjem događaja koji započinju navalom štediša na banke, portfolio poremećajima, bankrotom banaka i financijskih institucija, zatvaranjem, spajanjem i preuzimanjem problematičnih banaka i općom državnom intervencijom u bankarski sustav.

Vrste i uzroci bankarskih poremećaja

U ekonomskoj su literaturi poznata dva smjera istraživanja bankarskih kriza: jedan smjer proučava mikroekonomski aspekt kriza, a drugi smjer traga za makroekonomskim indikatorima bankarskih kriza. Podjela na mikro i makroaspekt kriza potječe iz jasne konceptualne razlike između neuspjeha pojedinačnih banaka i sustavne bankarske krize.

⁵ Prve prijedloge kako mjeriti osjetljivost deviznog tržišta, odnosno pritiske na devizno tržište uzrokovane snažnim spekulativnim napadima nalazimo još kod Girtona i Ropera (1977.). Ideju o mjerenju pritiska na devizno tržište preuzimaju Eichengreen, Rose i Wyplosz (1995.), a nešto poslije i zagovornici koncepta "twin" kriza Kaminsky, Lizondo i Reinhart (1997.).

⁶ Istraživanje Capria i Klingebiel (1996.b) često je citiran izvor koji donosi listu kriznih bankarskih epizoda, koja je mnogim autorima poslužila kao polazište za identifikaciju kriza. Autori su poslije početnu listu iz godine 1996. revidirali i ažurirali (Caprio i Klingebiel, 1999.).

Pojedinačni bankarski neuspjeh

Banke se suočavaju s financijskim problemima, kao i svi ostali poslovni subjekti, kada vrijednost imovine banke padne ispod vrijednosti njezinih obveza, što se naziva tehnička nesolventnost. Vrijednost imovine banke može ugroziti rast *kreditnog rizika* (stupanj vjerojatnosti otplate duga), *tržišni rizik* (rizik promjene cijene imovine – koja kotira na tržištu)⁷ i operativni rizik. U prva dva slučaja banka može smanjiti svoj rizik pažljivim projiciranjem cijena imovine, diverzifikacijom svog kreditnoga portfolia i uzimanjem ili prihvaćanjem kolaterala (sredstava osiguranja potraživanja). No, zbog neizvjesnosti i nesavršenih (asimetričnih) informacija navedene rizike nije moguće u potpunosti izbjeći, jer poduzetnici u pravilu uvijek znaju više o svojim investicijskim poduhvatima od banke koja taj projekt kreditno podupire. Razni nepredviđeni događaji koji mogu poremetiti financijsku stabilnost dužnika banke ili uzrokovati poremećaj i komešanje na tržištima kapitala također povećavaju spomenute rizike i vjerojatnost bankarskog poremećaja. No za banke su sasvim sigurno najvažniji kretanje tržišnih kamatnih stopa i s time povezani *kamatni rizik*. Ako bankari ispravno ne anticipiraju kretanje svoje krivulje prinosa, stopa prinosa na aktivu može značajno pasti u odnosu na stopu koju plaćaju na svoje obveze. Spomenimo još i značaj izloženosti banaka *valutnom riziku*, koji nastaje zbog promjene tečaja nacionalne valute, što utječe na vrijednost bilančnih (i izvanbilančnih) pozicija nominiranih u stranoj valuti. Zbog razlike u iznosu aktive nominirane u nekoj stranoj valuti i iznosa pasive nominirane u toj istoj valuti, promjene tečaja te valute mogu rezultirati dobitkom ili gubitkom, a to utječe na vrijednost kapitala.

Banke mogu zapasti u krizu i zbog svoje sklonosti tzv. “*boom and bust*” *ponašanju* u tijeku poslovnog ciklusa (Gavin i Hausmann, 1996.). Banke su sklone u tijeku cikličkog uzleta podcijeniti problem asimetričnih informacija, negativne selekcije i moralnog hazarda, zbog čega mogu upasti u klopku financiranja projekata sa slabijim dugoročnim izgledima. Optimistička očekivanja u vrijeme ekonomskog uzleta potiču kreditnu aktivnost, a ulagački optimizam može dovesti do napuhavanja tržišta kapitala i snažnog rasta cijena raznih oblika imovine (*assets-price bubbles*). U takvim uvjetima banke postaju ranjive na nepredvidivo kasnije pogoršanje financijske situacije svojih dužnika, posebno ako dođe do smanjenja vrijednosti imovine, bez obzira radi li se o imovini banke ili, pak, o vrijednosti kolaterala.

⁷ Primjerice, obveznica nosi i tržišni i kreditni rizik. Tržišni rizik povezan je s mogućnošću promjene cijene na tržištu obveznica (ako tržišna cijena padne ispod cijene po kojoj je obveznica kupljena, dolazi do financijskog gubitka). Kreditni je rizik rizik naplate duga po obveznici.

Problemi asimetričnih informacija, porast kreditnog rizika i moralnog hazarda postaju osobito opasni u razdobljima visoke inflacije koja, rezultirajući padom realnih kamatnih stopa, dovodi do smanjenja štednje i potiče kreditiranje. Ako se kreditna ekspanzija odvija u uvjetima pada kvalitete kreditiranih projekata, banke se izlažu većem kreditnom riziku, čime se povećava vjerojatnost većih bankarskih gubitaka (*rizik nesolventnosti*). *Inflacija* može izazvati probleme u bankarstvu i standardnim makroekonomskim kanalima, povećavajući ekonomsku nesigurnost i nepostojanost vrijednosti robe i kapitala, dovodeći do značajnijeg poremećaja relativnih cijena, što općenito povećava vjerojatnost tržišnog neuspjeha brojnih poslovnih subjekata, među njima i banaka, ako nisu adekvatno procijenile rizik poslovanja u razdoblju visoke inflacije⁸.

Uz *rizik nesolventnosti* banke su izložene i *likvidnosnom riziku*. Taj rizik predstavlja potencijalnu opasnost od nemogućnosti podmirenja obveza u roku dospijeca, zbog neusklađene ročne strukture izvora sredstava i plasmana. Problem neusklađenosti ročne strukture pasive i aktive može povećati vjerojatnost navale štediša na šaltere ili trke na banku (*bank run*). Slučaj navale štediša na banku izložili su i objasnili Diamond i Dybvig (1983.) u svom poznatom modelu koji se zasniva na postojanju dviju ravnoteža: prva je situacija navale depozitara na banku, a druga je situacija u kojoj depozitari vjeruju u banku i u njoj zadržavaju svoje depozite. Prva (loša) ravnotežna situacija nastaje kada pojedini depozitari povlače depozite zbog straha da će to učiniti i svi ostali štediše zbog bilo kojeg razloga, dovodeći banku ubrzo u stanje nelikvidnosti, premda je banka bila u početku likvidna. To se još naziva i efektom koordinacijske greške depozitara (*coordination failure among depositors*). Djelotvoran institucionalni i regulatorni okvir, osobito kroz sustav osiguranja štednih uloga može oslabiti djelovanje efekta koordinacijske greške depozitara. No, ako visina premije osiguranja štednih depozita nije dovoljno visoka da bi odražavala stupanj izloženosti banke raznim rizicima, takav sustav osiguranja depozita može banku dodatno potaknuti na preuzimanje prevelikih rizika, pa banka može postati sklonija lošim plasmanima i još osjetljivija na iznenadne promjene makroekonomskih uvjeta. Na taj način sustav koji je imao za cilj smanjiti rizik likvidnosti, na kraju može povećati rizik insolventnosti.

U literaturi postoje različiti, često i suprotstavljeni stavovi o utjecaju sustava osigurane štednje i mogućnosti korištenja kredita *posljednjeg utočišta* (centralne banke) na ponašanje poslovnih banaka. Tako se uz pozitivne učinke sustava osiguranja štednih uloga često ističu i oni negativni. Naime, nerealno visoki iznosi osigurane štednje i niske premije osiguranja, koje objektivno ne odražavaju izloženost banaka poslovnim rizicima, i postojanje zajmodavca u krajnjoj potrebi (*lender of last resort*), mogu djelovati i negativno, potičući banke na još veću

⁸ Vidjeti u Boyd, Chang i Smith (1998.).

izloženost raznim rizicima u poslovanju, čime raste i vjerojatnost njihova tržišnog neuspjeha.

Bankarska “zaraza” ili sustavna bankarska kriza

Poremećaj u poslovanju banke može biti povezan s problemima drugih banaka ako sve ili većinu banaka u sustavu istovremeno pogodi neki nepredviđeni događaj ili ako su banke financijski izložene jedne prema drugima. U tim slučajevima postoji podloga za pojavu efekta bankarske zaraze. Poremećaji u bankarskom sustavu najčešće nastaju ako sve banke imaju slična fundamentalna obilježja.

Najčešći uzročnik pojave sustavnog bankarskog rizika i pojave sustavne krize⁹ jest djelovanje **efekta zaraze** zbog kojeg dolazi do proširenja financijskih poremećaja s jedne banke na ostale banke u sustavu. U literaturi se najčešće spominju *tri vrste bankarske zaraze*:

- a) “čista” bankarska zaraza,
- b) zaraza inicirana informacijama i
- c) institucionalna zaraza.

Do “čiste” bankarske zaraze može doći neovisno o promjeni ekonomskih preduvjeta¹⁰ i takvi poremećaji na bankarskom tržištu nisu potaknuti informacijama. Dakle, riječ je iznenadnoj panici među depozitarima, jer propast jedne banke dovodi do trke na šaltere ostalih banaka neovisno o sličnostima ili razlikama među bankama u sustavu. Ipak, Calomiris i Gorton (1991.) smatraju da je veoma teško razlikovati efekt čiste zaraze od zaraze inicirane informacijama. Njihov je stav da bankarsku krizu može potaknuti objava informacija o lošem poslovanju nekih ili svih banaka, no isto tako krizu mogu potaknuti nepotpune informacije među depozitarima. Kako depozitari nemaju informaciju o tome koje su banke izložene većim rizicima, počinje povlačenje depozita iz svih banaka. Institucionalna zaraza nastaje zbog direktne

⁹ Potresi u bankarstvu Finske, Norveške i Švedske u ranim devedesetima mogu se okarakterizirati sustavnom bankarskom krizom. Financijska liberalizacija u tim zemljama sredinom osamdesetima u razdoblju cikličkog uzleta i uz ekspanzivnu makroekonomsku politiku, potaknula je prekomjerno kreditiranje i dugoročno neodrživo ponašanje bankara i investitora. Makroekonomski zaokret koji je uslijedio u Europi i promjena monetarne politike skandinavskih zemalja, izazvali su pad cijena imovine, pojačali cikličku kontrakciju, što je rezultiralo gubicima po plasmanima niza banaka. Podrobnije o uzrocima sustavne bankarske krize u skandinavskim zemljama u devedesetima vidjeti u Drees i Pazarbasioglu (1998.).

¹⁰ Vidjeti Kaufman (1994.) i Masson (1998.).

međusobne izloženosti banaka na međubankarskom tržištu. Taj oblik zaraze jednostavno opisuje prošireni Diamond-Dybvig model u kojem se umjesto odnosa dviju banaka i dviju ravnotežnih situacija, promatra odnos i međusobna izloženost više različitih banaka na bankarskom tržištu.¹¹ Riječ je o modelu širenja sustavnog rizika i destabilizacije međubankarskog tržišta. Međusobnim kreditiranjem banke “u hodu” rješavaju svoje privremene probleme likvidnosti bez troška držanja viška rezervi, ali, postojanje međubankarskog tržišta pojačava izloženost sustava riziku koordinacijske pogreške depozitara, čak i kada su sve banke solventne. Prošireni Diamond-Dybvig model polazi od pretpostavke da bilo koji egzogeni šok koji dovodi do povećanja potražnje za gotovinom jedne ili više banaka, dovodi do ozbiljnog likvidnosnog problema koji može zahvatiti cijeli sustav. Moguće je zamisliti situaciju u kojoj neka banka, koja zbog nepredviđenog događaja postane privremeno nelikvidna, neće biti u stanju na međubankarskom tržištu dovoljno brzo pribaviti sredstva za premošćivanje problema. Ona može krenuti u brzu naplatu svojih međubankarskih potraživanja, dovodeći ostale banke u sličnu situaciju. Na taj način poremećaj u jednoj banci može destabilizirati bankarski sustav u cjelini¹².

Osim efekta zaraze, u literaturi se često spominju i dva načina transmisije poremećaja, od kojih oba predstavljaju tzv. **efekt prelijevanja** ili “*spillover*” efekt. Kod prvog načina, zbog uključenosti banaka u sustav platnog prometa, i zbog izloženosti banaka na međubankarskom tržištu, može doći i do porasta rizika nesolventnosti, dakle i do stvarnih bankarskih gubitaka, bez obzira na uzrok njihova nastanka. Ponašanje prema “zakonima stada” na tržištima kapitala uzrok je druge vrste “*spillover*” učinka, zbog kojeg iznenadni šok na tržištu kapitala može ugroziti ukupnu likvidnost financijskih tržišta, čak i bankarskih sustava, bez obzira koji je segment financijskog tržišta bio inicijalno pogođen (tržište vrijednosnih papira, tržište *izvedenica* ili *derivativa*¹³, tržište nekretnina).

¹¹ Vidjeti: Freixas, Parigi i Rochet (1999.) i Allen i Gale (2000.). Allen i Gale analiziraju mogućnost širenja zaraze između regionalnih banaka koje su izložene jedna prema drugoj međubankarskim potraživanjima; kada jednu regiju zahvati bankarska kriza, banke druge regije mogu pretrpjeti gubitke zbog pada vrijednosti potraživanja problematične regionalne banke.

¹² Freixas, Parigi i Rochet (1999.) u nastavku svoga rada preispituju ulogu centralne banke u sprečavanju širenja sustavnog rizika na međubankarskom tržištu i opravdanost “too big to fail” politike u slučaju kada inicijalno zdrav sustav (solventne banke) zbog nepredviđenog događaja zapadne u likvidnosne probleme.

¹³ Derivati su vrsta vrijednosnih papira, kao što su ugovori o opcijama, koji se zasnivaju na vrijednosnim papirima ili robi.

Razlika između bankarske osjetljivosti i krize

Osnovni je nedostatak većine dosadašnjih empirijskih radova o bankarskim krizama to što često ne razlikuju osjetljivost bankarskog tržišta na poremećaje od stvarne krize. Rezultat je nepostojanje jedne eksplicitne i opće prihvaćene mjere osjetljivosti sustava na poremećaje, koju je moguće analizirati prije izbijanja krize. Istraživači najčešće tek implicitno pretpostavljaju da je osjetljivost financijskog sustava zapravo veoma blaga verzija prave krizne epizode. No, *ranjivost sustava može se promatrati kao obilježje strukture bankarskog sustava, a krizu valja promatrati kao moguću (ne i bezuvjetnu) posljedicu različitih negativnih utjecaja na strukturu bankarskog sustava*. Što je sustav u kvalitativnom smislu ranjiviji, to je i vjerojatnost izbijanja krize veća zbog iznenadnog šoka¹⁴. Ranjivost je stoga značajno obilježje strukture bankarskog sustava i potreban uvjet podložnosti poremećajima. U dosadašnjim se istraživanjima uzročnika bankarskih kriza ipak premalo vodilo računa o potrebi razlikovanja osjetljivosti na poremećaje od prave krize. Ovdje je riječ i o veoma značajnom problemu za monetarne vlasti, jer se fokusiraju pitanja prevencije i preventivnih mjera prema stupnju osjetljivosti bankarskog sektora.¹⁵ Ako se ranjivost sustava analizira samo nakon već proživljene krize, što o toj istoj ranjivosti znamo iz razdoblja koja ne završavaju kriznom epizodom? Možemo li prepoznati rizike u svakom trenutku i odnosimo li se prema stupnju osjetljivosti sustava na adekvatan način pripremom preventivnih mjera? Ne praveći razliku između osjetljivosti i krize gubimo iz vida značajne informacije iz razdoblja koja nisu završila krizom, a koja nam mogu pomoći u predviđanjima budućih poremećaja. Ako monetarne vlasti uče na temelju ex-post analiza i otkriju uzročnike već proživljenih kriza, ako se mogu tim informacijama koristiti za praćenje osjetljivosti sustava na poremećaje, logičan će rezultat biti razlika među signalnim indikatorima za različita razdoblja i za različite zemlje. Stoga valja izbjegavati jednoobrazne (reducirane) i statičke modele bankarskih kriza. Izazov za istraživače mora biti izgradnja efikasnih dinamičkih modela praćenja strukturne osjetljivosti bankarskih sustava na poremećaje.

Istražujući kako financijska struktura utječe na pojavu kriza, Eichengreen i Rose (1998.) predlažu praćenje *ključnih mjera osjetljivosti bankarskog sustava*:

¹⁴ Za pojašnjenje strukturne osjetljivosti može poslužiti primjer kristalne čaše koja je krhka zbog svoje molekularne strukture (Bell i Pain, 2000.). Autori su se poslužili usporedbom koju je iznio Rudiger Dornbusch (1998.), opisujući razoran utjecaj nepredvidivog događaja, potresa na strukturu građevine u svojoj analizi uzročnika poslovnih ciklusa.

¹⁵ Priprema hitnih mjera prevencije za slučaj širenja likvidnosnih poteškoća, smanjila je rizik od ozbiljnijeg sistemskog poremećaja u bankarskoj industriji Velike Britanije na početku devedesetih, kada se u gubicima našlo nekoliko manjih banaka, smatra Logan (2000.).

- a) *M4(M2)/rezerve (reserve adequacy ratio* – odnos šireg novca i deviznih rezervi, čije povećanje prati proces financijske liberalizacije i rast osjetljivosti sustava uz nespremnju bankarsku superviziju i regulativu u situaciji kreditne ekspanzije),
- b) *udio bankarskih rezervi u ukupnoj bankarskoj aktivni* kao mjera likvidnosti bankarskog sustava i
- c) *udio bankarskih kredita javnom sektoru u ukupnim plasmanima* kao pokazatelj izloženosti bankarskog sektora nepovoljnim kretanjima fiskalnih varijabli.

Uzroci bankarskih poremećaja

Dokaze o djelovanju efekta čiste bankarske zaraze nećemo naći u empirijskim istraživanjima kriza. Najčešće se u literaturi spominje efekt zaraze inicirane informacijama (*information-based contagion*), koja uglavnom zahvaća banke slične bilančne strukture¹⁶. Većina istraživanja pokazuje da razne **informacije o poslovnoj klimi, o izvorima sredstava, o tržišnoj strukturi i o makroekonomskom okruženju banaka** mogu biti korisni signali koji ukazuju na mogućnost pojave krize. Negativne promjene u makroekonomskom okruženju i u ekonomskoj politici (slabost monetarne i fiskalne politike koja može dovesti do neodrživih razina deficita platne bilance i/ili budžetskog deficita), i negativne promjene makroekonomskih varijabli (BDP i kamatnih stopa) za banku mogu biti veoma neugodno iznenađenje. Sa druge, pak, strane, pozitivna kretanja tih varijabli i pozitivno makroekonomsko okruženje mogu banke potaknuti na prekomjerno kreditiranje i na pretjerano izlaganje prije spomenutim rizicima. Indikatori sposobnosti banaka da objektivno procjene sve vrste rizika u svome poslovanju, u značajnoj mjeri mogu pomoći u ocjeni njihove osjetljivosti na promjene makroekonomskih uvjeta. I razne **institucionalne varijable** mogu olakšati ili pak otežati funkcioniranje financijskog sustava. U brojnim se istraživanjima ispituje kako na pojavu bankarskih poremećaja djeluju razina kvalitete institucionalnog okvira, sustav plaćanja u zemlji, sustav osiguranja štednih uloga, i razvijenost međubankarskog tržišta i izloženost banaka na financijskom tržištu. Kada tome dodamo i one pokušaje koji ispituju ulogu **vanjskih (međunarodnih) čimbenika, vrste tečajnih režima, i procesa financijske liberalizacije**, lista potencijalnih uzročnika bankarskih poteškoća postaje sve opsežnija.

¹⁶ Vidjeti: Kaufman (1994.), Aharony i Swary (1996.). Docking, Hirshey i Jones (1997.).

No, na osnovi dosadašnjih empirijskih analiza moguće je listu uzročnika značajno suziti, osobito ako tragamo za konsenzusom među istraživačima. Empirijski nam radovi otkrivaju da su među **makroekonomskim varijablama** najčešći i naj snažniji uzročnici bankarskih poremećaja¹⁷:

- 1) snažan rast kreditne aktivnosti
- 2) porast udjela vanjskog duga u bruto domaćem proizvodu
- 3) promjene realnih kamatnih stopa
- 4) deregulacija politike pasivnih kamatnih stopa.

Od **mikroekonomskih varijabli** najčešće se spominju dva pokazatelja koji se smatraju dobrim *proxy* varijablama osjetljivosti banaka i bankarskog sustava na poremećaje¹⁸:

- 1) porast udjela nepodmirenenih zajmova u ukupnoj bankarskoj aktivni
- 2) nizak udio kapitala u ukupnoj aktivni (imovini) banke.

Većina autora dijeli mišljenje kako u tržištima u nastajanju bankarsku stabilnost najčešće ugrožava kombinacija između “nerazborite” domaće makroekonomske politike i procesa financijske deregulacije, čemu se nerijetko pridružuju i nepovoljna kretanja u međunarodnom okruženju. Istraživači će se uglavnom složiti i o tvrdnji da su problematične banke obično jače izložene prema sektorima ekonomije koji u početku doživljavaju nagli rast, među kojima brojni i bankrotiraju neposredno prije izbijanja bankarske krize. Ipak ostaje činjenica da kada se gore navedena kratka lista signifikantnih uzročnika bankarskih problema proširi ostalim potencijalnim čimbenicima (međunarodni čimbenici, tečajni režimi, financijska liberalizacija, sustav osiguranja štednih uloga, kvaliteta institucionalnog okvira,...) koji su bili predmetom dosadašnjih analiza, konsenzusa među istraživačima ima sve manje, a rasprava postaje sve polemičnija.¹⁹

Bez obzira na polemične tonove u raspravama o uzrocima kriza, istraživači se ipak slažu u tvrdnji da su bankarske krize mnogo ozbiljnije, oštrije, i opasnije za gospodarski život zemlje od valutnih kriza. Vremenski traju duže od valutnih, o čemu svjedoči obrazac ponašanja brojnih ekonomskih i financijskih varijabli koje još mjesecima nakon krize zadržavaju negativan trend kretanja ili se veoma sporo oporavljaju. Bankarska je kriza opasnija od valutne jer može paralizirati financijski “krvotok” zemlje u koji su uključeni i javni i privatni sektor, može izazvati poteškoće u poslovanju, pa čak i bankrote brojnih poslovnih subjekata, i trajnije poljuljati

¹⁷ Vidjeti u: Hardy i Pazarbasioglu (1999.) i Eichengreen i Arteta (2000.).

¹⁸ Vidjeti u: Hardy i Pazarbasioglu (1999.) i Gonzalez-Hermosillo (1999.).

¹⁹ Podrobnije o uzročnicima bankarskih kriza i debati među ekonomistima o mjerljivim i teže mjerljivim pokretačima poremećaja vidjeti Ahec-Šonje (2002., doktorska disertacija).

povjerenje štediša i svih ostalih komintenata u bankarski i financijski sustav. Bankarske su krize oštrije i stoga što su skuplje od valutnih, jer iziskuju vrlo visoke troškove saniranja posrnulog bankarskog sustava. Ti se troškovi najčešće kreću od 4%-7% BDP za razvijene zemlje, a u zemljama u razvoju i tržištima u nastajanju fiskalni se troškovi bankarskih kriza često penju i znatno više od 10% BDP.²⁰

Metodologija istraživanja bankarskih kriza

Iz pregleda literature o financijskim krizama (valutnim, bankarskim, dužničkim) može se zaključiti da je istraživačima ipak najteže bilo identificirati i definirati bankarsku krizu, prije svega zbog ograničenosti podataka i pravih tržišnih indikatora promjene vrijednosti bankarskog kapitala. U analizi bankarskih kriza najteže je utvrditi datum njihova početka, a i o definiciji sustavne bankarske krize još uvijek nije ostvaren konsenzus među istraživačima. Stoga se u literaturi pojavljuju različite definicije, ovisno o kombinaciji događaja i pokazatelja koje su pojedini istraživači uzimali u razmatranje. To je glavni razlog zbog kojeg empirijski dio literature o bankarskim krizama još uvijek ostavlja dojam nesređenosti i neujednačenosti u pristupu analizi poremećaja.

Sustavnu potragu za uzrocima bankarskih (i financijskih) kriza nećemo naći samo u znanstvenoj ekonomskoj literaturi. Indikatore ranog upozorenja kriza počele su u devedesetima razvijati i vodeće svjetske financijske institucije, i razne agencije za utvrđivanje kreditnog rizika zemalja koje izlaze na svjetsko financijsko tržište. S vremenom se procjenama osjetljivosti financijskih sustava i stupnja rizičnosti za potencijalne ulagače počinju baviti i privatni sektor, i bankarski supervizori.²¹ No većina tih sustava procjene osjetljivosti ipak se zasniva na indikatorima koji su

²⁰ Trošak sanacije bankarskog sustava u skandinavskim zemljama, Finskoj, Švedskoj i Norveškoj, u razdoblju godina 1991.-1992. prema procjenama Kaminsky i Reinhart (1999) iznosio je 5%-7% BDP, što je blizu procjenama Eichengreena i Arteta (2000.) koji govore o trošku od 4%-10% BDP. Među tržištima u nastajanju spomenut ćemo Venezuelu, u kojoj je trošak rehabilitacije bankarskog sustava iznosio 13% BDP godine 1994. Grube procjene govore da je trošak tzv. prve bankarske krize u Hrvatskoj, od početka tranzicije do godine 1996. iznosio oko 23% BDP iz godine 1996., a trošak druge bankarske krize iz godine 1998. znatno je niži i iznosi oko 3%-4% BDP iz godine 1999.

²¹ Izradom sustava pokazatelja za rano upozorenje kriza danas se bave, primjerice, *IMF Policy Development and Review Department* (sustav ranog upozorenja), *Bank for International Settlements* (BIS) koji prati financijsku osjetljivost tržišnih ekonomija u nastajanju, *IMF Research Department* (primjenom signalne metode), *The World Bank Country Credit Risk Department* (model procjene stupnja rizičnosti neispunjenja dužničkih obaveza), *World Bank - IMF Financial Sector Assessment Program (FSAP)* (razvitak tzv. makroprudencijalnih indikatora - *macroprudential indicators*), i *OECD*.

izabrani na osnovi *ad hoc* procjena pojedinih institucija, a ne u okviru znanstveno-istraživačkih analiza koje polaze od teorijskih saznanja o uzrocima financijskih i bankarskih kriza.

Premda pojavu praktičnih i jednostavnih sustava za rano upozorenje kriza ranih devedesetih ne treba zanemariti, ipak su takvi pokušaji u sjeni ozbiljnijih znanstvenih istraživanja koja su potpomogla nastanku zaokruženih teorijskih modela valutnih i bankarskih kriza. S pojavom prvih ozbiljnijih valutnih poremećaja u svijetu na svršetku sedamdesetih, krenulo se u empirijsku potragu za uzrocima tih kriza. To je dovelo do razvijanja tzv. **tradicionalnih metoda analize**, koje se na svršetku osamdesetih i na početku devedesetih počinju koristiti i u analizama uzročnika bankarskih kriza. Tradicionalnim metodama analize smatraju se: a) kvalitativne usporedbe i opisi kriznih događaja i b) razni ekonometrijski (parametarski) modeli. U drugoj polovini devedesetih razvija se alternativna metoda poznata kao **signalna ili neparametarska metoda** koja pokušava prevladati nedostatke tradicionalnih tehnika u potrazi za indikatorima financijskih kriza.

Tradicionalni modeli

Među tradicionalne tehnike analize ubrajaju se jednostavni kvalitativni opisi događaja koji prethode krizi, bez testiranja utjecaja pojedinih varijabli, i radovi koji uglavnom uz pomoć grafičke metode istražuju kretanje osnovnih ekonomskih varijabli prije i nakon izbijanja financijskih kriza.²² Među tradicionalnim metodama ipak dominira upotreba ekonometrijskih (parametarskih) modela, a najčešće se koriste **ekonometrijski modeli za procjenu vjerojatnosti pojave krize**. Modelima procjene vjerojatnosti utvrđuje se postojanje veze između potencijalnih indikatora kriza (nezavisne varijable) i varijable koja odražava valutni ili bankarski poremećaj²³. Prve metodološke naputke za primjenu te metode dali su Blanco i Garber (1986.) u analizi uzroka meksičke krize ranih osamdesetih, pa ih stoga smatramo pionirima u primjeni metode procjene vjerojatnosti u analizi platno-bilančnih kriza.

²² Ovom su se metodom u svojim istraživanjima koristili primjerice Kamin (1988.), Edwards (1989.), Dornbusch, Goldfajn i Valdes (1995.), Eichengreen, Rose i Wyplosz (1995.), Frankel i Rose (1996.), Eichengreen i Rose (1998.), Kaminsky i Reinhart (1999.), Caramazza, Ricci i Salgado (2000.), i Aziz, Caramazza i Salgado (2000.).

²³ Premda među ekonometrijskim modelima u analizi kriza dominiraju logit ili probit modeli vjerojatnosti, spomenimo još i tzv. *valute-at-risk* modele nastale na osnovi modela racionalnih očekivanja i uz pomoć kojih se izračunava državni trošak (gubitak) zbog napuštanja zadanog pariteta tečaja (Blejer i Schumacher (1998.)), i *strukturni vektorsko-autoregresijski model* kojim se koristi Weber (1998) u potrazi za uzrocima valutnih poremećaja SAD, Francuske, Njemačke, Italije, Belgije, Nizozemske, Danske i Velike Britanije za razdoblje 1972.-1994.

No, nije rijetkost da se u istom istraživačkom poduhvatu kombiniraju različite tehnike, stoga se i u sofisticiranim analizama koje se koriste ekonometrijskim modelima može naići na jednostavne kvalitativne opise kriznih događaja²⁴. Iako je metoda procjene vjerojatnosti gotovo tradicionalno vezana uz istraživanja valutnih kriznih epizoda, značajni su istraživački pokušaji primjene te metode i u otkrivanju signala bankarskih kriza (Hardy i Pazarbasioglu, 1998.; Demirguc-Knut i Detragiache, 1998).

U modelima procjene vjerojatnosti kriza se obično definira uz pomoć indeksa pritiska na devizno tržište, ako je riječ o valutnoj krizi²⁵, ili identificiranjem “datuma” izbijanja sustavne bankarske krize, ako se istražuju poremećaji u bankarskom sektoru. Zbog specifičnog načina identificiranja poremećaja na tim tržištima u model ulaze binarne zavisne varijable koje poprimaju vrijednost **0**, ako nema poremećaja na valutnom ili bankarskom tržištu, odnosno vrijednost **1**, u slučaju pojave poremećaja/krize. Upravo zbog kvalitativnog karaktera zavisne varijable, utjecaj potencijalnih indikatora kriza na vjerojatnost pojave krize procjenjuje se uz pomoću tzv. **logit ili probit modela**. Riječ je o nelinearnim modelima vjerojatnosti i oba su veoma popularna u praktičnim ekonomskim istraživanjima. Izbor jednog od ta dva modela ovisit će o izboru distribucije procijenjenih vjerojatnosti: kod *logit modela* vjerojatnosti leže na tzv. *logističkoj krivulji*, a kod *probit modela* vjerojatnosti leže na *krivulji kumulativne normalne distribucije*²⁶. Zbog premise o postepenom pogoršanju ekonomskih uvjeta prije izbijanja kriznog događaja, u ovim se modelima koriste nezavisnim varijablama s određenim vremenskim pomakom unatrag. Regresijskom se analizom potom “hvata” učinak promjene potencijalnih indikatora (nezavisnih varijabli) na vjerojatnost pojave krize i identificiraju se varijable koje statistički pomažu u predviđanju kriznog događaja. Za razliku od

²⁴ Tim su se pristupom koristili Frankel i Rose (1996.), ispitujući uzroke valutnih kriza u 105 zemalja u razvoju; Eichengreen, Rose i Wyploz (1996.), analizirajući efekt prelijevanja financijskih poremećaja između dvadesetak razvijenih zemalja; Sachs, Tornell i Velasco (1996.), analizirajući tzv. “*tequila*” efekt, tj. spekulativnu paniku koja se nakon meksičke krize godine 1994. proširila na Argentinu, Brazil i Filipine; Cumby i Wijnbergen (1989) i Ötker i Pazarbasioglu (1994., 1995.) koji analiziraju pojedinačne slučajeve devalvacije; Edin i Vredin (1993.), Edwards (1989.) i Klein i Marion (1994.) koji uspoređuju razlike u intenzitetu valutnih poremećaja među zemljama; Kruger, Osakwe i Page (1998.) koji ispituju je li valutna kriza posljedica pogoršanja osnovnih ekonomskih preduvjeta ili efekta prelijevanja krize. Modelima procjene vjerojatnosti u kombinaciji s kvalitativnim opisom događaja koristili su se u svojim istraživanjima i Caramazza, Ricci i Salgado (2000.), Corsetti, Pesenti i Roubini (1998.), Eichengreen i Rose (1998.), i Milesi-Ferritti i Razin (1998.).

²⁵ O indeksu pritiska na devizno tržište i njegovoj primjeni u istraživanju poremećaja na hrvatskom deviznom tržištu vidjeti u Ahec-Šonje (2002).

²⁶ Obje krivulje distribucije imaju oblik slova S, veoma su slične i bliske u sredini raspona, osim što logistička krivulja ima nešto manje strme krajeve od kumulativne normalne distribucije. Za ocjenjivanje regresijskih koeficijenata kod logit ili probit modela najčešće se koristi metodom maksimalne vjerojatnosti.

standardne regresijske metode, kod modela vjerojatnosti (*logit ili probit*) procijenjeni parametri uz objašnjavajuće varijable ne predstavljaju njihov marginalni utjecaj na zavisnu varijablu. Ako je ocijenjeni parametar statistički signifikantan, riječ je o varijabli koja povećava (uz pozitivan predznak) ili smanjuje (uz negativan predznak) vjerojatnost pojave krize.

Prednost tradicionalne metode procjene vjerojatnosti svodi se na jednostavnost tumačenja rezultata, jer se sve informacije o nadolazećoj krizi izražavaju jednim brojem, uz simultanu procjenu utjecaja svih potencijalnih signalnih indikatora krize. No, istraživači uviđaju da je ta prednost istovremeno i nedostatak metode. Taj pristup ne omogućuje rangiranje indikatora prema njihovoj *relativnoj prognostičkoj snazi* u najavi kriza. Ovdje su varijable jednostavno ili signifikantne ili nisu signifikantne, a šalju li one ponekad i krive, netočne signale, to ova regresijska metoda ne može. Dalje, za pouzdanu procjenu vjerojatnosti pojave kriza potrebno je raspolagati velikim brojem opservacija i dugim vremenskim serijama na godišnjoj razini. To se također može smatrati nedostatkom metode, jer je veoma teško, ponekad i nemoguće izgraditi opsežne baze podataka o krizama i o svim mogućim utjecajima na nju, i to za sve zemlje promatranog uzorka.

Signalni (neparametarski) pristup

Signalni ili neparametarski pristup pokušava prevladati gore navedene poteškoće i ograničenja tradicionalnih tehnika u potrazi za indikatorima valutnih i bankarskih poremećaja. Polazna je pretpostavka signalne metode da se poremećaji koji mogu završiti krizom ne zbivaju slučajno, već su rezultat postepenog pogoršanja ekonomskih uvjeta. Signalni pristup polazi od detaljne analize ponašanja svih ekonomskih i financijskih varijabli, kretanje kojih u *pretkriznom* razdoblju bitno odstupa od uobičajenog ponašanja u *normalnim* razdobljima. Značajnije odstupanje odabranih pokazatelja od uobičajenog kretanja smatra se ***signalom ili upozorenjem budućeg poremećaja***. Signalni pristup zasnovale su Kaminsky, Lizondo i Reinhart (1997.) kao alternativnu metodu analize financijskih kriza, koja omogućuje dublje razumijevanje ponašanja makroekonomskih snaga koje ekonomiju “guraju” u kriznu situaciju²⁷.

Zanimljivo je napomenuti da ideja o razvijanju sustava indikatora koji signaliziraju buduće ekonomske događaje i nije novost u ekonomskoj literaturi. Iako je ta ideja nova u analizi financijskih poremećaja, ipak je riječ o ideji staroj gotovo

²⁷ U literaturi se stoga signalna metoda često naziva KLR metodom.

koliko su stare teorije i modeli poslovnih ciklusa. Stoga za poznavatelje modela poslovnih ciklusa signalna metoda nije novost. Ta se metoda konceptijski, i samo djelomično i metodološki, oslanja na poznatu NBER-ovu metodu indikatora (*leading indicators approach*), kojom se tradicionalno koristi za analizu i predviđanje cikličkih zaokreta u tržišnim gospodarstvima.²⁸ To nije zanemariva činjenica zbog na već postojeće dugogodišnjeg istraživačkog iskustva u primjeni barometarske metode u analizi gospodarskog ciklusa Hrvatske (CROLEI prognostički indeks).

Prednost je signalne metode u jednostavnosti njezine praktične primjene, jer nema zahtjeva za upotrebom veoma strogih analitičkih zahvata nad podacima. Prati se ponašanje izabrane grupe indikatora u razdobljima neposredno prije i nakon izbijanja krize i uspoređuje se s njihovim kretanjem u *normalnim* razdobljima. Istraživači koji su dosad primjenjivali signalnu metodu tvrde da *signalni indikatori* zaista *signaliziraju povećanje ranjivosti sustava na poremećaje* i na taj način *upozoravaju na povećanje vjerojatnosti izbijanja valutne ili bankarske krize*. Stoga, za razliku od tradicionalnih metoda, signalni pristup može odgovoriti na pitanje *što zaista znamo o ponašanju pojedinih ekonomskih pokazatelja u turbulentnim razdobljima koja nisu završila kriznim događajem?*

Signalnom se metodom može utvrditi relativna prognostička snaga pojedinog indikatora, što omogućuje rangiranje pokazatelja prema jačini i pouzdanosti njihovih upozoravajućih signala. Takvi indikatori ne služe samo za alarmiranje kriznih događaja, već je njima moguće pratiti i razinu osjetljivosti sustava na poremećaje u svakom trenutku. To je istovremeno i osnovna prednost signalne metode pred tradicionalnim tehnikama. Stoga signalni sustav pokazatelja može biti koristan izvor informacija monetarnim vlastima o ranjivosti financijskog sustava i, u kombinaciji s ostalim raspoloživim metodama nadzora, može povećati manevarski prostor za prilagodbu mjera ekonomske politike da bi se ublažile posljedice kriza, ako ih je nemoguće izbjeći.

Budući da je signalna metoda *novost* u primijenjenim istraživanjima financijskih poremećaja, ne iznenađuje još uvijek mali i ograničen broj radova koji testiraju upotrebljivost te metode u analitičke i prognostičke svrhe. Dosad su signalnu metodu u svojim analizama primjenjivali Edison (2000.), Goldstein, Kaminsky i Reinhart (2000.), Kaminsky, Lizondo i Reinhart (1997.), Kaminsky (1998.), Nierhaus (2000.), Bruggemann i Linne (1999.), i Glick i Hutchison (2000.). Zato

²⁸ *National Bureau of Economic Research* zasnovao je ovu metodu za kratkoročno prognoziranje ekonomske aktivnosti još u pedesetim godinama 20. stoljeća. *Metoda indikatora ili barometarska metoda* veoma je popularna u razvijenim zemljama i ima široku primjenu u istraživanjima cikličkih obilježja gospodarske aktivnosti. Ta je metoda u Hrvatskoj prvi put primijenjena tek 1994./95., kada je izgrađen prvi domaći prognostički sustav indikatora i kratkoročan prognostički indeks CROLEI. O razvitku i prilagodbi metode indikatora za praćenje cikličnosti hrvatskoga gospodarstva vidjeti podrobnije u Ahec-Šonje (2000., 1996., 1995.a, 1995.b).

se danas praktična primjena i provjera signalne metode u znanstvenim i stručnim radovima smatra velikim istraživačkim izazovom. Zbog te činjenice i zbog jednostavnosti primjene i u otežanim uvjetima statističke prirode s kakvima se suočavamo u ozbiljnijim domaćim istraživačkim pokušajima, u posljednje je dvije godine testirana se mogućnost primjene signalne metode u analizi osjetljivosti deviznog i bankarskog tržišta u Hrvatskoj²⁹. U nastavku rada bit će prikazani rezultati prvog takvog domaćeg istraživačkog pokušaja kojem je cilj, uz pomoć signalne metode, izgraditi dinamički sustav za rano upozorenje bankarskih poremećaja/kriza u Hrvatskoj.

Indikatori osjetljivosti bankarskog tržišta u Hrvatskoj – test signalne metode

Utvrđivanje kriznih datuma – signalni horizont

U odnosu na valutne krize, bankarske je krize objektivno teže identificirati. Koji će od prije spomenutih kriterija identifikacije početka sustavne bankarske krize biti korišten (Caprio-Klingebiel, Demirguc-Knut-Detragiache ili Kaminsky-Reinhart pristup) ovisi prije svega o procjeni istraživača. Oni moraju biti dobro informirani o stanju u bankarskom sustavu, da bi mogli objektivno procijeniti zahvaća li poremećaj tek pojedine banke bez opasnosti po sustav ili, pak, poremećaj poprima razmjere sustavne bankarske krize. Informiranost analitičara, pak, ovisi o transparentnosti izvještavanja o kretanjima u bankarskom sustavu.

Da bi se osigurala usporedivost podataka, iz analize se isključuje razdoblje od početka političkog i ekonomskog osamostaljenja Hrvatske, pa sve do uvođenja Stabilizacijskog programa. Time se žele izbjeći razdoblje hiperinflacije i problemi vezani uz statistički obuhvat podataka. Hrvatska je od trenutka svog političkog i gospodarskog osamostaljenja proživjela dvije bankarske krize s veoma visokim troškovima njihova rješavanja. Uzroci prve krize ili tzv. krize starih banaka (Privredne banke Zagreb, Riječke, Splitske i Slavonske banke) njihova naslijeđena loša aktiva iz prošlog ekonomskog sustava i posljedice rata u Hrvatskoj. Procjene govore da je ukupan trošak prve bankarske krize iznosio 4,7 milijarde USD, što je obuhvaćalo sanaciju spomenute četiri banke, pretvaranje devizne štednje u javni dug (godine 1992.) i izdavanje 990 milijuna USD tzv. velikih obveznica godine

²⁹ Vidjeti Ahec-Šonje (2002.).

1991. Koliko su ti troškovi bili visoki govori i gruba procjena udjela troška prve bankarske krize u BDP iz godine 1996., a koja se kreće oko 23%³⁰.

Budući da korijeni prve bankarske krize izlaze iz referentnog razdoblja analize koja će se u ovom poglavlju provesti, usredotočit ćemo se na potragu za signalnim indikatorima druge bankarske krize u Hrvatskoj. Ona započinje još u ožujku godine 1998. propašću Dubrovačke banke, tada pete banke po veličini s oko 5% udjela u aktivi bankarskoga sustava, a odluka o njezinoj rehabilitaciji donesena je već u travnju godine 1998. U srpnju iste godine u blokadu ulazi Glumina banka, šesta po veličini sa 3,7% udjela u aktivi bankarskoga sustava u trenutku blokade, nakon čega se već u rujnu donosi odluka o neopravdanoj sanaciji, a tek u ožujku 1999. godine odluka o njezinom stečaju. Do svršetka 1998. i početka godine 1999. propadaju Županijska banka (1,6% udjela), Komercijalna banka (0,5% udjela), i Gradska banka Osijek (1,5% udjela), za koje je odluka o stečaju donesena na početku godine 1999. Uz spomenute veće banke do početka godine 1999. propadaju i manje banke i štedionice: Ilirija banka, Neretvansko-gospodarska banka, Agroobrtnička banka, Hrvatska gospodarska banka, Građanska štedionica Karlovac i Invest štedionica. U veljači 1999. u blokadu ulazi i Croatia banka sa 2% udjela u ukupnoj bankarskoj aktivi, za koju je oko polovine iste godine donesena odluka o sanaciji. Ukupan trošak druge bankarske krize procjenjuje se na oko 800 milijuna USD, od čega je polovina potrošena na sanaciju Dubrovačke i Croatia banke, a ostatak čini trošak isplate osigurane štednje propalih banaka i štedionica. Gruba procjena pokazuje da je udio troška razrješavanja druge bankarske krize u Hrvatskoj iznosio oko 3,7% BDP iz godine 1999.³¹

Signalni horizont razdoblje je unutar kojeg se očekuje da potencijalni signalni indikatori "proizvedu" upozoravajuće signale poremećaja. Koliki će se vremenski horizont odabrati ovisi o procjeni istraživača, no dosadašnje istraživačko iskustvo u primjeni prognostičkih modela pokazuje da se signali najčešće javljaju unutar jedne do najviše dvije godine prije izbijanja krize. Signal koji pokazatelj pošalje unutar izabranog signalnog horizonta smatra se dobrim ili točnim signalom, a svaki signal koji indikator proizvede u razdoblju koje ne završava krizom smatra se netočnim ili krivim signalom.

³⁰ Zbog usporedbe spomenimo da je trošak rehabilitacije bankarskog sustava u Venezueli godine 1994. iznosio 13% BDP, u Finskoj, Švedskoj i Norveškoj od 4%-10% BDP, a u ratu zahvaćenom Kuvajtu taj je trošak iznosio čak 45% BDP.

³¹ Prisjetimo se da u literaturi o bankarskim krizama još uvijek nema jasno definiranih pravila i kriterija klasifikacije bankarskih kriza prema njihovoj snazi. Prema jednom od tih kriterija, koje predlažu Demirguc-Knut i Detragiache (1997), obje se bankarske krize u Hrvatskoj mogu proglasiti sustavnim bankarskim krizama.

Signalni horizont
Bankarska kriza
19 mjeseci (7/97-1/99)

Primjenom kriterija utemeljitelja signalne metode, druga bankarska kriza u Hrvatskoj počinje u trenutku donošenja odluke o sanaciji prve problematične domaće banke, u travnju godine 1998. Osim što bankarska kriza može “tinjati” mjesecima prije zatvaranja pojedinih banaka ili donošenja odluke o sanaciji, njezine se posljedice mogu osjećati isto tako i mjesecima nakon njezina izbijanja. Stoga se za potrebe ove analize određuje **signalni horizont** od 9 mjeseci prije i nakon travnja godine 1998., koji obuhvaća **razdoblje od srpnja 1997. do siječnja godine 1999.** Unutar tog signalnoga horizonta ili “kriznog” razdoblja očekuju se jasni signali koji upozoravaju na poremećaje u bankarskom sustavu.

Izbor potencijalnih signalnih indikatora bankarskih kriza

Sastavljajući listu potencijalnih indikatora bankarskih poremećaja u Hrvatskoj, polazi se od teorijskih pretpostavki o kretanju makroekonomskih varijabli u pretkriznom razdoblju i već poznatih i provjerenih lista indikatora korištenih u vodećim empirijskim istraživanjima uzročnika kriza. Šira lista domaćih indikatora, signalna snaga kojih se testira, prikazana je u sljedećoj tablici, a prikaz metodoloških objašnjenja i izvora podataka korištenih u ovom istraživanju nalazi se u Prilogu.

Tablica 1.

**POTENCIJALNI INDIKATORI BANKARSKIH (I VALUTNIH)
POREMEĆAJA U HRVATSKOJ**

POTENCIJALNI SIGNALNI INDIKATORI	Očekivani predznak signala
1) Realan efektivni tečaj	-
2) Realan bilateralni tečaj HRK/EUR	-
3) Bruto međunarodne pričuve, u USD	-
4) Neto raspoložive pričuve, u USD (NUIR)	-
5) Neto raspoložive pričuve/M4	-
6) Inozemna aktiva HNB/M4	-
7) M4 multiplikator	+
8) M1 multiplikator	+
9) Ponuda novca M1, nominalno	+
10) Primarni novac M0	+
11) Domaći krediti/domaća aktivnost	+
12) Rast kredita poslovnih banaka domaćim sektorima	+
13) Bankarski depoziti (M4-gotovina)	-
14) Pričuve banaka kod HNB/ukupna aktiva banaka	-
15) Potraživanja banaka od javnog sektora/ukupna bankarska potraživanja	+
16) Neto potraživanja monetarnih institucija od središnje države	+
17) Krediti HNB poslovnim bankama	+
18) Inozemne obveze monetarnih institucija	+
19) Rast industrijske proizvodnje	-
20) Izvoz, u USD	-
21) Uvoz, u USD	+
22) Saldo robne razmjene	-
23) Budžetski deficit/BDP	+
24) Budžetski deficit (bez kapitalnih prihoda)/BDP	+
25) Realne kamate na tržištu novca	+
26) Aktivna/pasivna kamatna stopa	+
27) Saldo tekućeg računa bilance plaćanja (kvartalno)	-
28) Kapitalni priljev (kvartalno)	-

Varijable se iskazuju u obliku međugodišnjih stopa rasta osim tečaja, kamata, NUIR/M4, inozemne aktive HNB/M4, i budžetskog deficita/BDP, salda tekućeg računa bilance plaćanja i kapitalnog priljeva. Dvije se posljednje varijable s liste, na žalost, ne mogu uvrstiti u konačni sustav za rano upozorenje zbog kvartalne dinamike njihova praćenja, a riječ je o veoma značajnim pokazateljima međunarodne likvidnosti: deficitu tekućeg računa bilance plaćanja i kapitalnom priljevu. Primjenom signalne metode moguće ih je ocijeniti, ali se njima ne može koristiti za kontinuirano praćenje osjetljivosti deviznog tržišta, niti se može koristiti u izradi složenih indikatora poremećaja.

U nastavku dajemo kratak osvrt na neke stilizirane činjenice o ponašanju izabranih potencijalnih indikatora poremećaja prije i u tijeku bankarskih (i valutnih) kriza, kao podsjetnik na teorijske pretpostavke o utjecaju raznih ekonomskih i financijskih varijabli na pojavu kriza.

- U dosadašnjim je istraživanjima na velikim uzorcima zemalja otkriveno da su najčešće u pretkriznim razdobljima tečajevi nacionalnih valuta značajno precijenjeni ili da postoji jači aprecijacijski pritisak na domaće valute. Ako se realna aprecijacija događa zbog inflacije, tada je inflacija najava poremećaja. Ako do realne aprecijacije dolazi zbog nominalne aprecijacije tečaja, tada to može biti posljedica snažnijeg priljeva kapitala (priljev portfolio kapitala) i/ili posljedica pretjeranog zaduživanja u inozemstvu (tzv. *overborrowing syndrome* - efekt pretjeranog zaduživanja iz modela treće generacije spekulativnih napada McKinnona i Philla (1996)). Stoga je očekivani predznak signala **realnog efektivnog tečaja i realnog bilateralnog tečaja HRK/EUR** u pretkriznom razdoblju negativan.
- U pretkriznom se razdoblju očekuje i smanjenje **međunarodnih pričuva (bruto i neto)** kao posljedica obrane tečaja, a istraživanja su potvrdila da rezerve često padaju i u tijeku bankarskih kriza. Analizirat će se i kretanje **neto raspoloživih rezervi/M4**, i **neto inozemne aktive HNB/M4** (međunarodne rezerve čine najveći dio neto inozemne aktive HNB), uz očekivano smanjivanje tih odnosa u pretkriznim razdobljima. Pretpostavka je da štetiše, a osobito u zemljama u razvoju i tržištima u nastajanju, "bježe" u valute koje smatraju sigurnijim oblikom držanja svoje financijske imovine kako slabi kredibilitet i vjerodostojnost ekonomske (monetarne i tečajne) politike. Valutna kriza generira opasnost od postupnog jačeg gubitka deviznih rezervi i slijedom toga pada pokriva monetarnih agregata međunarodnim rezervama (adekvatnost rezervi), do kojeg obično dolazi nekoliko mjeseci prije izbijanja kriza. Indikator devizne rezerve/M4 odražava stupanj pokriva obveza bankarskog sustava deviznim rezervama. U slučaju valutnog poremećaja koji dovodi do povećane potražnje za devizama zbog bijega bankarskih komintenata u sigurnije valute, ovaj indikator odražava sposobnost monetarnih vlasti da tim zahtjevima udovolji. Pad toga indikatora često prati proces financijske liberalizacije i kreditne ekspanzije u uvjetima slabog i nerazvijenog regulatornog okvira i bankarske supervizije.
- U slučaju **M4 i M1 multiplikatora** očekujemo pozitivan predznak njihovih signala u pretkriznim razdobljima. Pretpostavka je da su ovi pokazatelji usko povezani s rastom domaćeg bankarskog sektora, koji mogu podupirati različiti procesi. Neke od tih procesa monetarna vlast može kontrolirati, primjerice, proces financijske liberalizacije smanjenjem stope obvezne rezerve, što dovodi do postepenog rasta M1 multiplikatora. Snažan rast M1 multiplikatora signal je monetarne ekspanzije nakon koje slijedi deprecijacija. Sa druge, pak, strane, snažan rast deviznih depozita u značajnoj će mjeri povećati M4 multiplikator, neovisno o mjerama monetarne politike. Razmjerno brz porast deviznih depozita može biti znak i moralnog hazarda, ako depoziti priteču u sustav privučeni nerealno visokim pasivnim kamatnim stopama.

- **Primarni novac M0 i novčana masa M1** novčani su agregati kretanje kojih odražava karakter monetarne politike u pretkriznim razdobljima. Razmjerno jak rast tih agregata odražava monetarnu ekspanziju i potiče deprecijacijske pritiske, stoga se u pretkriznim razdobljima očekuje pozitivan predznak signala tih varijabli.
- **Kreditna ekspanzija** smatra se signalom i za valutne i za bankarske poremećaje. Snažniji porast kreditne aktivnosti često prati proces domaće i vanjske financijske liberalizacije, no čest je pratilac i klasičnog cikličkog “pregrijavanja” ekonomije u tijeku uzlazne faze gospodarskog ciklusa. Nagla kreditna ekspanzija može značiti i smanjenu pažnju i sposobnost procjene kreditnog rizika po jedinici novoodobrenog kredita, a posljedica je povećanje kreditnog rizika za banke. Stoga varijable **kreditni/domaća aktivnost i rast kredita poslovnih banaka domaćim sektorima** imaju pozitivan predznak utjecaja na bankarske i valutne poremećaje.
- Signalnim se indikatorima prati osjetljivost okruženja u kojem djeluje bankarski sektor. Budući da se uz pomoć ove metode analiziraju varijable na makrorazini, a ne pokazatelji “zdravlja” i poslovanja pojedinih banaka, signalni indikatori ne ukazuju na propast pojedinih problematičnih banaka, već je njima moguće pratiti osjetljivost bankarskog sustava na razne promjene i utjecaje iz okruženja. Bankarsko okruženje čine brojni čimbenici poput makroekonomskog okruženja, ekonomske (monetarne i tečajne) politike, institucionalnog, regulatornog i pravnog okvira, sve do tržišne strukture i poslovne klime u zemlji. Bankarsku osjetljivost pratimo pomoću sljedećih indikatorima: **bankarskih depozita** (očekuje se pad prije i/ili u tijeku bankarske krize, kao znak navale štediša na banke zbog pada povjerenja u domaći financijski sustav), **pričuve banaka kod HNB/ukupna aktiva banaka** (mjera likvidnosti bankarskog sustava, očekuje se smanjenje odnosa zbog naglog rasta svih vrsta potraživanja poslovnih banaka – kreditne ekspanzije i/ili zbog povlačenja depozita koji ulaze u osnovicu za obračun obveznih rezervi; povlačenje deviznih depozita znači povećanu potražnju za devizama; ako devizni depoziti ne ulaze u osnovicu za obračun obvezne rezerve, smanjuju se depoziti u domaćoj valuti što može biti posljedica općeg pada povjerenja u financijski sustav što prethodi deprecijaciji), **udio potraživanja banaka od javnog sektora (središnje i lokalne države) u ukupnim potraživanjima** (porast izloženosti banaka nepovoljnim kretanjima fiskalnih varijabli signal je povećane ranjivosti bankarskog sektora; slijed fiskalna ekspanzija – monetarna ekspanzija - deprecijacija), **neto potraživanja monetarnih institucija od središnje države** (signal monetizacije budžetskog deficita, pozitivnog predznaka u pretkriznim razdobljima), **kreditni HNB poslovnim bankama** (indikator likvidnosti bankarskog sustava, koji raste s porastom poteškoća s likvidnošću) i **inozemne obveze monetarnih institucija - HNB i poslovnih banaka** (porast obveza prema međunarodnim financijskim institucijama i inozemnim vjerovnicima smatra se signalom povećane ranjivosti bankarskog sustava na poremećaje; može biti znak porasta moralnog hazarda povezanog s eksternim sektorom i posljedica pretjeranog zaduživanja u inozemstvu zbog domaće kreditne ekspanzije – McKinnon-Phill sindrom pretjeranog zaduživanja).
- **Industrijska proizvodnja i izvoz** najčešće imaju negativan predznak signala u pretkriznim razdobljima. Jača aprecijacija koja često prethodi valutnim krizama može dovesti do smanjenja izvoza ili usporavanja njegova rasta (rast u vrijeme valutne krize i do 20% niži od rasta izvoza u normalnim razdobljima), a slijedom toga i do usporavanja gospodarske aktivnosti. Općenito, prevladava mišljenje da valutnim krizama prethodi usporavanje gospodarske aktivnosti ili recesija, a trend pogoršanja uvjeta trgovine najčešće se poklapa sa trendom usporavanja proizvodnje u pretkriznom razdoblju. Često se zbog toga odgovornost za krizne događaje pripisuje ekonomskim vlastima koje nastoje “isforsirati” devalvaciju radi prevladavanja negativnih trendova u izvozu i i proizvodnji. Takve se politike smatraju neučinkovitim, jer ekonomija može završiti u lošoj ravnoteži u kojoj očekivanja inflacije i rasta nominalnih plaća mogu još više pogoršati izvoznu konkurentnost, a devizno tržište učiniti trajno nestabilnim.
- Ponašanje je **uvoza** teže procijeniti na osnovi kretanja relativnih cijena u pretkriznom razdoblju, pa stoga u literaturi nalazimo oprečne stavove o predznaku utjecaja uvoza. Ako u pretkriznom razdoblju dolazi do usporavanja ekonomske aktivnosti ili je ekonomija već zaokrenula u recesiju,

uvoz može usporavati. No jednako se tako može očekivati da ekonomija prije izbijanja valutnog poremećaja ne usporava svoj rast, a i jači aprecijacijski pritisci u pretkriznom razdoblju mogu utjecati na povećanje uvoza (dakle, potaknut rastom domaće potražnje i/ili jačom aprecijacijom valute). U ovom se istraživanju pretpostavlja da uvoz u pretkriznom razdoblju raste, stoga ima pozitivan predznak utjecaja na krizne događaje.

- Očekivano smanjenje izvoza i povećanje uvoza u pretkriznim razdobljima čini pritisak na povećanje deficita tekućeg računa bilance plaćanja i na pogoršanje bilance robne razmjene. **Saldo robne razmjene i saldo tekućeg računa bilance plaćanja** stoga imaju negativan predznak utjecaja na krizne događaje. No mnogi autori smatraju da je kretanje realnog tečaja dovoljno dobra aproksimacija zbivanja u bilancama robne razmjene i na tekućem računu bilance plaćanja.
- Povećanje **budžetskog deficita** primarni je signalni indikator valutne krize poznat još iz prve generacije modela valutnih kriza uz poznati slijed fiskalna ekspanzija – monetarna ekspanzija - deprecijacija. No izloženost bankarskog sektora nepovoljnim kretanjima fiskalnih varijabli može povećati i osjetljivost bankarskog sustava na poremećaje. Bankarska kriza također može dovesti do porasta budžetskog deficita zbog povećanih troškova sanacije bankarskog sektora i isplate osigurane štednje, pa ako uslijedi snažan rast monetarnih i kreditnih agregata s ciljem rješavanja poremećaja u bankarstvu dolazi do jačanja deprecijacijskih pritisaka.
- **Kamatne stope** obično su slabi indikatori valutnih kriza i pokazuju se mnogo uspješnijima u anticipiranju bankarskih poremećaja. Porast nominalnih (i realnih) kamatnih stopa čest su rezultat mjera monetarnog sažimanja i porasta nelikvidnosti u financijskom sustavu, a može značiti i povećanu segmentaciju tržišta. Do povećane segmentacije tržišta može doći zbog rasta razlika u percepciji rizika pojedinih financijskih institucija. Može se očekivati da će zdrave banke prve moći procijeniti da ima loših banaka, a to će se reflektirati rastom kamatnih stopa na tržištu novca, čak i ako ne dođe do promjene monetarne politike. Rast odnosa aktivnih i pasivnih kamatnih stopa može signalizirati visok stupanj rizičnosti i pogoršanje kvalitete plasmana banaka, zatim nedostatak konkurencije i slabost institucionalnog i regulatornog okvira.
- Iako bi se na listi potencijalnih indikatora morali naći vanjski dug i udio kratkoročnog duga u ukupnom vanjskom dugu, te se varijable neće koristiti u analizi, jer se tek od prosinca godine 2000. objavljuju na mjesečnoj razini, a u ožujku 2000. došlo je i do promjene metodološkog obuhvata podataka.

Signali, kritične granice i matrica ocjenjivanja signala

Indikatori šalju upozoravajuće signale kada njihova vrijednost prelazi unaprijed utvrđenu kritičnu granicu. Kritične granice valja odabrati pažljivo, vodeći računa o tome da obuhvatimo što manje krivih signala i da se ne zanemare brojni točni signali. Korištenjem percentilnih mjera određene su kritične granice k^* za svaki pojedinačni indikator I_t sa šire liste, koje odvajaju *ekstremne* od *normalnih* vrijednosti indikatora.

Nakon izbora kritičnih granica, određuje se *ukupan broj točnih i netočnih signala* indikatora u *kriznim* i *nekriznim* razdobljima. Dobar je i pouzdan signalni indikator onaj koji šalje upozoravajuće signale unutar signalnog horizonta (prije

izbijanja poremećaja) i ako ne šalje upozoravajuće signale u ostalim, normalnim razdobljima³².

Nakon izbora potencijalnih signalnih indikatora i utvrđivanja njihovih kritičnih granica prelazi se na ocjenjivanje kvalitete i vjerodostojnosti signala svakog pojedinog indikatora. Indikatore ocjenjujemo uz pomoć veoma jednostavne matrice koju prikazujemo u sljedećoj tablici:

Tablica 2.

MATRICA ZA OCJENJIVANJE SIGNALNIH INDIKATORA

UNUTAR SIGNALNOG HORIZONTA	IMA KRIZE	NEMA KRIZE	ukupni signali
ima signala ($S_t = 1$)	A	B	A+B
nema signala ($S_t = 0$)	C	D	C+D
ukupni signali	A+C	B+D	A+B+C+D
točni signali	A	D	A+D
udio točnih u ukupnima	$A/(A+C)$	$D/(B+D)$	$(A+D)/(A+B+C+D)$
udio netočnih u ukupnima	$C/(A+C)$	$B/(B+D)$	$(B+C)/(A+B+C+D)$

Izvor: Kaminsky, Lizondo i Reinhart (1997); Nierhaus (2000)

Signalni je horizont razdoblje prije pojave krize unutar kojeg se očekuju signali potencijalnih indikatora, dok su:

- A - broj mjeseci pojave točnih signala (ima signala, ima krize),
- B - broj mjeseci pojave krivih signala (ima signala, nema krize),
- C - broj mjeseci pojave krivih signala (nema signala, ima krize),
- D - broj mjeseci pojave točnih signala (nema signala, nema krize).

Ova matrica zapravo prikazuje četiri "idealna" slučaja, jer u stvarnosti ni jedan indikator ne može zadovoljiti u potpunosti navedene matrične kriterije. No, ova je matrica koristan predložak da bi se utvrdilo koji su indikatori bliži, a koji udaljeniji od idealnih obilježja. Idealni je indikator onaj koji proizvodi samo točne signale, a to su slučajevi A (ima signala, ima krize) i D (nema signala, nema krize), i to *svaki* mjesec unutar utvrđenog signalnog horizonta (npr. 12 mjeseci prije krize). U tim idealnim slučajevima vrijedi da je $A > 0$, a $C = 0$, i $D > 0$, a $B = 0$.

³² Podrobnije o ovom metodološkom koraku vidjeti u Ahec-Šonje (2002.).

Na osnovi ove matrice mogu se izračunati mjere koje služe za rangiranje indikatora prema njihovoj prognostičkoj snazi i pouzdanosti signala. Kaminsky, Lizondo i Reinhart (1997.) predlažu izračunavanje *postotka pogođenih kriza*, tj. udjela onog broja kriza koje je indikator uspio najaviti barem jednim signalom unutar signalnog horizonta u ukupnom broju kriza.

Sljedeći je pokazatelj koji se dobiva iz gornje matrice *omjer točnih signala i ukupnog broja signala u razdobljima koja završavaju krizom*, izražen kao $A/(A+C)$. U ovom bi slučaju *maksimalni* učinak ($A/(A+C) = 1$) imao indikator koji šalje signale *svakog* mjeseca unutar signalnog horizonta, i to prije svake promatrane krize (dakle, $C=0$). Na osnovi gornje matrice moguće je izračunati i *omjer pogrešnih signala i ukupnog broja signala u nekriznim, normalnim razdobljima*, koji je izražen kao $B/(B+D)$. Što je taj omjer manji (bliži 0), to je indikator bolji, jer to znači da je indikator proizveo manje pogrešnih signala u razdobljima koji ne završavaju krizom.

Ključna mjera koja se izračunava na osnovi gornje matrice jest *mjera signalne pogreške* (*adjusted noise-to-signal ratio*), koja se izračunava na osnovi naprijed spomenutih dviju mjera i pruža informaciju o uspješnosti indikatora da proizvede dobar i izbjegne krivi signal. Riječ je o jednostavnom omjeru između udjela pogrešnih signala i udjela točnih signala u ukupnom broju signala ili:

$$\delta = [B/(B+D)] / [A/(A+C)]$$

Samo idealni indikator krize može imati vrijednost mjere signalne greške jednaku nuli. To je moguće u slučaju kad je brojnik gornjeg izraza jednak nuli, što znači da unutar normalnog razdoblja indikator nije proizveo ni jedan pogrešan signal za krizu ($B=0$). Ako je udio pogrešnih signala u normalnom razdoblju jednak udjelu točnih signala u pretkriznom razdoblju, tada je mjera signalne pogreške jednaka jedan. Kada udio pogrešnih signala u normalnim razdobljima premaši broj točnih signala u kriznim razdobljima, mjera signala greške postaje veća od jedan. Stoga je mjera signalne pogreške ključna za izbor uže liste najboljih signalnih indikatora krize, pri čemu je kriterij izbora $\delta \in (0,1)$. Svi oni pokazatelji kojih je mjera signalne pogreške jednaka ili veća od jedan, ispuštaju se s liste signalnih varijabli i ne mogu se koristiti za izračunavanje složenih ili kompozitnih indeksa za rano prepoznavanje kriza.

Kvalitetu signala ocjenjujemo i na osnovi usporedbe vjerojatnosti krize uvjetovane signalom ($A/(A+B)$) s neuvjetovanom vjerojatnošću pojave krize ($A+C)/(A+B+C+D)$. *Uvjetovana vjerojatnost* veća je od neuvjetovane samo kod pokazatelja koji su se pokazali uspješnima u najavi krize i kojih je mjera signalne pogreške manja od jedan. Izbor najuspješnijih indikatora ovisi i o utvrđenom vremenu prethođenja ili "*lead time*" svakoga od njih. Nije svejedno upozorava li indikator

na mogućnost pojave krize dvanaest mjeseci ili samo jedan mjesec prije njezina izbijanja. Stoga je, bez obzira na rezultate ocjene indikatora na osnovi matrice ocjenjivanja, potrebno utvrditi "lead time" svakog pojedinog pokazatelja, odnosno koliko su mjeseci prije izbijanja krize pojedini pokazatelji proizveli prve upozoravajuće signale.

Posljednji kriterij za ocjenu indikatora jest utvrđivanje *vjerodostojnosti ili postojanosti signala* kojom indikator najavljuje poremećaj. Mjera postojanosti signala jednostavan je inverz mjere signalne pogreške ($\delta^{-1}=[A/(A+C) / B/(B+D)]$), a govori nam koliko je puta signal u pretkriznom razdoblju postojaniji u odnosu na "normalna" razdoblja. Što je mjera signalne greške nekog indikatora manja, to je postojanost njegova signala u pretkriznim razdobljima veća, a to znači da indikator bolje "anticipira" nadolazeću krizu.

Najbolji pojedinačni indikatori osjetljivosti bankarskog tržišta

Sljedeća tablica prikazuje rezultate ocjene signala potencijalnih indikatora za bankarske poremećaje u Hrvatskoj, dobijenih na osnovi pojedinačnih matrica ocjenjivanja za svaki pojedini indikator.

Tablica 3.

OCJENA KVALITETE SIGNALA ZA BANKARSKE POREMEĆAJE U HRVATSKOJ

INDIKATORI	udio	udio	mjera	"lead time"	P kriza/signal	P kriza/signal – P kriza
	dobrih signala	loših signala	signalne pogreške	indikatora		
	A/(A+C)	B/(B+D)	$\frac{B/(B+D)}{A/(A+C)}$	prije 4/98	A/(A+B)	$\frac{A/(A+B) - A+C/(A+B+C+D)}{A/(A+B)}$
1. Realan efektivni tečaj	0,63	0,06	0,10	5	0,86	0,51
2. Realan tečaj HRK/EUR	0,16	0,29	1,81	4	0,18	-0,10
3. Bruto međunarodne rezerve, u USD	0,58	0,24	0,41	10	0,48	0,20
4. Neto raspoložive rezerve, u USD	0,58	0,24	0,41	10	0,48	0,20
5. Neto raspoložive rezerve/M4	0,47	0,30	0,64	1	0,33	0,09
6. Inozemna aktiva HNB/M4	0,89	0,05	0,06	8	0,85	0,61
7. M4 multiplikator	0,58	0,12	0,21	10	0,65	0,37
8. M1 multiplikator	0,05	0,33	6,60	0	0,06	-0,22
9. Ponuda novca M1, nominalno	0,16	0,29	1,81	18*	0,18	-0,10
10. Primarni novac M0	0,00	0,35	∞	0	0,00	-0,28

11. Krediti/domaća aktivnost	0,84	0,14	0,17	9	0,70	0,42
12. Rast kredita, nominalno	0,89	0,12	0,13	10	0,74	0,46
13. Bankarski depoziti (M4-gotovina)	0,11	0,31	2,82	0	0,12	-0,16
14. Bankarske rezerve/bankarska aktiva	0,74	0,06	0,08	10	0,82	0,54
15. Potraživanja od javnog sektora/ukupna potraživanja poslovnih banaka	0,00	0,35	∞	0	0,00	-0,28
16. Neto potraživanja monet. institucija od središnje države	0,00	0,34	∞	0	0,00	-0,28
17. Krediti HNB poslovnim bankama	0,63	0,10	0,16	9	0,71	0,43
18. Inozemne obveze monetarnih institucija	0,42	0,18	0,43	2	0,47	0,19
19. Rast industrijske proizvodnje	0,21	0,38	1,81	0	0,17	-0,11
20. Izvoz, u USD	0,26	0,24	0,92	10*	0,29	0,01
21. Uvoz, u USD	0,11	0,31	2,82	0	0,12	-0,16
22. Saldo robne razmjene	0,37	0,20	0,54	12	0,41	0,13
23. Budžetski deficit/BDP	0,11	0,32	2,91	0	0,14	-0,14
24. Budž.def./BDP (bez kapitalnih prihoda)	0,11	0,32	2,91	0	0,14	-0,14
25. Realne kamate na tržištu novca	0,47	0,29	0,62	0**	0,39	0,11
26. Aktivna/pasivna kamatna stopa	0,05	0,45	9,00	0	0,04	-0,24
27. Saldo tekućeg računa BP (kvartalno)	0,67	0,25	0,37	2 kvartala	0,44	0,16
28. Kapitalni priljev (kvartalno)	0,50	0,21	0,42	1 kvartal	0,38	0,18

Napomene:

* broj mjeseci pojave prvog signala prije travnja godine 1998., ali koji nije postojan u tijeku kriznog razdoblja 7/97.-1/99.

** signal poremećaja pojavljuje se tek 5/98. i traje sve do 6/99.

Najviše su točnih signala unutar signalnog horizonta imale varijable: rast kredita (89%) i inozemna aktiva HNB/M4 (89%), a najmanje točnih signala u kriznom razdoblju šalju varijable: krediti poslovnih banaka javnom sektoru i primarni novac (ni jedan točan signal), i M1 multiplikator i aktivna/pasivna kamatna stopa (5%).

U normalnim razdobljima najviše pogrešnih signala šalju varijable aktivna/pasivna kamatna stopa (45%) i industrijska proizvodnja (38%), a u «nekriznim» mjesecima najmanje griješe upravo oni indikatori koji su najtočnije upozoravali na porast osjetljivosti bankarskog sustava unutar signalnog horizonta.

Mjera signalne greške otkriva indikatore koji najbolje anticipiraju bankarsku krizu godine 1998. i koji istovremeno proizvode najmanje pogrešnih signala u normalnim razdobljima. Riječ je o varijablama: realan efektivni tečaj (0,10), inozemna aktiva HNB/M4 (0,06), rast kredita (0,13), rezerve banaka/ukupna bankarska aktiva (0,08), krediti HNB poslovnim bankama (0,16), M4 multiplikator (0,21) i međunarodne rezerve (0,41). Primarni novac i krediti monetarnih institucija javnom sektoru nisu proizvele ni jedan točan signal u tijeku devetnaestomjesečnog signalnog horizonta. Također je zanimljivo da bankarski depoziti nisu zadovoljili

kriterije za izbor u sustav signalnih indikatora. Ta je varijabla za vrijeme cijelog promatranog razdoblja slala više pogrešnih nego točnih signala, a to se odrazilo na mjeru signalne greške (2,82). Pored toga, bankarski depoziti nisu proizveli ni jedan upozoravajući signal prije travnja godine 1998., već se prvi signali pojavljuju tek u prosincu iste godine i traju do proljeća godine 2000. Prema tome, prije travnja 1998. nije bilo navale štediša na banke, nego je pad depozita uslijedio nakon propasti prvih banaka, pa se zbog toga *varijabla bankarskih depozita može smatrati zaostajućim indikatorom krize iz godine 1998.*

Indikatori koji najbolje anticipiraju događaje u bankarstvu veoma rano šalju upozoravajuće signale. U odnosu na početak krize inozemna aktiva HNB/M4 šalje postojane signale 8 mjeseci prije, M4 multiplikator, krediti i rezerve banaka/ukupna aktiva 10 mjeseci prije i krediti HNB poslovnim bankama 9 mjeseci prije. Veoma rane, ali nepostojane signale poremećaja šalju novčana masa (18 mjeseci) i saldo robne razmjene (12 mjeseci). Zadovoljavajuće ocjene pokazuju i realne kamate na tržištu novca, koje događaj u travnju godine 1998. ipak nisu uspjele najaviti, ali su svoj prvi signal poslale već u svibnju iste godine i zadržale se u kritičnom području sve do lipnja godine 1999.

Indikatori koji prema kriterijima signalne metode najbolje anticipiraju krizni događaj, ulaze u uži izbor pokazatelja za rano prepoznavanje i uočavanje bankarskih poremećaja. Sljedeća tablica prikazuje sustav od osam najboljih signalnih indikatora osjetljivosti hrvatskog bankarskog tržišta na poremećaje.

Tablica 4.

SUSTAV ZA RANO UPOZORENJE BANKARSKIH
POREMEĆAJA U HRVATSKOJ

INDIKATORI	MJERA SIGNALNE GREŠKE	VRIJEME PRETHODENJA
1. Inozemna aktiva HNB/M4	0,06	8 mjeseci
2. Rezerve banaka kod HNB/ukupna bankarska aktiva	0,08	10 mjeseci
3. Krediti banaka domaćim sektorima	0,13	10 mjeseci
4. Krediti HNB poslovnim bankama	0,16	9 mjeseci
5. M4 multiplikator	0,21	10 mjeseci
6. Bruto međunarodne rezerve, USD	0,41	10 mjeseci
7. Inozemne obveze monetarnih institucija	0,43	2 mjeseca
8. Realne kamate na tržištu novca	0,62	0 mjeseci

Valja napomenuti da se ovim sustavom indikatora ne može prognozirati propast pojedinačnih banaka, jer se radi o makroekonomskim varijablama. To mogu razni sustavi mikroekonomskih pokazatelja poslovanja banaka izrada kojih pripada u nadležnost sektora nadzora banaka. No, takve je sustave moguće i poželjno kombinirati sa sustavima makroekonomskih signalnih indikatora, koji prije svega prate razinu osjetljivosti bankarskog sektora na *vanjske* poremećaje, koji izviru iz poslovnog okruženja, domaće makroekonomske (fiskalne i monetarne) politike ili zbivanja u međunarodnom okruženju.

Kompozitni ili složeni indikatori bankarskih kriza

Osjetljivost bankarskog tržišta moguće je pratiti pojedinačnom analizom svakog signalnog indikatora uvrštenog u sustav za rano upozorenje. Potrebno je kontinuirano mjesečno ažurirati podatke, i iznova utvrđivati kritične vrijednosti pokazatelja. Kretanje indikatora u kritičnom području nekoliko mjeseci uzastopno može se smatrati jasnim signalom povećane osjetljivosti bankarskoga tržišta na poremećaje. No, postoji i jednostavniji način prikazivanja informacija koje nude sustavi za rano upozorenje. Jednostavnost se postiže izračunavanjem složenih ili kompozitnih indeksa koji se dobivaju kao obični ili ponderirani prosjeci signala pojedinačnih indikatora sustava. Složeni indikator bankarskih poremećaja u Hrvatskoj na taj način prikazuje “grupno” ponašanje najboljih signalnih indikatora osjetljivosti.


Jednostavan prosjek pokazatelja iz sustava za rano upozorenje (tablica 4.) prethodno pretvorenih u binarne signalne varijable $S_{r,t}$, ($r=1,\dots,8$) predstavlja neponderiranu varijantu *složenog indikatora bankarskih poremećaja*:

$$SI_t = \sum_{r=1,\dots,8} S_{r,t} / 8$$

Prilazom kritične granice k^* (75%tni percentil), složeni indikator SI šalje jasne signale za poremećaj gotovo svih 19 mjeseci, koliko iznosi signalni horizont posljednje bankarske krize. U ostalim (normalnim) razdobljima upozoravajućih signala nema, premda i u kolovozu godine 2001., neponderiran SI prelazi nakratko kritičnu granicu (slika 1.).

Slika 1.

NEPONDERIRAN SLOŽENI INDIKATOR BANKARSKIH
POREMEĆAJA U HRVATSKOJ



Druga varijanta složenog indikatora uzima u obzir informacije o prognostičkoj snazi pojedinih komponenti. *Ponderiran složeni indikator bankarskih poremećaja SI** je:

$$\text{ponderirani } SI_t^* = \sum_{r=1, \dots, 8} S_{r,t} \omega_r$$

gdje su $\omega_r = [(1/\delta_r) / \sum_{r=1, \dots, 9} 1/\delta_r]$ ponderi signalnih binarnih varijabli $S_{r,t}$ ($r=1, \dots, 8$).

Ponderi komponenti složenog indikatora bankarskih poremećaja prikazani su u sljedećoj tablici.


Tablica 5.

KOMPONENTE I PONDERI SLOŽENOG INDIKATORA
 ZA BANKARSKE POREMEĆAJE

INDIKATORI	ponderi u % $\omega_r = [(1/\delta_r) / \sum_{r=1, \dots, 9} 1/\delta_r]$
1. Inozemna aktiva HNB/M4	30,7
2. Rezerve banaka u HNB/ukupna bankarska aktiva	23,0
3. Krediti banaka domaćim sektorima	14,2
4. Krediti HNB poslovnim bankama	11,5
5. M4 multiplikator	8,8
6. Bruto međunarodne rezerve, USD	4,5
7. Inozemne obveze monetarnih institucija	4,3
8. Realne kamate na tržištu novca	3,0
UKUPNO	100,0

Slika 2.

PONDERIRANI SLOŽENI INDIKATOR BANKARSKIH
 POREMEĆAJA U HRVATSKOJ



Gornja slika jasno pokazuje da nema većih razlika u ponašanju jednostavnog SI i ponderiranog SI* indikatora u promatranome razdoblju. Složeni indikator SI* prelazi svoju kritičnu granicu k^* samo unutar signalnog horizonta za bankarsku krizu, a u kolovozu 2001. dostiže, ali ne prelazi, kritičnu vrijednost. Visoku prognostičku snagu kompozitnih indikatora poremećaja potvrđuje i analiza kvalitete njihovih signala prikazana u sljedeće dvije tablice.

Tablica 6.

SIGNALI I KRITIČNE GRANICE SLOŽENIH INDIKATORA
(BANKARSKI POREMEĆAJ)

Indikatori	početak krize (4/98) signali
1. Inozemna aktiva HNB/M4	1
2. Rezerve banaka u HNB/ukupna bankarska aktiva	1
3. Krediti banaka domaćim sektorima	1
4. Krediti HNB poslovnim bankama	1
5. M4 multiplikator	0
6. Bruto međunarodne rezerve, USD	0
7. Inozemne obveze monetarnih institucija	1
8. Realne kamate na tržištu novca	0
neponderirani SI	$SI = 0,63 > k^* (0,5)$
ponderirani SI*	$SI^* = 0,84 > k^* (0,59)$

Tablica 7.

OCJENA SIGNALA SLOŽENIH INDIKATORA
ZA BANKARSKE POREMEĆAJE

INDIKATORI	% dobrih signala	% loših signala	mjera signalne pogreške	P kriza/signal	P kriza/signal – P kriza
	$A/(A+C)$	$B/(B+D)$	$\frac{B}{(B+D)}$ $A/(A+C)$	$A/(A+B)$	$A/(A+B) - A+C/(A+B+C+D)$
neponderirani SI	79	2	0,03	0,94	0,66
ponderirani SI*	84	2	0,02	0,94	0,66

U travnju godine 1998. pet od ukupno osam indikatora iz sustava za rano upozorenje šalje signal za krizu. Zato oba složena indikatora značajno prelaze svoje kritične granice u tom mjesecu. I unutar cijelog signalnog horizonta složeni indikatori uspješno upozoravaju na poremećaj u bankarstvu, pri čemu je nešto uspješniji ponderirani SI* sa 84% točnih signala poremećaja, ali, oba indikatora s vjerojatnostima pojave krize uvjetovane njihovim signalima od 94% bolji su od bilo kojeg pojedinačnog signalnog indikatora iz sustava za rano upozorenje. Stoga se uz sustav indikatora svakako preporučuje i korištenje složenih indikatora za praćenje i prognoziranje stupnja ranjivosti domaćeg bankarskog sustava.

Zaključak

Indikatore poremećaja u bankarskom sektoru utvrdili smo na osnovi analize ponašanja brojnih ekonomskih i financijskih varijabli u vrijeme posljednje bankarske krize u Hrvatskoj 1998./99. Kriznim događajem proglašena je odluka o sanaciji Dubrovačke banke u travnju godine 1998., nakon čega je uslijedio snažan poremećaj na bankarskome tržištu, koji se očitovao bankrotom većeg broja manjih banaka i štedionica. Analizom kretanja raznih varijabli mjesecima prije i nakon tog događaja dobijen je *sustav indikatora osjetljivosti bankarskog tržišta u Hrvatskoj*. Lista indikatora koji su najbolje anticipirali zbivanja na bankarskom tržištu 1998./99. sadrži: (1) *udio inozemne aktive HNB u M4*, (2) *udio rezervi banaka (kod HNB) u ukupnoj bankarskoj aktivi*, (3) *rast kreditne aktivnosti*, (4) *kredite centralne banke poslovnim bankama*, (5) *novčani multiplikator M4*, (6) *bruto međunarodne rezerve*, (7) *inozemne obveze monetarnih institucija* i (8) *realne kamate na tržištu novca*. Odabrani indikatori poremećaja na bankarskom tržištu odražavaju stanje likvidnosti u domaćem financijskom sustavu, obilježja ekonomske (i monetarne) politike i izloženost domaćih financijskih institucija međunarodnim tokovima kapitala.

Pokazatelj adekvatnosti rezervi (udio inozemne aktive HNB u M4) koji izražava sposobnost monetarnih vlasti da udovolji zahtjevima konverzije aktive denominirane u domaćoj valuti u deviznu aktivu, svojim je smanjenjem snažno signaliziralo poremećaj u bankarskoj industriji u godini 1998. Smanjenje toga pokazatelja posljedica je **pada međunarodnih rezervi** još na svršetku godine 1997. zbog mjera monetarnih vlasti da održe stabilan tečaj i upravljaju likvidnošću bankarskog sektora. Budući da je u to vrijeme snažno rasla kreditna aktivnost poslovnih banaka, mjere centralne banke usmjerene na povlačenje viška likvidnosti rezultirale su prodajom deviza iz pričuva. Kreditna je ekspanzija (**rast kredita poslovnih banaka domaćim sektorima**) u pretkriznom razdoblju značila i smanjenu pažnju i sposobnost procjene kreditnog rizika u uvjetima neadekvatne kontrole i supervizije poslovanja banaka. Pojava moralnog hazarda može objasniti

i **kretanje M4 multiplikatora**, jer razmjerno brz porast deviznih depozita može biti znak i moralnog hazarda ako depoziti priteču privučeni nerealno visokim pasivnim kamatnim stopama. Tome ide u prilog i **ponašanje realnih kamata na tržištu novca**, koje su u pretkriznom razdoblju znatno premašile svoju kritičnu granicu kretanja. Podsjetimo se da na kamatne stope može djelovati i povećana segmentacija tržišta zbog razlika u percepciji rizika pojedinih financijskih institucija da ako sami sudionici na bankarskom tržištu procijene da raste broj loših banaka, to se može reflektirati rastom kamatnih stopa na tržištu novca. Osim toga, visina je kamatnih stopa u tome razdoblju odražavala i efikasnost poslovanja banaka i visinu njihovih troškova, proces restrukturiranja bankarskog sektora, stupanj rizika i pravne nesigurnosti i financijsku nedisciplinu. **Odnos bankarske rezerve/ukupna aktiva banaka** trajno se kretao u kritičnom području u tijeku kriznog razdoblja. U početku krize, dok još nisu padali bankarski depoziti, taj je indikator bio pod dominantnim utjecajem rasta ukupne bankarske aktive zbog rasta svih vrsta bankarskih potraživanja. No nakon izbijanja krize oko polovine godine 1998., pogoršanju toga odnosa pridonio je i pad bankarskih depozita zbog porasta nepovjerenja u domaći bankarski sustav (zato što depoziti ulaze u osnovicu za obračun obveznih pričuva). Pogoršano stanje u bankarskom sektoru koje je postalo očito već u proljeće godine 1998. i problemi s likvidnošću s kojim su se susrele i dotad zdrave banke, potakle su intervenciju monetarnih vlasti koja se odrazila **rastom kredita poslovnim bankama** namijenjenih održavanju likvidnosti sustava.

Provedeno je istraživanje pokazalo da je primjenom signalne metode moguće pratiti osjetljivost domaćeg bankarskog sustava i otkriti ekonomske i financijske varijable koje upozoravaju na porast ranjivosti bankarskog sektora na poremećaje. Pritom se naglašava potreba kontinuiranog praćenja sustava signalnih indikatora, i potrebu njihova periodičkog preispitivanja i revidiranja, da bi analizom bile obuhvaćene i nove informacije, odnosno novi, potencijalno značajni indikatori koji su u prijašnjim analizama bili zaobiđeni ili zanemareni. Zato ove sustave indikatora valja promatrati prije svega kao dinamične mehanizme praćenja strukturne osjetljivosti financijskih sustava na poremećaje, koji mogu zajedno s ostalim analitičkim metodama pomoći monetarnim i ekonomskim vlastima u održavanju stabilnosti domaćeg financijskog sustava.

Prilog

Opis vremenskih serija i izvora podataka

Izvori podataka:

Bilten Hrvatske narodne banke (HNB);

Mjesečno statističko izvješće, Državni zavod za statistiku (DZS)

Mjesečni statistički prikaz Ministarstva financija (MF)

Napomena:

Pokazatelji korišteni u istraživanju izraženi su u obliku međugodišnjih stopa rasta, osim sljedećih varijabli: tečaj, kamatne stope, budžetski deficit/BDP, inozemna aktiva HNB/M4, neto raspoložive rezerve/M4, saldo tekućeg računa bilance plaćanja i kapitalni priljev.

1) **Realan efektivni tečaj** – ponderirani geometrijski prosjek indeksa bilateralnih tečajeva kune (euro, USD, CHF, GBP, SLT) korigiranih odnosom indeksa cijena na malo zemalja partnera i domaćeg indeksa cijena na malo (Bilten HNB, Tablica H10)

2) **Realan bilateralni tečaj HRK/EUR** – nominalni bilateralni tečaj HRK/EUR (srednji tečaj HNB na svršetku razdoblja) korigiran odnosom HCPI u euro zoni i domaćeg indeksa cijena na malo (Bilten HNB, Tablica H9; DZS)

3) **Međunarodne pričuve, bruto (USD)** – međunarodne pričuve HNB koje uključuju specijalna prava vučenja, pričuvne pozicije u MMF, zlato, strane valute i depozite kod stranih banaka, i obveznice i zadužnice (Bilten HNB, Tablica H6)

4) **Neto raspoložive rezerve HNB (USD)** – međunarodne pričuve HNB umanjene za inozemnu pasivu, devizne blagajničke zapise i obveznu pričuvu u devizama (HNB)

5) **Neto raspoložive rezerve/M4** – M4 sadrži novčanu masu M1, štedne i oročene depozite, devizne depozite i obveznice i instrumente tržišta novca (Bilten HNB, Tablica B1)

6) **Inozemna aktiva HNB/M4** – inozemna aktiva HNB uključuje zlato, specijalna prava vučenja, pričuvnu poziciju kod MMF, efektivni strani novac u blagajni, sredstva na tekućim računima u stranim bankama, oročene depozite kod

inozemnih banaka i pripadajuće obračunane kamate, plasmane u vrijednosne papire u devizama i ostala potraživanja (Bilten HNB, Tablica C1)

7) **M4 multiplikator** – M4/M0, M0 primarni je novac (Bilten HNB, Tablica A1)

8) **M1 multiplikator** – M1/M0, (Bilten HNB, Tablica A1)

9) **Ponuda novca** – novčana masa M1 (Bilten HNB, Tablica A1)

10) **Primarni novac M0** – gotovo novac izvan banaka, novčana sredstva u blagajni banaka, depoziti banaka kod HNB, depoziti ostalih bank. institucija i ostalih domaćih sektora kod HNB (Bilten HNB, Tablica A1)

11) **Domaći krediti/domaća aktivnost** – odnos ukupnih (kunskih i deviznih) kredita poslovnih banaka domaćim sektorima i industrijske proizvodnje kao aproksimacije domaće aktivnosti (obje serije izražene kao bazni indeksi, prosjek 1995.=100), (Bilten HNB, Tablica D5; DZS)

12) **Rast kredita poslovnih banaka domaćim sektorima** – ukupni (kunski i devizni), (Bilten HNB; Tablica D5)

13) **Bankarski depoziti** – M4 umanjeno za novac u optjecaju (Bilten HNB; Tablica A1, C1)

14) **Pričuve banaka kod HNB/ukupna bankarska aktiva** – pričuve banaka ukupne (kunske i devizne (Bilten HNB; Tablica D1)

15) **Potraživanja PB od javnog sektora/ ukupna potraživanja PB** – zbroj potraživanja poslovnih banaka od lokalne i središnje države kao udio u ukupnim potraživanjima poslovnih banaka (zbroj odgovarajućih stavki iz konsolidirane bilance poslovnih banaka) (Bilten HNB, Tablica D1)

16) **Neto potraživanja monetarnih institucija od središnje države** – potraživanja HNB i poslovnih banaka od središnje države umanjena za depozite središnje države kod HNB i banaka (Bilten HNB; Tablica B1)

17) **Kreditni HNB poslovnim bankama** – krediti za refinanciranje, lombardni krediti, kratkoročni krediti za likvidnost, interventni krediti, specijalni krediti za premošćivanje nelikvidnosti (Bilten HNB, Tablica C1)

18) **Inozemne obveze monetarnih institucija** – HNB i poslovnih banaka (Bilten HNB, Tablica C1 i D1)

19) **Indeks industrijske proizvodnje** – prosjek 1995=100 (DZS)

20) **Izvoz**, u USD (DZS)

21) **Uvoz**, u USD (DZS)

22) **Saldo robne razmjene** – definiran kao razlika logaritama izvoza i uvoza (DZS)

23) **Budžetski deficit/BDP** – mjesečni nominalni BDP dobijen interpolacijom iz kvartalnih podataka (DZS, MF)

- 24) **Budžetski deficit (bez kapitalnih prihoda)/BDP** – (DZS, MF)
- 25) **Realne kamate na tržištu novca** – nominalne kamate na tržištu novca (u % na godišnjoj razini, na dnevnom tržištu) umanjene za stopu promjene cijena na malo na godišnjoj razini, (Bilten HNB Tablica G1 i DZS)
- 26) **Aktivna/pasivna kamatna stopa** – odnos nominalne kamatne stope na kratkoročne kunske kredite bez valutne klauzule i nominalne kamatne stope na kunske depozite (depozite po viđenju, štedne i oročene depozite) bez valutne klauzule (iskazane u % na godišnjoj razini); (Bilten HNB Tablice G1 i G2)
- 27) **Saldo tekućeg računa bilance plaćanja** (kvartalno) – u USD (Bilten HNB Tablica H1)
- 28) **Kapitalni priljev** (kvartalno), u USD (Bilten HNB, Tablica H5)

LITERATURA

1. Aharony, J. i I. Swary, (1996.), “Additional Evidence on the information-based Contagion Effects of Bank Failures”, *Journal of Banking and Finance*, **20**, 57-69.
2. Ahec-Šonje, A., (2002.), *Pokazatelji valutnih i bankarskih kriza – Hrvatska i svijet*, doktorska disertacija, Ekonomski fakultet, Zagreb.
3. Ahec-Šonje, A., (2000.), “Ekonomska prognostika u Hrvatskoj: CROLEI indeks”, *Ekonomski pregled*, **51(5-6)**, 579-605.
4. Ahec-Šonje, A., (1996.), “Navješćujući indikatori hrvatskog gospodarstva”, *Privredna kretanja i ekonomska politika*, **46**, 43-70.
5. Ahec-Šonje, A., (1995.a), “Metode predviđanja ekonomskih fluktuacija s naglaskom na “pristup indikatora””, *Ekonomski pregled*, **46(11-12)**, 820-837.
6. Ahec-Šonje, A., (1995.b), *Sustav prethodećih pokazatelja gospodarske aktivnosti u Republici Hrvatskoj*, magistarski rad, Ekonomski fakultet, Zagreb.
7. Allen, F. i D. Gale, (2000.), “Financial Contagion”, *Journal of Political Economy*, **108(1)**, 1-33.
8. Aziz, J., F. Caramazza i R. Salgado, (2000.), “Currency crises: in search of common elements”, *IMF Working Paper*, **00/67**, Washington, D.C.: International Monetary Fund.
9. Bell, J. i D. Pain, (2000.), “Leading Indicator Models of Banking Crises – a Critical Review”, *Bank of England Financial Stability Review*, **9** (December).

10. Blanco, H. i P. Garber, (1986.), "Recurrent Devaluation and Speculative Attacks on the Mexican Peso", *Journal of Political Economy*, **94(1)**, 148-166.
11. Blejer, M. i L. Schumacher, (1998.), "Central Bank Vulnerability and the Credibility of Commitments: A Value-at-Risk Approach to Currency Crises", *IMF Working Paper*, **98/65**, Washington, D.C.: International Monetary Fund.
12. Bordo, M. i B. Eichengreen, (1999.), "Is Our Current International Financial Environment Unusually Crisis Prone?" u D. Gruen i L. Gower, (ured.), *Capital Flows and the International Financial System*, Sydney: Reserve Bank of Australia, 18-75.
13. Boyd, J., Chang, C. i B. Smith, (1998.), "Moral Hazard Under Commercial and Universal Banking", *Journal of Money, Credit and Banking*, **30 (3)**, 426-468.
14. Bruggemann, A. i T. Linne, (1999.), "How Good are Leading Indicators for Currency and Banking Crises in Central and Eastern Europe? An Empirical Test, *IWH Discussion Paper*, **95**, Institut für Wirtschaftsforschung Halle, (LINK dokumentacija).
15. Calomiris, C.W. i G. Gorton, (1991.), "The Origins of Banking Panics: Models, Facts, and Bank Regulation" u G. Hubbard, (ured.), *Financial Markets and Financial Crises*, Chicago: University of Chicago Press, 109-173.
16. Caprio, G. i D. Klingebiel, (1996.a), "Bank Insolvencies: Cross-Country Experience" *Policy Research Working Paper*, **1620**, Washington, D.C.: The World Bank.
17. Caprio, G. i D. Klingebiel (1996.b), "Bank Insolvency: Bad Luck, Bad Policy, or Bad Banking?", rukopis, (*Annual World Bank Conference on Development Economics*, April 1996), Washington, D.C.: The World Bank.
18. Caprio, G. i D. Klingebiel (1999.), "Episodes of Systematic and Borderline Financial Crises", rukopis, Washington, D.C.: The World Bank.
19. Caramazza, F., L. Ricci i R. Salgado, (2000.), "Trade and Financial Contagion in Currency Crises", *IMF Working Paper*, **00/55**, Washington, D.C.: International Monetary Fund.
20. Corsetti, G., P. Pesenti i N. Roubini, (1998.), "Paper Tigers? A Model of the Asian Crisis", *NBER Working Paper*, **6783**, Cambridge, Mass.: National Bureau of Economic Research.
21. Cumby, R. i S. Wijnbergen, (1989.), "Financial Policy and Speculative Runs with a Crawling Peg: Argentina 1979-81", *Journal of International Economics*, **27**, 111-127.
22. Demirguc-Knut, A. i E. Detragiache, (1997.), "The Determinants of Banking Crises: Evidence from Developing and Developed Countries", *IMF Working Paper*, **97/106**, Washington, D.C.: International Monetary Fund.
23. Demirguc-Knut, A. i E. Detragiache, (1998.), "Financial Liberalization and Financial Fragility", *IMF Working Paper*, **98/83**, Washington, D.C.: International Monetary Fund.

24. Diamond, D. i P. Dybvig, (1983.), "Bank Runs, Deposit Insurance, and Liquidity", *Journal of Political Economy*, **91(3)**, 410-419.
25. Docking, D.S., M. Hirshey i E. Jones, (1997.), "Information and Contagion Effects of Bank Loan-Loss Reserve Announcements", *Journal of Financial Economics*, **43**, 219-239.
26. Dornbusch, R., (1998.), "After Asia: New Directions for the International Financial System", http://www.bos.frb.org/economic/conf/conf42/con42_10.pdf
27. Dornbusch, R., I. Goldfajn i R. Valdes, (1995.), "Currency Crises and Collapses", *Brookings Papers on Economic Activity*, **2**, 219-295.
28. Drees, B. i C. Pazarbasioglu, (1998.), "The Nordic Banking Crises: Pitfalls in Financial Liberalization?", *IMF Occasional Paper*, **161**, Washington, D.C.: International Monetary Fund.
29. Edin, P.-A. i A. Vredin, (1993.), "Devaluation Risk in Target Zones: Evidence from the Nordic Countries", *Economic Journal*, **103**, 161-175.
30. Edison, H., (2000.), "Do Indicators of Financial Crises Work? An Evaluation of an Early Warning System", *International Finance Discussion Paper*, 675, Washington, D.C.: Board of Governors of the Federal Reserve.
31. Edwards, S., (1989.), *Real Exchange Rates, Devaluation, and Adjustment: Exchange Rate Policy in Developing Countries*, Cambridge, Mass: MIT Press.
32. Eichengreen, B., A. Rose i C. Wyplosz, (1995.), "Exchange Market Mayhem: The Antecedents and Aftermath of Speculative Attacks", *Economic Policy*, **21** (October), 249-312.
33. Eichengreen, B., A. Rose i C. Wyplosz, (1996.), "Contagious Currency Crises", *NBER Working Paper*, **5681**, Cambridge, Mass.: National Bureau of Economic Research.
34. Eichengreen, B. i A. Rose, (1998.), "Staying Afloat When the Wind Shifts External Factors and Emerging-Market Banking Crises" *NBER Working Paper*, **6370**, Cambridge, Mass.: National Bureau of Economic Research.
35. Eichengreen, B. i C. Arteta, (2000.), "Banking Crises in Emerging Markets: Risks and Red Herrings", 6th Dubrovnik Conference on Economies in Transition, June 2000.
36. Frankel, J. i A. Rose, (1996.), "Currency Crashes in Emerging Markets: An Empirical Treatment", *International Finance Discussion Paper*, **534**, Washington, D.C.: Board of Governors of the Federal Reserve.
37. Freixas, X., B. Parigi i J. C. Rochet, (1999.), "Systemic Risk, Interbank Relations and Liquidity Provision by the Central Bank", *CEPR Discussion Paper*, **2325**, London: Center for Economic Policy Research.
38. Gavin, M. i R. Hausmann, (1996.), "The Roots of Banking Crises: The Macroeconomic Context", u R. Hausmann i L. Rojas-Suarez, (ured.), *Banking Crises in Latin America*, Baltimore, Maryland: John Hopkins University Press, 27-63.

39. Girton, L. i D. Roper, (1977.), "A Monetary Model of Exchange Market Pressure Applied to Postwar Canadian Experience", *American Economic Review*, **76(2)**, 537-548.
40. Glick, R. i M. Hutchison, (2000.), "Banking and Currency Crises: How Common Are Twins?", *HKI Working Paper*, **1/2000**, Hong Kong: Institute for Monetary Research.
41. Goldstein, M., G. Kaminsky i C. Reinhart, (2000.), *Assessing Financial Vulnerability: an Early Warning System for Emerging Markets*. Washington, D.C.: Institute for International Economics.
42. Gonzalez-Hermosillo, B., (1999.), "Determinants of Ex-Ante Banking System Distress: A Macro-Micro Empirical Exploration of Some Recent Episodes" *IMF Working Paper*, **99/33**, Washington, D.C.: International Monetary Fund.
43. Gorton, G., (1991.), "Banking Panics and Business Cycles" u N.F.R. Crafts, N.H. Dimsdale i S. Engerman (ured.), *Quantitative Economic History*, Oxford: Clarendon.
44. Hardy, D. i C. Pazarbasioglu, (1998.), "Leading Indicators of Banking Crises: Was Asia Different?", *IMF Working Paper*, **98/91**, Washington, D.C.: International Monetary Fund.
45. Hardy, D. i C. Pazarbasioglu, (1999.), "Determinants and Leading Indicators of Banking Crises: Further Evidence", *IMF Staff Papers*, **46(3)**, Washington, D.C.: International Monetary Fund, 247-258.
46. Kaufman, G. G., (1994.), "Bank Contagion: A Review of the Theory and Evidence", *Journal of Financial Services Research*, **8**, 123-150.
47. Kamin, S., (1988.), "Devaluation, External Balance and Macroeconomic Performance: A Look at the Numbers", *Studies in International Finance*, **62**, Princeton: Princeton University.
48. Kaminsky, G. i C. Reinhart, (1996.), *Banking and Balance-of-Payment Crises: Models and Evidence*, Washington D.C.: Board of Governors of the Federal Reserve.
49. Kaminsky, G., S. Lizondo i C. Reinhart, (1997.), "Leading Indicators of Currency Crises", *Policy Research Working Paper*, **1852**, Washington D.C.: The World Bank.
50. Kaminsky, G., (1998.), "Currency and Banking Crises: The Early Warnings of Distress", *International Finance Discussion Paper*, **629**, Washington D.C.: Board of Governors of the Federal Reserve.
51. Kaminsky, G. i C. Reinhart, (1999.), "The Twin Crises: The Causes of Banking and Balance-of-Payments Problems", *American Economic Review*, **89(3)**, 473-500.
52. Kindleberger, C., (1996.), *Manias, Panics, and Crashes: A History of Financial Crises*, New York: John Wiley&Sons, Inc. (treće izdanje)

53. Klein, M.W. i N. Marion, (1994.), "Explaining the Duration of Exchange Rate Pegs", *NBER Working Paper*, **4651**, Cambridge, Mass.: National Bureau of Economic Research.
54. Kruger, M., Osakwe, P.N. i J. Page, (1998.), "Fundamentals, Contagion and Currency Crises: An Empirical Analysis", *Bank of Canada Working Paper*, **98-10**, Bank of Canada, 98-110.
55. Lindgren, C. J., G. Garcia i M. Saal, (1996.), *Bank soundness and Macroeconomic Policy*, Washington, D.C.: International Monetary Fund.
56. Logan, A., (2000.), "The Early 1990s Small banks Crisis: Leading Indicators", *Bank of England Financial Stability Review*, **9** (December).
57. Masson, P., (1998.), "Contagion, Monsoonal Effects, Spillovers and Jumps Between Multiple Equilibria", *IMF Working Paper*, **98/142**, Washington, D.C.: International Monetary Fund.
58. McKinnon, R. i H. Pill, (1996.), "Credible Liberalisations and International Capital Flows. The Overborrowing Syndrome", u T. Ito i A. Krueger, (ured.), *Financial Regulation and Integration in East Asia*, Chicago: University of Chicago Press.
59. Milesi-Ferritti, G. i A. Razin, (1998.), "Current Account Reversals and Currency Crises: Empirical Regularities", *IMF Working Paper*, **98/99**, Washington, D.C.: International Monetary Fund.
60. Nierhaus, W. (2000.), "Currency Crises Indicators - The Signal Approach", rukopis, IFO Institute for Economic Research, (25th CIRET Conference dokumentacija).
61. Ötker, I. i C. Pazarbasioglu, (1994.), "Exchange Market Pressures and Speculative Capital Flows in Selected European Countries", *IMF Working Paper*, **94/21**, Washington, D.C.: International Monetary Fund.
62. Ötker, I. i C. Pazarbasioglu, (1995.), "Speculative Attacks and Currency Crises: The Mexican Experience", *IMF Working Paper*, **95/112**, Washington, D.C.: International Monetary Fund.
63. Sachs, J., A. Tornell i A. Velasco, (1996.), "Financial Crises in Emerging Markets: The Lessons From 1995", *Brookings Papers on Economic Activity*, **1**, 147-215.
64. Weber, A., (1998.), "Wources of Currency Crises: An Empirical Analysis" *Oesterreichische Nationalbank Working Paper*, **25**, Wien: Oesterreichische Nationalbank.

SENSITIVITY ANALYSIS OF THE BANKING SYSTEM - THE APPLICATION OF "SIGNAL" METHOD

Summary

This paper is an attempt of detailed analysis of macroeconomic and financial background of the last banking crisis in Croatia which started in spring 1998. Taking the existing theoretical explanations of the banking crises' causes as a starting point, it has been tested the possibility of usage of the new analytical and prognostic method - signal method, in establishment of the first domestic system of indicators for early notification of banking disruptions. The signal indicators systems enable continuous observation of sensitivity level of banking market, and combined with other analytical methods they can represent a remarkable source of information for monetary and economic authorities about the level of financial stability in a country. This paper presents the beginning of a serious research undertaking, the final goal of which is development of efficient and dynamic system for early notification of banking crises in Croatia.