GODINA
HRVATSKE
NARODNE
BANKE

Istraživanja I-61

Hrvatski indeks sistemskog stresa (HISS)

Ervin Duraković

Zagreb, ožujak 2021.



HRVATSKA NARODNA BANKA · CROATIAN NATIONAL BANK

Navodi u tekstu stavovi su autora te ne moraju nužno izražavati stajalište ili mišljenje Hrvatske narodne banke.

Croatian systemic stress index (CSSI)

Abstract

In order to help identify systemic risk episodes in Croatia, the paper presents the construction of the Croatian systemic stress index (CSSI), a composite indicator that synthesises the daily indicators of financial stress from several financial markets into a single indicator using Modern Portfolio Theory. In this way, for the first time events in domestic financial markets were quantified in a comprehensive manner and on a daily basis, taking into account the high level of correlation between the markets during the periods of adverse events. Considering the spill-over and the propagation of systemic disturbances in several markets at the same time with possible consequences for economic activity, the presented methodological approach is a key contribution of this paper to the literature on systemic risks. The constructed index identifies three significant systemic stress episodes in Croatia: the recession in the late nineties, the start of the Global Financial Crisis in 2008, the debt sustainability and bank solvency crisis in the EU periphery in 2011/2012, as well as the recent systemic event resulting from the COVID-19 pandemic. The robustness of the results was confirmed by applying several different methodological approaches, while the quantification of systemic shocks on the economy is assessed by employing the TVAR model with results suggesting a non-linear relationship between the financial sector and macroeconomic developments and defining the threshold of the index above which shocks can have a significant impact on economic activity. The constructed index has a wide area of potential application in empirical research; however, the largest contribution is expected in the area of macroprudential policy assessment and designing the timely and appropriate stabilisation policy.

Keywords: systemic stress, financial stress, modern portfolio theory, systemic risk, financial market, TVAR model, systemic shock

JEL: E44, E50, G01, G10, G20

Sažetak

Kako bi se prepoznale epizode sistemskog stresa u Republici Hrvatskoj, u radu je konstruiran hrvatski indeks sistemskog stresa (HISS), kompozitni pokazatelj koji primjenom moderne teorije portfelja dnevne pokazatelje financijskog stresa na pojedinim tržištima sintetizira u jedinstven pokazatelj. Na ovaj su način prvi put na sveobuhvatan način i na dnevnoj razini kvantificirani događaji na domaćim financijskim tržištima, pri čemu je uzeta u obzir visoka koreliranost tržišta u razdobljima nepovoljnih događaja. Ovakav metodološki pristup ključan je doprinos ovog rada literaturi na temu sistemskih rizika s obzirom na to da se poremećaji sistemskoga karaktera prelijevaju i propagiraju na više tržišta istodobno uz moguće posljedice na makroekonomsko okružje. Konstruirani pokazatelj identificira tri važnije krizne epizode u Hrvatskoj koje su sistemskoga karaktera: recesiju potkraj devedesetih godina, početak globalne financijske krize 2008. godine te krizu održivosti državnog duga i solventnosti banaka u rubnim zemljama europodručja 2011. i 2012. godine. Robusnost rezultata potvrđena je primjenom nekoliko različitih metodoloških pristupa, a kvantifikacija utjecaja takvih sistemskih šokova na gospodarstvo procijenjena je TVAR modelom, čiji rezultati upućuju na nelinearnu vezu između financijskog sektora i makroekonomske dinamike te definiraju vrijednost indeksa iznad koje šokovi mogu imati znatan utjecaj na gospodarsku aktivnost. Konstruirani indeks mogao bi se primijeniti na širokom polju empirijskih istraživanja, no njegov najveći doprinos zasigurno je na području ocjene makroprudencijalne politike te praćenja procesa neravnoteža u sustavu oblikovanja pravodobne i primjerene politike stabilizicaje.

Ključne riječi: sistemski stres, financijski stres, teorija portfelja, sistemski rizici, financijska tržišta, TVAR model, sistemski šokovi

JEL: E44, E50, G01, G10, G20

Sadržaj

1. Uvod 6
2. Kratak pregled literature 8
3. Sistemski stres – definicija i problem mjerenja 9
4. Metodologija izračuna indeksa sistemskog stresa za Hrvatsku 12
4.1. Odabir pokazatelja 12
4.2. Konstrukcija tržišnih podindeksa 15
4.3. Sažimanje podindeksa u kompozitni pokazatelj stresa 17
4.4. Određivanje težinskih faktora 20
5. Hrvatski indeks sistemskog stresa (HISS) 22
6. Analiza robusnosti 29
7. Sistemski šokovi i gospodarska aktivnost – primjena na RH 32
8. Zaključak 36
9. Literatura 38
Prilog 1. Deskriptivna analiza 43
Prilog 2. GARCH modeli 46
Prilog 3. Indeks fragilnosti bankovnog sustava 47
Prilog 4. Opis korištenih pokazatelja 47
Devizno tržište 47
Novčano tržište 48
Obvezničko tržište 49
Dioničko tržište 50
Posrednici 52

1. Uvod

Čovjek koji pati ili je pod stresom prije nego je potrebno,
pati više nego je potrebno.

Seneka (4. pr. n. e. – 65. n. e.), rimski filozof

Kako bi se očuvala stabilnost financijskog sustava te minimizirali ekonomski i socijalni troškovi njegovih eventualnih poremećaja, potrebno je kontinuirano praćenje stresnih uvjeta na njemu. To je posebno došlo do izražaja u posljednjoj svjetskoj financijskoj krizi, pa ne čudi da su mnoge zemlje, pa tako i Hrvatska, u posljednjih desetak godina uložile znatan napor u proširenje postojećih tehnika i pokazatelja te izmjenu regulative, a s ciljem očuvanja i jačanja financijske stabilnosti sustava. U skladu s time, pravodobne reakcije nositelja politika, odnosno pravodobno donošenje odluka o mjerama i instrumentima od krucijalne su važnosti, a rano i što točnije detektiranje poremećaja, odnosno stresa na financijskim tržištima jedan je od najvećih izazova iz perspektive nositelja ekonomske politike i glavni je motiv ovog istraživanja.

Međutim, dok je u teoriji optimizacijski imperativ pravodobnoga i primjerenog upravljanja (financijskim) sustavom sasvim jasan, u empiriji se pojavljuje niz poteškoća za navedenu zadaću, pri čemu se kao osnovni analitički problem ističe činjenica da fenomen stresa nije izravno mjerljiv te da je njegova kvantifikacija otežana. Stoga se u praktičnom smislu rješenje svodi na: (i) neizravno mjerenje putem niza kvantitativnih i kvalitativnih pokazatelja te (ii) izvlačenje jedinstvene informacije o stresu iz odabranog skupa pokazatelja. Također, kako bi se premostio informacijski jaz, u pravilu snažno prisutan zbog relativno niske frekvencije u ekonomskoj statistici, rabe se pokazatelji na dnevnoj frekvenciji, koji se uglavnom zasnivaju na podacima s financijskih tržišta. Naravno, pri tom procesu odabira adekvatnih pokazatelja ne postoje jasni kriteriji, već je potrebno imati na umu pitanja stupnja integriranosti (u kontekstu vjerojatnosti prelijevanja stresa s jednog tržišta na drugo) i plitkosti pojedinih tržišta (u kontekstu broja i opsega financijskih transakcija). Dodatno se postavlja i pitanje statističke podloge odnosno nedostupnosti podataka istraživaču, što je (objektivno) ograničavajući faktor. Unatoč tome, broj takvih potencijalno važnih pokazatelja relativno je velik, pa se u literaturi i praksi često rabe kompozitni indeksi koji sažimaju brojne informacije dobivene na osnovi svakog od njih. Takvi indeksi gotovo u realnom vremenu omogućuju mjerenje razine stresa u financijskom sustavu.

No, osim očite koristi i prednosti korištenja brzo dostupnih informacija o neravnotežnim procesima, važno je razumjeti njihovu dualnu prirodu. S jedne strane, mogući su autonomno generirani poremećaji unutar financijskog sustava koji se, potraju li, odnosno ako nije riječ o jednokratnom poremećaju, mogu u bliskoj budućnosti odraziti na kretanja u realnoj ekonomiji. S druge strane, sistemski poremećaji ili egzogeni šokovi nastali u realnoj sferi gospodarstva također mogu destabilizirati financijska tržišta koja povratno reagiraju negativno, pojačavajući sekundarne učinke prema ostatku

ekonomije. Oba aspekta valja imati na umu pri interpretaciji stresnih epizoda koje se mogu izdvojiti na temelju kompozitnog indeksa, što je važno pri njihovoj upotrebi u okviru makrobonitetne politike. Uz prethodno navedeno, bitno je naglasiti kako konstruirani dnevni indeks stresa može biti vrlo koristan alat u komunikaciji nositelja ekonomske politike s javnošću pri obrazlaganju odluka o upotrebi mjera koje su usmjerene na jačanje i očuvanje stabilnosti financijskog sustava na rizike.

Dodatne koristi za Republiku Hrvatsku od dnevnog indeksa sistemskog stresa, koji prema saznanjima autora trenutno ne postoji, mogle bi biti znatne. Prije svega, Hrvatska je u posljednjih dvadesetak godina prošla kroz nekoliko karakterističnih razdoblja poput: recesije krajem devedesetih, snažnoga kreditnog rasta nakon konverzije eura, snažne i dugotrajne recesije tijekom i nakon globalne financijske krize. Mogućnost korištenja jedinstvenog indikatora za kvantifikaciju sistemskog stresa otvara niz mogućnosti za druga empirijska istraživanja koja su dosad za sistemski stres rabila zamjenske ili indikatorske varijable. Također, široku primjenu ovaj bi indeks mogao imati i na području makroprudencijalne politike, a pogotovo pri procjeni efikasnosti sadašnjih ili budućih instrumenata.

S obzirom na sve navedeno, cilj je ovog istraživanja konstruirati kompozitni pokazatelj sistemskog stresa za Hrvatsku, koji će na dnevnoj razini upućivati na razinu poremećaja na domaćim financijskim tržištima, a uzimajući u obzir i njihovu međupovezanost (koreliranost) te važnost za realno gospodarstvo. Upravo uključivanje sistemske komponente u izračun pokazatelja primjenom moderne teorije portfelja ključan je doprinos ovog rada, odnosno njegov iskorak u odnosu na dosad izrađene indekse u domaćoj literaturi. Također, i sama konstrukcija indeksa, odnosno odabir njegovih komponenti, analitički je doprinos ovog rada s obzirom na to da je struktura hrvatskoga financijskog tržišta znatno drugačija od onih za koje su ovakvi indeksi već konstruirani. Izrađeni metodološki pristup omogućuje jednostavniju interpretabilnost rezultata i olakšava detektiranje točnog uzroka poremećaja. Dodatan doprinos analizi i posljedicama sistemskih poremećaja dan je i time što se prvi put kvantificira razina indeksa koja upućuje na promjenu režima u kojemu se financijska tržišta u određenom razdoblju nalaze te se ocjenjuju efekti zabilježenih sistemskih šokova na gospodarsku aktivnost zemlje.

Rad je strukturiran na sljedeći način. Nakon uvoda, u drugom je poglavlju prikazan kratak pregled literature. U trećem dijelu definiran je pojam financijskoga (sistemskog) stresa te se podrobnije razlaže problem njegova kvantificiranja. U četvrtom dijelu detaljno se opisuje metodološki pristup za konstruiranje kompozitnog indeksa za Republiku Hrvatsku, pri čemu se sustavno navode i opisuju korišteni pokazatelji s reprezentativnih tržišta, analizira se način njihova agregiranja u tržišne podindekse te određuje međusobna koreliranost tržišta i važnost za realno gospodarstvo. U petom je poglavlju prikazan ključan rezultat istraživanja – hrvatski indeks sistemskog stresa (HISS), pomoću kojega se analiziraju uzroci zabilježenih poremećaja i ujedno stavljaju u kontekst međunarodnog okružja. Konstukcijom dvaju alternativnih indeksa u šestom

se poglavlju provodi analiza robusnosti kompozitnog pokazatelja, a u sedmom se poglavlju kvantificira prag za klasifikaciju razine indeksa u pojedini režim te se analizira utjecaj detektiranih sistemskih šokova na hrvatsko gospodarstvo. Glavni zaključci provedenog i smjernice za buduća istraživanja nalaze se u posljednjem poglavlju.

2. Kratak pregled literature

Prvi rad s temom definiranja i kvantificiranja financijskog stresa veže se uz Illing i Liu (2003.), koji su velik broj dnevnih pokazatelja s bankovnog i deviznog tržišta, tržišta kapitala te tržišta javnoga i privatnog duga Kanade agregirali u kompozitni pokazatelj primjenom nekoliko različitih tehnika. U prvom redu riječ je o jednostavnom uprosječivanju, metodi jednake varijance i tehnici faktorske analize. Kao područje istraživanja, litaratura koja analizira opisanu problematiku očekivano je doživjela znatan rast nakon 2008. godine, kada je velik broj autora na sličan način pristupio tom problemu, ponajprije prilagođavajući broj pokazatelja i obuhvaćenih tržišta ekonomskim karakteristikama analiziranih zemalja. Primjerice, Cardarelli i ostali (2009.) za 17 razvijenih zemlja svijeta ili Blix Grimaldi (2010.) za skupinu zemalja europodručja. No, ipak, svojevrsna je prekretnica u metodološkom smislu rad Holló i Lo Duca (2012.), koji se prvi put usredotočuju na mogući sistemski karakter fenomena financijskog stresa. Koristeći se metodom moderne teorije portfelja, koja se tipično upotrebljava pri optimizaciji odnosa prinosa i portfeljne rizičnosti, autori su konstruirali indeks sistemskog stresa za skupinu zemalja europodručja. U odnosu na dotadašnju literaturu, spomenuti rad razmatra stres u kontekstu povezanosti reprezentativnih tržišta (međukoreliranosti) u vremenu, kao i važnosti pojedinog tržišta za realno gospodarstvo. Na sličan način Duprey i Klaus (2015.) konstruiraju indekse za pojedine zemlje europodručja, ali s nekoliko ograničavajućih faktora. Naime, usporedivost indeksa zahtijeva dostupnost istovjetnih pokazatelja s tržišta pojedinih zemalja, a različite karakteristike tržišta tih zemalja onemogućuju takvu zadaću. Stoga je taj metodološki pristup većina drugih zemalja primijenila na pojedinačnoj osnovi, a prvi put u ovom radu i Hrvatska. U recentnom razdoblju primjer su Velika Britanija, Turska i Norveška, gdje su indeksi sistemskog stresa redom prikazani u radovima Chatterjee i ostali (2017.), Chadwick i Ozturk (2018.) te Hagen i Pettersen (2019.).

Međutim, ovakvi se pokazatelji u literaturi osim njihove konstrukcije *per se*, sve više razmatraju i kao objašnjavajuća varijabla u empirijskim istraživanjima povezanima s provođenjem monetarne i makroprudencijalne politike te ocjenom učinaka sistemskih kriznih epizoda na makroekonomska kretanja. Primjerice, prema Hubrich i Tetlow (2015.), u slučaju SAD-a prelazak iz normalnog režima u kriznu epizodu nepovoljno se odražava na izglede realne ekonomije, a konvencionalna monetarna politika tijekom takvih razdoblja relativno je slaba. Štoviše, za zemlje europodručja indeks iskazuje znatnu i robusnu prediktivnost za standardne makroekonomske varijable poput

inflacije, rasta realnog BDP-a i kamatnih stopa monetarne politike, gdje je prediktivna snaga posebno snažna za kretanje gospodarske aktivnosti (Kremer, 2016.). Snažnu makroekonomsku prediktivnost ovakvih indeksa potvrđuje i činjenica da je indeks sistemskog stresa za europodručje – CISS uključen kao jedna od osam sastavnica vodećega ekonomskog indeksa (engl. *Leading Economic Index – LEI*) za ocjenu poslovnih ciklusa. Isto tako, indeksi sistemskog stresa pokazali su se i kao jedan od korisnih pokazatelja za kalibraciju protucikličkih zaštitnih slojeva kapitala u Europi pri fazi njihov snižavanja (Detken i ostali, 2014. i BCBS, 2017.).

Kada je riječ o domaćoj literaturi, koliko je autoru poznato, samo se jedan rad – Dumičić (2014.) – djelomično dotiče problematike razmatrane u ovom istraživanju. Međutim, on se u bitnome razlikuje od ovog istraživanja. Naime, u središtu pozornosti rada autorice jest odabir adekvatnih pokazatelja s tri financijska tržišta, koji se na osnovi metode zajedničkih komponenti agregiraju u dnevni pokazatelj financijskog stresa. Ovim se istraživanjem, kao što je već spomenuto u uvodu, kvantificira sistemski stres odnosno uključuje sistemska komponenta financijskog stresa, uzimajući u obzir koreliranost reprezentativnih tržišta, kao i važnost tih tržišta za realno gospodarstvo. To je omogućeno drugim metodološkim pristupom, primjenom moderne teorije portfelja, koja ujedno i pojednostavljuje interpretabilnost rezultata te osigurava ocjenu egzaktnog doprinosa pojedinih tržišta (i njihovih odabranih pokazatelja) ukupnom stresu. Osim toga, ovo istraživanje razlikuje se i po povijesnoj duljini vremenskih serija, broju obuhvaćenih tržišta, uključivanju desetodnevnih podataka iz bilanci banaka pri izračunu fragilnosti bankarskog sektora te načinu transformacije i ujednačenosti broja pokazatelja s reprezentativnih tržišta. Naposljetku, no ne i manje važno, prvi se put kvantificira razina sistemskog stresa koja bi se s odmakom mogla odraziti na realno gospodarstvo (industrijsku proizvodnju), ali se i ocjenjuje utjecaj sistemskih šokova na kretanje industrije u Hrvatskoj.

3. Sistemski stres – definicija i problem mjerenja

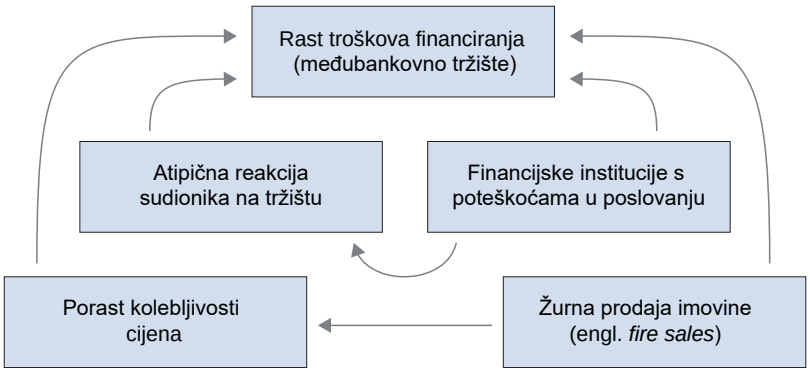
Financijski stres moguće je tumačiti kao atipično ponašanje ili naglu promjenu ponašanja sudionika na financijskim tržištima koja u nekoj mjeri odražava njihove reakcije na opća ekonomska kretanja ili određene poremećaje u vlastitom poslovanju, odnosno njihovu neposrednom poslovnom okružju, a prema pretpostavci u njihovoj ranoj fazi razvoja. Međutim, ako taj fenomen rezultira znatnim i dugotrajnim negativnim utjecajem na realnu ekonomiju ili, alternativno, stvarnim ekonomskim stresom ne nužno povezanim s uobičajenom recesijom, definiramo ga kao sistemski stres (Duprey, 2015.). Prema Hakkio i Keeton (2009.) financijski stres manifestira se kao: (a) povećana neizvjesnost sudionika na financijskim tržištima glede vrijednosti financijske imovine, a koja se tipično očituje u povećanoj kolebljivosti cijena; (b) povećana neizvjesnost glede očekivanja budućih ekonomskih kretanja; (c) znatno

smanjenje sklonosti glede držanja rizične (engl. *flight to quality*) i nelikvidne imovine (engl. *flight to liquidity*) te (d) povećana asimetričnost informacija između kupaca i prodavatelja financijske imovine (intenziviranje problema negativne selekcije i moralnog hazarda).

Iz navedenoga proizlazi da financijski stres može izazvati niz neželjenih lančanih reakcija na tržištima koja pružaju sredstva, informacije i osiguranje klijentima u javnom i privatnom sektoru, čime se izdvaja kao potencijalan faktor subooptimalne alokacije resursa, pa i potpuno narušene funkcije posredništva (Balakrishnan i ostali, 2009.). Prema Arinš i ostali (2012.) taj trenutak u pravilu čine tri elementa. Prvo, povišena razina stresa povećava troškove financiranja nefinancijskih poduzeća i kućanstava. Zatim, u uvjetima neizvjesnosti i asimetričnih informacija kreditne institucije mogu znatno postrožiti svoju procjenu boniteta dužnika i na taj način smanjiti potražnju za kreditima. Posljednje, investitori mogu odgađati odluke o kupnji financijske i nefinancijske imovine i time smanjiti potražnju za kreditima te posljedično dodatno povećati razinu stresa.

Jasno je da se "sazrijevanje" inicijalnoga stresnog impulsa u osnovi odvija izravno među financijskim agentima i u poslovanju s njihovim klijentima (primarni učinci; vidi Sliku 1.) te neizravno u prilagođavanju svih ostalih privrednih subjekata na te posljedice, što naposljetku može destabilizirajuće djelovati na cjelokupni gospodarski sustav, naravno s negativnom povratnom vezom prema samim financijskim tržištima (sekundarni učinci). Pritom je važno imati na umu kako disperzija i multiplikacija stresa ovise o jakosti i učestalosti vanjskih šokova, količini akumuliranih neravnoteža u financijskom sustavu (primjerice visoka poluga, znatan udio nelikvidne imovine i slično), autonomnoj sposobnosti sustava da ih apsorbira (stupanj otpornosti) te, naravno, o reakcijama nositelja mikrobonitetne politike prije i tijekom takvih epizoda i očekivanjima tržišnih sudionika u odnosu na te reakcije (Hollo, 2012.).

Slika 1. Povratne veze i multiplikacija financijskog stresa



Izvor: Guilleminot i ostali, 2013. (prilagodio autor)

Posebice je složeno pitanje intenzitet financijskog stresa, odnosno o kojoj je razini stresa riječ u nekoj fazi krizne epizode. Intuitivno je jasno da visoka razina stresa odražava veliku vjerojatnost materijalizacije sistemskih rizika zbog atipičnog ponašanja sudionika na financijskim tržištima, dok, suprotno, njegova niska razina upućuje na stabilnost financijskog sustava[1]. No, Hanschel i Monnin (2005.) u svom radu razdoblja niske razine stresa opisuju samo kao razdoblja njegove kvaziodsutnosti, drugim riječima na stres se gleda kao na pojavu stalno prisutnu u financijskom sustavu. Naime, dulja trajanja takvih razdoblja mogu implicirati da su tržišni sudionici preoptimistični (primjerice razdoblja kreditne ili investicijske ekspanzije) i time upućivati na potencijalne makrofinancijske neravnoteže. Tomu u prilog idu i rezultati pojedinih empirijskih istraživanja prema kojima snažan rast kreditiranja popraćen znatnim rastom cijena nekretnina u predstresnom razdoblju (razdoblje niske razine stresa) na financijskim tržištima povećava vjerojatnost da se financijski stres naposljetku razvije u ekonomsku krizu (Cardarelli, Elekdag i Lall, 2009.).

Iako je stres na financijskim tržištima dobro poznat fenomen koji utječe na normalno funkcioniranje i stabilnost sustava, teško ga je kvantificirati i pratiti jer nije direktno mjerljiva veličina. To čini prvi problem u pokušaju njegova identificiranja. Neizravno mjerenje podrazumijeva korištenje niza informacija, ne nužno isključivo kvantitativnih, koje mogu upućivati na nastanak i razvoj tog poremećaja. Svakako je pritom potrebno osloniti se na veći broj pokazatelja kako bi se reducirao stupanj njegove pogrešne specifikacije, posebno imajući na umu objektivno ograničavajuće faktore u procesu odabira koji reduciraju raspoloživost adekvatnih pokazatelja, poput kratkih vremenskih serija ili čak nedostupnosti pojedinih varijabli te nezadovoljavajuće kvalitete korištene statistike (primjerice u našem slučaju podaci o spot kupnji/prodaji deviza zbog izrazite kolebljivosti iznosa trgovanja). Ukratko, potrebno je iznaći sintetičku mjeru, i to po mogućnosti kontinuiranu. S obzirom na prethodno navedeno, a s ciljem povećanja robusnosti indeksa odnosno njegove preciznosti u detektiranju poremećaja potrebno je voditi računa o sljedećem:

(a) Pokazateljima bi trebao biti obuhvaćen što veći broj financijskih tržišta, s obzirom na to da postoji realna mogućnost da se poremećaji na određenom financijskom tržištu neće preliti na ostala tržišta. Primjerice, u slučaju Hrvatske mala je vjerojatnost da će se poremećaji na tržištu kapitala preliti na ostatak financijskog sustava.

(b) Pokazatelji moraju odražavati relativno velik broj i opseg financijskih transakcija. Naime, plitko tržište, odnosno tržište s malim brojem i opsegom financijskih transakcija može iskazivati poremećaje koji nisu bitno povezani s financijskim stresom i obratno. Primjerice, s relativno malim brojem dionica kojima se trguje na tržištu kapitala, poremećaj detektiran zbog povećanog volumena trgovanja jednom od njih ne mora nužno odražavati financijski stres.

[1] Pod pojmom financijskog sustava podrazumijevaju se financijska tržišta, institucije i posrednici.

4. Metodologija izračuna indeksa sistemskog stresa za Hrvatsku

Metodološki pristup izračunu HISS-a, grubo govoreći, sastoji se od tri razine. U prvom koraku potrebno je u skladu sa svim izrečenim u prethodnom poglavlju odabrati adekvatne pokazatelje financijskog stresa. Potom se na temelju tih varijabli izračunavaju podindeksi za pojedino reprezentativno tržište te se naposljetku konstruira kompozitni pokazatelj financijskog stresa za Hrvatsku.

4.1. Odabir pokazatelja

Pri konstruiranju indeksa financijskog stresa za pokazatelje se u literaturi najčešće odabiru dnevni ili unutardnevni podaci s tržišta vrijednosnih papira, deviznoga i novčanog tržišta te podaci o bankovnom sektoru. Illing i Liu (2006.) ističu da su takvi indeksi vrlo korisni za analizu zbivanja na visokorazvijenim financijskim tržištima s brojnim financijskim instrumentima i pokazateljima, no ako se prilagodi skup pokazatelja koji se upotrebljavaju za izračun indeksa, mogu se primijeniti i u zemljama sa slabije razvijenim financijskim tržištima, kao što je Hrvatska. U skladu s tim potrebno je voditi računa o specifičnostima domaćih financijskih tržišta, ekonomskim obilježjima zemlje i kretanjima na vanjskim financijskim tržištima za koja se ocjenjuje da bi mogla znatno utjecati na stabilnost domaćega financijskog tržišta.

Slijedom navedenog kao ključni segmenti domaćega financijskog sustava razmatraju se devizno i međubankovno tržište, tržišta obveznica i vrijednosnih papira te financijski posrednici. Svaki od ovih segmenata bit će predstavljen kao podindeks kompozitnog pokazatelja i sadržavat će po tri pojedinačna pokazatelja[2] financijskog stresa (izuzev posrednika), njih ukupno 13. Na taj se način obuhvaćaju specifične informacije za kvantificiranje sistemskog stresa, a korištenje podataka dostupnih na dnevnoj ili desetodnevnoj razini omogućuje mjerenje materijaliziranih sistemskih rizika u realnom vremenu. Osim toga valja naglasiti da, iako bi tri varijable u svakom tržišnom segmentu trebale pružiti komplementarne informacije kompozitnom pokazatelju, ipak se očekuje njihova visoka međusobna korelacija tijekom epizoda ozbiljnijih stresnih poremećaja (Holló, Kremer i Lo Duca, 2012.).

U osnovi su neki od navedenih pokazatelja izraženi u razinama, dok se financijski stres u literaturi detektira i korištenjem pokazatelja kolebljivosti i relativnog odnosa cijena (engl. *spread*). Naime, neizvjesnost sudionika na financijskim tržištima glede budućega kretanja fundamentalnih odrednica cijena može se ogledati u njihovoj izrazitoj kolebljivosti ili divergenciji, a da pritom apsolutne razine cijena ostanu na relativno

[2] Zbog konzistentnosti za pojedino je tržište uključen jednak broj pokazatelja. Budući da se podindeksi računaju kao jednostavni prosjeci, s pretpostavkom o normalnoj distribuiranosti transformiranih pokazatelja, uključivanje dodatnog pokazatelja za određeno tržište smanjilo bi varijancu prosjeka odnosno varijancu podindeksa.

Tablica 1. Pokazatelji korišteni pri konstrukciji indeksa sistemskog stresa

Tržište	Pokazatelji	Početak uzorka	Mjerna jedinica	Transformacija
Devizno	Kolebljivost tečaja kune prema euru	3. rujna 1996.	–	GARCH (1,1) model
	Razlika između kupovne i prodajne cijene tečaja kune prema euru	2. rujna 1996.	pips	dnevne vrijednosti
	Akumulirani gubitak u posljednjih pet godina	2. rujna 1996.	–	CMAX transformacija
Novčano	Kolebljivost prekonoćnog ZIBOR-a	23. veljače 1996.	postotak	GARCH (1,1) model
	Razlika između tromjesečnog ZIBOR-a i kamatne stope na trezorske zapise MF-a	17. rujna 1996.	postotni bodovi	dnevne vrijednosti
	Razlika između tromjesečnog ZIBOR-a i kamatne stope monetarne politike	22. veljače 1996.	postotni bodovi	dnevne vrijednosti
Obvezničko	Kolebljivost prinosa na državne obveznice	1. kolovoza 1996.	postotak	GARCH (1,1) model
	EMBI razlika prinosa	31. srpnja 1996.	bazni bodovi	dnevne vrijednosti
	Akumulirani gubitak u posljednje tri i pol godine	31. srpnja 1996.	–	CMAX transformacija
Dioničko	Kolebljivost mjerena indeksom CROBEX	3. rujna 1997.		GARCH (1,1) model
	Korelacija povrata na obvezničkom i dioničkom tržištu	29. siječnja 2001.	–	dnevne vrijednosti
	Akumulirani gubitak u posljednje dvije godine	2. rujna 1997.	–	1-CMAX transformacija
Bankovno	Indeks fragilnosti bankovnog sustava	2. rujna 2000.	–	interpolacija desetodnevnih vrijednosti

Napomena: CMAX transformacijom vrijednost pokazatelja u svakom danu zamjenjuje se omjerom njegove vrijednosti u tom danu i maksimalne vrijednosti u prethodno definiranom razdoblju. Prestanak daljnjeg izračuna indeksa ZIBOR od početka 2020. godine zahtijeva prilagodbu odgovarajućih pokazatelja s novčanog tržišta, što u ovom radu nije učinjeno, već su korištene njegove posljednje vrijednosti s kraja 2019. godine. Jedno od mogućih rješenja za aproksimaciju vrijednosti ZIBOR-a jest putem implicitnih kunskih kamatnih stopa dobivenih iz *swap* transakcija valutnog para EUR/HRK.

Izvori: Bloomberg; Zagrebačka burza; HNB; autor

niskoj razini. Po svojoj prirodi riječ je o izvedenim varijablama. Općenito govoreći razmatrani pokazatelji uključuju kolebljivost povrata imovine, spreadove i pokazatelje akumuliranih gubitaka kako bi se obuhvatili glavni simptomi financijskog stresa, dok se uključivanjem dugoročnih varijabli pokušava obuhvatiti što više epizoda financijskog stresa i financijskih ciklusa. Svi korišteni pokazatelji navedeni u Tablici 1. konstruirani su tako da njihova viša vrijednost odgovara porastu financijskog stresa. Njihov detaljan opis i deskriptivna statistika prikazani su u Prilogu 1. i Prilogu 4.

Pokazatelji na domaćem deviznom tržištu[3], kroz koje se uglavnom ogledaju epizode

[3] Neki se autori kao pokazateljima stresa na deviznom tržištu koriste indeksom pritiska na deviznom tržištu (IPDT), kojim se, uopćeno, promjene tečaja korigiraju intervencijama središnje banke. Drugim riječima, riječ je o konceptu kojim se mjeri promjena tečaja koja bi nastala da nema intervencija monetarnih vlasti. Međutim, osim toga što su reakcije nositelja politika sastavni dio ublažavanja stresnih događaja na tržištima, u kontekstu financijskog stresa na deviznom tržištu cilj je gledati stvarnu, a ne hipotetsku promjenu tečaja. Više o konstrukciji IPDT-u za domaću valutu vidi Krznar (2004.) ili recentnije Tatomir (2009.).

financijskoga tj. valutnog stresa, identificiraju razdoblja povećane kolebljivosti tečaja kune prema euru, smanjene likvidnosti na tržištu i akumuliranog slabljenja domaće valute. Činjenica da je Hrvatska visoko euroizirano gospodarstvo u kojemu je znatan dio domaće štednje, ali i ukupnih dužničkih obveza, vezan uz euro naglašava važnost ovog tržišta za ukupnu financijsku stabilnost zemlje, dok izrazito visoka izloženost valutnom riziku[4] čini jedan od glavnih izvora ranjivosti domaćega gospodarstva i daje sistemski karakter događajima na ovom tržištu.

Osim valutne izloženosti, dva važna obilježja strukture domaćega gospodarstva jesu i bankocentričnost financijskog sustava te visoka izloženost domaćih institucionalnih investitora državnom dugu. Stoga, poremećaji na bankovnom i obveznickom tržištu mogu biti važan okidač za materijalizaciju rizika u domaćem sustavu. Naime, urednom funkcioniranju financijskog sustava svake zemlje pridonose financijski posrednici. Priroda poslovanja takvih institucija izlaže ih brojnim rizicima, koji u slučaju materijalizacije mogu biti i sistemskoga karaktera odnosno proširiti se na ostatak financijskog sustava i potencijalno nepovoljno se odraziti na realno gospodarstvo, što naglašava njihovu važnost u očuvanju sveukupne financijske stabilnosti sustava. Osim što u nekim situacijama sami financijski posrednici mogu biti izvor financijskog stresa, moguć je njihov doprinos prelijevanju stresnih događaja i/ili propagaciji šokova s drugih financijskih tržišta. Primjerice, materijalizacija nekog od operativnih rizika u slučaju banaka može dovesti do znatnog odljeva depozita od strane deponenata i efektom zaraze ugroziti ostatak bankovnog sustava ili pak iznenadni šok na tržištima kapitala može ugroziti ukupnu likvidnost financijskih tržišta, pa tako i međubankovnog tržišta uz sve posljedice takvih događaja na poslovanje banaka i domaću ekonomiju. Kako bi se pratila razina otpornosti bankovnog sustava, konstruiran je indeks fragilnosti bankovnog sustava.

Nadalje, kretanja na tržištima državnih obveznica odražavaju percepciju rizika države te očekivanja investitora u vezi s mogućnošću podmirivanja dospjelih i budućih obveza zemlje. U tom se smislu nepovoljni događaji i zabrinutost investitora ogledaju u porastu pokazatelja akumuliranog prinosa tijekom vremena i (ili) relativnog odnosa cijene zaduživanja Hrvatske i europodručja. Osim toga, povećana neizvjesnost ili porast averzije investitora prema riziku često se očituje i u povećanoj kolebljivosti prinosa, što je također uključeno u konstuiranje kompozitnog indeksa. Sistemska važnost nepovoljnih događaja na ovim tržištima može biti znatna i proizlazi iz činjenice da osim porasta cijene financiranja zemlje i reperkusija na javne financije, visoka i izravna izloženost pojedinih domaćih sektora dugoročnom državnom dugu (institucionalnih investitora i banaka) čini njihove bilance iznimno osjetljivima na zamjetljiviji pad cijene odnosno rast prinosa državnih obveznica. Sve to u uvjetima financijskoga stresa znači velik rizik od prelijevanja šokova na druga domaća financijska tržišta.

[4] Ukupna zaduženost domaćih sektora u devizama na kraju 2019. godine iznosila je više od 500 mlrd. kuna (oko 150% BDP-a) odnosno gotovo 64% dužničkih obveza bilo je vezano uz euro.

Kada je riječ o pokazateljima na domaćem novčanom odnosno preciznije domaćem međubankovnom tržištu, oni su povezani s kolebljivošću i relativnim odnosom kamatnih stopa te odražavaju likvidnosne pritiske poslovnih banaka. Zahtjevi za kolateral i financiranje od strane središnje banke mogu biti od iznimne važnosti u razdobljima stresnih poremećaja, posebice onim sa sistemskim karakterom. Pokazatelji dioničkog tržišta obuhvaćaju kolebljivosti i snažne korekcije cijena imovine, kao i divergentna kretanja dioničkoga i obvezničkog tržišta, što je uobičajeno u razdobljima ozbiljnijih stresnih poremećaja. Iako je načelno, zbog plitkosti obaju tržišta, sistemska važnost takvih događaja relativno ograničena, visoke izloženosti pojedinih investitora mogu ih učiniti prilično ranjivima i djelovati na njihovo opće poslovanje.

4.2. Konstrukcija tržišnih podindeksa

Nakon odabira adekvatnih pokazatelja financijskog stresa, drugi je korak sintetiziranje događaja na pojedinom financijskom tržištu odnosno sažimanje tih pokazatelja u jedinstven podindeks za svako od reprezentativnih tržišta. Jedno od osnovnih pitanja koje se tom prilikom postavlja jest način na koji je moguće međusobno uskladiti varijable izražene u različitim mjernim jedinicama i/ili bitno različitim razinama, a da se pritom sačuva što veći broj informacija dobivenih na temelju svakog od pokazatelja. U suprotnom bi kretanje pojedinog podindeksa, a naposljetku i kompozitnog pokazatelja stresa bilo pogrešno određeno kretanjem isključivo varijabli s višim vrijednostima. Kao odgovor na postavljeno pitanje literatura nudi nekoliko metoda svođenja varijabli na zajedničku mjernu skalu. Primjerice, Morris (2010.) predlaže empirijsku standardizaciju varijabli na način da se vrijednost pojedinog pokazatelja u određenom danu umanji za srednju vrijednost uzorka varijable i potom dobivena razlika podijeli sa standardnom devijacijom uzorka. Louzis i Vouldis (2012.) slijede pristup logističke transformacije kako bi standardizirali inicijalne vrijednosti pokazatelja. Međutim, implicitna pretpostavka o normalnoj distribuiranosti polaznih varijabli često je narušena kod varijabli koje odražavaju kretanja na financijskim tržištima, što je bilo i u našem slučaju. Osim toga, spomenuti pristupi osjetljivi su i na prisutnost atipičnih vrijednosti (engl. *outlier*), koji se često pojavljuju upravo u razdoblju intenzivnoga financijskog stresa (Hakkio i Keeton, 2009.), što posljedično može dovesti do pogrešnog mjerenja stresa. Iz tih razloga transformaciji pokazatelja pristupilo se korištenjem empirijske kumulativne funkcije distribucije (engl. *Empirical Cumulative Distribution Function*), kao u Holló, Kremer i Lo Duca (2012.), a koja se često u kontekstu identifikacije financijskog stresa smatra funkcijom akumuliranog stresa. Tom transformacijom vrijednost svake pojedinačne varijable za svaki dan (u našem slučaju od 22. veljače 1996. do 1. svibnja 2020.) zamjenjuje se njezinim relativnim položajem u povijesnoj distribuciji te varijable.

Formalno, označimo s $x^i = (x_1^i, x_2^i, ..., x_n^i) n$ uzoračkih opažanja pojedinog pokazatelja financijskog stresa $i = 1,..., 15$ te odgovarajući uređeni uzorak s $(x_{[1]}^i, x_{[2]}^i, ..., x_{[n]}^i)$, gdje je $x_{[1]}^i \leq x_{[2]}^i \leq ... \leq x_{[n]}^i$. Drugim riječima, vrijednosti originalnog skupa podataka poredane

su tako da $x^i_{[1]}$ i $x^i_{[n]}$ odgovaraju minimalnoj odnosno maksimalnoj vrijednosti cijeloga uzorka. Potom se transformirane vrijednosti z^i_t za svaki dan $t = 1, 2,..., n$ definiraju na način da je

$$z^i_t = CDF(x^i_t) = \begin{cases} \frac{k}{n}, x^i_{[k]} \le x^i_t < x^i_{[k+1]}, k = 1, 2, ..., n-1, \\ 1, x^i_t = x^i_{[n]}. \end{cases} \quad (1)$$

Pojednostavljeno rečeno vrijednosti z^i_t jesu udio broja uzoračkih opažanja čija je vrijednost manja ili jednaka od x^i_t u ukupnom uzorku. Kako se može primijetiti, na taj način inicijalne vrijednosti i mjerne jedinice varijabli postaju nevažnima (engl. *unit free*) i zamijenjuju se vrijednostima koje su uvijek veće od 0 i manje od 1. Primjerice, transformirana vrijednost od 0,95 znači da je opažena vrijednost za taj dan veća ili jednaka od 95% do tada opaženih povijesnih vrijednosti.

Kada su pokazatelji jednom transformirani na prethodno opisani način, postavlja se pitanje na koji način pristupiti širenju uzorka u budućnosti, što u našem slučaju arbitrarno odgovara razdoblju nakon 1. svibnja 2020. Naime, činjenica da je riječ o relativnom povijesnom položaju pojedine vrijednosti za neki od pokazatelja rezultira time da širenjem uzorka odnosno dodavanjem nove dnevne vrijednosti mijenjaju se i inicijalno utvrđene vrijednosti transformiranih pokazatelja. Međutim, kako je promjena razina pokazatelja tijekom vremena marginalna[5], u ovom se radu širenju uzorka pristupilo na rekurzivan način

$$z^i_{n+T} = CDF(x^i_{n+T}) = \begin{cases} \frac{k}{n+T}, x^i_{[k]} \le x^i_{n+T} < x^i_{[k+1]}, k = 1, 2, ..., n+T-1, \\ 1, x^i_{n+T} = x^i_{[n+T]}. \end{cases} \quad (2)$$

gdje su T dani nakon 1. svibnja 2020. Time je kretanje podindeksa, a naposljetku i kompozitnog pokazatelja stresa konzistentno u vremenu.

Nakon što su po tri pokazatelja stresa ($ps = 1, 2, 3$) za svako od reprezentativnih financijskih tržišta ($tr = 1, 2, 3, 4, 5$) transformirana[6] na način opisan jednadžbom (1), agregirani su u podindekse pojedinog tržišta s^{tr} jednostavnim uprosječivanjem[7], odnosno za svaki dan vrijednost odgovarajućeg podindeksa izračunata je kao

$$s^{tr}_t = \frac{1}{3}\sum_{ps=1}^{3} z^{ps}_t. \quad (3)$$

[5] Primjerice, dodavanjem vrijednosti pokazatelja za dan 2. svibnja 2020. i s pretpostavkom izračuna transformirane vrijednosti na temelju jednadžbe (1), razine podindeksa maksimalno se promijene za 1/5.105 = 0,0002 jedinice. Svakoga sljedećeg dana ta bi razlika bivala sve manja.

[6] Za njihov grafički prikaz vidi Prilog 1.

[7] Neki autori predlažu agregiranje i metodom glavnih komponenata (engl. *PCA – Principal Component Analysis*). Međutim, zbog jednostavnijeg tumačenja kretanja kompozitnog indeksa stresa i vrlo sličnih rezultata koji se dobiju primjenom metode jednostavnog uprosječivanja (Holló, Kremer i Lo Duca, 2012.), odabrana je upravo ova posljednja.

4.3. Sažimanje podindeksa u kompozitni pokazatelj stresa

Sljedeći je korak agregiranje pet podindeksa u kompozitni pokazatelj koji mjeri sistemsku razinu stresa na financijskim tržištima. U tom je smislu prije svega važno razlikovati dvojak pogled na sistemski stres, horizontalni i vertikalni. S jedne strane, sve veća međupovezanost financijskih tržišta smanjuje vjerojatnost ograničenog djelovanja nestabilnosti unutar financijskog sustava i ima za posljedicu brže odnosno snažnije prelijevanje i propagaciju šokova između pojedinih tržišta. Takav horizontalni pogled na stres drugim riječima znači da će u situaciji ozbiljnijih poremećaja, neovisno o prirodi financijskog šoka – endogenoj ili egzogenoj, kretanja na nekim ili čak svim financijskim tržištima biti visoko korelirana i pridonijeti bržem širenju zaraze unutar financijskog sustava. S druge strane, uzajamna povezanost financijskih tržišta i realnoga gospodarstva čini vertikalni pogled na sistemski stres. Metodologija prezentirana u nastavku ovog poglavlja slijedi suvremenu teoriju portfelja, prema kojoj se na svojevrstan način uzimaju u obzir prethodno dva spomenuta obilježja sistemskoga stresa. Naime, u svojoj se osnovi teorijom portfelja disperzija rizika i optimiziranje prinosa na imovinu opisuje relativnim udjelom i vrijednošću pojedine vrste imovine te njihovom uzajamnom koreliranošću. U terminima kvantificiranja sistemskog stresa to odgovara važnosti pojedinog tržišta za realno gospodarstvo, razini vrijednosti pojedinačnih podindeksa te njihovoj međusobnoj koreliranosti. Pojednostavljeno rečeno, ovakvim se pristupom naglasak stavlja na situacije u kojima je stres prisutan na nekoliko tržišta u isto vrijeme te se istodobno financijski poremećaji distribuiraju kroz financijski sustav i prelijevaju na realno gospodarstvo. Ovakav pristup prvi je put prikazan u Holló, Kremer i Lo Duca (2012.), a od tada su ga, među ostalim, primijenili i Louzis i Vouldis (2012.), Braga i ostali (2014.) te Chatterjee i ostali (2017.), za konstruiranje pokazatelja u Grčkoj, Portugalu i Velikoj Britaniji.

Formalno, kompozitni pokazatelj sistemskog stresa za Hrvatsku konstruiran je na temelju sljedeće jednakosti

$$HISS_t = (w \circ s_t)\, C_t (w \circ s_t)' \tag{4}$$

gdje su $w = (w_1, w_2, w_3, w_4, w_5)$ vektor fiksnih težina pojedinog podindeksa, $s_t = (s_{1,t}, s_{2,t}, s_{3,t}, s_{4,t}, s_{5,t})$ vektor vrijednosti podindeksa u trenutku t, $w \circ s_t$ Hadamardov produkt[8], a C_t simetrična 5×5 matrica vremenski promjenjivih koeficijenata korelacije $\rho_{ij,t}$ između svakog podindeksa i i j, $(i, j = 1, 2, 3, 4, 5)$ definirana kao

[8] Čini umnožak pojedinog elementa vektora težina podindeksa i odgovarajućih vrijednosti podindeksa u svakom trenutku t.

$$C_t = \begin{pmatrix} 1 & \rho_{12,t} & \rho_{13,t} & \rho_{14,t} & \rho_{15,t} \\ \rho_{12,t} & 1 & \rho_{23,t} & \rho_{24,t} & \rho_{25,t} \\ \rho_{13,t} & \rho_{23,t} & 1 & \rho_{34,t} & \rho_{35,t} \\ \rho_{14,t} & \rho_{24,t} & \rho_{34,t} & 1 & \rho_{45,t} \\ \rho_{15,t} & \rho_{25,t} & \rho_{35,t} & \rho_{45,t} & 1 \end{pmatrix}.$$

Relativna kompleksnost u procjeni dinamičke korelacijske matrice C_t zahtijeva pristup koji uključuje dva koraka, a u svakom od njih vrijednosti su uvjetne varijance odnosno uvjetne korelacije izražene putem rekurzivnog sustava jednadžbi. Konkretnije, nakon što je u prvom koraku putem nelinearnoga asimetričnog GARCH (1,1) modela (Engle i Ng, 1993.) za pojedini podindeks $i = 1,..,5$ procijenjena uvjetna varijanca promjenjiva u vremenu, izračunu dinamičkih vrijednosti korelacijske matrice pristupilo se primjenom standardnog DCC modela (Engle, 2002.). U tu su svrhu pretpostavljene dinamike vremenskih nizova $s_{i,t}$ definirane sljedećom jednakošću

$$s_{i,t} = \mu_i + \upsilon_{i,t},\ i = 1,...,5,\ t = 1,...,T \tag{5}$$

gdje su $\upsilon_{i,t}$ nezavisne, jednako distribuirane, slučajne varijable s razdiobom $N(0, \sigma_{i,t}^2)$, a uvjetna varijanca $\sigma_{i,t}$ opisana NAGARCH(1,1) modelom na način da je

$$\sigma_{i,t}^2 = \omega_i + \alpha_i(\tilde{s}_{i,t-1} - \gamma_i \sigma_{i,t-1})^2 + \beta_i \sigma_{i,t-1}^2 \tag{6}$$

Pri tome $\tilde{s}_{i,t} = (s_{i,t} - \mu_i)$ označuje odstupanje pojedinog podindeksa od njegove uzoračke srednje vrijednosti, a uvjeti $\omega_i > 0$, $\alpha_i, \beta_i \geq 0$, $\alpha_i(1 + \gamma_i^2) + \beta_i < 1$ osiguravaju nenegativnost i stacionarnost procesa varijance. Svi parametri modela procijenjeni su metodom maksimalne vjerodostojnosti (engl. *Maximum Likelihood Estimation*). Nadalje, u drugom su koraku na temelju standardiziranih reziduala $\varepsilon_{i,t} = \upsilon_{i,t}/\sigma_{i,t}$ dobivenih iz jednakosti (5) i (6) te primjenom MLE metode procijenjeni parametri modela koji za svaki dan t opisuje dinamiku uvjetnih korelacija rekurzivno na sljedeći način

$$Q_t = (1 - \mathrm{a} - \mathrm{b})\bar{C} + \mathrm{a}\varepsilon_{t-1}\varepsilon_{t-1}' + \mathrm{b}Q_{t-1} \tag{7}$$

$$C_t = Q_t^{*-1} Q_t Q_t^{*-1},$$

gdje su a i b skalari koji zadovoljavaju uvjet $\mathrm{a} + \mathrm{b} < 1$, te $\bar{C}$ i Q_t^* matrice dimenzija 5×5 definirane tako da je $\bar{C} = E[\varepsilon_t \varepsilon_t']$ i $Q_t^* = [q_{ii,t}^*] = [\sqrt{q_{ii,t}}]$, odnosno za dijagonalnu matricu Q_t^* se na i-tom dijagonalnom mjestu nalazi korijen i-te dijagonalne vrijednosti matrice Q_t.

Osim toga, iz komparativnih je razloga u ovom radu alternativno primijenjen u literaturi prilično zastupljen i ponešto jednostavniji pristup izračuna korelacijskih vrijednosti na temelju eksponencijalno vaganih pomičnih prosjeka (engl. *Exponentially weighted moving averages – EWMA*) odnosno opisan rekurzivnim sustavom jednadžbi

$$\begin{aligned} \sigma_{ij,t} &= \lambda\sigma_{ij,t-1} + (1-\lambda)\tilde{s}_{i,t}\tilde{s}_{j,t} \\ \sigma^2_{i,t} &= \lambda\sigma^2_{i,t-1} + (1-\lambda)\tilde{s}^2_{i,t} \\ \rho_{ij,t} &= \frac{\sigma_{ij,t}}{\sigma_{i,t}\sigma_{j,t}} \end{aligned} \tag{8}$$

gdje je $\tilde{s}_{i,t} = (s_{i,t} - 0,5)$ za svaki (i = 1, 2, 3, 4, 5) odstupanje podindeksa od njegove teorijske srednje vrijednosti, a parametar izglađivanja λ konstantan i prema JP Morgan-ovoj metrici rizika jednak 0,93. Inicijalne vrijednosti varijanci i kovarijanci u trenutku t=0 definirane su na uzorku od 1. siječnja 2001. do 31. prosinca 2006., tj. u razdoblju relativno niske razine stresnih poremećaja.

Rezultati obaju pristupa pri izračunu uvjetne varijance (jednakosti (6) i (8)) na promatranom se uzorku razlikuju, a zbog dvije važne prednosti NAGARCH modela, posebice kada je riječ o predviđenim vrijednostima varijance u dugom roku, korištenje toga modelskog pristupa ocjenjuje se prikladnijim. Naime, predviđanje vrijednosti varijance putem EWMA modela rezultira persistentnošću u širenju šokova na pojedinim financijskim tržištima, što u okviru teme ovoga rada može biti od iznimne važnosti i dovesti do nerealnih procjena varijance u budućim trenucima, a osobito tijekom duljeg razdoblja. Drugim riječima, svojevrsna tromost koja obilježava kidanje dostignutih veza među financijskim tržištima može rezultirati time da kvantificirane razine sistemskog stresa u nekom budućem trenutku budu precijenjene odnosno podcijenjene u odnosu na stvarnu razinu poremećaja na tržištima, ovisno o tome bilježe li se sistemski šokovi na iznadprosječnim ili ispodprosječnim razinama. Osim spomenute manjkavosti, EWMA model ne uzima u obzir i dva ne manje važna, često prisutna obilježja podataka s financijskih tržišta, a koja su se i u ovom radu pokazala statistički značajnima. Riječ je o prisutnosti efekta poluge (engl. *leverage effect*) koji upućuje na to da nepovoljni događaji povećavaju buduću varijancu u većoj mjeri u odnosu na istovjetne pozitivne događaje na pojedinom tržištu te o prisutnosti asimetričnosti informacija. Sve navedene manjkavosti uvažene su korištenjem nelinearnoga asimetričnog GARCH(1,1) modela, a međusobna povezanost pojedinih financijskih tržišta izračunata na taj način prikazana je na sljedećoj slici.

Već na temelju Slike 2., a prije konstrukcije kompozitnog pokazatelja stresa, može se zorno uočiti kako su u tri povijesno poznate epizode ozbiljnijih stresnih poremećaja podindeksi snažno pozitivno korelirani, od čega su u dva od tih triju razdoblja sva promatrana tržišta korelirana na razini višoj od 0,94. To se odnosi na razdoblja od drugog tromjesečja 1999. do sredine 2000. godine te od posljednjeg tromjesečja 2008. i tijekom 2009. godine. Krajem 2011. i početkom 2012. godine povezanost tržišnih

Slika 2. "Heatmap" korelacija između pojedinih podindeksa



Napomena: KOR(i,j) označuje korelaciju između tržišta *i* i *j*, pri čemu su tržišta označena s: 1 – devizno, 2 – novčano, 3 – obvezničko, 4 – dioničko i 5 – bankovno. Korelacije su prikazane na mjesečnoj razini.

Izvor: autor

kretanja bila je malo niža i prosječno je iznosila 0,76. Upravo ta razdoblja odgovaraju razdobljima triju važnih kriza koje su se manifestirale u Hrvatskoj, a redom je riječ o bankovnoj krizi, svjetskoj financijskoj krizi i krizi na tržištima javnog duga perifernih zemalja Europske unije. Na taj je način i slikovito vidljivo kako su u razdobljima važnijih stresnih epizoda na pojedinim tržištima većina ili čak sva tržišta snažno pozitivno korelirana odnosno šokovi na jednom tržištu prelijevaju se i propagiraju na ostala tržišta, što i na ovakav rudimentaran način opravdava pretpostavku o primjeni teorije portfelja pri izračunu kompozitnog pokazatelja sistemskog stresa i uzimanje u obzir međusobne povezanosti financijskih tržišta. Naposljetku, promotrimo li još jednom jednakost (4,) preostaje odrediti težinu kojom je pojedini podindeks uključen u izračun kompozitnog pokazatelja.

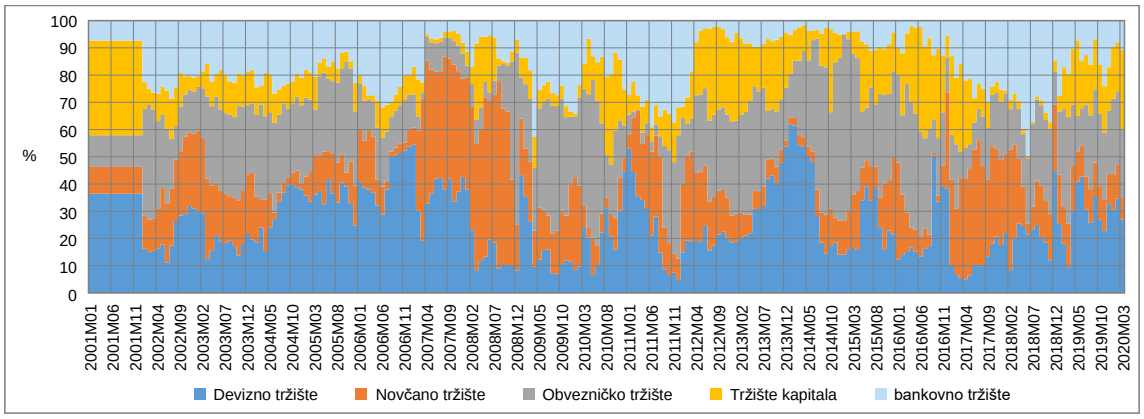
4.4. Određivanje težinskih faktora

Vrijednosti težinskih faktora kojima je pojedini podindeks uključen u konstrukciju kompozitnog pokazatelja stresa, kao što je već ranije spomenuto, trebale bi u što je moguće većoj mjeri odražavati valjan doprinos događaja na svakom od razmatranih tržišta za realno gospodarstvo. Međutim, kako navodi relevantna literatura, u praksi to zapravo znači da je potrebno odabrati reprezentativan pokazatelj kretanja gospodarske aktivnosti, na kojemu će se procijeniti matematički doprinos svakog od podindeksa kretanju odabranog pokazatelja, uzimajući u obzir i ekonomsku relevantnost tako određenih vrijednosti težinskih faktora. U skladu s time, ocjeni i definiranju adekvatnih težina za pojedino financijsko tržište pristupilo se na jedan od sljedeća tri načina. Prva dva načina uključuju ocjenu težinskih faktora putem VAR modela (engl. *Vector Autoregressive model*) na način da obje modelske procjene podrazumijevaju prosječnu dekompoziciju varijance na dvanaestomjesečnom horizontu. Pritom je prvi model

ocijenjen na skupnoj osnovi i dobivene se težine dinamički mijenjaju na mjesečnoj razini, dok se drugom modelskom ocjenom regresiraju svaki od podindeksa zasebno i dobivene težine uprosječene su te jednake na cijelom uzorku. Posljednjim su pristupom težinski faktori arbitrarno određeni tako da je doprinos svakog od pet tržišta jednak 0,2.

Zavisna varijabla u primijenjenim modelima jest obujam industrijske proizvodnje, koja može služiti kao dobar pokazatelj za ukupnu gospodarsku aktivnost u nekoj zemlji. Naime, neka ranija istraživanja potvrđuju kako kratkoročna varijabilnost tog pokazatelja ciklički prati i iznimno dobro predočuje kretanje realnoga hrvatskog BDP-a (Cerovac, 2005.). Osim toga, riječ je o mjesečnom pokazatelju, što je iznimno važno ako se uzme u obzir da su konstruirani podindeksi na dnevnoj razini, pa viša frekvencija ovisne varijable pridonosi boljoj procjeni utjecaja kratkoročnih šokova s financijskih tržišta. Desezonirani podaci indeksa industrijske proizvodnje počinju od siječnja 1999. do ožujka 2020. godine, te su transformirani pomoću empirijske kumulativne funkcije distribucije. Broj pomaka vektorskih modela odabran je na osnovi Akaikeovih informacijskih kriterija koji preporučuju korištenje dvaju pomaka, a na temelju provedenih testova o prisutnosti jediničnoga korijena sve su varijable izražene u prvim diferencijama.

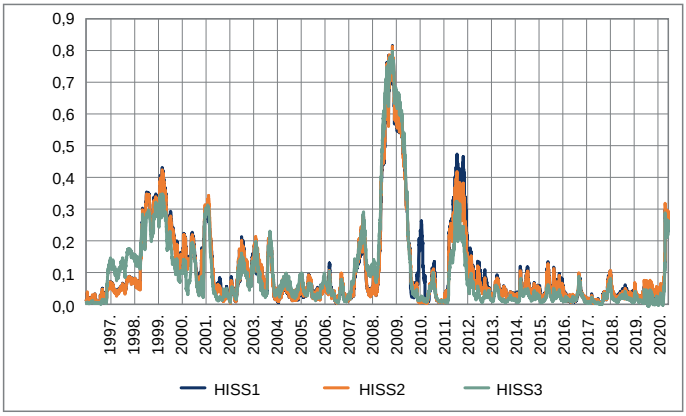
Slika 3. Težinski udjeli za pojedino tržište promjenjivi u vremenu, na mjesečnoj razini



Izvor: izračun autora

Dobiveni rezultati za težine promjenjive u vremenu (Slika 3.) upućuju na malo veći prosječni udio deviznoga i obvezničkog tržišta u odnosu na ostala tržišta. Međutim, u pojedinim razdobljima to nije slučaj, kao na primjer malo veći udio novčanog tržišta u razdoblju neposredno prije svjetske financijske krize kao odraz pritisaka na likvidnost banaka kada su međubankovne kamatne stope dosegnule razine od 8 do 9% ili tržišta kapitala sredinom 2017. godine kao posljedica događaja vezanih uz koncern Agrokor. Kada je riječ o težinskim faktorima nepromjenjivima u vremenu, oni su u razdoblju od veljače 1996. do ožujka 2020. godine za devizno tržište, novčano tržište, obvezničko tržište, dioničko tržište i financijske posrednike redom iznosili 34%, 9%, 25%, 11% i 21%.

Slika 4. Kompozitni pokazatelji sistemskog stresa u ovisnosti o težinama pojedinog tržišta



Napomena: HISS1 dobiven je uz promjenjive težine na mjesečnoj razini prikazane na Slici 3., HISS2 uz težine koje su za pojedino tržište jednake tijekom cijelog razdoblja, dok je HISS3 dobiven uz težine od 0,2 za pojedino tržište.

Izvor: izračun autora

Odabir težina za pojedino financijsko tržište neznatno utječe na kretanje kompozitnih pokazatelja sistemskog stresa te, neovisno o načinu izračuna težina, sva tri pokazatelja identificiraju tri važnije stresne epizode (Slika 4.). Prosječna odstupanja na cijelome su uzorku 2,9% (HISS1-2), 3,2% (HISS1-3) i 1,8% (HISS2-3), a slične rezultate dobili su Hollo i Lo Duca (2012.), kao i drugi autori relevantne literature. Stoga, imajući na umu promjenjivost veza između financijskih tržišta i realnoga gospodarstva te činjenicu da neovisno o načinu odabira težinskih faktora gore konstruirani pokazatelji podjednako dobro identificiraju razdoblja važnijih, kao i onih manje važnih stresnih epizoda, u ovom su radu uzete u obzir težine promjenjive u vremenu. Dodatno, time se isključuje i arbitrarnost u odlučivanju kada pristupiti njihovu revidiranju.

5. Hrvatski indeks sistemskog stresa (HISS)

Prije no što se pokaže ključan rezultat istraživanja, potrebno je istaknuti dvije stvari. Prvo, na osnovi metodološkog pristupa opisanog u prethodnom poglavlju kompozitni pokazatelj stresa poprima vrijednosti na intervalu od 0 (isključeno) do 1 (uključeno), a viša vrijednost upućuje na porast razine sistemskog stresa na jednom ili više financijskih tržišta. Pri tome se maksimalna vrijednost indeksa ostvaruje u situaciji kada su istodobno ispunjeni sljedeći uvjeti: financijski stres u isto se vrijeme materijalizira na svim promatranim tržištima, kretanja na tržištima u tom su trenutku savršeno pozitivno korelirana (korelacija jednaka 1) te su vrijednosti svakog od pokazatelja koji su sadržani u podindeksima najviše u odnosu na sve dotad zabilježene. Međutim, valja naglasiti kako postoje situacije koje mogu odražavati visok intenzitet sistemskog stresa, a da

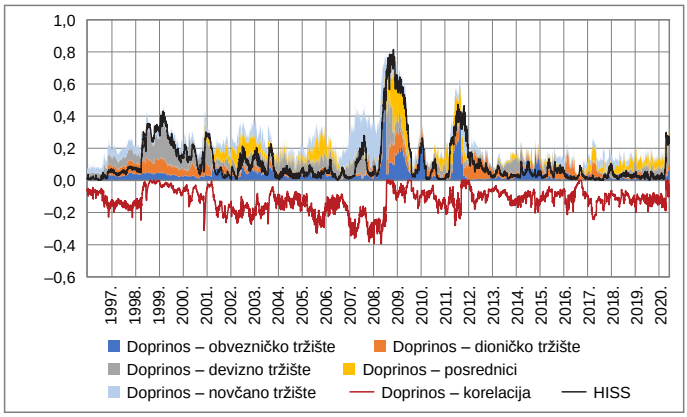
indeks trenutno ne zabilježi ovako ekstremne razine. To se događa u situacijama kada se prelijevanje stresa među tržištima odvija s određenim odmakom.

U sljedećem koraku, doprinosi pojedinih tržišta kretanju kompozitnog pokazatelja sistemskog stresa izračunati su na osnovi formule (4) iz prethodnog poglavlja, a uz pretpostavku savršene koreliranosti podindeksa odnosno tako da su svi koeficijenti korelacije jednaki jedan. Razlika tako konstruiranog pokazatelja ($HISS^{\text{savršena korelacija}}$) i HISS-a odražava doprinos korelacija u pojedinom trenutku t:

$$\text{Doprinos korelacije}_t = HISS_t - HISS_t^{\text{savršena korelacija}} \quad (9)$$

No, budući da su vrijednosti pokazatelja uz savršenu koreliranost uvijek više od vrijednosti HISS-a, doprinosi međupovezanosti tržišta uvijek su manji od nule. Viša vrijednost doprinosa korelacija (odnosno manje negativna) zapravo znači da su tržišta snažno pozitivno korelirana, dok vrijednost jednaka nuli odražava savršenu koreliranost pojedinih tržišta (jednaku jedan). Doprinosi i ukupni pokazatelj sistemskog stresa na financijskim tržištima prikazani su na sljedećoj slici.

Slika 5. Hrvatski indeks sistemskog stresa te doprinosi pojedinih tržišta i korelacija



Napomena: Od svibnja 2019. glavnina varijacija s novčanog tržišta proizlazi iz promjena ZIBOR-a, s obzirom na to da se kamatne stope monetarne politike nisu mijenjale, a kamatne stope na tromjesečne trezorske zapise MF-a u tom su razdoblju zadržane na istovjetnim razinama zbog izostanka trgovanja. Pritom su za vrijednosti pokazatelja s novčanog tržišta u prvih pet mjeseci 2020. zadržane posljednje vrijednosti ukinutog ZIBOR-a s kraja prethodne godine, s obzirom na to da u tom razdoblju nisu zabilježena nekolateralizirana prekonoćna trgovanja i trgovanja s rokovima dospijeća od 3 mjeseca na međubankovnom tržištu, kao i trgovanja trezorskim zapisima s tromjesečnom ročnošću. Stoga su korištene informacije s novčanog tržišta u navedenom razdoblju ograničene, što valja imati na umu i pri tumačenju ukupnih rezultata, te posebice rezultata za posljednje razdoblje.

Izvor: izračun autora

Prema rezultatima možemo vidjeti tri razdoblja ozbiljnijih stresnih poremećaja te nekoliko poremećaja blažeg intenziteta i kraćeg trajanja (Slika 5.). Gledano kronološki, prvo razdoblje naglašenih stresnih poremećaja uz vrijednost pokazatelja od 0,38

zabilježeno je početkom 1999. godine i trajalo je do sredine sljedeće godine. Iako slika upućuje na to da je glavnina zabilježenih poremećaja proizlazila s deviznog tržišta i tržišta kapitala, razumno je pretpostaviti da bi i doprinos financijskih posrednika, kao potkomponente konstruiranog pokazatelja, u tom razdoblju znatno utjecao na kretanje indeksa (porast njegove vrijednosti). No, duljina te vremenske serije pri konstrukciji indeksa ne obuhvaća spomenuto razdoblje. Naime, razmatrano se razdoblje podudara s drugom bankovnom krizom u Hrvatskoj, koja je započela tijekom 1998. godine i pogodila uglavnom nove banke u naglom usponu. Neprimjerena kreditna politika tih banaka tijekom ranih devedesetih godina, pojačana različitim eksternim šokovima, dovela je do potrebe za njihovom sanacijom ili izlaskom s tržišta (Jankov, 2000.). Posljedica takvih događaja bio je znatan porast nelikvidnosti na međubankovnom tržištu, što se odrazilo i na rastuću nelikvidnost drugih poslovnih subjekata u gospodarstvu. Konsolidacija bankovnog sektora, popraćena znatnim pogoršanjem fiskalne pozicije zemlje, rezultirala je povećanom neizvjesnošću u gospodarskom sustavu i pritiscima na slabljenje domaće valute. Navedeno se ogledalo u pojačanoj kolebljivosti na deviznom tržištu, kao i naglašenoj deprecijaciji tečaja kune prema euru (više od 7%). U takvim su uvjetima znatno porasli i prinosi na državne obveznice Hrvatske u odnosu na prinose drugih zemalja u razvoju i dosegnuli gotovo povijesne razine od približno 9%, a njihova kolebljivost također je bila izražena. Slično tome, opisani događaji povećali su i neizvjesnost glede buduće vrijednosti dionica. Time je porasla kolebljivost na dioničkom tržištu, a investitori su akumulirali gubitke u odnosu na prethodno dvogodišnje razdoblje. Ipak, kontinuirano poduzimanje mjera od strane HNB-a s ciljem očuvanja stabilnosti i osnaživanja bankovnog sustava te postupni oporavak gospodarstva tijekom 2000. godine djelovali su stabilizirajuće na spomenute događaje na domaćim financijskim tržištima.

Druga epizoda visoke razine sistemskog stresa odgovara razdoblju od rujna 2008. i tijekom 2009. godine, kada je vrijednost kompozitnog pokazatelja dosegnula svoj povijesni maksimum (0,79). To se razdoblje odnosi na svjetsku financijsku krizu, koja je pogodila financijska tržišta velike većine zemalja, pa tako i Hrvatske. U odnosu na kriznu epizodu krajem devedesetih godina, kada se stresni impuls uglavnom veže uz događaje u domaćoj ekonomiji, ovo stresno razdoblje u najvećoj mjeri karakterizira prelijevanje nepovoljnih događaja iz inozemstva, obilježenih propašću američke investicijske banke Lehman Brothers. Tom su prilikom sva domaća tržišta istodobno iskazala visoku prisutnost stresa. Prije svega, proizašli pritisci i nesklonost ulagača rizičnim ulaganjima snažno su utjecali na domaće tržište kapitala. Znatan pad cijena vlasničkih i dužničkih vrijednosnih papira popraćen njihovom visokom kolebljivošću rezultirao je visokim gubitcima investitora, a zabrinutost glede održivosti oporavka svjetskih ekonomija i loši makroekonomski pokazatelji hrvatskoga gospodarstva nepovoljno su djelovali na premiju za rizik zemlje te prinose na državne obveznice. Posljedični porast cijena domaćega i inozemnoga kapitala za sve domaće sektore, unatoč padu referentnih kamatnih stopa u europodručju, učinio ga je teže dostupnim. U takvim su se uvjetima smanjen priljev kapitala te negativna očekivanja kućanstava i poduzeća glede budućih gospodarskih kretanja odrazili i na kolebljivost te pojačane

deprecijacijske pritiske na domaću valutu. Slično tome, pogoršavanje gospodarske i financijske situacije u zemlji i okružju nepovoljno se odrazilo i na bilance domaćih banaka, ponajviše u smislu kvarenja kreditnog portfelja privatnog sektora, kao i usporavanja ukupne kreditne aktivnosti (poglavito stanovništva) te stagnirajućeg priljeva domaćih depozita. Sve navedeno potaknulo je banke na promjenu svojih politika i veću orijentiranost ka kreditiranju portfelja države, pritom imajući na umu naglašenu potrebu zemlje za financiranjem u tom razdoblju i njezinu relativno manju rizičnost. U takvom okružju znatnije zaduživanje dijela domaćih banaka od strane banaka majki djelovalo je u smjeru blagog smanjivanja fragilnosti bankovnog sustava, a potreba pojedinih banaka (većinom malih) za kratkoročnom likvidnošću stvorila je pritisak na kamatne stope na novčanom tržištu te se odrazila na sve veću zastupljenost kolateraliziranog oblika međubankovnog financiranja. Međutim, aktivnim mjerama monetarne politike takvi su pritisci vrlo brzo obuzdani, a visoka kapitaliziranost i dobri tržišni rezultati banaka pridonijeli su očuvanju financijske stabilnosti ovog sektora.

Posljednje razdoblje zamjetljivijih poremećaja u hrvatskom financijskom sustavu zabilježeno je od sredine 2011. do početka 2012. godine. Tada su kriza održivosti državnog duga rubnih zemalja europodručja i krhkost bankarskih sektora velikog broja zemalja europodručja, osobito Španjolske, Portugala i Grčke, djelovali na gospodarstva većine europskih zemalja, pa tako i hrvatsko. Pod utjecajem pooštrenih uvjeta financiranja na inozemnom i domaćem tržištu te pada izvozne potražnje Hrvatska je ponovno ušla u recesiju, a sistemski stres zabilježen na domaćim financijskim tržištima rezultirao je time da kompozitni pokazatelj dosegne vrijednost od čak 0,51. Nepovoljni događaji u najvećoj su se mjeri ogledali u pokazateljima na domaćem obvezničkom tržištu, gdje su zbog nesklonosti ulagača riziku i povećane premije za rizik zemlje porasli zahtijevani prinosi na državne vrijednosne papire. Njihova kolebljivost i razlika u odnosu na prinose obveznica zemalja u razvoju također su znatno porasli. Paralelno s time, smanjen priljev kapitala izložio je domaće banke većim rizicima eksterne likvidnosti, a kako bi zadržale stabilne stope rasta ukupnoga kreditiranja zbog potisnutoga kreditiranja sektora poduzeća i stanovništva banke su se preusmjerile na snažnije financiranje države. Iako se sve to kratkoročno odrazilo na indeks fragilnosti bankovnog sektora, njegova dostatna kapitaliziranost u cjelini činila ga je otpornim.

Nadalje, valja istaknuti i nekoliko razdoblja u kojima su na temelju kompozitnog pokazatelja zabilježeni poremećaji koji su unatoč malo blažem intezitetu i ograničenom sistemskom djelovanju iskazali izvjesno trajanje. U tom su smislu događaji na deviznom tržištu obilježili 2001. godinu, posebice tijekom prvog tromjesečja i kolovoza te godine, kada su izraženi deprecijacijski pritisci i kolebljivost tečaja kune prema euru bili posebno naglašeni. U prvom su dijelu godine, osim uobičajenih sezonskih utjecaja i otplate deviznih obveza poduzeća, tome pridonijeli povećana potražnja za devizama od strane stanovništva i rast njihove kunske likvidnosti nastavkom isplate osigurane štednje. S druge pak strane, sredinu godine obilježile su izražene valutne špekulacije nefinancijskih poduzeća i banaka zbog znatnog viška kunske likvidnosti i regulatorno potaknute devizne liberalizacije, koja je omogućila poduzećima slobodno držanje

deviznih sredstva na računima domaćih poslovnih banaka. Tom je prilikom osim deviznih intervencija središnja banka donijela niz odluka s ciljem da se dodatno ublaže deprecijacijski pritisci na tečaj domaće valute.

Drugu polovinu 2007. i prvu polovinu 2008. godine obilježili su neki nepovoljni inozemni, ali i domaći događaji. Početak krize na američkom tržištu drugorazrednih hipotekarnih kredita i s time povezana promijenjena percepcija rizika ulagača na svim svjetskim tržištima kapitala, a osobito na tržištima zemalja u razvoju, djelovali su u smjeru znatnog porasta kolebljivosti prinosa na domaće državne obveznice te razlike između prinosa na hrvatske euroobveznice i referentne njemačke obveznice. S druge pak strane, glavninu događaja na domaćem tržištu obilježio je neuobičajeno snažan porast visine i kolebljivosti kamatnih stopa na novčanom tržištu. Pod utjecajem neravnoteže između ponude i potražnje, odnosno činjenice da sudionici s viškom sredstava nisu bili voljni taj višak plasirati po dotad uobičajenim cijenama manjoj skupini banaka koja je stvarala znatan dio potražnje za kunama, kamatne su stope u listopadu 2007. dosegnule razinu od gotovo 8%. Unatoč tome što je bila riječ o kratkoročnim događajima, u uvjetima plitkoga novčanog tržišta sve je to rezultiralo zadržavanjem kamatnih stopa na povišenim razinama i početkom sljedeće godine. Uz sve navedeno, promatrano razdoblje koincidira s postupkom prikupljanja ponuda za kupnju dionica T-HT-a te s njim povezane velike potražnje za kunama i smanjene likvidnosti na deviznom tržištu.

Treća epizoda blago povišene razine stresa u najvećoj je mjeri obilježila razdoblje drugoga i trećeg tromjesečja 2010. godine, kada su pokazatelji s domaćega obvezničkog tržišta bili pod snažnim utjecajem kretanja na svjetskim financijskim tržištima. Naime, u tom je razdoblju zabrinutost glede kulminacije fiskalne krize u Grčkoj i dinamike rasta svjetskoga gospodarstva osnažila percepciju rizika svjetskih ulagača, a neizvjesnosti povezane s ekonomskim oporavkom najvećih europskih gospodarstava i visoki proračunski manjkovi, prisutni još od početka svjetske financijske krize, dodatno su utjecali na porast nesklonosti investitora riziku. U takvim su uvjetima i zahtijevani prinosi na hrvatske euroobveznice znatno porasli, a njihova je kolebljivost i razlika u odnosu na prinose državnih obveznica zemalja u razvoju snažno povećana. Međutim, donošenje odluke o uspostavi Programa za tržišta vrijednosnih papira[9] u svibnju 2010. od strane ESB-a postupno je ublažilo napetosti na financijskim tržištima zemalja europodručja i već se krajem godine pozitivno odrazilo na cijenu obveznica Hrvatske.

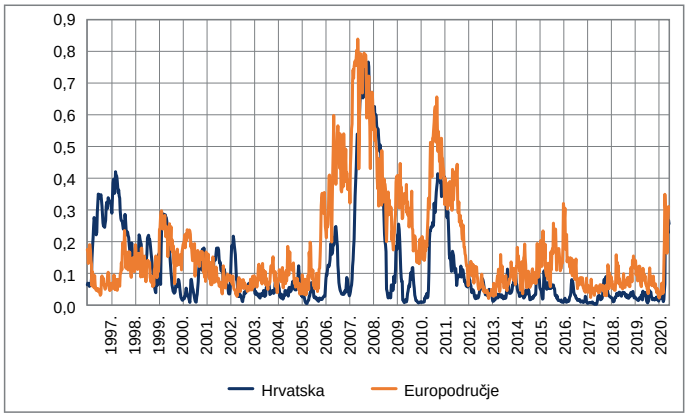
Dodatno istaknimo kako se širenje zdravstvene krize uzrokovane virusom COVID-19 u Hrvatskoj od sredine ožujka 2020. u velikoj mjeri odrazilo na domaća financijska tržišta (posebno devizno i obvezničko), što je jasno vidljivo i u razini pokazatelja stresa. No, u ovome trenutku još uvijek nije moguće ocijeniti duljinu trajanja poremećaja i njegov daljnji sistemski karakter. Zbog toga, kao i znatnih reakcija fiskalnih i monetarnih vlasti,

[9] Dostupno na: https://www.ecb.europa.eu/ecb/legal/pdf/l_12420100520en00080009.pdf

iz trenutne perspektive opisujemo ga kao kratkoročni poremećaj, s mogućnošću razvoja krizne epizode u budućnosti.

Naposljetku valja spomenuti i razdoblja u kojima je razina sistemskog stresa bila niska, i to iz dva razloga. Prije svega, upravo je u razdobljima povoljnih gospodarskih i makroekonomskih uvjeta u zemlji i inozemstvu, kada je materijalizirani sistemski rizik bio nizak, dolazilo do znatne akumulacije rizika. Takva razmatranja važna su iz pozicije makroprudencijalne politike koja mora biti protuciklička. Također, iako se posljednjih nekoliko godina bilježi iznimno niska razina sistemskog stresa, pojedini idiosinkratski poremećaji, kao što su, primjerice, oni povezani s nepovoljnim događajima u koncernu Agrokor tijekom prvog tromjesečja 2017., ipak su se u određenoj mjeri odrazili na domaća financijska tržišta. No, njihovo ograničeno djelovanje koje se većinom ogledalo u pokazateljima na dioničkom tržištu i u manjoj mjeri pokazateljima fragilnosti bankovnog sustava, povoljno se odrazilo na doprinos korelacija (više negativan), čime je ukupno zabilježena razina sistemskog stresa zadržana na niskoj razini. Mogućnost razdvajanja idiosinkratskih i sistemskih šokova govori u prilog konstruiranom indeksu.

Slika 6. Usporedba indeksa sistemskog stresa za Hrvatsku i europodručje



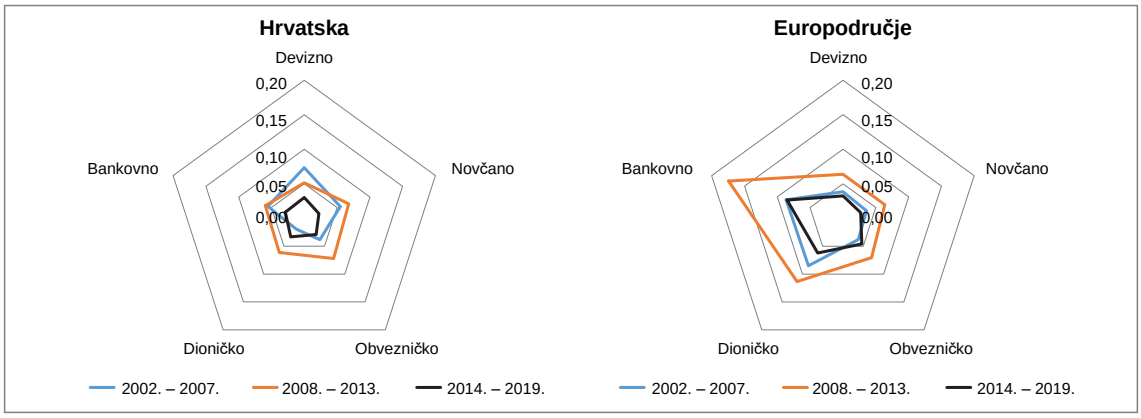
Napomena: Vrijednosti indeksa prikazane su na tjednoj razini i dobivene su kao prosjek dnevnih podataka. Podaci o pokazatelju za europodručje dostupni su na adresi https://sdw.ecb.europa.eu/browse.do?node=9689686

Izvori: ESB; autor

Usporednom analizom kompozitnih pokazatelja za Hrvatsku i europodručje moguće je uočiti relativno visoku usklađenost u njihovu kretanju, na što upućuje i korelacija viša od 0,8 (Slika 6.). Visoka razina integriranosti domaćega gospodarstva na tržišta europodručja i s time povezana visoka usklađenost poslovnih ciklusa i korelacija ekonomskih šokova rezultirajući su čimbenik prelijevanja stresa iz inozemstva u Hrvatsku (Kotarac i ostali, 2017.). To je jasno vidljivo u razdobljima ozbiljnijih stresnih poremećaja, kao što su globalna financijska kriza i kriza javnoga duga u Europi, ali i u razdobljima relativno niže razine indeksa početkom 2000-ih. Prisutnost identificiranog stresa u europodručju u tim je razdobljima očekivano prethodila njegovu prelijevanju i materijalizaciji u Hrvatskoj, ali je sveukupno bila malo jačeg intenziteta i duljeg

trajanja, što bi se djelomično moglo objasniti dubinom i heterogenošću financijskih tržišta zemalja europodručja. Ipak, određena razdoblja karakteriziraju poremećaji ograničenog djelovanja za Hrvatsku, koji se sa stranih tržišta nisu u znatnoj mjeri odrazili na domaće pokazatelje stresa. Primjer su posljednja dužnička kriza u Grčkoj početkom 2015. i izglasavanje o izlasku Velike Britanije iz Europske unije sredinom 2016. godine. U tom su se smislu spomenuti događaji u najvećoj mjeri nepovoljno odrazili na valutna tržišta i tržišta kapitala zemalja europodručja. Slabljenje eura i porast kamata na državne dužničke papire samo su kratkoročno povisili prinose na državne obveznice većine zemalja, a među njima i Hrvatske, što je rezultiralo blagom aprecijacijom tečaja kune prema euru. Marginalna razina izloženosti domaćih subjekata prema državnom dugu Grčke otklonila je mogućnost primarnih učinaka takvih događaja na domaću ekonomiju. Jednako tako, malo viša razina neizvjesnosti na stranim dioničkim tržištima koja zbog pregovora između Velike Britanije i Europske komisije u određenoj mjeri traje sve do danas, neznatno se odrazila na razine dioničkih indeksa domaćih financijskih i nefinancijskih poduzeća. Njihova relativno mala izloženost britanskom tržištu nije rezultirala materijalizacijom sistemskih rizika na domaćem tržištu kapitala. Iz tih razloga domaći indeks bilježi kretanja u tim razdobljima u uskom rasponu svoje kolebljivosti i na niskim razinama.

Slika 7. Prosječni doprinosi pojedinih tržišta na kretanje indeksa za Hrvatsku i europodručje



Izvor: izračun autora

Detaljniji pogled na strukturu doprinosa pojedinih financijskih tržišta kretanju kompozitnih pokazatelja stresa za Hrvatsku i europodručje, unatoč već spomenutoj visokoj usklađenosti njihova kretanja, upućuje na to da se tržišta obuhvaćena nepovoljnim događajima i jačina tih događaja prosječno bitno razlikuju (Slika 7.). Ovisno o razdoblju, u slučaju Hrvatske poremećaji su se većinom odrazili na devizno i obvezničko tržište, dodatno naglašavajući ranjivosti domaće ekonomije koje proizlaze iz strukture i još visoke razine duga države te euroiziranosti gospodarstva. S druge strane, plitkost domaćega međubankovnoga i dioničkog tržišta te dobra kapitaliziranost domaćih banaka utjecali su na ograničeno djelovanje nepovoljnih događaja. Suprotno

tome, u sva tri promatrana petogodišnja razdoblja upravo su financijski posrednici i u malo manjoj mjeri tržišta dionica bili glavni kanali transmisije stresa zemalja europodručja. To je posebice došlo do izražaja u razdoblju od 2008. do 2013. godine zbog snažne kreditne kontrakcije europskih banaka i smanjenog priljeva kapitala, osobito perifernih zemalja europodručja. Nepovoljni tržišni rezultati pojedinih banaka bili su popraćeni njihovom narušenom stabilnošću i dodatno produbljenom krhkošću, što se posebno odnosi na banke u zemljama kao što su Italija, Španjolska ili Grčka. Nadalje, kada je riječ o intezitetu doprinosa reprezentativnih tržišta, općenito su prosječni doprinosi u slučaju Hrvatske ponešto blažeg intenziteta u odnosu na europodručje. To je i očekivano za postrecesijsko razdoblje (nakon 2014. godine), kada je zabilježena razina stresa niža u odnosu na onu zabilježenu u europodručju. Međutim, u razdoblju snažnih poremećaja od 2008. do 2014. godine doprinosi većine financijskih tržišta zemalja europodručja bili su malo snažnijeg intenziteta unatoč približno jednakoj razini stresa koji je zabilježen kompozitnim pokazateljima. Razlog je tome nehomogenost financijskih tržišta zemalja europodručja, čime se prelijevanje stresnih događaja među zemljama članicama odvija s određenim odmakom (Tsopanakis, 2018. i Macdonald, 2014.), a što u pojedinom trenutku rezultira malo nižom koreliranošću tržišta u odnosu na koreliranost domaćih financijskih tržišta u isto vrijeme. Naposljetku, slijedom svega navedenog možemo zaključiti kako informacije dobivene isključivo na osnovi usporedne analize kretanja pokazatelja sistemskog stresa daju samo djelomičan odgovor na razinu sistemskih poremećaja u zemlji, dok je potpun proces analize tih poremećaja (izuzev onih idiosinkratskih) nerazdvojivo povezan s istodobnim praćenjem pojedinih pokazatelja stresa na financijskim tržištima europodručja, što posebice vrijedi za mala, otvorena i euroizirana gospodarstva, kao što je hrvatsko.

6. Analiza robusnosti

Adekvatan pristup analizi robusnosti pokazatelja sistemskog stresa podrazumijevao bi da se uz potpun i egzaktan popis epizoda financijskih poremećaja na domaćim tržištima analizira detektirajuće svojstvo konstruiranog pokazatelja. Međutim, koliko je autoru poznato, tako detaljna baza podataka ne postoji, tj. postoji samo djelomična baza Europskog odbora za sistemske rizike[10] iz 2017. godine, koja upućuje samo na dvije ozbiljnije sistemske krize produljenog trajanja u Hrvatskoj. Iz tog se razloga analizi robusnosti pristupilo na način konstruiranja dvaju alternativnih i metodološki relativno jednostavnijih indeksa financijskog stresa, koji bi trebali upućivati na relativno zadovoljavajuću usklađenost u detektiranju poremećaja. Stoga, nakon što su pokazatelji transformirani na način opisan u 3. poglavlju, agregirani su u prvi indeks financijskog

[10] Excel baza podataka financijskih kriza za sve zemlje Europske unije, pa tako i Hrvatsku, dostupna je na sljedećoj internetskoj adresi: https://www.esrb.europa.eu/pub/financial-crises/html/index.en.html.

stresa (IFS1) jednostavnim uprosječivanjem, odnosno za svaki dan vrijednost indeksa izračunata je kao

$$IFS1_t = \frac{1}{13}\sum_{i=1}^{13} z_{i,t} \tag{10}$$

Kao što se može vidjeti iz prethodne jednakosti, takvim načinom agregiranja svim su pokazateljima dodijeljene jednake težine, čime se relativizira njihova važnost u detektiranju financijskog stresa. Međutim, takav pristup opravdan je iz više razloga. Naime, u uvjetima kada ne postoji popis povijesnih stresnih događaja kojima bi se mogla provjeriti robusnost rezultata, izmijenjene težine inducirale bi nepotrebnu pristranost, čime bi se izravno došlo u koliziju s činjenicom da pokazatelji obuhvaćaju što veći broj tržišta i odražavaju relativno velik broj i opseg financijskih transakcija. Dodatno, na taj se način izbjeglo donošenje arbitrarnih odluka u smislu kada i koliko često revidirati dodijeljene težine.

Drugi pristup odgovara izračunu kompozitnog indeksa detekcijom ekstremnih promjena u vremenskim serijama. Glavna motivacija za ovaj pristup leži u činjenici da se financijski stres (kvantitativno), osim u razini pokazatelja, može promatrati i iz druge perspektive kroz apsolutne promjene tih razina. Može se reći da zapravo mjerimo snagu stresa. Na taj način dodatno upotpunjujemo sliku o njegovoj prisutnosti u sustavu. Metodološki pristup u nastavku zbog jednostavnosti navodimo u tri koraka. Za početak inicijalni pokazatelji transformirani su na temelju apsolutnog odstupanja apsolutnih promjena od njihova prosjeka. Odnosno, imajući na umu već spomenutu notaciju iz 3. poglavlja, transformirane vrijednosti z_t^i za svaki dan definirane su na način da je

$$z_t^i = \left| \frac{1}{T}\sum_{k=2}^{T} |\Delta x_k^i| - |\Delta x_t^i| \right|, \; t = 2,...,T, \tag{11}$$

gdje je $\Delta x_t^i = x_t^i - x_{t-1}^i$ apsolutna promjena vrijednosti pokazatelja u odnosu na vrijednost iz prethodnog dana. U sljedećem koraku, oslanjajući se na teoriju ekstremnih vrijednosti (engl. *Extreme Value Theory*), detektirani su stresni trenuci na koje upućuje pojedini pokazatelj. Naime, primjenom grafičke metode, tzv. Hill plot (vidi Prilog 1.), za pojedini pokazatelj određen je prag tolerancije koji je jednak 96. percentilu povijesne distribucije transformiranih vrijednosti tog pokazatelja. Ako je transformirana vrijednost pokazatelja u nekom danu iznad tog praga, smatra se da je taj pokazatelj u tom danu uputio na stres. Prethodno navedeno može se opisati na način da je

$$S_{i,t} = \begin{cases} 1, \text{ ako je } z_t^i \geq 96-\text{og percentila distribucije}, \\ 0, \text{ inače.} \end{cases} \tag{12}$$

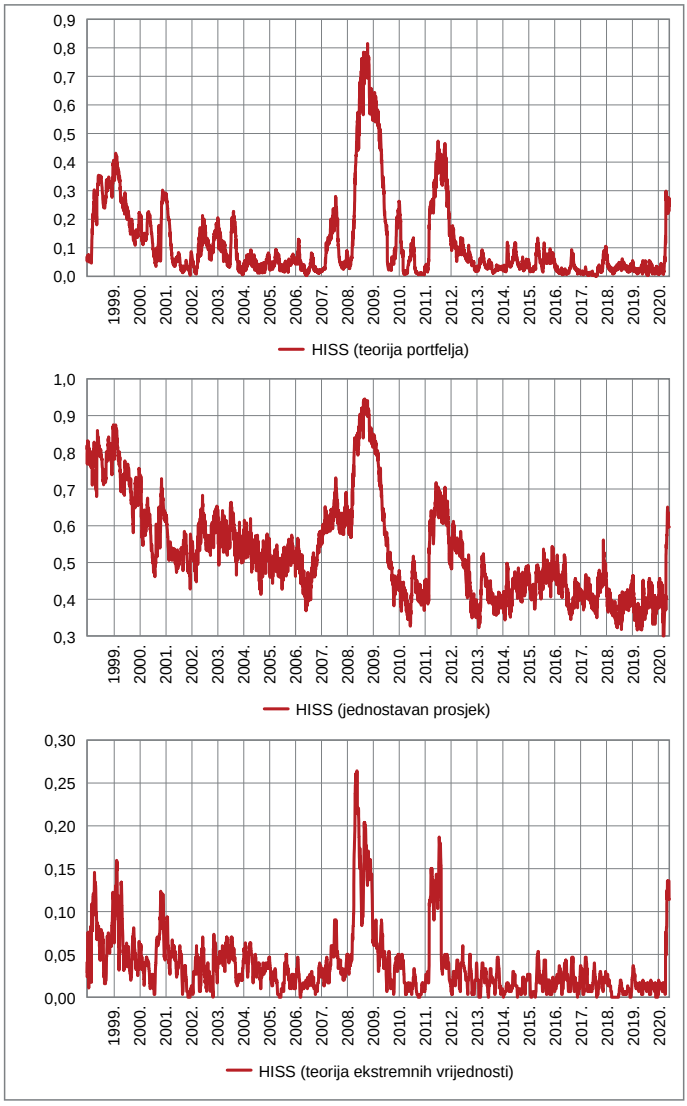
gdje je $S_{i,t}$ binarna vrijednost pokazatelja i u trenutku t. U tom kontekstu, prosječan broj pokazatelja koji upućuje na stres S_t u svakom trenutku jednak je

$$S_t = \frac{1}{13}\sum_{i=1}^{13} S_{i,t} \tag{13}$$

Naposljetku, kompozitni indeks financijskog stresa (IFS2) konstruiran je kao jednomjesečni (23 radna dana) centrirani pomični prosjek vrijednosti S_t. Odnosno,

$$IFS2 = \frac{1}{13}\sum_{k=t-11}^{t+11} S_k, \;\; t = 12, ..., T-11. \tag{14}$$

Slika 8. Usporedba glavnog i alternativnih indeksa stresa za Hrvatsku



Izvor: izračun autora

Analizirajući dobivene rezultate, može se uočiti da unatoč odabranoj metodologiji i različitim pokazateljima indeksi podudarno identificiraju tri dulje epizode povišenog stresa na domaćem financijskom tržištu koje odražavaju ozbiljnije poremećaje: 1999. – 2000.; 2008. – 2009.; 2011. – 2012. U tom kontekstu može se tvrditi da je korelacija između alternativno identificiranih stresnih epizoda signifikantna. Izvjestan broj iznimno kratkih poremećaja nije potpuno sinkroniziran, odnosno istodobno detektiran u svakom pristupu, što se u određenoj mjeri može objasniti inherentnom kolebljivošću serija koja proizlazi iz drugačijih metodoloških pristupa njihove konstrukcije. No, i sami koeficijenti korelacije (ρ) na uzorku cijelih serija, tj. svih kratkoročnih oscilacija bez obzira na globalne stresne epizode, pokazuju zadovoljavajući stupanj korelacije ($\rho_{HISS1,\,HISS2} = 0,76$; $\rho_{HISS1,\,HISS3} = 0,79$; $\rho_{HISS2,\,HISS3} = 0,76$), posebno kad se imaju na umu različite transformacije pojedinačnih komponenti agregatnih pokazatelja kao i razlike u metodama njihova agregiranja. Ti rezultati potvrđuju robusnost ovih indeksa, a njihova pouzdanost rezultat je još jednog elementa primijenjenoga metodološkog okvira koji se empirijski dokazuje upravo visokim stupnjem njihove usklađenosti: bez obzira na razlike u pojedinačnim komponentama, načinu njihove transformacije ili njihovu broju, ako su zadovoljeni kriteriji reprezentativnosti uzorka (vidjeti potpoglavlje 2.1.), rezultat će biti uglavnom jednak i relativno pouzdan.

7. Sistemski šokovi i gospodarska aktivnost – primjena na RH

Uvodno je istaknuto kako praćenje razine sistemskog stresa u financijskom sustavu može poslužiti nositeljima ekonomskih politika za pravodobnu, tj. što je ranije moguću detekciju poremećaja u sustavu. No, osnovna pitanja koja se pritom postavljaju jesu nakon koje se razine stresa može očekivati da će se ti poremećaji odraziti na realna ekonomska kretanja i s kojim vremenskim odmakom će se takvi događaji materijalizirati. Po uzoru na Afonso A., Baxa J. i Slavik M. (2018.) odgovor na postavljena pitanja dobit ćemo primjenom specifičnog oblika VAR modela. Njime se kvantificira prag prelaska iz normalnog u stresni režim, a korištenjem funkcija impulsnog odaziva dobivenih tim modelom ocjenjuje se utjecaj sistemskih šokova na industrijsku proizvodnju[11].

Slijedom svega navedenog za razlikovanje režima u kojemu se indeks nalazi primjenjuje se bivarijantni vektorski autoregresijski model (engl. *Threshold Vector Autoregression Model – TVAR*) koji je specificiran na sljedeći način:

$$x_t = \begin{cases} \alpha^L + \beta_1^L x_{t-1} + \beta_2^L x_{t-2} + e_t^L, & HISS_{t-d} < \tau, \\ \alpha^H + \beta_1^H x_{t-1} + \beta_2^H x_{t-2} + e_t^H, & HISS_{t-d} > \tau \end{cases} \tag{15}$$

[11] Istovjetno argumentaciji u Poglavlju 3. i određivanju težinskih faktora pri konstrukciji indeksa, korištenje obujma industrijske proizvodnje dobro aproksimira kretanje gospodarske aktivnosti, pri čemu su podaci dostupni na mjesečnoj razini.

pri čemu je $x_t = (IP_t, HISS_t)$ vektor godišnje promjene obujma industrijske proizvodnje i indeksa sistemskog stresa u mjesecu t, d broj mjeseci pomaka indeksa i τ njegova nedefinirana vrijednost koja razdvaja normalan (L) od stresnog (H) režima.

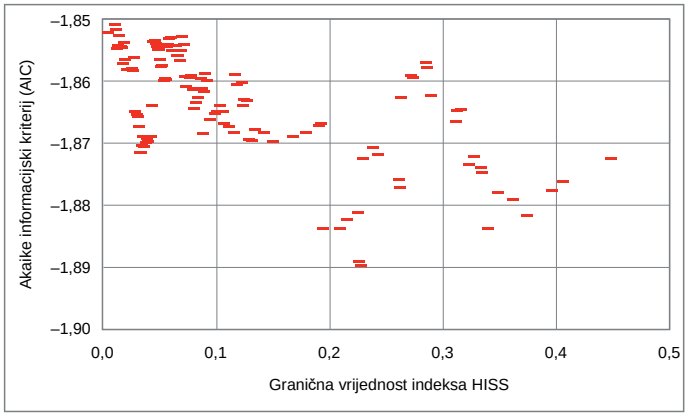
Procjena sustava jednadžbi podrazumijeva dva koraka, uobičajena za ovakvu skupinu modela. U prvom koraku primjenom nekoliko statističkih testova ispituje se prisutnost efekta praga (engl. *threshold effect*) odnosno prikladnost TVAR naspram jednostavnog VAR modela, te se procjenjuje optimalan prag kašnjenja (engl. *threshold delay*) granične varijable HISS. Provedenim Tsay testom (1986.) odbacuje se nulta hipoteza o nepostojanju nelinearnosti, što upućuje na to da se TVAR u odnosu na VAR model ocjenjuje prikladnijim. Štoviše, naspram TVAR (2) modela s dva granična praga i tri režima najprikladnijim je ocijenjen prethodno definiran TVAR (1) model s jednim pragom, tj. dva režima – normalnim i stresnim. Nadalje, rezultati testa upućuju na to da se iz skupa $d = \{1,2,3,4\}$ adekvatnim ocjenjuje dvomjesečno kašnjenje granične varijable.

Naposljetku se u drugom koraku, na osnovi procjene sustava jednadžbi (15) metodom najmanjih kvadrata, za svaku graničnu vrijednost $\tau \in [0,1]$ izračunava Akaike informacijski kriterij kao:

$$AIC = \log\left(\sum_{t=1}^{N} \frac{r_t^2}{\upsilon}\right) + \frac{2}{N} \cdot \upsilon \qquad (16)$$

gdje je υ ukupan broj nezavisnih varijabli, N ukupan broj opažanja, a r greške modela. Rezultati toga ključnoga koraka prikazani su na sljedećoj slici.

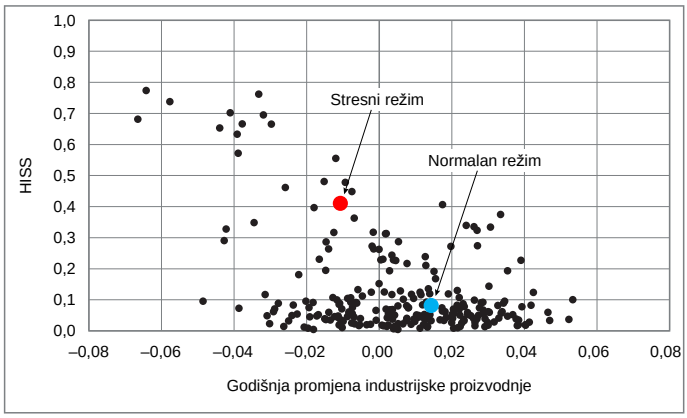
Slika 9. Usporedba AIC vrijednosti TVAR(1) modela u ovisnosti o graničnim vrijednostima indeksa stresa



Izvor: izračun autora

Na osnovi dobivenih vrijednosti Akaike informacijskoga kriterija moguće je uočiti kako se za graničnu vrijednost indeksa od 0,219 postiže najniža vrijednost informacijskoga kriterija (Slika 9.). Porastom praga iznad te razine AIC vrijednosti postaju sve manje granulirane i uz relativno viši raspon vrijednosti koje dosežu. Takav je rezultat očekivan s obzirom na to da se broj opažanja koji mijenja režim, odnosno koji se svrstava u režim suprotan postojećem, smanjuje s povećanjem granične vrijednosti. Da nije riječ samo o tehnički optimalnoj vrijednosti, uočljivo je i praktično u usporedbi detektiranog praga i empirijskih podataka. Prvo, kvantificirana vrijednost odgovara 79. percentilu povijesne distribucije konstruiranog indeksa i kao takva osigurava da se samo visoke razine sistemskog stresa, tj. ozbiljniji stresni poremećaji poput svjetske financijske krize 2008. godine, klasificiraju u stresni režim. Drugo, pri toj razini praga modelski je opis podataka najoptimalniji, tj. uz najmanju grešku i klasificira uzorak na dva režima, gdje se u svakom od njih bilježe kretanja industrijske proizvodnje različitih predznaka (Slika 10.). Naime, razdoblja stresa osim očekivanog pada industrije obuhvaćaju i njezina pozitivna ostvarenja, dok su u normalnom režimu prisutne negativne vrijednosti. Prosječne vrijednosti indeksa stresa znatno su više u stresnom režimu, a industrijska je proizvodnja negativna. Dodatno, moguće je uočiti negativnu povezanost između razine stresa i kretanja industrijske proizvodnje.

Slika 10. Dijagram rasipanja mjesečnog pokazatelja gospodarske aktivnosti i sistemskog stresa uz njihove prosječne vrijednosti za oba režima



Napomena: Vrijednosti indeksa stresa prikazane su s dvomjesečnim pomakom. Crvenom točkom prikazana je prosječna promjena industrijske proizvodnje (–0,011) i indeksa stresa (0,41) u stresnom režimu, a plava točka označuje redom prosječne vrijednosti od (0,014) i (0,08) u normalnom režimu.

Izvor: izračun autora

Rezultati procjene regresijskih jednadžbi TVAR(1) modela prikazani su u Tablici 2. i odnose se na dio sustava (17) u kojemu je godišnja promjena industrijske proizvodnje neovisna, a razina sistemskog stresa za Hrvatsku jedna od objašnjavajućih varijabli. Predznaci koeficijenata i njihova relativna veličina očekivani su i upućuju na nelinearnu vezu između financijskog sektora i makroekonomske dinamike. Drugim riječima, rezultati upućuju na to da propagacija nepovoljnih šokova – transmisija stresa – iz

Tablica 2. Prikaz odabranih rezultata procjene TVAR(1) modela ovisno o režimu i na cijelom uzorku

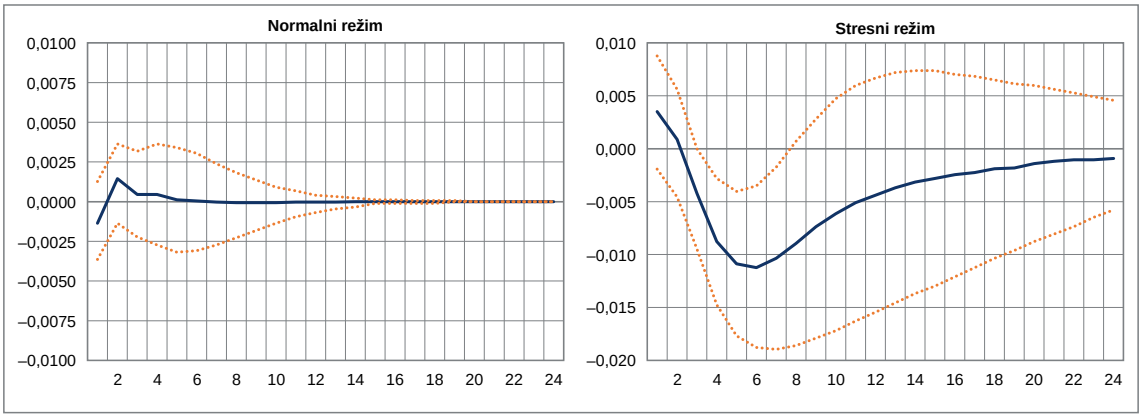
	Normalni režim (HISS < 0,219)	Stresni režim (HISS > 0,219)	Cijeli uzorak
Srednja vrijednost (IP)	0,014	–0,011	0,01
# observacija	243	46	289
$\beta_{IP(t),\ HISS(t-1)}$	0,033 (0,03)	–0,004 (0,03)	0,010 (0,02)
$\beta_{IP(t),\ HISS(t-2)}$	–0,028 (0,03)	–0,072 (0,04)	–0,044 (0,02)
Konstanta	0,004 (0,00)	0,051 (0,01)	0,007 (0,00)
AIC	–8.648	–7.026	–4.921

Napomena: U zagradama su navedene razine statističke značajnosti (p-vrijednosti). Prikazani su oni rezultati regresijske procjene koji se odnose na ovisnu varijablu godišnje stope promjene industrijske proizvodnje.

Izvor: izračun autora

financijske sfere na realnu ekonomiju ovisi o režimu u kojemu dolazi do inicijalnog impulsa, a latentno stanje za varijacije relativno je visoko na povišenim razinama sistemskog stresa i nisko u "normalnom" režimu. Do sličnih zaključaka došli su i brojni drugi autori, primjerice Hubrich i J. Tetlow (2016.). Neovisno o tome gleda li se iz perspektive pojedinog režima ili cijeloga uzorka, najveći (nepovoljan) utjecaj na razinu industrijske proizvodnje u današnjem trenutku proizlazi iz razine stresa zabilježene dva mjeseca prije, dok je taj učinak iz prethodnog mjeseca višestruko slabiji. Štoviše, utjecaj razine indeksa stresa iz prošlog mjeseca postaje pozitivan u slučaju zadržavanja

Slika 11. Funkcije impulsnog odaziva industrijske proizvodnje na sistemski šok od jedne standardne devijacije u pojedinom režimu



Napomena: Os apscisa označuje mjesece, a na osi ordinata prikazane su razine godišnjih stopa promjene industrijske proizvodnje. Plava je linija funkcija odaziva, dok su crvenom linijom označena odstupanja od srednje vrijednosti za dvije standardne devijacije.

Izvor: izračun autora

vrijednosti indeksa ispod kvantificiranog praga od 0,219, što je vidljivo iz predznaka koeficijenta zaostajuće varijable od jednog pomaka. Promjene se snažnije odražavaju unutar stresnog režima, za vrijeme kojeg bi početni pomak vrijednosti indeksa, tj. istovjetan onome u "normalnom" režimu, inicijalno djelovao dva i pol puta snažnije na smanjenje industrijske proizvodnje. Takav nepovoljan utjecaj nastavlja se i u sljedećem mjesecu, na što upućuju negativni predznaci oba razmatrana koeficijenta zaostajuće varijable.

Nalaze opisane parcijalne analize koeficijenata potvrđuju i razmatranja dinamičkog utjecaja sistemskih šokova na industrijsku proizvodnju u Republici Hrvatskoj. U tu svrhu na Slici 11. prikazane su funkcije impulsnog odaziva industrijske proizvodnje u normalnom i stresnom režimu. Odazivi industrijske proizvodnje na sistemske šokove zabilježene indeksom stresa, relativno gledajući, znatno se razlikuju i asimetrične su prirode. Naime, osim što su očekivano snažniji u slučaju materijalizacije šokova u stresnom režimu, iščezavanje odaziva malo je duljeg trajanja u odnosu na šokove koji se manifestiraju u normalnom režimu. Konkretnije, promjena indeksa stresa za jednu standardnu devijaciju u normalnom režimu smanjuje industrijsku proizvodnju za 0,1% na horizontu od jednog mjeseca, dok je u sljedeća dva mjeseca taj učinak čak neznatno pozitivan (0,08%). Ipak, učinak tog šoka nakon šest mjeseci iščezava. Suprotno tome, u stresnom režimu reakcija industrijske proizvodnje na sistemski šok dugoročno je negativna, a učinak tog šoka iščezava za više od godinu i pol dana. Porast indeksa stresa za jednu standardnu devijaciju u razdobljima visoke razine sistemskih poremećaja smanjuje industrijsku proizvodnju za 1,2%, što je znatno ako se uzme u obzir da je u posljednjih dvadeset godina njezina prosječna godišnja stopa rasta iznosila 1,0%.

8. Zaključak

U ovom se radu prvi put u domaćoj literaturi, koliko je autoru poznato, konstruira dnevni sintetički pokazatelj sistemskog stresa na domaćim financijskim tržištima. Riječ je o sveobuhvatnom pokazatelju kojim se na dnevnoj razini omogućuje detektiranje stresnih epizoda, koje, potraju li, mogu biti sistemski značajne. Dosad se samo jedan rad u domaćoj literaturi odnosio na sličnu temu za slučaj Hrvatske, pri čemu je razmatran isključivo pojam financijskog stresa i samim time nije uključivao jednu njegovu potencijalno važnu karakterizaciju – sistemsku komponentu. Drugim riječima, ovaj pokazatelj uzima u obzir procijenjenu važnost događaja na pojedinom tržištu za realno gospodarstvo. Osim toga, još jedan od doprinosa obuhvaćenih ovim radom jest i uključivanje međusobne koreliranosti kretanja na tržištima, što je od posebne važnosti u razdobljima ozbiljnijih stresnih epizoda u smislu prelijevanja i produbljivanja iniciranoga stresnog impulsa. Ova ključna unaprjeđenja metodološki su omogućena primjenom moderne teorije portfelja, poznate teorije za mjerenje stupnja diverzifikacije rizika u financijskoj industriji, zbog čega je izrađeni indeks iskorak u odnosu na dosad

konstruirane indekse. Analiza robusnosti konstruiranog pokazatelja stresa upućuje na to da, unatoč različitim metodološkim pristupima izrade pomoćnih pokazatelja, podjednako upozoravaju na razdoblja znatnijega jačanja stresa u financijskom sustavu.

Na taj je način napravljen korak više u praćenju ovoga kompleksnog fenomena – sistemskog stresa, a što bi u osnovi trebalo i olakšati praćenje procesa neravnoteže te omogućiti oblikovanje pravodobne i primjerene politike stabilizacije. S obzirom na rano dostupne pokazatelje primijenjene u izračunu indeksa, regulatoru se otvara mogućnost da adekvatno prati razinu i/ili jačinu stresa na financijskim tržištima i u skladu s tim daljnjom analizom točnog uzroka poremećaja pravodobno djeluje, koristeći se kratkoročnim, ad hoc mjerama (primjerice deviznim intervencijama) ili dugoročnim mjerama poput promjene makroprudencijalne regulative. Ne manje važna jest moguća primjena i važnost ovog pokazatelja u okviru testiranja otpornosti banaka na stres. Usporedba rezultata različitih scenarija stresnog testiranja, sintetiziranjem u jedinstvenu vrijednost, omogućuje njihovu jednostavniju i sveobuhvatniju interpretaciju. Iako se u tom smislu na svojevrstan način već rabi u HNB-u, ovako unaprijeđen pokazatelj stresa omogućuje i to da stupanj poremećaja na financijskom tržištu induciran stresnim uvjetima u gospodarstvu uvažava već spomenute činjenice o međupovezanosti financijskih tržišta, kao i o povezanosti tih tržišta i realnoga gospodarstva.

Osim navedenih informacija, izloženi kompozitni indeksi financijskog stresa mogu poslužiti i za detekciju stupnja poremećaja u odnosima među financijskim agentima koji se pojavljuje kao reakcija na sistemske pritiske kakve su nagomilane neravnoteže. Potonja skupina pokazatelja popularno se naziva “barometar”, a ovakvi indeksi pripadaju skupini koja se naziva “termometar”. Anticiklička politika od regulatora bi zahtijevala da raspoloživim makrobonitetnim instrumentima jača financijske kapacitete sudionika na tržištu u fazi kumuliranja rizika, a kada nastupi silovito rješavanje problema u sustavu (destabilizacija koja nužno prethodi novoj budućoj razini stabilizacije, a koju signaliziraju indikatori stresa), tada bi te kapacitete trebalo oslobađati (postupno ili naglo, ovisno o procjeni regulatora).

Nadalje, primjenom skupine VAR modela u radu je kvantificirana razina pokazatelja koja upućuje na režim u kojemu se financijska tržišta u svakom trenutku nalaze, te je procijenjen utjecaj detektiranih sistemskih šokova na industrijsku proizvodnju Republike Hrvatske. Rezultati upućuju na to da propagacija nepovoljnih šokova – transmisija stresa – iz financijske sfere na realnu ekonomiju očekivano ovisi o režimu u kojemu dolazi do inicijalnog impulsa, a funkcije odaziva, relativno gledajući, asimetrične su prirode. Šokovi u stresnom režimu, odnosno na razinama pokazatelja višima od 0,219, četverostruko su snažniji i trostruko duljeg trajanja u odnosu na šokove koji se manifestiraju u normalnom režimu. U tom smislu iščezavaju tek za godinu i pol dana.

S obzirom na navedeno, pri tumačenju ovih i sličnih indeksa potrebno je voditi računa o promjenjivosti veza između financijskih tržišta i ostatka ekonomije. Stoga proces konstrukcije ovakvih indeksa nikada ne završava, već je potrebno redovito i

pravodobno revidirati ovakve indekse kako bi što realnije odražavali stvarnu strukturu ekonomije i veze između pojedinih tržišta. Primjerice, najavljeno uvođenje eura, kao službene valute u Republici Hrvatskoj, zahtijevat će novi skup pokazatelja s deviznog tržišta, prestanak korištenja ZIBOR-a od početka 2020. godine zahtijeva njegovu zamjenu odgovarajućom referentnom kamatnom stopom na međubankovnom tržištu, dok bi daljnji porast važnosti nebankovnih financijskih institucija zahtijevao dodatne pokazatelje iz tog segmenta financijskog sustava. Naposljetku, dodatne koristi zasigurno će dati poboljšanja i analize predviđene budućim istraživanjima, kao što su primjena ARCH Markovljeva modela promjene režima (SWARCH) pri identificiranju stresnih epizoda, a koji bi povrh normalnoga i stresnog režima uključivao i treći režim – akumulacije stresa, određivanje preciznosti odnosno statističke značajnosti razine promjene pojedinog režima te predviđanja razine stresa u idućem razdoblju (engl. *forecasting*) i konstruiranje sustava ranog upozorenja na stres.

9. Literatura

Aboura, S. i Roye, B. (2017.): *Financial stress and economic dynamics: An application to France*, Kiel Working Paper, Kiel Institute for the World Economy, No. 1834, svibanj

Afonso, A., Baxa, J. i Slavík, M. (2018.): *Fiscal developments and financial stress: a threshold VAR analysis*, Empirical Economics, Vol. 54, issue 2, 395 – 423.

Alessandri, P. i Mumtaz, H. (2019.): *Financial Regimes and Uncertainty Shocks*, Journal of Monetary Economics, Vol. 101., str. 31 – 46, siječanj

Arinš, M., Sinenko, N. i Titarenko, D. (2012.): *Latvian Financial Stress Index,* Discussion Paper, Latvijas Banka

Arsov, I., Canetti, E., Kodres, L. E. i Mitra, S. (2013.): *Near-Coincident Indicators of Systemic Stress*, IMF Working Paper, No. 115, svibanj

Balakrishnan, R., Danninger, S., Elekdag, S. i Tytell, I. (2009.): *The Transmission of Financial Stress from Advanced to Emerging Economies*, IMF Working Papers 09/133, International Monetary Fund

Basel Committee on Banking Supervision (2017.): *Range of practices in implementing the countercyclical capital buffer policy*, Bank for International Settlements, Implementation reports, lipanj

Baskaya, Y. S., Giovanni, J., Kalemli-Ozcan, S. i Ulu, M. F. (2017.): *International Spillovers and Local Credit Cycles*, CEPR Discussion Paper 11839, Centre for Economic Policy Research, London

Basten, M., Bengtsson, E., Detken, C., Klaus, B., Koban, A., Kusmierczyk, P., Lang, J. H., Lo Duca, M. i Peltonen, T. (2017.): *A new database for financial crises in European countries*, European Central Bank Occasional Paper Series, No. 194, srpanj

Blix Grimaldi, M. (2010.): *Detecting and Interpreting Financial Stress in the Euro Area*, European Central Bank Working Paper Series, No. 1214, lipanj

Braga J. P., Pereira, I. i Reis, T. B. (2014.): *Composite Indicator of Financial Stress for Portugal*, Financial Stability Papers, Banco de Portugal, listopad

Caggiano, G., Castelnuovo, E. i Figueres, J. M. (2020.): *Economic Policy Uncertainty Spillovers in Booms and Busts*, Oxford Bulletin of Economics and Statistics, Department of Economics, University of Oxford, Vol. 82., No. 1, str. 125 – 155, veljača

Cardarelli, R., Elekdag, S. i Lall, S. (2011.): *Financial Stress and Economic Contractions*, Journal of Financial Stability, Vol. 7

Carlson, M. A., Lewis, K. F. i Nelson, W. R. (2012.): *Using Policy Intervention to Identify Financial Stress*, Finance and Economics Discussion Series Working Paper, Board of Governors of the Federal Reserve System, Washington, DC

Cerovac, S. (2005.): *Novi kompozitni indikatori za hrvatsko gospodarstvo: prilog razvoju domaćeg sustava cikličkih indikatora*, Istraživanja HNB-a, br. 16, travanj

Chadwick, M.G. i Ozturk, H. (2018.): *Measuring Financial Systemic Stress for Turkey: A Search for the Best Composite Indicator,* Central Bank of the Republic of Turkey, Working Paper No. 18/16, listopad

Chatterjee, S., Chiu, C.W., Duprey, T. i Hacioglu Hoke, S. (2017.): *A financial stress index for the United Kingdom*, Bank of England, Staff Working Paper No. 697, prosinac

Chen, C. W. i Lee, J. C. (1995.): *Bayesian inference of threshold autoregressive models*, Journal of Time Series Analysis, Vol. 16, No. 5, str. 483 – 492

Davig, T. i Hakkio, C. (2010.): *What Is the Effect of Financial Stress on Economic Activity?*, Federal Reserve Bank of Kansas City Economic Review, drugo tromjesečje, str. 35 – 62.

Detken, C., Weeken, O., Alessi, L., Bonfim, D., Boucinha, M., Castro, C., Frontczak, S., Giordana, G., Giese, J., Jahn, N., Kakes, J., Klaus, B., Lang, J., Puzanova, N. i Welz, P. (2014.): *Operationalising the countercyclical capital buffer: indicator selection, threshold identification and calibration options*, ESRB Occasional Paper Series, No. 5, lipanj

Diebold, F.X. i Yilmaz, K. (2012.): *Better to give than to receive: predictive directional measurement of volatility spillovers*, Economic Journal, Vol. 119, str. 158 – 171.

Dooley, J. M., Oet, M. V. i Ong, S. J. (2015.): *The financial stress index: Identification of systemic risk conditions*, EconPapers, Vol. 3, No. 3, str. 1 – 25.

Dumičić, M. (2014.): *Pokazatelji financijskog stresa za male otvorene visokoeuroizirane zemlje – primjer Hrvatske*, Istraživanja HNB-a, br. 43, lipanj

Duprey, T., Klaus, B. i Peltonen, T. (2015.): *Dating systemic financial stress episodes in the EU countries*, European Central Bank Working Paper Series, No. 1873, prosinac

Engle, R. i Ng, V. (1993.): *Measuring and Testing the Impact of News on Volatility,* The Journal of Finance, Vol. 48, No. 5, prosinac

Engle, R. F. (2002.): *Dynamic Conditional Correlation - A Simple Class of Multivariate Generalized Autoregressive Conditional Heteroskedasticity Models*, Journal of Business and Economic Statistics, Vol. 20, No. 3, str. 339 – 350.

Frutos, J. C., Garcia-de-Andoain, C., Heider, F. i Papsdorf, P. (2016.): *Stressed interbank markets: evidence from the European financial and sovereign debt crisis*, European Central Bank Working Paper Series, No. 1925, lipanj

Garcia-de-Andoain, C., Hoffmann, P. i Manganelli, S. (2014.): *Fragmentation in the euro overnight unsecured money market*, European Central Bank Working Paper Series, No. 1755, prosinac

Garcia-de-Andoain, C. i Kremer, M. (2018.): *Beyond spreads: measuring sovereign market stress in the euro area*, European Central Bank Working Paper Series, No. 2185, listopad

Ghosh, S. (2011.): *A simple index of banking fragility: application to Indian data,* The Journal of Risk Finance, Vol. 12, No. 2, str. 112 – 120, ožujak

Gramlich, D., Oet, M. V. i Ong, S. J. (2017.): *The contributions to systemic stress of financial interactions between the US and Europe*, The European Journal of Finance, Vol. 23, No. 12, veljača

Haan, J., Jacobs, J., Jing, Z. i Yang, H. (2015.): *Identifying banking crises using money market pressure: New evidence for a large set of countries*, Journal of Macroeconomics, Vol. 43, str. 1 – 20, ožujak

Hagen, M. i Pettersen, P. M. (2019.): *An improved composite indicator of systemic stress (CISS) for Norway*, Staff Memo, Norges Bank, No. 3, travanj

Hakkio, C., S. i Keeton, W., R. (2009.): *Financial Stress: what is It, how Can It Be Measured, and why Does It Matter?*, Economic Review, Federal Reserve Bank of Kansas City, issue Q II

Hanschel, E. i Monnin, P. (2005.): *Measuring and Forcasting Stress in the Banking Sector: Evidence from Switzerland*, BIS Papers, No. 22, travanj

Heider, F., Hoerova, M. i Holthausen C. (2014.): *Liquidity hoarding and interbank market spreads: The role of counterparty risk*, Journal of Financial Economics, No. 118, 336 – 354.

Hollo, D., Kremer i M., Lo Duca, M. (2012.): *CISS – A Composite Indicator of Systemic Stress in the Financial System*, European Central Bank Working Paper Series, No. 1426, ožujak

Hubrich, K. i Tetlow, R. (2015.): *Financial stress and economic dynamics: The transmission of crises*, Journal of Monetary Economics, Elsevier, vol. 70(C), str. 100 – 115.

Illing, M. i Liu, Y. (2003.): *An Index of Financial Stress for Canada*, Bank of Canada Working Paper, No. 2003-14, Bank of Canada

Isa, M. A., Ismail, N., Mazlan, N. F. i Rahman, N. H. (2018.): *Modelling Banking Sector Fragility Index: Evidence from Southeast Asian Emerging Economies*, Conference Paper, China International Risk Forum 2017., At Shanghai Jiao Tong University, Shanghai, Chin, travanj

Jankov, Lj. (2000.): *Problemi banaka: Uzroci, načini rješavanja i posljedice*, Pregled HNB-a, br. 2, siječanj

Kim, C. i Nelson, C. (1999.): *State-Space Models with Regime Switching*, Massachusetts Institute of Technology, Massachusetts

Kotarac, K., Kunovac, D. i Ravnik, R. (2017.): *Usklađenost poslovnih ciklusa i ekonomskih šokova između Hrvatske i država europodručja*, Istraživanja HNB-a, br. 51, listopad

Kremer, M. (2016.), *Financial stress indices: An introduction*, Spanish Review of Financial Economics, Vol. 14, str. 1 – 4.

Kremer, M. (2016.): *Macroeconomic Effects of Financial Stress and the Role of Monetary Policy: A VAR Analysis for the Euro Area*, International Economics and Economic Policy, Vol. 13, No. 1

Lall, S., Cardarelli, R. i Elekdag, S. (2009.): *Financial Stress, Downturns, and Recoveries*, IMF Working Papers, No. 100, svibanj

Louzis, D. P. i Vouldis, A. T. (2013.): *A financial systemic stress index for Greece*, Bank of Greece Working Papers, No. 155, ožujak

Macdonald, R., Sogiakas, V. i Tsopanakis, A. (2014.): *An investigation of systemic stress and interdependencies within the Eurozone and Euro Area countries,* Economic Modelling, Elsevier, Vol. 48(C), str. 52 – 69.

Miglietta, A. i Venditti, F. (2019.): *An indicator of macro-financial stress for Italy*, Bank of Italy Occasional Papers, No. 497, travanj

Pesaran, M. H. i Shin, Y. (1999.): *Generalized impulse response analysis in linear multivariate models*, Economics Letters, Vol. 58, pp. 17 – 29.

Saldias, M. (2017.): *The Nonlinear Interaction Between Monetary Policy and Financial Stress*, IMF Working Papers, No. 184, kolovoz

Shim, I. i Shin, K. (2018.): *Financial stress in lender countries and capital outflows from emerging market economies*, BIS Working Papers, No. 795, rujan

Sorić, P. (2007.): *Utjecaj volatilnosti tečaja kune na hrvatski izvoz*, Financijska teorija i praksa Vol. 31, No. 4, str. 347 – 363, prosinac

Szendrei, T. i Varga, K. (2017.): *FISS – A Factor Based Index of Systemic Stress in the Financial System*, Magyar Nemzeti Bank Working Paper, No. 9, kolovoz

Thiem, C. (2018.): *Cross-category spillovers of economic policy uncertainty,* Ruhr Economic Papers, No. 744, RWI - Leibniz-Institut für Wirtschaftsforschung, Ruhr-University Bochum, TU Dortmund University, University of Duisburg-Essen

Tsay, R. (1986.): *Nonlinearity tests for time series*, Biometrika, Vol. 73, No. 2, 461 – 466, kolovoz

Tsopanakis, A., Zhang, D. i Yan, M. (2018.): *Financial stress relationships among Euro area countries: An R-vine Copula approach,* The European Journal of Finance, Vol. 24, No. 17, str. 1587 – 1608, prosinac

Wen, Y. (2015.): *A composite indicator of systemic stress (CISS) for Norway – A reference indicator for the reduction of the countercyclical capital buffer*, Staff Memo, Norges Bank, No. 4

Prilog 1. Deskriptivna analiza

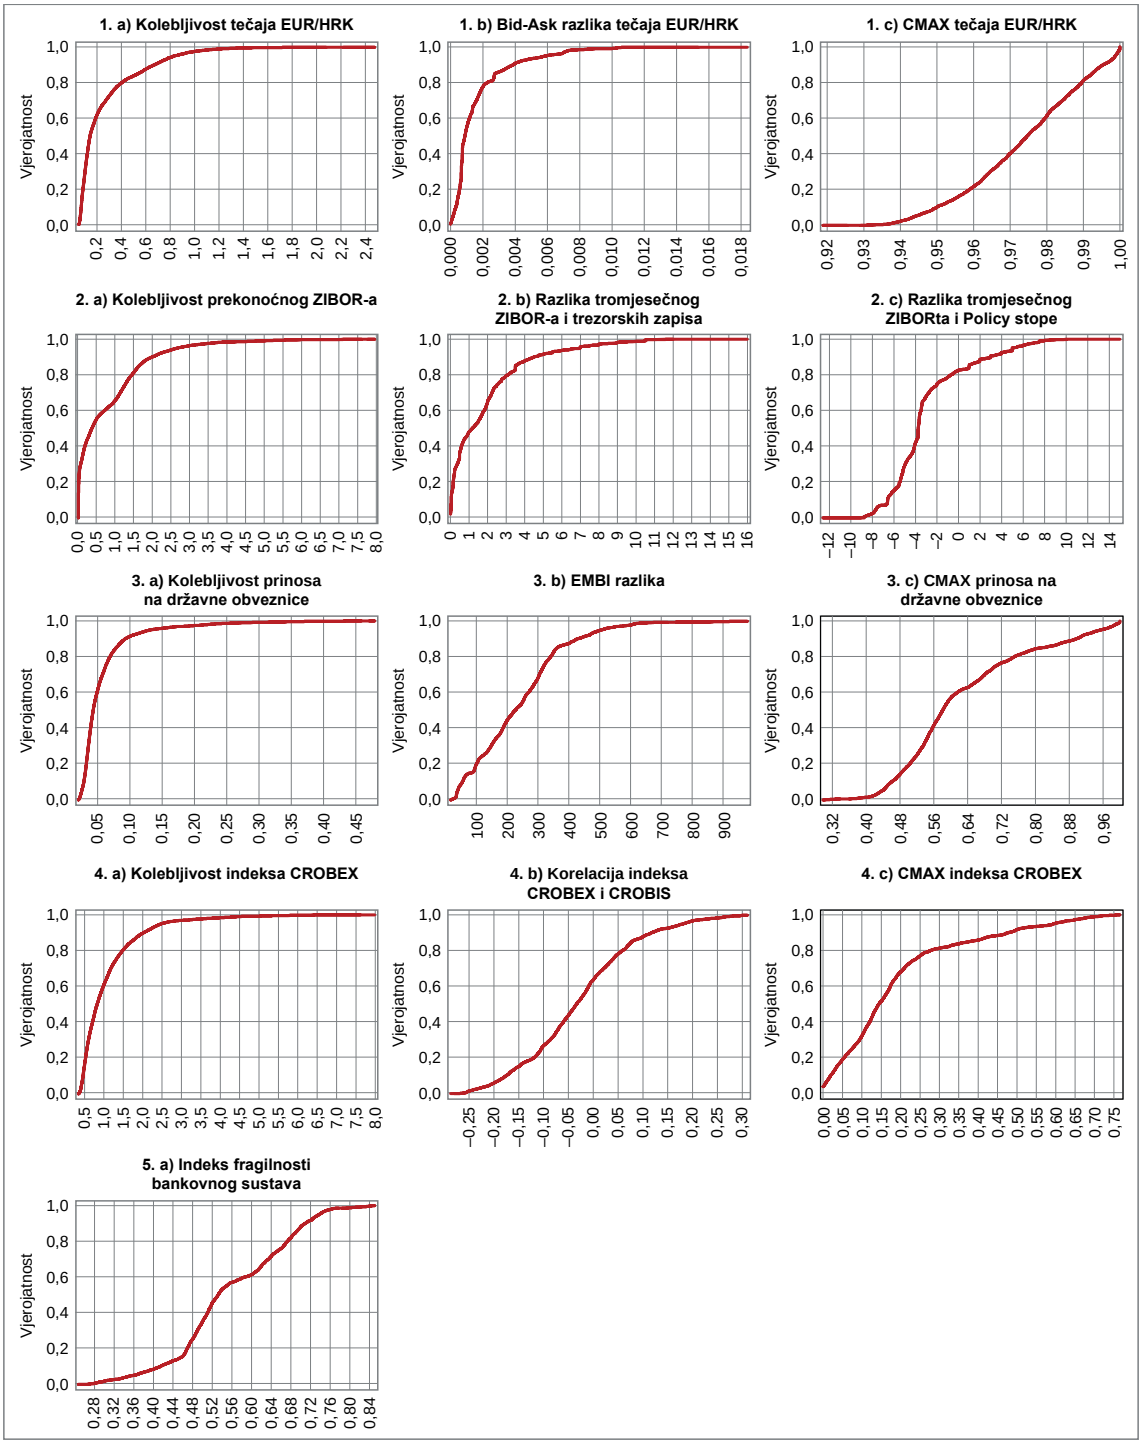
Tablica I.: Deskriptivna statistika inicijalnih pokazatelja

	Prosjek	Medijan	Maksimum	Minimum	Standardna devijacija	Broj opažanja
Devizno tržište						
Kolebljivost tečaja HRK/EUR (%)	0,258	0,141	2,477	0,050	0,268	6173
Bid-Ask razlika (pps)	0,002	0,001	0,018	0	0,002	6174
CMAX tečaja HRK/EUR (razina)	0,974	0,975	1	0,919	0,016	5524
Novčano tržište						
Kolebljivost prekonoćnog ZIBOR-a (%)	0,780	0,343	7,959	0,027	1,011	6306
Razlika tromjesečnog ZIBOR-a i Trezorskih zapisa (p. b.)	1,798	1,120	16,000	0	2,181	6163
Razlika tromjesečnog Zibor-a i Policy stope (p. b.)	–2,966	–3,740	15,000	–12,580	3,602	6308
Obvezničko tržište						
Kolebljivost prinosa na državne obveznice (%)	0,057	0,043	0,479	0,019	0,047	6191
EMBI razlika (b. b.)	233,529	225,320	979,200	17,000	145,506	6197
CMAX prinosa na državne obveznice (razina)	0,614	0,576	1	0,293	0,166	6192
Tržište kapitala						
Kolebljivost indeksa CROBEX (%)	1,079	0,805	7,986	0,344	0,827	5912
Korelacija indeksa CROBEX i CROBIS (razina)	–0,028	–0,032	0,310	–0,287	0,108	5024
CMAX indeksa CROBEX (razina)	0,185	0,139	0,766	0	0,171	5913
Bankovno tržište						
Indeks fragilnosti bankovnog sustava (razina)	0,348	0,331	0,851	0,247	0,116	5125

Napomena: U zagradama su naznačene mjerne jedinice pokazatelja, pri čemu pps označuje pipse, a p. b. i b. b. jesu postotni odnosno bazni bodovi. Podaci na temelju kojih je izračunata deskriptivna statistika uključuju radne dane za razdoblje od 22. veljače 1996. do 1. svibnja 2020.

Izvor: izračun autora

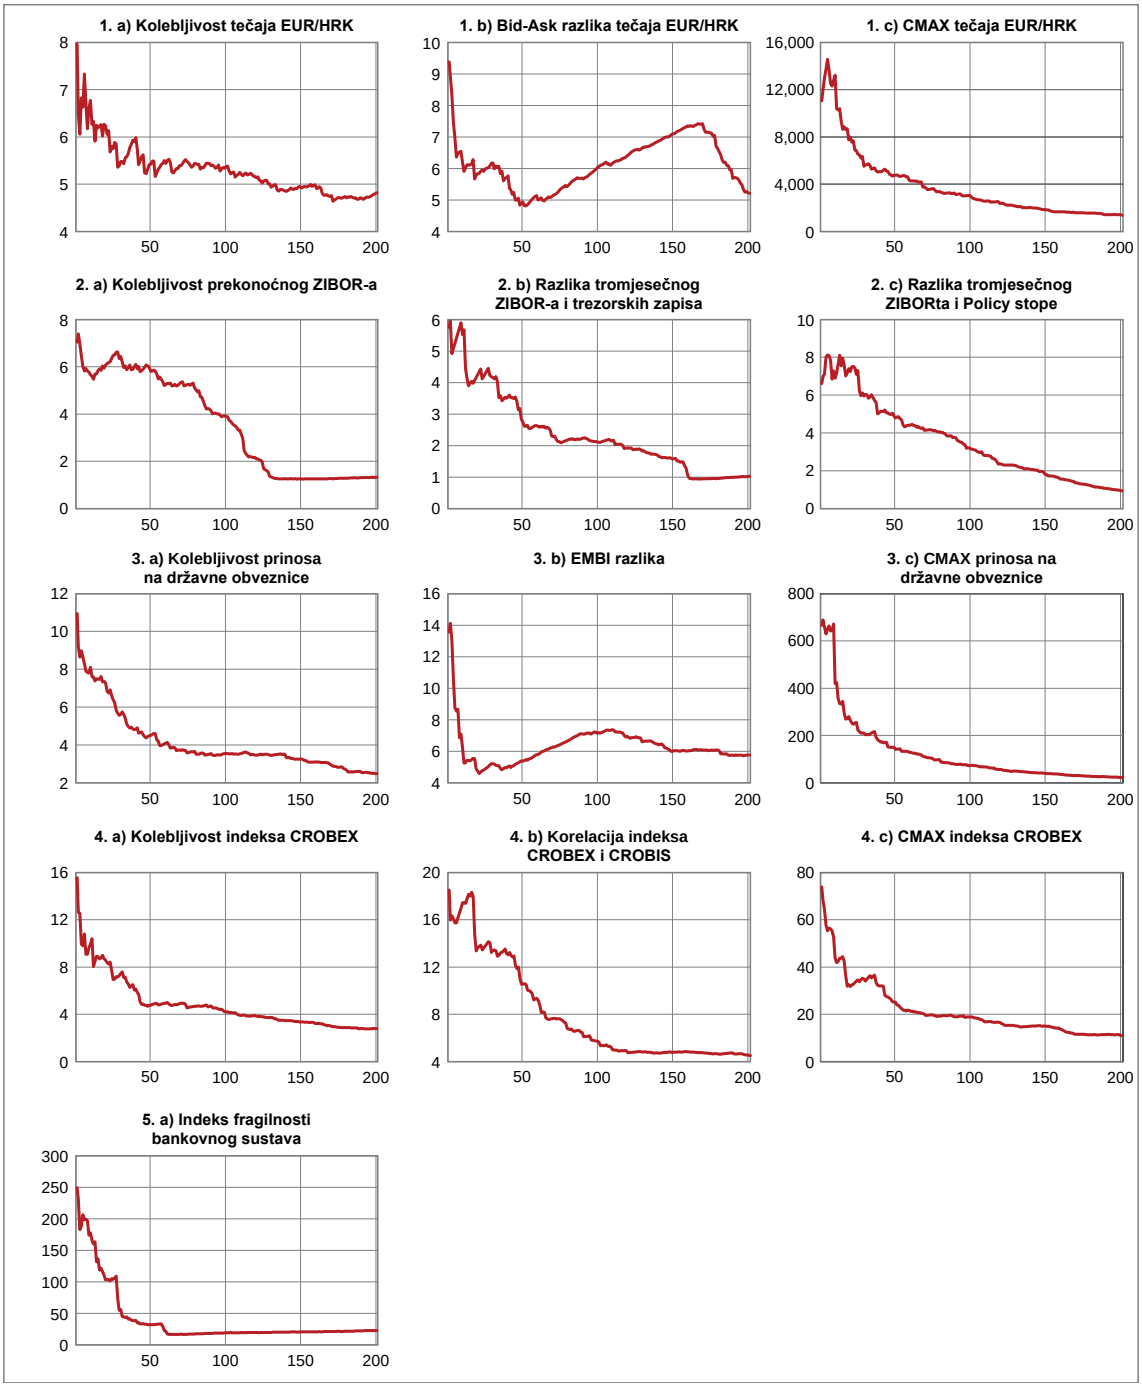
Slika I.: Empirijske kumulativne funkcije distribucije inicijalnih pokazatelja



Napomena: Na osi apscisa prikazane su apsolutne vrijednosti pokazatelja.

Izvor: izračun autora

Slika II.: Hill plot za skup pokazatelja primijenjenih pri izračunu pomoćnog indeksa financijskog stresa



Napomena: Za uređeni uzorak $x_{[1]} \leq \cdots \leq x_{[n]}$ Hillov procjenitelj repnog indeksa distribucije definiran je s $\hat{\alpha}_k = \left(\sum_{j=1}^{k} \ln \left(\frac{x_{[n-j+1]}}{x_{[n-k+1]}} \right) \right)^{-1}$ za *k* posljednjih vrijednosti tog uzorka. Optimalni kvantil distribucije računamo za različite *k*-ove tražeći "relativno stabilne" vrijednosti $\hat{\alpha}$. Na osi apscisa odnosno ordinata nalaze se vrijednosti *k* odnosno $\hat{\alpha}$.

Izvor: izračun autora

Prilog 2. GARCH modeli

U većini radova koji se tiču konstruiranja kompozitnih pokazatelja sistemskog stresa izračunu kolebljivosti na financijskim tržištima pristupa se primjenom realizirane kolebljivosti (engl. *realized volatility*), a osnovna pretpostavka takve formulacije kolebljivosti jest postojanje homoskedastičnosti. Međutim, mnogi financijski i makroekonomski vremenski nizovi imaju tendenciju izrazito velikih raspona kolebljivosti u određenim razdobljima odnosno karakterizira ih promjena varijance tijekom vremena (heteroskedastičnost), a promatranjem vremenskih nizova dnevnih i unutardnevnih financijskih podataka moguće je uočiti i još neke stilizirane činjenice koje ih karakteriziraju (Sorić, 2007.). Isti autor ističe da su to serijska ovisnost podataka te da je distribucija podataka asimetrična i ima zadebljane repove. Stoga se u ovom radu izračunu kolebljivosti vremenskih serija s financijskih tržišta pristupilo primjenom generaliziranoga autoregresivnog uvjetno heteroskedastičnog modela (engl. *Generalized AutoRegressive Conditional Heteroscedasticity* – GARCH model). Literatura kao jedan od najprimjerenije ocijenjenih predlaže GARCH (1,1) model, koji je formalno zapisan sljedećim sustavom jednadžbi:

$$\begin{cases} r_t = C + \varepsilon_t \\ \sigma_t^2 = \omega + \alpha\varepsilon_{t-1}^2 + \beta\sigma_{t-1}^2 \end{cases}$$

gdje ε_t označuje proces inovacija, σ_t uvjetnu varijancu od ε_t, a parametri ω, α i β zadovoljavaju uvjete $\omega > 0$, $\alpha, \beta \geq 0$.

Tablica II.: Procjena parametara GARCH(1,1) modela za izračun kolebljivosti odabranih pokazatelja

Parametri	Tečaj EUR/HRK	Prekonoćni ZIBOR	Prinos na državne obveznice	Indeks CROBEX
		Srednja jednadžba		
C-Konstanta	3,4E–04* (0,002)	–0,001* (0,001)	–0,002*** (4,5E–04)	0,018** (0,009)
		Jednadžba varijance		
ω	2,2E–04*** (2,6E–05)	3,1E–05*** (2,9E–07)	3,9E–05*** (1,7E–06)	0,01*** (9,8E–04)
α	0,11*** (0,006)	0,05*** (3,4E–04)	0,10*** (0,003)	0,08*** (0,005)
β	0,88*** (0,005)	0,95*** (6,8E–05)	0,89*** (0,003)	0,91*** (0,005)
		Durbin-Watson test		
DW	2,08	2,12	1,96	2,01

Napomena: ***, ** i * označuju razinu značajnosti od 10%, 5% i 1%. U zagradama su dane standardne pogreške procijenjenih parametara. Pretpostavljena je Studentova t-distribucija standardiziranih inovacija modela.

Izvor: izračun autora

Prilog 3. Indeks fragilnosti bankovnog sustava

Indeks fragilnosti bankovnog sustava konstruiran je na osnovi tri ključna pokazatelja koja mogu upućivati na prisutnost ili mogućnost nastanka bankovnih kriza i uključuje ukupno stanje bankovnih depozita, kredita privatnom sektoru i inozemnih obveza (Isa, M. i ostali, 2018.). Time se pokušava obuhvatiti izloženost banaka sljedećim ekonomskim rizicima – riziku likvidnosti koji nastaje zbog znatnog odljeva depozita, kreditnom riziku putem rastuće baze za materijalizaciju loših plasmana i valutnom riziku s obzirom na to da deprecijacija domaće valute direktno utječe na stanje njihovih obveza prema inozemstvu. Godišnje stope promjena ovih triju pokazatelja u najvećoj bi mjeri trebale upućivati na promjene krhkosti bankovnog sustava bilo koje zemlje, pa tako i Hrvatske. Prema Ghosh (2011.) svaki je od triju pokazatelja standardiziran na sljedeći način $d^i = \frac{p^i - \min(p^i)}{\max(p^i) - \min(p^i)}$, $i \in \{\text{depoziti, krediti, inozemne obveze}\}$ a izračunati indeks prilagođen je tako da njegov rast upućuje na povećanje fragilnosti bankovnog sustava i odražava Euklidovu udaljenost od točaka najmanje ranjivosti. Za depozite je to odstupanje od jedinice, dok je kod druga dva pokazatelja to vrijednost odstupanja od nule. Indeks fragilnosti definiran je na sljedeći način

$$IFBS = \frac{\sqrt{(1 - d^{\text{depoziti}})^2 + (d^{\text{krediti}})^2 + (d^{\text{ino_obveze}})^2}}{\sqrt{3}}.$$

Tako konstruirani indeks poprima vrijednosti između 0 i 1.

Prilog 4. Opis korištenih pokazatelja

Devizno tržište

- **Kolebljivost tečaja HRK/EUR:** U epizodama financijskog stresa uglavnom se pojavljuju rastuća nesklonost prema riziku i neizvjesnost investitora (Adam i ostali, 2014.), koja se na deviznim tržištima tipično ogleda kroz povećanu kolebljivost tečaja. Empirijska literatura upućuje na to da takvi događaji ponajprije rezultiraju malim, ali postojećim smanjenjem izvoza robe i usluga u Hrvatskoj (Šorić, 2008.), a nepovoljan utjecaj na bilance poduzeća (izvozno i uvozno orijentiranih) može otežati njihovo poslovanje u srednjoročnom razdoblju (Cabrera i ostbali, 2014.). Na taj način, među ostalim, rastuća kolebljivost može pridonijeti i sistemskom stresu. Kolebljivost je izračunata na apsolutnim dnevnim log-promjenama tečaja primjenom GARCH (1,1) modela[12]. Dnevni podaci počinju od 3. rujna 1996., a izvor podataka je Hrvatska narodna banka.

[12] Detaljnije o GARCH modelima vidi u Ghysels i Wang (2011.), a za specifikaciju i ispis svih rezultata modela za izračun kolebljivosti u ovom radu vidi Prilog 2.

- **Bid-ask razlika tečaja HRK/EUR:** Omjer razlike između kupovnoga i prodajnog tečaja (engl. *bid-ask spread*) i srednjeg tečaja predstavlja relativnu visinu zahtijevane premije za rizik od strane investitora na deviznom tržištu. Bojazan investitora od nemogućnosti zatvaranja svojih deviznih pozicija u relativno kratkom roku dovodi do porasta ovog pokazatelja i tipično je u situacijama poremećaja na financijskim tržištima. Dnevni podaci počinju od 2. rujna 1996., a izvor je podataka Bloomberg.
- **Akumulirani gubitak:** Negativni šokovi u gospodarstvu ili na financijskim tržištima mogu rezultirati postupnim deprecijacijskim pritiscima na domaću valutu. U takvim bi uvjetima prije svega porastao teret otplate dugova za stanovništvo, poduzeća i državu te se nepovoljno odrazio na financijski položaj svih domaćih sektora. U slučaju da takvo razdoblje potraje, moguća je manifestacija sistemskog stresa. Pokazatelj akumuliranoga gubitka na deviznom tržištu odnosno akumulirane deprecijacije kune prema euru u posljednjih pet godina, tj. 1302 radna dana[13] izračunat je za svaki dan t na sljedeći način:

$$CMAX_t^{\text{tečaj}} = \begin{cases} \dfrac{\text{srednji tečaj}_t}{\max\left[\text{srednji tečaj}_j \mid j \in \{t-1301, \ldots, t-1, t\}\right]}, & t > 1302 \\ \dfrac{\text{srednji tečaj}_t}{\max\left[\text{srednji tečaj}_j \mid j \in \{1, 2, \ldots, 1302\}\right]}, & t \leq 1302 \end{cases}.$$

Dnevni podaci počinju od 2. rujna 1996., a izvor je podataka Hrvatska narodna banka.

Novčano tržište

- **Kolebljivost prekonoćnog ZIBOR-a:** Prekonoćni ZIBOR jest kamatna stopa na kratkoročno neosigurano međubankovno kreditiranje u domaćoj valuti. Porast kolebljivosti ove kamatne stope povezan je s povećanom neizvjesnošću na hrvatskom međubankovnom tržištu i u pravilu odražava kratkoročno rastući pritisak na likvidnost banaka. Neizvjesnost često zbog povećanja asimetričnosti informacija odnosno nepoznavanja stanja likvidnosti i solventnosti drugih banaka rezultira bijegom u kolateralizirano pozajmljivanje (bijeg u kvalitetu) ili pozajmljivanje depozita od strane središnje banke (bijeg u likvidnost). Navedeno bi se moglo negativno odraziti na sistemski stres. Kolebljivost je izračunata na apsolutnim dnevnim promjenama kamatne stope primjenom GARCH (1,1) modela. Dnevni podaci počinju od 23. veljače 1996., a izvor je podataka Hrvatska narodna banka.

[13] Inicijalna vagana ročnost novoodobrenih eurskih kredita privatnom sektoru u razdoblju od kraja 2011. do početka 2020. godine iznosila je približno pet godina.

- **Razlika tromjesečnog ZIBOR-a i tromjesečne kamatne stope na trezorske zapise:** Informacije sadržane u razlici tromjesečnog ZIBOR-a i kamatne stope na tromjesečne trezorske zapise pokazatelj su stresa na međubankovnom tržištu u smislu cijene kolaterala. Rast razlike implicira sve skuplje nekolateralizirano odnosno jeftinije kolateralizirano zaduživanje. Naime, povećana vjerojatnost neispunjavanja obveza povezanih s vraćanjem zajma ili rast nelikvidnosti banke dužnika potaknut će banke kreditore na sve veće usmjeravanje ka plasiranju kolateraliziranih zajmova u razdobljima financijskog stresa. Dnevni podaci počinju od 17. rujna 1996., a izvor je podataka Hrvatska narodna banka.
- **Razlika tromjesečnog ZIBOR-a i tromjesečne kamatne stope monetarne politike**[14]**:** Kamatne stope na trezorske zapise korištene u prethodnom pokazatelju u odnosu na kamatne stope na kratkoročno financiranje poslovnih banaka kod središnje banke tržišno određene su ponudom i potražnjom te osim rizika likvidnosti odražavaju i rizik druge ugovorene strane (engl. *counterparty risk*). Osim toga, moguće je da se u razdobljima značajne nelikvidnosti banaka zbog asimetričnosti informacija pojavi i nemogućnost njihova financiranja na međubankovnom tržištu, a kao zajmodavac u krajnjoj nuždi posluži središnja banka (engl. *lender of last resort*). Slijedom navedenog, informacije sadržane u ovoj kamatnoj razlici detektiraju ozbiljnije likvidnosne poremećaje, koji nisu nužno obuhvaćeni gornjim pokazateljem, a njezin rast upućuje na porast financijskog stresa. Dnevni podaci počinju od 22. veljače 1996., a izvor je podataka Hrvatska narodna banka.

Obvezničko tržište

- **Kolebljivost prinosa na državne obveznice:** Kolebljivost prinosa na generičku desetogodišnju hrvatsku državnu obveznicu nominiranu u eurima izračunata je primjenom GARCH(1,1) modela na apsolutnim dnevnim promjenama. Porast ovoga pokazatelja obično je povezan s rastućom neizvjesnošću investitora glede podmirivanja dospjelih i budućih obveza zemlje. Dnevni podaci počinju od 1. kolovoza 1996., a izvor su podataka Bloomberg i Bank of America Merrill Lynch.
- **EMBI**[15] **razlika prinosa:** Ovim pokazateljem predstavljena je relativna percepcija rizičnosti zemlje od strane investitora u državne obveznice, a

[14] Kamatna stopa monetarne politike (engl. *policy rate*) odnosi se na kamatnu stopu Hrvatske narodne banke na kratkoročne kredite za likvidnost banaka, pri čemu je prekonoćna kamatna stopa za likvidnost na kraju travnja 2020. godine iznosila 2,5%. Za korištenje kratkoročnoga kredita za likvidnost dulje od tri mjeseca izračunava se kao kamatna stopa na prekonoćni kredit uvećana za 1,5 postotnih bodova. Striktno govoreći ovaj oblik kreditiranja poslovnih banaka od strane središnje banke ne mora biti nužno povezan s likvidnosnim pritiscima na međubankovnom tržištu, već može biti isključivo rezultat tehničkog problema ili operativne pogreške banke zbog koje se unutardnevni krediti koji nisu otplaćeni prije zatvaranja sustava poravnanja automatizmom pretvaraju u prekonoćne kredite. Međutim, razmatranjem tromjesečne kamatne stope za likvidnost takve situacije su uklonjene.

[15] EMBI (engl. *Emerging Market Bond Index*) je indeks koji čini vagani prinos na državne obveznice nominirane u američkim dolarima i s rokom dospjeća većim od 2,5 godine. Konstruira se za rastuća tržišta (zemlju ili skupinu zemalja), a sastavlja ga i objavljuje investicijska banka J. P. Morgan.

izračunat je kao razlika indeksa EMBI za Hrvatsku i europodručje. Njegov rast implicira viši trošak zaduživanja odnosno veću percepciju rizičnosti Hrvatske u odnosu na rastuća tržišta europodručja, što može biti znak stresa na domaćim financijskim tržištima. Primjerice, razlog rasta može biti povećana neizvjesnost investitora glede urednog podmirivanja budućih obveza od strane države, smanjena sklonost glede držanja rizične imovine i drugo. Međutim, valja naglasiti kako rast ovoga pokazatelja ne mora nužno biti uzrokovan financijskim stresom, već primjerice može biti posljedica povećanog pesimizma investitora koji je obično reakcija na pretjerani optimizam u prijašnjem razdoblju. Dnevni podaci počinju od 31. srpnja 1996., a izvor su podataka Bloomberg i J. P. Morgan.

- **Akumulirani gubitak:** Ovim pokazateljem identificiraju se razdoblja koja su obilježena apsolutnim rastom prinosa na državne obveznice ili njegovim zadržavanjem na povišenim razinama, a koja nisu nužno obuhvaćena prethodnim pokazateljima. Primjerice, nesklonost investitora prema riziku, kao posljedica stresnih događaja u prijašnjem razdoblju, može djelovati na opći porast prinosa ili zadržavanje negativne percepcije rizičnosti zemlje. To osim što rezultira povećanim troškovima finanaciranja zemlje, tijekom duljeg razdoblja može se odraziti i na cijenu bankovnoga kreditiranja ostalih domaćih sektora, nefinancijskih poduzeća i stanovništva, uz deflacijske učinke na gospodarstvo. Akumulirani gubitak prinosa na državne obveznice u posljednjih 839 radnih dana[16] za svaki je dan t izračunat na sljedeći način:

$$CMAX_t^{prinos} = \begin{cases} \dfrac{prinos_t}{\max\left[prinos_j \,\middle|\, j \in \{t-838, \ldots, t-1, t\} \right]}, & t > 839 \\ \dfrac{prinos_t}{\max\left[prinos_j \,\middle|\, j \in \{1, 2, \ldots, 839\} \right]}, & t \leq 839 \end{cases}.$$

Dnevni podaci počinju od 31. srpnja 1996., a izvor su podataka Bloomberg i Bank of America Merrill Lynch.

Dioničko tržište

- **Kolebljivost mjerena indeksom CROBEX[17]:** Porast kolebljivosti na dioničkom tržištu uobičajeno odražava neizvjesnost investitora glede

[16] Preostalo vagano dospijeće obveznica Republike Hrvatske nominiranih u eurima izračunato je prema podacima iz Strategije upravljanja javnim dugom za razdoblje 2019. – 2021. (dostupno na internetskim stranicama Ministarstva financija) te je na dan 1. siječnja 2020. iznosilo 4,83 godine. Budući da se uobičajeno pri razmatranju prinosa na državne obveznice (izračuni indeksa i slično) ne uzimaju u obzir obveznice s dospijećima manjim od 1,5 godine, pomično razdoblje akumuliranih gubitaka definirano je za prethodne 4,83 – 1,5 = 3,33 godine, odnosno 839 radnih dana.

[17] CROBEX je dionički cjenovni indeks koji uključuje vrijednost dionica od 15 do 25 likvidnih i tržišno najkapitaliziranijih poduzeća. Sastavlja ga i objavljuje Zagrebačka burza.

vrijednosti imovine, kao i neizvjesnost glede ponašanja drugih investitora. Izračunata je na dnevnim log-povratima primjenom GARCH (1,1) modela. Dnevni podaci počinju od 3. rujna 1997., a izvor je podataka Zagrebačka burza.

- **Akumulirani gubitak:** Iako je kolebljivost cijena imovine ključan pokazatelj stresa na financijskim tržištima, moguće je da promjena raspoloženja na tržištima zbog smanjenja fundamentalne vrijednosti imovine rezultira postupnim smanjivanjem cijene dionica, a uz potpuni izostanak kolebljivosti. Zbog toga je za svaki dan *t* izračunat akumulirani gubitak na dioničkom tržištu u posljednje dvije godine, tj. 521 radni dan mjereno indeksom CROBEX na način da je:

$$CMAX_t^{crobex} = \begin{cases} \dfrac{crobex_t}{\max\left[crobex_j \,\middle|\, j \in \{t-520, \ldots, t-1, t\}\right]}, & t > 521 \\ \dfrac{crobex_t}{\max\left[crobex_j \,\middle|\, j \in \{1, 2, \ldots, 521\}\right]}, & t \leq 521 \end{cases}.$$

Porast gornjeg pokazatelja upućuje na znatniji pad cijena dionica u vremenu, kao rezultat materijaliziranih stresnih događaja, iako i njegovo smanjenje zbog rasta CROBEX-a može upućivati na stvaranje cjenovnog balona. No, to odražava moguće predstojeće stresne događaje. Dnevni podaci počinju od 2. rujna 1997., a izvor je podataka Zagrebačka burza.

- **Korelacija povrata na obvezničkom i dioničkom tržištu:** Empirijska literatura pokazuje da je korelacija između povrata na tržištima kapitala i obvezničkim tržištima pozitivna u dugom roku, a za vrijeme stresnih epizoda snažno je negativna (Baele i ostali, 2013.). Razlog tome leži u činjenici da u razdobljima takvih stresnih situacija na dioničkom tržištu investitori u bijegu za sigurnost (engl. *flight to safety*) odnosno u bijegu za kvalitetom i likvidnosti (engl. *flight to quality and liquidity*) imaju tendenciju preusmjeriti svoj kapital iz dionica u državne obveznice i na taj si način, uz trošak malo nižih prinosa, osigurati ulaganja od daljnjih gubitaka. Slijedom navedenog, na temelju dnevnih log-povrata na domaćem dioničkom tržištu (mjereno indeksom CROBEX) i na domaćem obvezničkom tržištu (mjereno indeksom CROBIS[18]) za svaki dan *t* izračunate su realizirane korelacije $KOR_t^{crobex_crobis}$ u posljednjih šest mjeseci, tj. 130 radnih dana na sljedeći način:

$$KOR_t^{crobex_crobis} = \frac{\sum_{m=0}^{129} r_{t-m}^{crobex} r_{t-m}^{crobis}}{\sqrt{\sum_{m=0}^{129} \left(r_{t-m}^{crobex}\right)^2} \sqrt{\sum_{m=0}^{129} \left(r_{t-m}^{crobis}\right)^2}}.$$

[18] CROBIS je cjenovni indeks državnih obveznica i obveznica državnih agencija koje imaju nominalnu vrijednost izdanja veću od 75 mil. EUR, dospijeće veće od 18 mjeseci i ugovorene su s fiksnom kamatnom stopom.

Dnevni podaci počinju od 29. siječnja 2001., a izvor je podataka Zagrebačka burza.

Posrednici

- **Indeks fragilnosti bankovnog sustava:** Dominantan oblik financijskog posredništva u Hrvatskoj obavljaju bankovne institucije[19], koje drže više od dvije trećine financijske imovine cijeloga financijskog sustava. Zbog toga je na osnovi desetodnevnih[20] podataka iz bilanci banaka izračunat indeks fragilnosti bankovnog sustava (za detalje vidi Prilog 3.), koji uzima u obzir tri ključna rizika banaka koji mogu rezultirati narušavanjem njihovih bilanci – kreditni i valutni rizik te rizik likvidnosti. Porast ovoga pokazatelja odražava rastuću fragilnost domaćega bankovnog sustava. Dnevni podaci počinju od 2. rujna 2000., a izvor je podataka Hrvatska narodna banka.

[19] Iako je financijski sustav u znatnoj mjeri bankocentričan, što je posebno obilježje tranzicijskih zemalja, posljednjih petnaest godina vidljiva je sve veća zastupljenost institucionalnih investitora, ponajprije mirovinskih i investicijskih fondova te društava za osiguranje. Međutim, izračunata je samo fragilnost bankovnog sustava, s obzirom na to da je fragilnost nebankovnih financijskih posrednika u znatnoj mjeri povezana s događajima na tržištima državnog duga i tako indirektno obuhvaćena pokazateljima na obvezničkom tržištu.

[20] Desetodnevni podaci kubičnom su interpolacijom svedeni na dnevnu razinu.

IZDAVAČ
Hrvatska narodna banka
Trg hrvatskih velikana 3
10000 Zagreb
T. +385 1 4564 555
www.hnb.hr

GLAVNI UREDNIK
Ljubinko Jankov

UREDNIŠTVO
Vedran Šošić
Gordi Sušić
Davor Kunovac
Maroje Lang
Davor Galinec
Maja Bukovšak
Dražen Odorčić
Boris Cota
Tomislav Ridzak
Evan Kraft
Ante Žigman

IZVRŠNI UREDNIK
Katja Gattin Turkalj

LEKTORICA
Sanda Uzun-Ikić

DIZAJNER
Vjekoslav Gjergja

GRAFIČKI UREDNIK
Slavko Križnjak

Za stajališta iznesena u ovom radu odgovorni su autori i ta stajališta nisu nužno istovjetna službenim stajalištima Hrvatske narodne banke.

Molimo korisnike ove publikacije da pri korištenju podataka obvezno navedu izvor.

ISSN 1334-0077 (online)

Hrvatski indeks sistemskog stresa (HISS)

ISSN 1334-0077 (online)

