

MATEMATIČKI MODEL I PROGRAMSKA PODRŠKA ZA ODREĐIVANJE VRIJEDNOSTI GRANIČNE OBVEZNE PRIČUVE KAO INSTRUMENTA MONETARNE POLITIKE

mr. sc. Darko PONGRAC
Hrvatska narodna banka, Zagreb

Izvorni znanstveni članak**

UDK: 336.7

JEL: E5

prof. dr. sc. Kristina ŠORIĆ
Ekonomski fakultet, Zagreb

doc. dr. sc. Višnja VOJVODIĆ ROSENZWEIG
Ekonomski fakultet, Zagreb

Sažetak

U radu se promatra problem međuovisnosti ciljeva središnje banke i poslovnih banaka. Osnovni je cilj Hrvatske narodne banke postizanje i održavanje stabilnosti cijena. Zbog višegodišnjeg problema visokog udjela inozemnog duga u BDP-u, aktivnosti središnje banke uvelike su usmjerene na destimuliranje rasta zaduživanja poslovnih banaka u inozemstvu. Radi sprječavanja daljnjeg rasta inozemnog duga poslovnih banaka, HNB se koristi s nekoliko instrumenata monetarne politike, među kojima se posebno izdvaja granična obvezna pričuva. Nasuprot tome, cilj poslovnih banaka je ostvarenje što veće dobiti. Pritom se one zadužuju u inozemstvu po nižoj, a sredstva plasiraju u obliku kredita na domaćem tržištu po višoj kamatnoj stopi i tako ostvaruju svoj cilj. Da bi granična obvezna pričuva imala željene učinke, potrebno je odrediti optimalni postotak izdvajanja. Za to je razvijen matematički model dvorazinskoga mješovitog 0-1 programiranja. Cilj voditelja (u ovom primjeru HNB-a) jest određivanjem različitih postotaka pričuve minimizirati porast kreditnih plasmana stanovništvu od poslovnih banaka, a cilj sljedbenika (poslovnih banaka) jest maksimizacija dobiti. S matematičke je strane to NP-težak problem i stoga se za njegovo rješavanje primjenjuje heuristika. Na kraju su provedene simulacije radi verifikacije modela i izloženi rezultati numeričkih izračuna.

* Primljeno (Received): 1.6.2007.

Prihvaćeno (Accepted): 27.8.2007.

Ključne riječi: instrumenti monetarne politike, kreditni plasmani poslovnih banaka, granična obvezna pričuva, model dvorazinskoga mješovitog 0-1 programiranja, NP-težak problem, heuristika

1. Uvod

Kako inozemni dug poslovnih banaka čini velik udio u ukupnome inozemnom zaduženju Republike Hrvatske, Hrvatska narodna banka (HNB) se koristi mjerama kojima može utjecati na ponašanje banaka. Jedna od njih, na koju je stavljen naglasak u ovom radu, jest i granična obvezna pričuva (u daljnjem tekstu GOP). Među ostalim, cilj rada je i određivanje vrijednost postotka izdvajanja GOP-a, kojim bi se poslovne banke navelo da ograniče rast svojih zaduživanja u inozemstvu.

Radi određivanja tog postotka, u ovom je radu formuliran matematički model međusobne ovisnosti djelovanja središnje banke i poslovnih banaka. Model pripada klasi modela dvorazinskoga mješovitog 0-1 programiranja. Na gornjoj je razini odlučivanja središnja banka, a unutar ovog rada njezin je cilj minimizirati porast kredita što ih poslovne banke odobravaju stanovništvu. Na donjoj su, podređenoj razini odlučivanja poslovne banke, čiji je cilj maksimizacija dobiti. Dobit poslovnih banaka definirana je kao razlika u kamatama koje one ostvaruju od plasmana kredita na domaćem tržištu i kamata što ih plaćaju na svoja zaduživanja u inozemstvu. Ostali prihodi poslovnih banaka u ovom su radu zanemareni i promatraju se kao izvor pokrića poslovnih rashoda. Model je razvijen uz određene pretpostavke koje pojednostavnjuju realnu situaciju, ali bi se uz pretpostavku profesionalne primjene, bez bitnih zahvata u osnovnu ideju, mogao dograditi drugim elementima odnosa središnje banke i poslovnih banaka. Promatrana su dva modela. Prvi, temeljni model osim obvezne pričuve (OP) kao trajne mjere djelovanja obuhvaća i graničnu obveznu pričuvu te posebnu obveznu pričuvu (POP). Drugi je model proširenje prvog modela za upis obveznih blagajničkih zapisa (OBZ-a). POP je uključen u prvi model samo na razini definicije, dok se u numeričkim simulacijama izdavanje obveznica od poslovnih banaka zanemaruje. Ta pretpostavka ne narušava primjenjivost modela jer ne utječe na numeričke rezultate, a usto su odmah nakon njezina uvođenja poslovne banke zaustavile svoje zaduživanje putem izdavanja obveznica.

Općenito, modeli dvorazinskog programiranja pripadaju klasi NP-teških problema. Osim toga, modeli razvijeni u ovom radu problemi su velikih dimenzija zbog velikog broja realnih i cjelobrojnih varijabli te ograničenja. Usto, parametri kao što su kamatne stope poslovnih banaka po kojima se odobravaju krediti na domaćem tržištu poslovna su tajna. Stoga su pri numeričkim simulacijama uvedene mnoge relaksacije.

U postupku rješavanja modela razvijene su heuristike utemeljene na tabu pretraživanju, te je izrađena programska podrška za primjenu programskog paketa CPLEX9. Ta je programska podrška omogućila niz analiza utjecaja različitih vrijednosti GOP-a na plasmane poslovnih banaka.

Potom je napravljen niz numeričkih simulacija radi verifikacije postavljenih modela. Promjena parametara, dodavanje drugih pretpostavki, promatranje POP-a, mijenjanje ciljeva središnje banke i poslovnih banaka te uključivanje dodatnih elemenata monetarnog sustava nisu značajniji zahvat u osnovne ideje kreiranog modela i način njegova rješavanja.

Numerički rezultati pokazuju bitne razlike ovisno o tome primjenjuje li se efektivna ili nominalna kamatna stopa. Dobiveni numerički rezultati mogu se iskoristiti i za druge *ex ante* analize učinaka monetarne politike.

Rad se sastoji od sedam poglavlja i priloga. U 2. poglavlju opisana je međuovisnost djelovanja središnje banke i poslovnih banaka. Težište osvrta je na djelovanju HNB-a, i to na porastu inozemnog zaduživanja poslovnih banaka. Taj je problem naglašen zbog visoke inozemne zaduženosti Hrvatske, koja prelazi razinu od 80% BDP-a, što se prema ekonomskoj teoriji smatra gornjom granicom inozemne zaduženosti, nakon koje prijeti opasnost od izbijanja tzv. dužničke krize.

U 3. poglavlju konstruirani su matematički modeli za određivanje optimalne vrijednosti GOP-a. Prvi model opisuje stanje propisanih mjera središnje banke za usporenu rasta inozemnog zaduživanja banaka i prekomjernog rasta plasmana koje je vrijedilo do siječnja 2007. Drugi model, osim mjera koje obuhvaća prvi, obuhvaća i novouvedenu mjeru upisa OBZ-a koja je na snazi od siječnja 2007. godine. Budući da, kao što je već rečeno, problemi dvorazinskog programiranja pripadaju klasi NP-teških problema, za njihovo se rješavanje razvijaju heuristike. Heuristike razvijene za potrebe ovog rada, kao i osnovne metode primijenjene za izradu tih heuristika, te relaksacije opisane su u 4. poglavlju.

U 5. poglavlju dani su rezultati numeričkih simulacija koji su dobiveni rješavanjem pomoću heuristika opisanih u prethodnom poglavlju. Analize su napravljene uz upotrebu nominalne i efektivne kamatne stope. Na kraju, u 6. i 7. poglavlju, iznose se zaključci i upućuje na moguća daljnja istraživanja radi dogradnje modela.

Ukratko, cilj je ovog istraživanja kreiranje matematičkog modela trenutnog stanja i odnosa između središnje banke i poslovnih banaka u segmentu inozemnog zaduživanja banaka. Opisano je sadašnje stanje tog dijela bankarskog sustava, te je izvršenjem numeričkih simulacija uz određene pretpostavke koje pojednostavnjuju realnu situaciju ustanovljen odnos između mjera središnje banke i ostvarene dobiti poslovnih banaka.

2. Međuovisnost djelovanja središnje banke i poslovnih banaka

HNB na području monetarne politike provodi različite mjere kako bi održao stabilnost cijena, odnosno kako bi podržao što veći gospodarski rast uz što nižu inflaciju i tako proveo svoju zakonom definiranu ulogu. Iz prošlosti je poznato da razdoblja visoke inflacije uglavnom dovode do kolapsa gospodarstva, jer se pažnja poduzetnika pomiče s proizvodnje dobara na to kako očuvati vrijednost imovine koju posjeduju i kojom upravljaju.

Moderni ekonomski sustavi pokazuju da je inflacija na određeni način potrebna kako bi se postigao gospodarski rast. Usto je gotovo nemoguće uspostaviti vezu između stope inflacije i gospodarskog rasta, što dodatno otežava djelovanje središnje banke. Ona se mora brinuti o stabilnosti cijena, ali i dopustiti njihov određeni rast kako bi se postigao što veći gospodarski razvoj.

U gospodarstvu zemlje kao što je Hrvatska, koja više od 50% svog BDP-a ostvaruje razmjenom sa svijetom, postoji dodatna opasnost od uvoza inflacije, pa stabilnost cijena istodobno znači i stabilnost tečaja prema valuti u kojoj je indeksirana većina kreditnih poslova, kao i cijena trajnih dobara (u primjeru Hrvatske u euru). Istodobno, s obzirom

na iznimno otvoreno tržište, postoji velika mogućnost prenošenja inflacije iz inozemstva (npr. velik porast cijena energenata na svjetskom tržištu izravno utječe na porast domaćih cijena). Zato je važno ukupno inozemno zaduženje, kako se time ne bi ostvarivao priljev novčanih sredstava koja mogu znatno utjecati na stabilnost domaćih cijena, kao i na veliko pogoršanje vanjskotrgovinske bilance zemlje, što može dovesti do dugoročnih problema u razvoju gospodarstva.

Kako inozemni dug poslovnih banaka čini velik udio u ukupnom inozemnom zaduženju, HNB se koristi mjerama kojima može utjecati na ponašanje banaka. Jedna od njih, na koju je u ovom radu stavljen naglasak, jest i granična obvezna pričuva.¹ To je obvezni devizni depozit položen na neodređeni rok na devizni račun u središnjoj banci. Iznos depozita određuje se kao postotak osnovice koju čini kumulativni porast inozemne pasive banke s obzirom na bazno razdoblje. Velik je problem odrediti vrijednost tog postotka kojim bi se postigli željeni učinci na bankovni sustav.

Osim granične obvezne pričuve, korištene su još dvije mjere – posebna obvezna pričuva i obvezni blagajnički zapisi. Posebna obvezna pričuva mjera je slična graničnoj obveznoj pričuvi, a od nje se razlikuje po obuhvatu izvora sredstava zaduženja poslovnih banaka. Obračunava se na izdane obveznice, neovisno o tome jesu li one izdane u zemlji ili inozemstvu.

Obvezni blagajnički zapisi vrijednosni su papiri koje poslovne banke moraju upisati kod središnje banke na prekoračenje dopuštenog rasta kreditnih plasmana. Njihov upis reguliran je posebnim odlukama središnje banke,² a rok dospijeca im je 360 dana. Posebnost tih vrijednosnih papira je u tome da s njima nije moguće trgovati na sekundarnom tržištu.

Obvezna pričuva ili politika rezervi likvidnosti,³ posljednja je mjera središnje banke koja je korištena u ovom radu. To je jedna od najstarijih mjera kojom se koriste središnje banke. Na najrazvijenijim financijskim tržištima značenje te mjere bitno je smanjeno i kompenzirano drugim mjerama monetarne politike, posebno operacijama na otvorenom tržištu.

Važnost te mjere, posebno na nerazvijenijim financijskim tržištima, jest u tome da se pomoću nje jednostavno kontrolira monetarna i kreditna multiplikacija novca. Osim toga,

¹ Godine 2004. započela je primjena GOP-a po stopi od 24%; u veljači 2005. godine stopa je povećana na 30% i obračunavala se u odnosu prema istome baznom razdoblju. U svibnju iste godine stopa izdvajanja je još jedanput povećana i iznosila je 40% s obzirom na početno obračunsko razdoblje. U studenom 2005. godine odluka je izmijenjena na način da su u obračun uključeni i neradni dani, a dan obračuna pomaknut je na drugu srijedu u mjesecu. U prosincu 2005. godine novom izmjenom odluke uvedeno je i drugo obračunsko razdoblje, a na porast duga s obzirom na to novo obračunsko razdoblje izdvaja se dodatnih 15% porasta inozemnog zaduženja. Posljednjom izmjenom odluke iz lipnja 2006. proširena je osnovica za izdvajanje GOP-a na jamstva te na druga plasiranja koja se vode izvanbilančno, a stopa izdvajanja GOP-a za takve plasmane iznosi 55%.

² Obvezni su blagajnički zapisi kao mjera središnje banke prvi put bili na snazi tijekom 2003. godine, a tada je dopušteni rast plasmana bio 16% godišnje, odnosno 4% kvartalno i u toj se dinamici obavljao njihov upis. Mjera je ponovno na snazi od siječnja 2007, pri čemu je u početku dopušteni rast plasmana bio 1% mjesečno, ali je tijekom godine ta mjera nekoliko puta mijenjana. Za razliku od 2003. godine, kada je mjera trajala samo godinu dana, očekuje se da će ta mjera sada biti dugotrajnija.


³ Obvezna je pričuva propisani iznos dijela prikupljenih depozita koji poslovne banke minimalno moraju izdvojiti na posebne račune u središnjoj banci ili održati na svojim računima u obliku likvidnih financijskih sredstava.

toj su mjeri podložne isključivo institucije na koje utječe središnja banka, a to su banke i štedionice, dok su ostali sudionici financijskog tržišta isključeni. Budući da je na najrazvijenijim financijskim tržištima udio nebankarskog sektora veći od 50%, jasno je zašto je na njima oslabio utjecaj te mjere.

Poslovne banke, pak, traže različite načine kojima bi zaobišle mjere što ih propisuje HNB te ostvarile interese svojih vlasnika, ponajprije što veću dugoročnu dobit.

U poslovanju hrvatskih banaka, na strani izvora sredstava velik dio čine kratkoročni depoziti, dok su drugi bitan izvor sredstava srednjoročni i dugoročni krediti uzeti na svjetskome financijskom tržištu. Na strani plasmana, pak, prevladavaju srednjoročni i dugoročni odobreni krediti stanovništvu i gospodarstvu. Sve je značajniji i udio kratkoročnih plasmana stanovništvu putem okvirnih kredita po tekućim računima i putem kreditnih kartica. S obzirom na to da banke posljednjih godina u većoj mjeri kreditiraju stanovništvo, koje se pak pretežito zadužuje za finalnu potrošnju, i to velikim dijelom uvozne robe, HNB svojim mjerama nastoji utjecati na banke, kako bi one smanjile kreditiranje stanovništva za finalnu potrošnju. Na taj način HNB nastoji utjecati na cjelokupno gospodarstvo jer bi dosadašnje ponašanje banaka i stanovništva, bez reakcije središnje banke gotovo sigurno dovelo do gospodarskog sloma.

Slika 1. Distribucija kredita banaka po institucionalnim sektorima (u mlrd. kn)



Najvažniji cilj poslovnih banaka jest ostvarivanje dobiti.⁴ Međutim, njihova uloga u financijskom sustavu neke zemlje mnogo je važnija i kompleksnija od jednostavnog ostvarivanja dobiti od poslovanja. Banke svojom aktivnošću utječu na druge poslovne subjekte, a samim time i na cjelokupno gospodarstvo neke zemlje. Središnja banka svoje ciljeve ne ostvaruje izravnim kontaktom s drugim subjektima u financijskom sustavu neke zemlje, građanima i poduzećima, već djeluje posredno, utjecajem na poslovne banke.

Vlasnici hrvatskih banaka najvećim dijelom potječu s prostora Europske unije, gdje ne mogu ostvarivati tolike dobiti od odobrenih kredita jer su tržišni uvjeti takvi da su kamatne stope na odobrene kredite osjetno niže nego u Hrvatskoj. Kako bi zadovoljile želje svojih vlasnika i zaobišle mjere koje im propisuje HNB, poslovne su banke velik dio svog poslovanja prebacile na povezana poduzeća. Zato je u drugoj polovici 2006. godine zabilježen blagi pad inozemnog duga poslovnih banaka, a porastao je udio inozemnog duga sektora poduzeća.⁵ HNB je, pak, kako bi zaustavio takvo ponašanje banaka, svoje mjere, koliko god su mu dopuštale zakonske ovlasti, proširio i na povezana poduzeća, da bi svojim mjerama u najvećem mogućem opsegu obuhvatio sve poslovne subjekte na koje može izravno ili neizravno utjecati.

3. Matematički modeli

U ovom radu opisat ćemo samo mali dio iz širokog spektra različitih vrsta matematičkog programiranja koji je korišten za razvijanje modela odnosa između HNB-a i poslovnih banaka. Kako je ovdje matematički model postavljen kao problem dvorazinskog programiranja, ukratko ćemo izložiti osnovne pojmove potrebne za njegovo razumijevanje.

Bitno obilježje svih problema dvorazinskog programiranja jest to da donositelj odluke na gornjoj razini utječe na ponašanje donositelja odluke na donjoj razini, na njegov moguć izbor i korist koja proizlazi iz tog izbora.

Prvu formulaciju problema dvorazinskog programiranja u monografiji o tržišnoj ekonomiji *Marktform und Gleichgewicht* postavio je H. von Stackelberg 1934. godine. Ekonomska teorija igara proučava specijalan tip problema dvorazinskog programiranja poznat pod nazivom Stackelbergove igre. Opću definiciju problema, koja obuhvaća više razina, prvi su opisali Bialas i Karwan 1982. godine.

Problem dvorazinskog programiranja poseban je slučaj problema višerazinskog programiranja. Tu grupu problema matematičkog programiranja odlikuju ova zajednička obilježja:

- dvije su razine donositelja odluke, gornja i donja, a među njima postoji hijerarhijski odnos i jedna na drugu utječu,
- odluka se najprije donosi na gornjoj razini (u terminima teorije igara donosi je igrač koji prvi povlači potez),

⁴ U Galac i Dukić (2005) iznesen je stav da pojedine banke tržišni udio, i time ostvareni dugoročni profit, pretpostavljaju trenutačno ostvarenom profitu.

⁵ Sektor poduzeća obuhvaća i leasing kuće, koje su uglavnom vlasnički povezane s bankama.

- nakon toga reagira donja razina, koja kreira i provodi svoju strategiju, i to kao odgovor na potez gornje razine,
- obje razine imaju svoj cilj ili korisnost neovisno o ostalim jedinicama sustava,
- međudjelovanje donositelja odluka iskazani su kao funkcije cilja, te kao skup odluka koje može donijeti svaki od njih.

U ovom tekstu promatra se veliki hijerarhijski sustav i proces međudjelovanja koji se ostvaruje u vremenu, pri čemu je na gornjoj razini središnja banka, a na donjoj skup svih poslovnih banaka. Svaka poslovna banka djeluje neovisno o ostalim poslovnim bankama, u skladu sa svojom poslovnom strategijom.

S matematičkog stajališta, problem dvorazinskog programiranja je NP-težak problem, što znači da ne postoje algoritmi koji u polinomijalnom vremenu nalaze optimalno rješenje. Takvi složeni problemi i njihovo rješavanje pobuđuju velik interes jer su zastupljeni u mnogim područjima primjene. U posljednjih 30 godina različiti autori predložili su dvadesetak algoritama za rješavanje tih problema. Međutim, ti su algoritmi ili izuzetno neefikasni ili izrazito nepraktični u primjeni. Stoga se u praksi konstruiraju heurističke, a to je učinjeno i u ovom radu.

Izrađena su dva modela koja opisuju sadašnje stanje u djelovanju središnje banke prema poslovnim bankama. Prvi model, osim obvezne pričuve kao trajne mjere djelovanja, obuhvaća GOP i POP. Drugi model, koji opisuje sadašnje stanje jest proširenje prvog modela za upis OBZ-a.

Razlog za to razdvajanje na dva modela leži u činjenici da je upis obveznih blagajničkih zapisa mjera koja je na snazi od 1. siječnja 2007. godine. Dodatan razlog za razdvajanje na dva modela jest činjenica što je to mjera koja se obično smatra mjerom kratkog daha, i koja će biti na snazi ograničeno vrijeme.⁶ Sredstva koja su vezana ulaganjem u obvezne blagajničke zapise vraćaju se u sustav s dospijećem zapisa.⁷ U obveznim su, pak, pričuvama akumulirana velika sredstva bez roka dospijeća, koja ne mogu trenutačno, bez posljedica, biti vraćena u sustav.

U modelima je kao funkcija cilja središnje banke postavljeno smanjenje rasta plasma na poslovnih banaka prema stanovništvu. Odluka središnje banke jest postotak GOP-a. Kao funkcija cilja poslovnih banaka postavljena je maksimizacija dobiti.

3.1. Matematički model koji obuhvaća graničnu obveznu pričuvu i posebnu obveznu pričuvu

Radi formuliranja navedenoga matematičkog modela, definirajmo sljedeće vrijednosti

Indeksi

i – tip zaduženja ($i = 1$ krediti uzeti u inozemstvu, $i = 2$ obveznice)

j – poslovna banka, $j = 1, \dots, J$

⁶ Kada je ta mjera prethodno bila na snazi, vrijedila je samo godinu dana, odnosno tijekom 2003. godine, obračun i izdvajanje počelo je krajem prvog kvartala 2003. godine, a završilo je krajem prvog kvartala 2004. godine

⁷ Trenutačna odluka propisuje rok dospijeća od 360 dana.

- l – tip plasmana zaduženih sredstava ($l = 1$ stambeni krediti, $l = 2$ ostali krediti stanovništvu, $l = 3$ krediti poduzećima)
- p – propisani postotak granične/posebne obvezne pričuve
- t – vremensko razdoblje zaduživanja (makrorazdoblje), $t = 1, \dots, T$
- τ – vremensko razdoblje plasiranja (mikrorazdoblje) $\tau \in S_p$, $t = 1, \dots, T$

Parametri

- op^8 – postotak obvezne pričuve
- kb – kreditni multiplikator poslovne banke
- x_{jil0} – stanje duga banke j iz izvora sredstava i , koja je banka plasirala u plasman l na početku promatranog razdoblja
- W_{jl0} – stanje plasmana l banke j na početku promatranog razdoblja
- o_l – broj obroka u kojima se vraća plasman l
- b_i – broj obroka u kojima se vraća zaduženje i
- k_{it} – kamatna stopa uz koju se zadužuje iz izvora i u razdoblju t
- m_{jlt} – kamatna stopa uz koju banka j plasira sredstava l u razdoblju t
- d_{it} – minimalna potražnja koja mora biti zadovoljena za kreditnim plasmanima l u razdoblju t
- g_{it} – maksimalna ponuda kreditnih plasmana l u razdoblju t

Oznake

- y_{jilpt} – iznos sredstava što ih je banka j vratila putem anuiteta za izvor sredstava i , po kamatnoj stopi k_{it} , uz izdvajanje granične obvezne pričuve po stopi p u razdoblju t , a koja je plasirala u plasman l
- W_{jlt} – ukupni iznos sredstava što ih je banka j plasirala u plasman l u makrorazdoblju t po kamatnoj stopi m_{jlt}
- U_{jlt} – ukupni iznos sredstava što ih je banka j primila putem anuiteta iz plasmana l po kamatnoj stopi m_{jlt} u makrorazdoblju t
- Q_{jilpt} – stanje duga banke j iz izvora i posuđenih po kamatnoj stopi k_{it} , uz izdvajanje granične obvezne pričuve p na kraju razdoblja t
- R_{jlt} – stanje plasmana banke j u plasman l plasiranih po kamatnoj stopi m_{jlt} na kraju razdoblja t

Varijable odlučivanja

- x_{jilpt} – iznos sredstava što ih je banka j u razdoblju t posudila iz izvora i , po kamatnoj stopi k_{it} , uz izdvajanje granične obvezne pričuve po stopi p , a kako bi ih plasirala u plasman l
- w_{jlt} – iznos sredstava što ih je banka j plasirala u plasman l u mikrorazdoblju τ po kamatnoj stopi m_{jlt}

⁸ $op = 17\%$.

$$z_{ilpt} = \begin{cases} 1, & \text{ako je postotak propisane granične (i = 1) / posebne (i = 2) obvezne pri-} \\ & \text{čuve na posuđena sredstva za plasman l u razdoblju t jednak p} \\ 0, & \text{inače l = 1, 2 (krediti stanovništvu), l = 3 (krediti poduzećima)} \end{cases}$$

$$v_{jilpt} = \begin{cases} 1, & \text{ako je } \sum_{i,p,t} (x_{jilpt} - y_{jilpt}) > 0 \\ 0, & \text{inače } x_{jilpt} w_{jlt} \geq 0; z_{ilpt}, v_{jilpt} \in \{0, 1\} \end{cases}$$

Vrijede ovi izrazi za oznake:

$$y_{jilpt} = \frac{1}{b_i} (x_{jil0} + \sum_{\alpha=\max(t-b_i, 1)}^{t-1} z_{ilp\alpha} x_{jilp\alpha}), \quad \forall j, i, l, p, t \quad (a)$$

$$W_{jlt} = \sum_{\tau \in S_t} w_{jl\tau}, \quad \forall j, l, t \quad (b)$$

$$U_{jlt} = \frac{1}{o_l} (W_{jlt0} + \sum_{\alpha=\max(t-o_l, 1)}^{t-1} W_{jl\alpha}), \quad \forall j, l, t \quad (c)$$

$$Q_{jilpt} = \sum_{l=1}^3 (x_{jil0} + \sum_{\alpha=1}^t (x_{jilp\alpha} - y_{jilp\alpha})), \quad \forall j, i, p, t \quad (d)$$

$$R_{jlt} = W_{jlt0} + \sum_{\alpha=1}^t (W_{jl\alpha} - U_{jl\alpha}), \quad \forall j, l, t \quad (e)$$

Izraz (a) iskazuje koliko sredstava banka j treba vratiti u svakom razdoblju po osnovi kredita uzetih u inozemstvu ili po osnovi izdanih obveznica.⁹ Izraz (b) predočuje koliki su ukupni plasmani banke j u makrorazdoblju t ,¹⁰ a izraz (c) koliki su primici te iste banke po osnovi povrata dijela plasmana danih u prethodnim razdobljima.¹¹ Izraz (d) govori koliko je stanje zaduženja banke j na kraju razdoblja t ,¹² a izraz (e) koliko je stanje plasmana banke j na kraju razdoblja t .¹³

⁹ Pretpostavljeno je da se sredstva vraćaju u jednakim mjesečnim obrocima. U stvarnosti nije tako, već se krediti koje banke trebaju vratiti po pravilu vraćaju u kvartalnim, polugodišnjim ili godišnjim otplatnim kvotama, a obveznice se obično isplaćuju po dospijeću, pri čemu se kamata (kupon) isplaćuje polugodišnje ili godišnje, a moguće su i varijante kada se cjelokupni iznos (glavnica i kamata) isplaćuje s datumom dospijeća obveznice.

¹⁰ Iznos interkalarne kamate, koji banka naplati za isplate kredita prije datuma na koji kredit dospijeva, zanemariv je u odnosu prema svim ostalim prihodima poslovne banke.

¹¹ Danas banke odobravaju kredite s fleksibilnim datumom dospijeća (dospijeće kredita može biti bilo koji dan u mjesecu). Nekad su datumi dospijeća kredita bili "fiksni" za sve komitente i najčešće je dospijeće kredita bilo prvi ili posljednji dan u mjesecu, neovisno o danu u kojemu je kredit odobren.

¹² Bankovna pasiva.

¹³ Bankovna aktiva.

Model:

$$\min_z \sum_{\substack{l=1,2 \\ j,t}} (W_{jlt} - U_{jlt}) \quad (I)$$

uz ograničenja:

$$\sum_p z_{ilpt} = 1, \quad \forall j, l, t \quad (1)$$

$$\max \sum_i \left(\sum_l m_{jlt} R_{jlt} - \sum_{i,p} k_{it} Q_{jipr} \right) \quad \forall j \quad (II)$$

uz ograničenja:

$$W_{jlt} \leq \left(kb \left(\frac{100 - op}{100} \right) \right) \left(\sum_i x_{jil0} + \sum_{i,p,\alpha=1}^t v_{jilpt} \frac{100 - p}{100} z_{ilp\alpha} (x_{jilp\alpha} - y_{jilp\alpha}) \right. \\ \left. + \sum_{i,p,\alpha=1}^t (1 - v_{jilpt}) (x_{jilp\alpha} - y_{jilp\alpha}) \right) + \sum_{\alpha=1}^t U_{jl\alpha} - \sum_{\alpha=1}^{t-1} W_{jl\alpha} - W_{j0}, \quad \forall j, l, t \quad (2)$$

$$x_{jilpt} \leq M z_{ilpt}, \quad \forall j, l, p, t \quad (3)$$

$$\sum_{\alpha=1}^t (x_{jilp\alpha} - y_{jilp\alpha}) \leq M v_{jilpt}, \quad \forall j, l, p, t \quad (4)$$

$$\sum_{\alpha=1}^t (y_{jilp\alpha} - x_{jilp\alpha}) \leq M (1 - v_{jilpt}), \quad \forall j, l, p, t \quad (5)$$

$$W_{jlt} \geq d_{jlt}, \quad \forall j, t, l = 1, 2 \quad (6)$$

$$W_{jlt} \leq g_{jlt}, \quad \forall j, l, t \quad (7)$$

$$x_{jilpt} \quad w_{jlt} \geq 0, \quad z_{jilpt}, \quad v_{jilpt} \in \{0, 1\}, \quad \forall j, i, l, p, t \quad (8)$$

U izrazima (a) i (c) iznosi su jednaki otplatnim kvotama (ratama), dok prihodi ostvareni od naplaćenih kamata služe za pokriće kamatnih rashoda i ostvarivanje dobiti iz poslovanja.

Za kreditni multiplikator poslovne banke kb vrijedi izraz $kb = \frac{1}{1 - sz \times (1 - op)}$, gdje je, op propisani postotak obvezne pričuve, a sz postotak zadržavanja kredita u banci u obliku plasmana. Uz pretpostavljenu stopu zadržavanja $sz = 60\%$, izraz poprima oblik:

$$kb = \frac{100}{100 - 0,6 \times (100 - op)} = \frac{100}{40 + 0,6op} \quad (9)$$

Uvrštenjem izraza (9) u (2) dobivamo izraz:

$$W_{jt} \leq \left(\frac{100 - op}{40 + 0,6op} \right) \left(\sum_i x_{jit0} + \sum_{i,p,\alpha=1}^t v_{jilp} \frac{100 - p}{100} z_{ilp\alpha} (x_{jilp\alpha} - y_{jilp\alpha}) \right) + \sum_{i,p,\alpha=1}^t (1 - v_{jilp}) (x_{jilp\alpha} - y_{jilp\alpha}) + \sum_{\alpha=1}^t U_{jl\alpha} - \sum_{\alpha=1}^{t-1} W_{jl\alpha} - W_{jt0}, \quad \forall j, l, t \quad (10)$$

U modelu (I) – (10) središnja banka minimizira porast plasmana stanovništvu, dok poslovne banke, u granicama restrikcija koje im nameće gornja razina (voditelj), maksimiziraju svoju dobit. Mikrorazdoblja i makrorazdoblja uključena su u model jer središnja banka (voditelj) odluku o promjeni stope granične ili posebne obvezne pričuve donosi jedanput mjesečno, dok sljedbenici (poslovne banke) svoje odluke mogu donositi dnevno.

Ograničenje (1) govori da postoci granične i posebne obvezne pričuve mogu popriimiti samo jednu vrijednost za svaku vrstu izvora sredstava, kao i za svaku vrstu plasmana banaka. Oni su jednaki za sve banke i neovisni su o kamatnoj stopi po kojoj banka pribavlja sredstva. Osim toga, ti su postoci uvijek cjelobrojne vrijednosti.

Ograničenje (10) znači da sredstva koja banka j može plasirati u instrument l ne mogu biti veća od raspoloživih. Raspoloživa sredstva banke j sastoje se od početnog stanja posuđenih sredstava kojemu su pribrojena preostala sredstva posuđena iz izvora obuhvaćenih graničnom ili posebnom obveznom pričuvom, umanjena za sredstva vraćena po prethodnim posudbama te za postotak te pričuve u slučaju porasta zaduženja banke, ili samo umanjena za taj iznos u slučaju pada zaduženja banke po obuhvaćenim izvorima sredstava. Ta se sredstva množe kreditnim multiplikatorom (množiteljem) u promatranom razdoblju. U raspoloživa sredstva ulaze i naplaćene rate, prije izvršenih plasmana umanjene za plasirana sredstva u prethodnim razdobljima. To je ključno ograničenje u modelu.

Ograničenja (3) opisuju činjenicu da se banke mogu zadužiti u inozemstvu samo uz jednu stopu propisane granične ($i = 1$) / posebne ($i = 2$) obvezne pričuve na posuđena sredstva za plasman l u razdoblju t , pri čemu je M veliki realni broj.

Ograničenja (4) i (5) bitna su za određivanje statusa binarne varijable v , koja govori ima li u nekom razdoblju ukupno više posuđenih ili vraćenih sredstava,¹⁴ što je bitno radi izdvajanja granične ili posebne obvezne pričuve.

¹⁴ Ovisno o tome postoji li rast ili pad ukupnoga inozemnog zaduživanja.

Ograničenja (6) donje su ograde na svaki tip plasmana svake banke u svakom razdoblju. Donja je ograda razina planiranoga tržišnog udjela ili prag profitabilnosti.

Ograničenja (7) kazuju da je poznata maksimalna potražnja sredstava¹⁵ svake banke i u svakom razdoblju koja može biti zadovoljena, odnosno gornja ograda na razinu plasmana.

I, na kraju, ograničenja (8) uvjeti su ne-negativnosti i binarnosti varijabli.

3.2. Matematički model proširen na opis obveznih blagajničkih zapisa

Taj se model razlikuje od prethodnoga samo po ograničenju (10), koje je zamijenilo ovo ograničenje:

$$\begin{aligned}
 W_{jlt} \leq & \left(\left(\frac{100 - op}{40 + 0,6op} \right) \left(\sum_i x_{jil0} + \sum_{i,p,\alpha=1}^t v_{jilpt} \frac{100 - p}{100} z_{ilp\alpha} (x_{jilp\alpha} - y_{jilp\alpha}) \right. \right. \\
 & \left. \left. + \sum_{i,p,\alpha=1}^t (1 - v_{jilpt}) (x_{jilp\alpha} - y_{jilp\alpha}) \right) \right) + \sum_{\alpha=1}^t U_{jl\alpha} - \sum_{\alpha=1}^{t-1} W_{jl\alpha} - W_{jl0} \\
 & - 0,5 \sum_{\alpha=2}^t \left(\max \left\{ \left[\frac{\sum_{\beta=1}^{\alpha-1} W_{jl\beta}}{W_{jl0}} - \frac{\alpha - 1}{100} \right], 0 \right\} \cdot W_{jl0} \right), \quad \forall j, l, t \quad (11)
 \end{aligned}$$

Navedeno ograničenje govori kolika su najveća raspoloživa sredstva što ih banka j može plasirati u instrument l . Raspoloživa sredstva banke j sastoje se od početnog stanja posuđenih sredstava kojemu su pribrojena preostala sredstva posuđena iz izvora obuhvaćenih graničnom ili posebnom obveznom pričuvom, umanjena za sredstva vraćena po prethodnim posudbama te za postotak te pričuve u slučaju porasta zaduženja banke, ili samo umanjena za taj iznos u slučaju pada zaduženja banke po obuhvaćenim izvorima sredstava. Ta se sredstva množe kreditnim multiplikatorom (množiteljem) u promatranom razdoblju. U raspoloživa sredstva ulaze i naplaćene rate, prije izvršenih plasmana umanjene za sredstva plasirana u prethodnim razdobljima. Ako poslovna banka premaši dopušteni rast plasmana, raspoloživa se sredstva umanjuju za iznos u kojemu banka mora upisati obvezne blagajničke zapise HNB-a.

4. Relaksacija modela i heuristika za rješavanje problema

Opisani problem, kao i svi problemi dvorazinskog programiranja, pripadaju klasi NP-teških problema. Za rješenje tog problema razvijena je heuristika bazirana na kombinaciji metoda pretraživanja i tabu pretraživanja. Heuristika se provodi sljedećim postupkom:

¹⁵ To u stvarnosti znači da je banka odredila maksimalan iznos plasmana u svakom razdoblju kojim će zadovoljiti iskazanu potražnju kreditnih sredstava.

1. Za odabranu banku, mijenja se stopa granične/posebne obvezne pričuve i provjerava se je li uz tu stopu profitabilno odobravanje plasmana po postojećim kamatnim stopama za svaku vrstu plasmana.

2. Pamti se najniža i najviša stopa pričuve uz koju prestaje profitabilno poslovanje po svakoj vrsti plasmana posebno.

3. Ako je pronađeno rješenje za svaku vrstu plasmana, prestaje postupak traženja.

4. Provjerava se jesu li obrađene sve banke. Ako nisu, odabire se sljedeća banka i ide se natrag, na 2. korak, a ako jesu, prelazi se na korak 6.

5. Izračunava se prosječna stopa granične/posebne obvezne pričuve za sustav po svakoj vrsti plasmana posebno.

6. Završetak procesa izračuna.

Dijagram toka konstruirane heuristike prikazan je na slici 2. *Dijagram toka heuristike*. Za oba modela napravljena u ovom radu primijenjena je ista heuristika, ali s različito relaksiranim modelom.

U numeričkom dijelu provedene su određene relaksacije koje pojednostavnjuju model ili pak, zbog poslovne tajne, ne dopuštaju da banke čiji su se podaci koristili, budu prepoznate.

Prva je pretpostavka da je kamatna stopa na inozemno zaduženje za sve banke jednaka i da iznosi EURIBOR + 1,5 postotni bod za kredite, te EURIBOR + 2 postotna boda za obveznice. Prosječna vrijednost EURIBOR-a za plasmane od godinu dana koja je korištena u numeričkom izračunu bila je 4,06%.

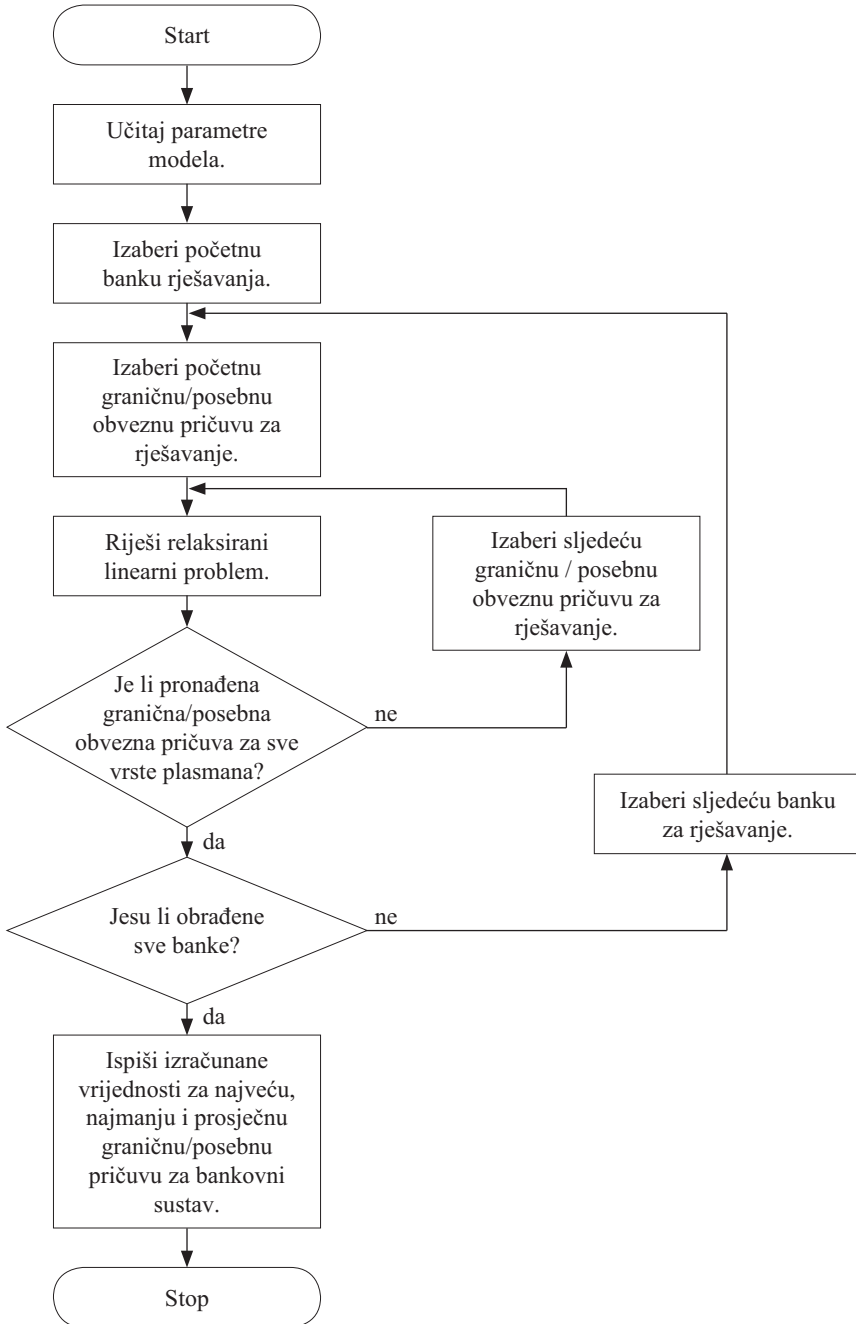
Kamatne stope po kojima banke plasiraju sredstva kreću se u rasponu od 4,02 do 8,21% za stambene kredite. Pri ostalim plasmanima stanovništvu kamatne su stope u rasponu od 7,30 do 11,92%. Kamatne stope za plasmane gospodarstvu imaju najveći raspon i kreću se od 5,20 do 11,75%.¹⁶ Podaci o korištenim kamatnim stopama za izračune dani su u tablicama 7. i 8.

Kamatne su stope u svim razdobljima promatranja, za svaku banku jednake jer smo uzeli prosječnu kamatnu stopu. Na taj smo način donekle uzeli u obzir i činjenicu da se kamatne stope mijenjaju. Osim toga, napravljena je dodatna analiza u kojoj je umjesto nominalne kamatne stope koju poslovne banke primjenjuju korištena njihova efektivna kamatna stopa (tabl. 9).

Kao što je rečeno u opisu modela, stopa granične ili posebne obvezne pričuve uvijek je cjelobrojna vrijednost. Analiza se provodi u rasponu od 10 do 80%, jer u tom slučaju zajedno s obveznom pričuvom (koja prema odluci o izdavanju obvezne pričuve iznosi 17%) čini izdavanje pričuve od najviše 97% iznosa povećanja posuđenih izvora sredstava, koja su predmet istraživanja. Nadalje, u model je uvedena pretpostavka da su stope granične i posebne obvezne pričuve jednake ($z_{1pt} = z_{2pt}$) i da je postotak granične/posebne obvezne pričuve na sve vrste plasmana jednak ($z_{i1pt} = z_{i2pt} = z_{i3pt}$).

¹⁶ Podaci su dobiveni od HNB-a i korišteni su za ovaj rad. Određene kategorije predočuju prosjeke više različitih tipova plasmana banaka (kunski krediti, valutni krediti, ...).

Slika 2. Dijagram toka heuristike



U modelu se promatraju samo makrorazdoblja jer se zbroj svih događanja u mikro-razdobljima unutar jednog makrorazdoblja može promatrati kao jedinstveni događaj u tom makrorazdoblju.

Kako su u modelu postavljene donja (tržišni udio banke) i gornja (maksimalna potražnja) ograda za svaku vrstu plasmana, iz numeričkih smo izračuna primijetili sljedeću činjenicu. Naime, za svaku banku i za svaku vrstu plasmana pri niskim su stopama granične/obvezne pričuve plasirana sredstva na gornjoj granici. Kako se stope granične/obvezne pričuve povećavaju, određeni plasmani gornje granice padaju na donju granicu (dakle, od iznosa dovoljnoga da se zadovolji maksimalna potražnja padaju na iznos dovoljan da se ostvari planirani tržišni udio). Pri tome za svaku banku i svaku vrstu plasmana postoji jedna stopa granične/obvezne pričuve pri kojoj plasirana sredstva s gornje granice padaju na donju. Takve su stope onda izračunane za svaku banku i za svaku vrstu plasmana. Potom je za svaku vrstu plasmana izračunana prosječna vrijednost GOP-a kao aritmetička sredina svih takvih GOP-ova, a ne samo minimalnoga i maksimalnoga. Prosječna je vrijednost izračunana kao aritmetička sredina jer smo pretpostavili da su tržišni udjeli jednaki. Treba napomenuti da je ta relaksacija uvedena zato da se iz podataka o tržišnom udjelu i kamatama ne prepoznaju banke obuhvaćene analizom. Konstruirana programska podrška bez ikakvih problema i napora dopušta različite tržišne udjele. Također, uzme li se u obzir da je većina kamatnih stopa za pojedinu vrstu plasmana i za pojedinu banku jednaka, tržišni udio zapravo i nema veliku ulogu prilikom izračunavanja prosječne vrijednosti GOP-a.

U sklopu opisanih heuristika u svim je točkama promatranja vrijednost binarne varijable v_{ijpt} postavljena na 1.¹⁷ Drugim riječima, pretpostavlja se stalni rast zaduživanja banaka jer to odgovara realnoj situaciji u bankarskom sustavu. Pri tome je moguća zamjena kreditnog zaduživanja zaduživanjem putem obveznica, i obratno. Zato smo u numeričkim izračunima, bez smanjenja općenitosti, izračunavali samo GOP.

Promatra se iznos granične/posebne obvezne pričuve pri kojemu pojedina vrsta plasmana doživljava promjenu s gornje na donju granicu plasiranja. Graničnu/posebnu obveznu pričuvu (p) propisuje gornja razina odlučivanja (središnja banka), dok poslovne banke odlučuju o iznosu svog zaduženja uz zadane uvjete (ne mogu utjecati na gornju razinu, kao ni na svjetsko tržište kapitala).

Za sve je banke inicijalno postavljen jednak udio na tržištu, te je u izračunima prosječnih vrijednosti stopa granične/posebne obvezne pričuve dovoljno upotrijebiti običnu aritmetičku sredinu. Početna razina plasmana od koje kreće izračun za svaku pojedinu banku napravljena je na način da je proveden izračun uz stopu granične obvezne pričuve od 55%, a zatim je ukupni zbroj svih plasmana raspoređen prema udjelima pojedinih plasmana u ukupnim plasmanima bankarskog sektora. Postoje dva tipa poslovnih banaka, a razlikuju se prema tome odobravaju li stambene kredite ili ne. Udjeli plasmana ovisno o tipu banke dani su u sljedećoj tablici.

Iz linearnih programa pomoću kojih je obavljan izračun uklonjeni su izrazi za oznake. Vrijednosti koje daju oznake iz prvog modela izračunane su kasnije unutar računalnog programa. Jedine korištene oznake su one za povrate ranije odobrenih plasmana (y_{ijpt}).

¹⁷ $v_{ijpt} = 1, \forall j, i, l, p, t$

Tablica 1. Udjeli plasmana u ukupnim plasmanima poslovne banke (u %)

Tip plasmana	Stambeni krediti	Ostali krediti stanovništvu	Krediti gospodarstvu
banke koje odobravaju stambene kredite	31,87	32,45	35,68
banke koje ne odobravaju stambene kredite	0,00	47,63	52,37

Izvor: HNB

5. Numerički rezultati i analize

Promatrane su poslovne banke u hrvatskome bankarskom sustavu. Osnovna razlika među pojedinim bankama jest različita kamatna politika. Vrijednosti kamatnih stopa dobivene su od HNB-a, a uzete su prosječne godišnje vrijednosti svake pojedine banke. Kamatne stope koje su primijenjene u analizi dane su u tablicama u prilogu (tabl. 7. i 9, vidi prilog).

Promatran je ostvareni iznos dobiti uz različite stope granične obvezne pričuve, odnosno stopa granične obvezne pričuve pri kojoj pojedini plasmani s gornje ograde padaju na donju.

Tablica 2. Udjeli plasmana u bankarskom sustavu (u %)

Tip plasmana	Stambeni krediti	Ostali krediti stanovništvu	Krediti gospodarstvu
Udjeli plasmana	24,37	36,02	39,61

Izvor: HNB

Pomoću podataka o udjelima pojedinih plasmana unutar bankarskog sustava, te izračunanih prosječnih vrijednosti za graničnu obveznu pričuvenu unutar svakoga pojedinog modela izračunana je stopa granične obvezne pričuve koja znatnije utječe na ponašanje sustava.

Analiza je napravljena uz primjenu nominalne kamatne stope. Ta kamatna stopa na neki način ipak skriva pravo stanje unutar bankovnog sustava.

Primijetimo da je razina plasmana ograničena, tj. da postoje donje i gornje ograde. Za mali GOP svaka banka u svakom razdoblju po svakom tipu plasmana maksimalno plasira, a za veliki GOP plasira minimalno. Prag na kojemu dolazi do opisane promjene ponašanja poslovne banke razlikuje se za pojedine poslovne banke.

U tablicama 3-6. dane su minimalne i maksimalne vrijednosti GOP-a uz koje za pojedine plasmane i pojedine banke dolazi do promjene ponašanja, tj. do pada s gornje na donju granicu plasmana (dosegnut je prag profitabilnosti ili ostvaren planirani tržišni udio za taj plasman i tu banku). Potom je izračunana prosječna vrijednost praga GOP-a kao aritmetička sredina svih pragova GOP-a.

Na opisani je način u modelu koji obuhvaća graničnu obveznu pričuvenu i posebnu obveznu pričuvenu sastavljena tablica 3.


Tablica 3. Rezultati osnovnog modela sadašnjeg stanja (u %)

Tip plasmana	Granična obvezna pričuva		
	minimalna	maksimalna	prosječna
stambeni krediti	16	59	40,38
ostali krediti stanovništvu	54	74	64,03
krediti gospodarstvu	35	72	55,56

Izvor: izračun autora

Upotrebom podataka o udjelima pojedinih plasmana iz tablice 2. i podataka o prosječnoj graničnoj obveznoj pričuvi iz tablice 3.¹⁸ dobivena je stopa utjecaja granične obvezne pričuve sustava od 54,91%.

Slika 3. Utjecaj promjene granične obvezne pričuve na profitabilnost plasmana u ovisnosti o nominalnoj kamatnoj stopi – osnovni matematički model (u %)



Izvor: izračun autora

Drugo je istraživanje provedeno na modelu proširenom na upis obveznih blagajničkih zapisa.

¹⁸ $0,2437 * 40,38 + 0,3602 * 64,03 + 0,3961 * 55,56 = 54,91$


Tablica 4. Rezultati modela proširenog na upis obveznih blagajničkih zapisa (u %)

Tip plasmana	Granična obvezna pričuva		
	minimalna	maksimalna	prosječna
stambeni krediti	16	59	40,08
ostali krediti stanovništvu	35	65	53,03
kreditu gospodarstvu	35	71	55,32

Izvor: izračun autora

Izračunom na temelju podataka o prosječnom GOP-u iz tog modela dobivena je stopa utjecaja granične obvezne pričuve sustava od 50,78%. Ona je, prema očekivanjima, niža od stope iz prethodnog modela.

Slika 4. Utjecaj promjene granične obvezne pričuve na profitabilnost plasmana u ovisnosti o nominalnoj kamatnoj stopi – matematički model proširen na upis obveznih blagajničkih zapisa (u %)



Izvor: izračun autora

Kako nominalna kamatna stopa nije realna cijena kreditnih plasmana poslovnih banaka, provedena je i analiza uz primjenu efektivne kamatne stope. Čak ni analiza uz tu stopu nije apsolutno pouzdana jer dio bankovnih plasmana po izuzetno visokim efektivnim kamatnim stopama ostaje skriven od statističkog praćenja središnje banke (pod tim se razumijeva niz podataka koji nisu uključeni u redovito izvješćivanje središnje banke).

I drugi dio analize započeo je korištenjem osnovnog modela sadašnjeg stanja koji obuhvaća graničnu obveznu pričuvu i posebnu obveznu pričuvu, a jedina promjena u izračunima, kako je već napomenuto, bilo je uvrštenje efektivne kamatne stope na plasmana poslovnih banaka.


Tablica 5. Rezultati osnovnog modela sadašnjeg stanja (u %)

Tip plasmana	Granična obvezna pričuva		
	minimalna	maksimalna	prosječna
stambeni krediti	18	65	44,62
ostali krediti stanovništvu	57	80	67,71
krediti gospodarstvu	42	78	62,29

Izvor: izračun autora

Izračunom iz podataka o prosječnoj stopi utjecaja GOP-a dobivena je stopa utjecaja granične obvezne pričuve sustava od 59,94%. U istome modelu, ali uz primjenu nominalne kamatne stope, stopa utjecaja granične obvezne pričuve sustava bila je 54,91%, pa je stopa uz efektivnu kamatnu stopu za 9,16% veća od stope uz nominalnu kamatnu stopu, što nije zanemariva činjenica.

Slika 5. Utjecaj promjene granične obvezne pričuve na profitabilnost plasmana u ovisnosti o efektivnoj kamatnoj stopi – osnovni matematički model (u %)



Izvor: izračun autora


Nakon toga provedena je analiza modela proširenoga na upis obveznih blagajničkih zapisa, uz primjenu efektivne kamatne stope, i za nj su dobiveni sljedeći rezultati.

Tablica 6. Rezultati modela proširenoga na upis obveznih blagajničkih zapisa (%)

Tip plasmana	Granična obvezna pričuva		
	minimalna	maksimalna	prosječna
stambeni krediti	18	65	44,23
ostali krediti stanovništvu	44	76	60,65
krediti gospodarstvu	42	78	61,97

Za taj je model, uz efektivnu kamatnu stopu, izračunana stopa utjecaja granične obvezne pričuve sustava od 57,17%. Ona je, prema očekivanjima, niža od stope iz prethodnog modela iz 5.3. U istom je modelu, ali uz primjenu nominalne kamatne stope (pogl. 5.2), stopa utjecaja granične obvezne pričuve sustava bila 50,78%, pa je stopa uz primjenu efektivne kamatne stope 12,58% veća od stope uz nominalnu kamatnu stopu, što također nije zanemarivo.

Slika 6. Utjecaj promjene granične obvezne pričuve na profitabilnost plasmana u ovisnosti o efektivnoj kamatnoj stopi – matematički model proširen na upis obveznih blagajničkih zapisa (u %)



Izvor: izračun autora

Iz svih tih izračuna vidljivo je da je ponašanje banaka na sličan način neovisno o tome primjenjuje li se u izračunu nominalna ili efektivna kamatna stopa, a razlika je sama stopa GOP-a koja utječe na ponašanje banaka. Ta je stopa u izračunima koji su provedeni uz primjenu efektivne kamatne stope viša.

Osim toga, grafovi o utjecaju promjene GOP-a na profitabilnost poslovanja u ovisnosti o kamatnoj stopi pokazuju jednu zanimljivost – odvajanje linije utjecaja na ostale plasmane stanovništvu od glavne linije utjecaja GOP-a u modelu proširenom na upis obveznih blagajničkih zapisa (sl. 4. i 6).

Zanimljiva činjenica koja se uočava iz tablice rezultata (tabl. 4. i 6) jest to da je u modelu koji obuhvaća upis obveznih blagajničkih zapisa prosječna stopa utjecaja GOP-a na ostale plasmane stanovništvu niža od prosječne stope utjecaja na plasmane gospodarstvu. Iz slika se također vidi da mjera upisa obveznih blagajničkih zapisa gotovo uopće ne utječe na stambene kredite, kao ni na kredite gospodarstvu. Ta bi se pojava mogla objasniti činjenicom da su ti plasmani banaka već sada na osjetno nižoj razini profitabilnosti od ostalih kredita stanovništvu, te je kod njih i utjecaj pada profitabilnosti osjetno slabiji. Modeli su, osim toga, za pojedinu vrstu plasmana dopuštali ostanak na početnoj razini, te i to ima utjecaja na rezultate analiza provedenih primjenom kreiranih matematičkih modela.

Kada bi statistički podaci središnje banke obuhvatili i kredite poslovnih banaka sakrivene od statističkog praćenja i odobrene po visokim efektivnim kamatnim stopama, vrlo je vjerojatno da bi izračunane stope utjecaja GOP-a bile još veće.

6. Zaključak

Poslovne banke putem različitih naknada mogu znatno uvećati nominalnu kamatnu stopu. Zbog tih razloga analiza podataka uz korištenje nominalne kamatne stope može navesti na pogrešne zaključke, te se ovim radom sugerira upotreba efektivne kamatne stope.

Slike pokazuju da promjena stope GOP-a u svim modelima jednako utječe na stambene kredite i na kredite gospodarstvu, a promjena utjecaja postoji samo kod ostalih plasmana stanovništvu.

Poslovne banke vode takvu poslovnu (kamatnu) politiku da stopa GOP-a koju propisuje središnja banka nema negativnog utjecaja na razinu plasmana, već samo na njihovu profitabilnost. Na primjer, ako stambene kredite odobrava po niskoj kamatnoj stopi, poslovna banka to nadoknađuje visokom kamatnom stopom na kredite gospodarstvu ili na ostale plasmane stanovništvu. Neke druge banke odobravaju sve kredite po ujednačenim kamatnim stopama. Radi tržišnih uvjeta, poslovne banke znatnije ne povećavaju kamatne stope na postojeće bankarske proizvode kako ne bi izgubile tržišne udjele, već nastoje uvesti nove proizvode, za koje uvode različite naknade i tako zapravo podižu efektivnu kamatnu stopu, bez promjene nominalne kamatne stope ili čak uz njezino smanjenje.

Hrvatska ima relativno velik inozemni dug i on premašuje 80% BDP-a. To je razina duga koju se smatra potencijalnim okidačem za izbijanje dužničke krize. Na porast duga značajno utječu poslovne banke koje se zadužuju u inozemstvu da bi, radi nedovoljne domaće akumulacije kapitala, ta sredstva plasirale u obliku različitih kredita stanovništvu i gospodarstvu.

Cilj HNB-a definiran je zakonom, a to je prije svega stabilnost cijena, odnosno stabilnost ukupnoga ekonomskog sustava Republike Hrvatske. Središnja banka svojim mjerama može djelovati samo prema bankarskom sektoru te nastojati zaustaviti rast inozemnog zaduživanja banaka. Pokazuje se da je rast inozemnog duga poslovnih banaka ipak usporen, da se dug države čak i smanjuje, ali značajno raste inozemni dug ostalih domaćih sektora. Tom porastu duga ostalih domaćih sektora uvelike pridonose leasing društva, na koja s njima povezane banke prebacuju dio poslovanja.¹⁹

Matematički modeli dvorazinskog programiranja razvijeni u ovom radu opisuju samo odnose između središnje banke i poslovnih banaka, usmjerene na inozemno zaduživanje poslovnih banaka. Pri tomu je glavni cilj središnje banke smanjiti rast bankovnih plasmana stanovništvu jer se gospodarski subjekti relativno jednostavno mogu sami izravno zadužiti u inozemstvu, a središnja banka ne može utjecati na to. Rezultati analize ovih modela pokazuju da bi primjena kreirane programske podrške dobro došla u *ex ante* analizi učinaka monetarne politike. Iako su u analizi upotrijebljene pretpostavke koje pojednostavnjuju model, njezini su rezultati ipak dobar putokaz kako bi središnja banka mogla postupati prilikom donošenja odluke o razini GOP-a. Također, svaka se dodatna činjenica vezana za hrvatski monetarni sustav, kao i realni podaci, vrlo lako mogu uključiti u samu programsku podršku koja bi na taj način mogla imati važnu ulogu u regulaciji monetarnih kretanja.

U idućem razdoblju bilo bi važno da središnja banka poboljša statistiku praćenja plasmana poslovnih banaka. Podaci dobiveni tim putem mogli bi dati kvalitetniju sliku bankarskog sektora Republike Hrvatske. Pomoću tako obrađenih podataka središnja bi banka mogla donositi mjere preciznije usmjerene na određena ponašanja poslovnih banaka.

7. Smjernice za buduća istraživanja

U idućim bi se istraživanjima mogle uvesti promjene u postojeći model izračuna stope utjecaja granične/posebne obvezne pričuve na način da se ta stopa računa za svaku banku posebno prema njezinoj distribuciji plasmana. Tako izračunana stopa za svaku poslovnu banku, uz stopu utjecaja granične/posebne obvezne pričuve sustava, dodavala bi se prema udjelu banke na tržištu. To bi ujedno utjecalo i na relaksaciju modela pri kojoj smo pretpostavili da se zaduživanje u inozemstvu stalno povećava (tj. sve su binarne varijable bile fiksirane na $v_{ijlpt} = 1$, a u daljnjem bi istraživanju trebalo pretpostaviti mogućnost pada zaduživanja).

Potrebno bi bilo provesti analizu osjetljivosti optimalnog rješenja promjenom parametara, odnosno za različite strategije poslovnih banaka izražene promjenjivom kamatnom stopom ili ostvarenjem planiranoga tržišnog udjela promatrati utjecaj na graničnu pričuvu. Bilo bi i zanimljivo provesti ekonometrijsku analizu ovisnosti GOP-a o kamatnoj stopi, kao i tržišnom udjelu poslovne banke.

Mogu se promatrati i neke druge funkcije cilja središnje banke i poslovnih banaka. Također je moguće promatrati neke potprobleme kao višekriterijske, pri čemu bi ciljevi bili dobit i ostvarenje tržišnog udjela.

¹⁹ Na primjer, kreditiranje kupovine osobnih vozila prebačeno je s klasičnih bankovnih kredita na kupovinu putem leasinga.

Jedno od novih istraživanja moglo bi se baviti pitanjem kakve bi još mjere središnja banka mogla propisati, a koje bi u sadašnjim uvjetima zaustavile daljnji rast inozemnog zaduživanja bankarskog sektora Hrvatske.

LITERATURA

- Babić, M., 1996.** *Makroekonomija*. Zagreb: MATE.
- Beenstock, M. [et al.], 2001.** "A macroeconomic model with oligopolistic banks: monetary control, inflation and growth in Israel". *Economic Modeling*, 20 (2003) 455-486
- Candler, W. and Townsley, R., 1982.** "A linear two-level programming problem". *Computers and Operations Research*, 9, 59-76.
- Deng, X., 1998.** "Complexity issues in bilevel linear programming" in A. Migdalas, P. M. Pardalos and P. Värbrand, eds. *Multilevel Optimization: Algorithms and Applications*. Dordrecht: Kluwer Academic Publishers, 149-164.
- Ellison, M. and Valla, N., 2000.** "Learning, uncertainty and central bank activism in an economy with strategic interactions". *Journal of Monetary Economics*, 48 (1) 153-171.
- Galac, T. i Dukić, L., 2005.** "Rezultati četvrtoga HNB-ova anketiranja banaka" [online]. *Pregledi*, P-20. Zagreb: Hrvatska narodna banka. Dostupno na: [<http://www.hnb.hr/publikac/pregledi/p-020.pdf?tsfsg=788b90bbef69ac43c92557a7c9a35e8b>].
- Garey, M. R. and Johnson, D. S., 1979.** *Computers and Intractability: A Guide to the Theory of NP-Completeness*. San Francisco: W.H. Freeman and Co.
- Glover, F. and Laguna, M., 1997.** *Tabu Search*. Boston/Dordrecht/London: Kluwer Academic Publishers.
- Hillier, F. S. and Lieberman, G. J., 1995.** *Introduction to Operations Research*. New York: McGraw-Hill.
- HNB, 2006.** *Bilten o bankama*, br. 13. Zagreb: Hrvatska narodna banka
- HNB.** *Bilten HNB*, br. 121, 123 i 124. Zagreb: Hrvatska narodna banka.
- Kahn, M., Kandel, S. and Sarig, O., 2001.** "Real and nominal effects of central bank monetary policy". *Journal of Monetary Economics*, 49 (8), 1493-1519.
- Moore, J. T. and Bard, J. F., 1990.** "The Mixed Integer Linear Bilevel Programming Problem". *Operations Research*, 38 (5), 911-921.
- Neralić, L., 2003.** *Uvod u matematičko programiranje 1*. Zagreb: Element.
- Perišin I., Šokman A. i Lovrinović, I., 2001.** *Monetarna politika*. Pula: Fakultet ekonomije i turizma "Dr. Mijo Mirković".

Prilozi

Tablica 7. Kamatne stope na plasmane poslovnih banaka primijenjene u analizi heuristika za izračun početnog stanja (u %)

Banka	Stambeni krediti	Potrošački krediti	Krediti gospodarstvu
01	–	9,31	9,61
02	–	10,58	11,37
03	–	12,19	10,58
04	–	10,77	9,29
05	–	9,54	5,12
06	–	10,76	11,96
07	–	9,24	9,70
08	–	10,38	8,91
09	6,89	11,63	11,75
10	8,21	9,77	7,29
11	4,84	9,51	8,32
12	4,90	9,72	6,43
13	4,00	9,47	6,66
14	4,19	8,03	6,76
15	6,91	10,20	8,15
16	5,91	8,25	6,87
17	6,00	12,54	7,84
18	5,63	7,70	7,90
19	7,44	10,49	7,87
20	7,00	7,54	8,39
21	5,04	9,12	5,81
22	7,84	7,17	8,62
23	4,91	8,83	6,25
24	8,00	9,40	9,55
25	7,52	11,34	8,85
26	5,45	9,33	6,30
27	5,20	9,00	7,27
28	7,00	11,51	8,16
29	7,15	11,47	10,51
30	4,87	8,36	7,05
31	4,77	9,48	5,56
32	8,00	8,71	8,34
33	3,86	8,42	6,34
34	5,36	9,62	5,74

Izvor: HNB

Tablica 8. Kamatne stope na plasmane poslovnih banaka primijenjene u analizi heuristika za izračune (u %)

Banka	Stambeni krediti	Potrošački krediti	Krediti gospodarstvu
01	–	9,35	9,16
02	–	9,87	9,35
03	–	11,20	11,39
04	–	9,86	9,21
05	–	8,93	7,92
06	–	10,31	11,26
07	–	9,01	8,24
08	–	8,05	8,03
09	6,89	10,99	11,75
10	8,21	8,56	8,15
11	4,84	8,99	9,82
12	4,96	9,36	6,99
13	4,11	9,02	6,84
14	4,21	7,63	7,17
15	6,91	10,02	8,45
16	5,91	7,97	6,80
17	5,49	11,92	5,81
18	6,01	9,04	8,02
19	7,44	9,23	8,10
20	7,00	7,80	7,80
21	5,31	9,07	6,74
22	6,93	7,30	8,02
23	5,07	8,06	6,12
24	8,00	8,83	8,91
25	6,73	10,52	8,73
26	5,35	9,23	5,80
27	4,87	8,21	6,25
28	7,00	9,68	7,64
29	7,15	10,94	7,48
30	4,72	7,84	7,13
31	4,57	8,92	5,20
32	6,50	7,95	7,70
33	4,02	7,79	6,19
34	5,04	9,11	5,24

Izvor: HNB

Tablica 9. Efektivne kamatne stope na plasmane poslovnih banaka primijenjene u analizi heuristika za izračune (u %)

Banka	Stambeni krediti	Potrošački krediti	Krediti gospodarstvu
01	–	17,60	15,15
02	–	13,21	12,27
03	–	16,06	14,85
04	–	11,03	10,49
05	–	16,35	11,32
06	–	12,77	15,33
07	–	12,69	9,75
08	–	9,05	10,16
09	7,12	13,27	11,75
10	9,68	11,12	9,48
11	4,93	10,48	10,08
12	5,30	10,77	7,86
13	4,12	9,85	7,62
14	4,46	8,31	7,58
15	7,43	12,16	10,69
16	6,39	9,46	7,49
17	8,09	11,93	5,81
18	6,14	11,77	9,53
19	8,80	11,16	10,12
20	7,56	8,63	9,15
21	5,63	10,24	7,39
22	7,36	7,76	9,34
23	5,19	8,28	6,27
24	7,43	10,47	11,36
25	6,86	12,70	10,49
26	5,49	10,53	6,61
27	5,08	9,17	6,87
28	7,56	11,37	8,64
29	7,99	13,93	8,58
30	5,16	8,74	8,29
31	5,17	10,33	8,54
32	6,70	8,92	8,33
33	4,69	9,92	7,56
34	5,33	10,68	5,84

Izvor: HNB

Tablica 10. Granična obvezna pričuva pri kojoj pojedini plasmani određene banke uz nominalnu kamatnu stopu prelaze u područje neprofitabilnosti – osnovni model (u %)

Banka	Stambeni krediti	Potrošački krediti	Krediti gospodarstvu
01	–	64	63
02	–	66	64
03	–	70	71
04	–	66	64
05	–	63	58
06	–	68	70
07	–	63	59
08	–	58	58
09	51	70	72
10	59	65	59
11	30	63	66
12	32	65	52
13	18	65	51
14	20	60	53
15	51	70	60
16	43	60	51
17	39	74	42
18	44	65	58
19	55	65	59
20	52	57	57
21	37	65	50
22	52	54	58
23	34	60	45
24	58	62	62
25	50	70	62
26	37	65	42
27	31	60	46
28	52	65	56
29	53	69	55
30	29	60	53
31	26	65	35
32	48	60	56
33	16	60	46
34	33	65	36

Izvor: HNB

Tablica 11. Granična obvezna pričuva pri kojoj pojedini plasmani određene banke uz nominalnu kamatnu stopu prelaze u područje neprofitabilnosti – model proširen na upis obveznih blagajničkih zapisa (u %)

Banka	Stambeni krediti	Potrošački krediti	Krediti gospodarstvu
01	–	55	63
02	–	57	64
03	–	62	71
04	–	57	63
05	–	53	57
06	–	59	70
07	–	53	59
08	–	48	58
09	51	62	71
10	59	51	59
11	30	53	66
12	32	55	52
13	17	53	51
14	19	45	53
15	51	58	60
16	43	47	50
17	38	65	42
18	44	53	58
19	55	54	58
20	52	46	57
21	36	54	50
22	51	35	58
23	33	48	45
24	58	52	62
25	50	60	61
26	37	54	42
27	30	49	46
28	52	57	56
29	53	62	55
30	28	46	53
31	26	53	35
32	48	47	56
33	16	46	45
34	33	54	35

Izvor: HNB

Tablica 12. Granična obvezna pričuva pri kojoj pojedini plasmani određene banke uz efektivnu kamatnu stopu prelaze u područje neprofitabilnosti – osnovni model (u %)

Banka	Stambeni krediti	Potrošački krediti	Krediti gospodarstvu
01	–	80	78
02	–	75	73
03	–	79	78
04	–	70	68
05	–	80	71
06	–	74	78
07	–	74	66
08	–	63	67
09	53	75	72
10	65	70	65
11	32	70	67
12	36	70	57
13	18	70	56
14	24	60	56
15	55	74	69
16	47	65	55
17	59	74	42
18	45	74	65
19	62	70	67
20	57	61	63
21	40	70	55
22	54	57	64
23	35	60	46
24	55	68	71
25	51	74	68
26	39	70	49
27	34	65	51
28	56	74	61
29	58	76	61
30	35	65	60
31	35	70	61
32	50	65	60
33	28	70	56
34	37	70	42

Izvor: HNB

Tablica 13. Granična obvezna pričuva pri kojoj pojedini plasmani određene banke uz efektivnu kamatnu stopu prelaze u područje neprofitabilnosti – model proširen na upis obveznih blagajničkih zapisa (u %)

Banka	Stambeni krediti	Potrošački krediti	Krediti gospodarstvu
01	–	76	78
02	–	68	73
03	–	74	77
04	–	62	68
05	–	74	70
06	–	67	78
07	–	67	65
08	–	44	67
09	53	68	71
10	65	62	64
11	31	60	67
12	36	61	57
13	18	57	56
14	24	49	55
15	55	65	69
16	47	55	55
17	58	65	42
18	45	64	65
19	62	62	67
20	55	51	63
21	40	59	54
22	54	46	64
23	35	49	46
24	55	60	70
25	51	67	68
26	38	60	49
27	33	54	51
28	55	63	61
29	58	70	61
30	34	52	59
31	34	59	61
32	50	53	59
33	28	58	55
34	36	61	42

Izvor: HNB

**Darko Pongrac, Kristina Šorić and Višnja Vojvodić
Rosenzweig: A Mathematical Model and Programme Support
for Determination of the Values of the Marginal Reserve Requirement
as Instrument of Monetary Policy**

Abstract

This paper studies the problem of interdependency between central bank and commercial banks goals. The basic central bank task is to achieve and to maintain price stability. Croatian external debt has been increasing for years and so the activities of the Croatian National Bank are designed to correct this situation. In order to stop the further increase of the external debt, the Croatian National Bank uses several monetary policy instruments, among which is the marginal reserve requirement. On the other hand, the goal of commercial banks is to maximise profits. Banks take loans from abroad at a lower interest rate and invest this money in Croatia at a higher interest rate, thus fulfilling their goal. In order to obtain the desired effects of the marginal reserve requirement, its optimal percentage value should be determined. This problem is modeled as a bilevel mixed 0-1 programming problem. The objective of the leader (Croatian National Bank) is to minimize the increase in household loans by setting different percentages of the reserve requirements for loans extended to households and for those granted to enterprises. The objective of the followers (banks) is to maximize profits. In order to solve this NP-hard problem a heuristic is proposed. In order to verify the model, the paper ends with simulations and the presentation of computational results.

Key words: monetary policy instruments, commercial banks credit activity, marginal reserve requirement, bilevel mixed 0-1 programming problem, NP-hard problem, heuristic