

## MJERENJE EFIKASNOSTI I PRODUKTIVNOSTI HRVATSKIH BANAKA MALMQUISTOVIM INDEKSOM PROMJENE UKUPNE FAKTORSKE PRODUKTIVNOSTI

Marko PRIMORAC\*, student  
Ekonomski fakultet u Zagrebu

Stručni članak\*\*  
UDK 336.71  
JEL D24

Zvonimir TROSKOT\*, student  
Ekonomski fakultet u Zagrebu

### Sažetak

*U znanstvenoj literaturi koja se bavi empirijskim mjerenjem relativne tehničke efikasnosti i promjene produktivnosti banaka tijekom vremena Malmquistov indeks promjene ukupne faktorske produktivnosti postao je najčešće korišteno analitičko oruđe. Pokazalo se da Malmquistov indeks pomaže i analitičarima središnje banke, kao i analitičarima komercijalnih banaka u praćenju kretanja unutar bankovnog sektora, te se može iskoristiti kao pomoć u nadzoru sustava ili pri strateškom planiranju.*

*Ovo je istraživanje usmjereno na relativnu usporedbu banaka unutar bankovnog sektora Hrvatske u razdoblju od 2000. do 2003. godine i prvi je rad u kojemu se analizira hrvatski bankovni sektor primjenom Malmquistova indeksa promjene ukupne faktorske produktivnosti. Znanstveni doprinos koji proizlazi iz te činjenice, dodatno je potenciran interdisciplinarnošću kojom je rad prožet. Primarni cilj istraživanja jest praćenje relativnih kretanja banaka unutar vrlo dinamičnoga bankovnog sektora Hrvatske. Istaknuta je potreba izgradnje dodatnih modela koji obuhvaćaju alternativne, prije svega, izvanbilančne pokazatelje.*

*Ključne riječi: Malmquistov indeks promjene ukupne faktorske produktivnosti, poslovna izvrsnost banaka, Hrvatska*

---

\* Autori zahvaljuju anonimnim recenzentima čiji su konstruktivni prijedlozi i kritike doprinijeli kvaliteti ovog članka. Posebnu zahvalu autori upućuju Tomislavu Petrovu koji im je ustupio svoja softverska rješenja za računanje indeksa.

\*\* Priljeno (Received): 30.5.2005.  
Prihvaćeno (Accepted): 28.11.2005.

## 1. Uvod

Ulaskom u treće tisućljeće snažan se utjecaj globalizacije, informatizacije te razvoja novih tehnologija osjeti u svakom segmentu ljudske djelatnosti. U nemilosrdnim uvjetima borbe za opstanak na tržištu nužne su česte interne analize poslovanja poduzeća i analize cjelokupnoga natjecateljskog tržišta koje se danas, s razvojem metodološkog aparata za poslovna istraživanja, sve češće provode. Da bi ostala konkurentna na pojedinim tržištima, poduzeća se neprestano moraju uspoređivati sa svojim konkurentima, *prepoznavati one najbolje* i nastojati učiti od njih prilagođavajući njihove planove razvoja radi primjene za vlastiti napredak. Dobro odabrana strategija može pomoći našem poduzeću da dosegne ili čak prestigne razinu poslovne izvrsnosti trenutačno najboljeg poduzeća. U posljednje je vrijeme jedan od najčešće korištenih instrumenata za ocjenjivanje uspješnosti poslovanja poduzeća relativna tehnička efikasnost te promjena višefaktorske produktivnosti, koja se dekomponira na promjenu relativne tehničke efikasnosti i pomak proizvodne granice između dva vremenska razdoblja. Interpretacija pomaka granice kao komponente indeksa promjene produktivnosti nezaobilazna je sastavnica svake analize.

Uzevši sve to u obzir, nameće se potreba za pronalaženjem upotrebljivog modela za praćenje poslovanja poduzeća unutar pojedinih grupa djelatnosti. Cilj ovog rada jest prezentirati Malmquistov indeks ukupne produktivnosti svih faktora (u daljnjem tekstu MPI) uz ilustraciju njegove primjene na bankovnom sektoru u Hrvatskoj u razdoblju od 2000. do 2003. godine. Indeks je namijenjen praćenju relativnog položaja banke prema granici određenoj najboljim bankama u sektoru. Sukladno tome, indeks se može koristiti za što ranije prepoznavanje slabosti pojedine banke unutar bankovnog sektora, što menadžeru može pomoći da pravodobno poduzme odgovarajuće preventivne mjere. Mnogi recentni radovi pokazali su adekvatnost te metode za praćenje kretanja unutar pojedinoga gospodarskog sektora. Metoda nastala iz mikroekonomske teorije učenja od najuspješnijih, danas je sve važnije analitičko oruđe menadžmenta u mnogim situacijama.

Bankovni je sektor, možemo reći, najbitniji sektor u modernim i razvijenim ekonomijama. U Hrvatskoj je taj sektor još uvijek u razvoju i još uvijek manje od 4% BDP-a dolazi iz sektora financijskih usluga, a u bankovnom sektoru radi samo oko 1,4% zaposlenog stanovništva. Hrvatski bankovni sektor ima strukturu oligopola. Dvije najveće banke u prvom polugodištu 2004. godine kontroliraju 42,3%, a šest najvećih banaka 79,1% ukupne aktive sektora.

Od 1990. do 1996. godine u Hrvatskoj je osnovano mnogo novih malih banaka. Visoki tržišni kamatnjak u to vrijeme omogućuje novim bankama da bez opterećenja naslijeđenim dugovima neko vrijeme posluju uz visoku dobit. Zanimljivo je pitanje je li odluka da se bankovni sektor nakon bankovne krize 1998. godine prepusti stranim investitorima bila dobra za Hrvatsku. Udio stranih vlasnika u ukupnoj aktivni bankovnog sektora Hrvatske povećao se sa 6,7% krajem 1998. na 83,7% krajem 2000. godine. Odluka da se neke banke saniraju i prepuste stranim investitorima očito je donesena kao posljedica bankovne krize, ne samo kao preventiva budućim nestabilnostima bankovnog sustava, nego i da bi se omogućio lakši transfer znanja.

Velike turbulencije u hrvatskom bankovnom sektoru prije 2000. godine navele su nas na istraživanje ponašanja banaka u "posttraumatskom" razdoblju namećući pitanje: "Je li

došlo do stabilizacije poslovanja komercijalnih banaka u Hrvatskoj?" Već na samom početku istraživanja, radi kreiranja cjelovitog panela, selektirane su banke koje su tijekom cijeloga promatranog četverogodišnjeg razdoblja poslovale s pozitivnom neto dobiti. Zbrojene su potom i bilančne pozicije banaka koje su se kasnije spojile ili je jedna preuzela drugu, čime je početni panel gotovo prepolovljen.

Rad je strukturiran tako da su u drugom odjeljku objašnjene Farrellove mjere radijalne relativne efikasnosti i primijenjene za mjerenje tehničke efikasnosti selektiranog uzorka banaka u hrvatskom bankovnom sektoru. U trećem odjeljku objašnjen je Malmquistov indeks promjene ukupne produktivnosti svih faktora, te je njegova primjena ilustrirana na istom uzorku banaka. Indeks je dekomponiran na indeks promjene radijalne relativne efikasnosti i indeks pomaka proizvodne granice. U četvrtom odjeljku dana su zaključna razmatranja.

## 2. Farrellove mjere radijalne relativne efikasnosti

Farrell je (1957) uočio<sup>1</sup> da se efikasnost poduzeća (u promatranom primjeru) sastoji od dvije komponente: *tehničke efikasnosti*, koja održava sposobnost poduzeća (banke) da iz raspoložive razine inputa ostvaruje maksimalan output, i *alokativne efikasnosti*, koja odražava sposobnost poduzeća (banke) da se koristi inputima u optimalnoj količini s obzirom na njihove cijene i tehnologiju proizvodnje. Te dvije mjere tada se kombiniraju u mjeru *ukupne ekonomske efikasnosti*.

*Primjer 1.* Za ilustraciju mjera efikasnosti orijentiranih prema smanjenju inputa promotrimo poduzeća (banke) koja korištenjem dvaju inputa,  $x_1$  i  $x_2$ , ostvaruju jedan output,  $y$ , te pretpostavimo da proizvodna tehnologija zadovoljava aksiom konstantnih prinosa. Poznavanje izokvante jediničnog outputa tehnički efikasnih poduzeća (banaka), prikazane kao  $SS'$  linija na slici 1, omogućuje mjerenje tehničke efikasnosti svakog poduzeća (banke) u uzorku, a poznavanje fiksnih cijena inputa podrazumijeva poznavanje izotroškovne crte  $AA'$ , koja omogućuje mjerenje alokacijske i ekonomske efikasnosti.

*Tehnička efikasnost* ( $TE_I$ ) poduzeća (banke) poistovjećenoga s točkom  $P$  definirana je sa:

$$TE_I(P) = \frac{OQ}{OP} = 1 - \frac{QP}{OP}. \quad (1)$$


*Alokacijska efikasnost* ( $AE_I$ ) poduzeća (banke) poistovjećenoga s točkom  $P$  definirana je kao:

$$AE_I(P) = \frac{OR}{OQ}, \quad (2)$$

jer udaljenost  $RQ$  predočuje neku vrstu mjere smanjenja troškova proizvodnje koji se mogu postići ako se proizvodnja poduzeća (banke) premjesti u alokacijski i tehnički efikasnu točku  $Q'$  iz tehnički efikasne, ali alokacijski neefikasne točke  $Q$ .

<sup>1</sup> Teorijski dio koji slijedi pisan je na temelju Farrell (1957), te Coelli (2005).

Slika 1. Tehnička i alokacijska efikasnost poduzeća za orijentaciju modela prema smanjenju inputa



Ukupna ekonomska efikasnost poduzeća (banke) poistovjećenoga s točkom  $P$  jest:

$$EE_1(P) = \frac{OR}{OP}, \quad (3)$$

gdje se udaljenost  $RP$  također može interpretirati u obliku smanjenja troškova. Primijetimo da umnožak mjera tehničke i alokacijske efikasnosti daje mjeru ukupne ekonomske efikasnosti:


$$TE_1(P)AE_1(P) = \frac{OQ}{OP} \frac{OR}{OQ} = \frac{OR}{OP} = EE_1(P). \quad (4)$$

*Primjer 2.* Mjere tehničke efikasnosti orijentirane prema smanjenju inputa, prikazane u prethodnom primjeru, odgovaraju na pitanje za koliko se količine inputa mogu proporcionalno smanjiti uz zadržavanje ostvarene količine outputa. Alternativno se može postaviti pitanje koliko se količine outputa mogu proporcionalno povećati uz primjenu dane razine inputa. Odgovor na to pitanje daju mjere efikasnosti orijentirane prema povećanju outputa. Za ilustraciju mjera efikasnosti orijentiranih prema povećanju outputa promotrimo poduzeća (banke) koja proizvode dva outputa,  $y_1$  i  $y_2$ , korištenjem jednog inputa,  $x$ .

Ako je na slici 2.  $ZZ'$  granica skupa proizvodnih mogućnosti, za tehnički neefikasnu točku  $A$  udaljenost  $AB$  mjera je njezine tehničke neefikasnosti, tj. količine outputa koja se može povećati bez korištenja dodatne količine inputa. Tada je mjera tehničke efikasnosti orijentirana prema povećanju outputa jednaka

$$TE_O(A) = \frac{OA}{OB}. \quad (5)$$

Slika 2. Tehnička i alokacijska efikasnost poduzeća za orijentaciju modela prema povećanju outputa



Ako raspoložemo cijenama outputa, možemo konstruirati izoprihodovnu crtu  $DD'$  i računati alokacijsku efikasnost:

$$AE_O(A) = \frac{OB}{OC}, \quad (6)$$

koja se može interpretirati u obliku povećanja prihoda. Ukupna ekonomska efikasnost definira se kao umnožak:

$$EE_O = TE_O(A)AE_O(A) = \frac{OA}{OB} \cdot \frac{OB}{OC} = \frac{OA}{OC}. \quad (7)$$

Uočimo neke bitne karakteristike Farrellovih mjera efikasnosti. Prvo, tehnička se efikasnost mjeri duž zrake iz ishodišta kroz točku kojom je opisano promatrano poduzeće (banka). Prednost radijalnih mjera jest invarijantnost s obzirom na jedinice mjere, tj. promjena jedinice mjere ne utječe na vrijednost mjere efikasnosti. Općenito, mjere koje nisu radijalne nisu invarijantne na promjenu jedinica mjere, jer tada promjena jedinice mjere rezultira pronalaženjem druge referentne točke na granici. Drugo, alokacijska je efikasnost razmatrana iz perspektive minimiziranja troškova i maksimiziranja prihoda, ali ne i iz perspektive maksimiziranja dobiti. Naime, adekvatna metodologija mjerenja efikasnosti bazirana na maksimiziranju dobiti tada još nije bila razvijena. Treće, navedene mjere efikasnosti pretpostavljaju da je poznata proizvodna funkcija. Budući da u praksi nije tako, efikasna se izokvanta procjenjuje iz uzorka podataka stohastičkim metodama ili se pretpostavi da je ona po dijelovima linearna konusna odnosno konveksna ljuska analiziranih poduzeća, kao u analizi obavijanja podataka. Napomenimo da različite tehnike za procjenu granica i različiti odabiri funkcionalnih oblika mogu dovesti do bitno različitih rezultata.

U nastavku članka za ilustraciju konkretne usporedne analize komercijalnih banaka u Hrvatskoj ograničit ćemo se na primjenu neparametarskih determinističkih granica analize obavijanja podataka. Više o formalnom zapisu korištenog modela može se pronaći u matematičkom dodatku ovog odjeljka. Metodom se vrlo jednostavno izvode mnoge korisne informacije.

### 2.1. Matematički dodatak

Empirijsko mjerenje radijalne relativne tehničke efikasnosti (Farrell, 1957), koje je za ilustraciju provedeno u situaciji kada proizvođači (banke) koriste više inputa za proizvodnju više outputa, utemeljeno je na output funkcijama udaljenosti (Shephard, 1953). Kako je cilj ovoga dodatka prezentirati minimalni analitički aparat potreban za empirijsku analizu, ograničit ćemo se na orijentaciju prema povećanju outputa. Pretpostavimo da se proizvođači (banke) koriste nenegativnim vektorom inputa  $x \in R_+^m$  da bi proizveli nenegativni vektor outputa  $y \in R_+^s$ , te se prisjetimo osnovnih pojmova iz ekonometrijske teorije poduzeća (Coelli, 2005; Kumbhakar, 2003).

*Graf proizvodne tehnologije* u vremenskom razdoblju  $t$ ,

$$GR(t) = \{(y, x) \mid x \text{ može proizvesti } y \text{ u vremenskom razdoblju } t\}, \quad (8)$$

opisuje skup mogućih input-output vektora u vremenskom razdoblju  $t$ .

*Skupovi outputa* proizvodne tehnologije u vremenskom razdoblju  $t$ ,

$$P^t(x) = \{y \mid (y, x) \in GR(t)\} \quad (9)$$

opisuju skupove outputa koji su mogući za svaki vektor inputa  $x$  u vremenskom razdoblju  $t$ .

*Izokvante outputa* u vremenskom razdoblju  $t$ ,

$$IsoqP^t(x) = \{y \mid y \in P^t(x), \lambda y \notin P^t(x), \lambda > 1\}, \quad (10)$$

opisuju razine outputa koje se mogu proizvesti input vektorom  $x$ , a za koje daljnja radijalna ekspanzija nije moguća primjenom input vektora  $x$  u vremenskom razdoblju  $t$ .

Prema Shephard (1953), *output funkcija udaljenosti* u vremenskom razdoblju  $t$  funkcija je:

$$D_\theta^t(y, x) = \min \{\mu \mid y / \mu \in P^t(x)\}. \quad (11)$$

Output-orijentirana mjera tehničke efikasnosti proizvođača  $(y, x)$  u vremenskom razdoblju  $t$  može se pomoću funkcija udaljenosti zapisati kao funkcija:

$$TE_\theta^t(y, x) = [\max \{\theta \mid D_\theta^t(\theta y, x) \leq 1\}]^{-1}. \quad (12)$$

### 2.2. Ilustracija Farrellove radijalne relativne tehničke efikasnosti na primjeru hrvatskoga bankarskog sektora

U ilustrativnom primjeru output-orijentirana mjera tehničke efikasnosti izvedena je korištenjem triju inputa – rada, kapitala i imovine, te dvaju outputa – dobiti prije i nakon oporezivanja, uz pretpostavku da je *Farrellov poliedarski konus* (Charnes, 1978) graf proizvodne tehnologije koja zadovoljava aksiom konstantnih prinosa. Iako

neka istraživanja hrvatskoga bankovnog sektora govore o “prisutnosti ekonomije razmjera” (Jemrić i Vujčić, 2002), metodologija za testiranje “prinosa s obzirom na razinu uložених inputa” (Simar i Wilson, 2002) kao javnosti dostupan program (Wilson, 2005) prvi je put ugrađena tek nakon pisanja ovog rada. Zbog navedenih razloga testiranje “postojanja ekonomije razmjera” u hrvatskom bankovnom sektoru u ovom radu nije provedeno.

Tablica 1. Farrellova mjera radijalne relativne tehničke efikasnosti prema granici hrvatskoga bankarskog sektora u promatranoj godini<sup>a</sup>

Broj	Banka	Relativna radijalna tehnička efikasnost			
		2000.	2001.	2002.	2003.
1.	Centar banka	0,38783	0,43277	0,62966	0,52534
2.	Credo banka	0,19033	0,33816	0,56861	0,30025
3.	Gospodarska kreditna banka	1,00000	0,84196	0,28819	0,44706
4.	Hrvatska poštanska banka	0,07001	0,12908	1,00000	1,00000
5.	HVB splitska banka	0,32937	0,72273	0,85903	0,77331
6.	Hypo Alpe-Adria	0,96694	1,00000	1,00000	1,00000
7.	Imex banka	0,74262	1,00000	1,00000	1,00000
8.	Istarska kreditna banka	0,59644	0,75046	0,77655	0,86438
9.	Jadranska banka	0,03719	0,15132	0,06561	0,18361
10.	Karlovačka banka	0,44358	0,17485	0,42050	0,36507
11.	Kreditna banka Zagreb	0,07231	0,07843	0,14592	0,38588
12.	Kvarner banka	0,24637	0,51573	0,59673	0,63200
13.	Nava banka	0,53615	0,27552	0,50247	0,44027
14.	Partner banka	0,32058	0,78340	0,71859	0,91901
15.	Podravska banka	0,05879	0,24179	0,47177	0,48501
16.	Požeška banka	1,00000	1,00000	0,71703	0,05562
17.	PBZ	0,60351	0,89589	1,00000	1,00000
18.	PB – Laguna banka	0,33572	0,62486	0,79484	0,73978
19.	Raiffeisenbank	0,99311	1,00000	0,64615	0,90909
20.	Riadria banka	0,18739	0,86475	0,93602	1,00000
21.	Samoborska banka	0,02909	0,05525	0,10625	0,00723
22.	Slatinska banka	0,29704	0,45957	0,70055	0,51040
23.	Štedbanka	1,00000	1,00000	1,00000	1,00000
24.	Varaždinska banka	0,34816	0,73235	0,83901	1,00000
25.	Volksbank	0,96945	0,81737	0,50993	0,49897
26.	Zagrebačka banka	1,00000	0,53916	0,73392	0,99804

<sup>a</sup> Izračun je napravljen korištenjem programa koji je Tomislav Petrov za osobne potrebe napravio u programskom paketu Mathematica. Rezultati su naknadno provjereni primjenom komercijalno dostupnog DEA Excel Solvera.

Odabir inputa i outputa preuzet je iz Zhu (2000), ali zbog oskudnosti javno dostupnih podataka ukupni su ostvareni prihodi morali biti zamijenjeni s dobiti prije oporezivanja. Napomenimo da je korisno izračunati mjere relativne tehničke efikasnosti za svaki podmodel korištenog modela, a umjesto upotrebe temeljnoga (bilančnog) kapitala, koji nije uvijek u korelaciji s kapitalom stvarno angažiranim u proizvodnji outputa, dobro se koristiti nekom drugom mjerom koja direktno sudjeluje u stvaranju nove vrijednosti. Bez obzira na to što zbog razloga navedenog na početku odjeljka upotreba adekvatnijih pokazatelja nije bila moguća, napravljeni je odabir ipak u skladu sa suvremenim razumijevanjem metodologije, što dopušta korištenje bilo kojih outputa i inputa koji se mogu staviti u smisleni ekonomski odnos. Zbog invarijantnosti MPI-ja s obzirom na promjene jedinica mjere, input rada nije bilo potrebno procjenjivati, već su umjesto troškova radne snage izraženih kunama (uz procjenu i naknada na temelju dionica, školovanja, korištenja službenih automobila, mobitela, troškova reprezentacije itd.) korišteni podaci o broju zaposlenih u pojedinoj banci. Financijski inputi i outputi prevedeni su u realne vrijednosti primjenom indeksa troškova života. Mjere efikasnosti gotovo su nepromijenjene ako se prevođenje nominalnih vrijednosti u realne provodi indeksom cijena u prodaji na malo ili indeksom inflacije. Detaljna rasprava o tome koji je indeks ispravno primijeniti može se pronaći u Berger, Forsund i Jensen (1992). Ekonomski analitičari i danas nemaju ista gledišta o tome kojim se indeksom koristiti, iako se najčešće koriste indeksom cijena u prodaji na malo.

U prethodnoj tablici dani su iznosi relativne radikalne tehničke efikasnosti za pojedine banke u razdoblju od 2000. do 2003. godine. Ti rezultati označavaju relativni položaj pojedine banke iz uzorka u odnosu prema efikasnoj granici bankovnog sektora u određenoj godini. Banke kojima je vrijednost relativne radikalne tehničke efikasnosti iznosila 1,00 činile su efikasnu granicu bankovnog sektora u dotičnoj godini. Vrijednosti manje od 1,00 govore koliko je pojedina banka bila efikasna u postotku referentne *benchmark* točke na granici. Efikasnu granicu tijekom promatranog razdoblja činilo je 11 od 26 banaka. Zanimljivo je istaknuti da se Štedbanka u sve četiri godine nalazila na granici efikasnosti. Kao svojevrsni *followeri* u smislu efikasnosti tri su puta zaredom, od 2001. do 2003, granicu činile i Hypo Alpe-Adria, te Imex banka. Godine 2003, kao posljednje godine u promatranom razdoblju, granicu su, uz već navedene, činile i Hrvatska poštanska banka, Privredna banka Zagreb, Riadria te Varaždinska banka. Vrlo je zanimljiv primjer Hrvatske poštanske banke koja je od vrlo neefikasne banke u 2000. (7%) i 2001. (12,9%) u 2002. godini postala efikasna, kakvom je ostala i u 2003. Požeška banka također je vrlo zanimljiv primjer, no, nažalost, suprotnog trenda. Od jedne među četiri efikasne banke 2000. godine i jedne među pet efikasnih banaka 2001. godine, Požešku je banku u posljednje dvije godine promatranog razdoblja pratio najprije umjereni pad efikasnosti 2002, kada je bila 71,7% efikasna, a godinu poslije pad efikasnosti bio je toliko dramatičan da je efikasnost nekada "uspješnog lidera" iznosila samo 5,56%. Vrlo slična pozitivna kretanja u smislu efikasnosti ostvarivale su Riadria i Varaždinska banka. Efikasnost tih dviju banaka porasla je, relativno naglo 2001. u odnosu prema 2000. godini, a zatim se polako primicala efikasnim, da bi se 2003. godine našle među njima. Dvije banke s relativno velikim tržišnim udjelom i pomalo čudnim kretanjem efikasnosti svakako su Raiffeisenbank i Zagrebačka banka. Raiffeisenbank je 2001, a skoro i 2000. godine, bila pozicionirana na samoj grani-



ci, da bi joj se relativna radijalna tehnička efikasnost u 2002. godini gotovo prepolovila. Godine 2003. zabilježen je ponovni rast efikasnosti, koja je u navedenoj godini iznosila oko 91%. Zagrebačka banka, kao banka koja je 2000. godine bila sastavni dio proizvodne granice, prepolovila je 2001. svoju efikasnost. Sljedeće dvije godine efikasnost joj je postupno rasla, te je 2003. iznosila 99,8%, što ju definitivno čini jednom od, u granicama efikasnosti, najuspješnijih banaka u hrvatskome bankovnom sektoru.

Istaknimo da je empirijska *benchmark* proizvodna granica izvedena iz Farrellova poliedarskog konusa neprekinuta i po dijelovima linearna funkcija, određena tehnički efikasnim bankama u uzorku. Naravno, ne postoji jamstvo da tako definirana deterministička granica ima veze sa “stvarnom” granicom. Zato je pri interpretaciji dobivenih rezultata potreban oprez.

### 3. Färeova varijanta Malmquistova indeksa produktivnosti

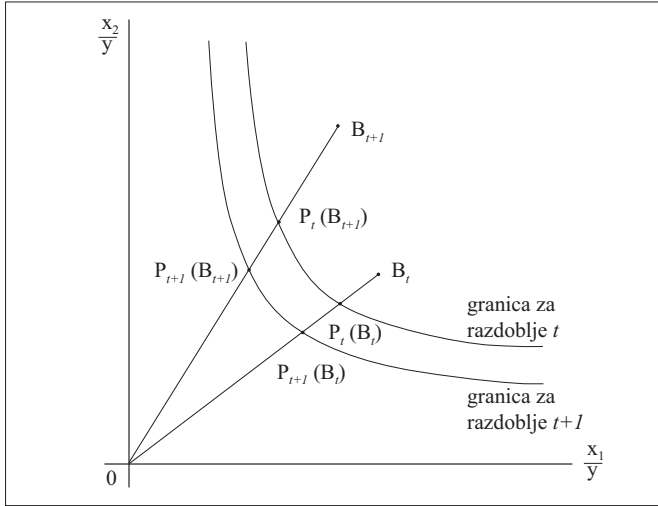
U situaciji jednog outputa i jednog inputa produktivnost se definira omjerom količina outputa i inputa. Kada poduzeća (banke) opisuje više inputa i više outputa, produktivnost analiziranog poduzeća (banke) definira se kao omjer indeksa razine outputa i indeksa razine inputa, a promjena tog omjera tijekom vremena odražava promjenu produktivnosti poduzeća (banke). U današnje je vrijeme prihvaćena činjenica da se tijekom vremena produktivnost poduzeća (banke) može promijeniti pomakom granice (zbog tehnološkog progressa koji se dogodio) i promjenom relativne tehničke efikasnosti poduzeća (određujemo je u odnosu prema granici promatranog trenutka). *Pomak granice* odražava “tehnološki progress” koji se dogodio unutar analiziranog uzorka poduzeća (banaka), a *promjena relativne tehničke efikasnosti* poduzeća (banke) unutar analiziranog uzorka poduzeća (banaka) tijekom vremena odražava pomak poduzeća (banke) s obzirom na efikasnu granicu uzorka poduzeća (banaka) na početku i na kraju promatranoga vremenskog intervala. Često se promjena višefaktorske produktivnosti mjeri Malmquistovim indeksom<sup>2</sup>, a linearno se programiranje koristi za njegovo izračunavanje<sup>3</sup>. Naime, u mnogim situacijama, pogotovo pri analizi rasta produktivnosti u institucijama javnog sektora, ne postoje podaci o cijenama (težinama) inputa i outputa. Često je problem određivanja težina inputa i outputa besmislen. Na primjer, koju cijenu dodijeliti ljudskom životu izgubljenom u prometnoj nesreći? Upravo zato što ne zahtijeva informacije o cijenama, ne zahtijeva nametanje funkcionalnog oblika preslikavanja koje inputima pridružuje outpute, niti zahtijeva eksplicitne pretpostavke o ponašanju analiziranih jedinica i procesu optimalizacije, Malmquistov

<sup>2</sup> Malmquistov indeks promjene višefaktorske produktivnosti nije izmislio Malmquist! Malmquist je u radu (Malmquist, 1953) uveo input funkcije udaljenosti u analizu potrošnje, izgrađujući metodu za empirijsko mjerenje životnog standarda. Indeks promjene životnog standarda definirao je kao odnos dviju input funkcija udaljenosti. U analizu proizvodnje, prije Malmquistova rada, input funkcije udaljenosti uveo je Debreu u svom radu iz 1951, a output funkcije udaljenosti uveo je Shephard (1953). Prirodna dogradnja njihovih radova definicija je indeksa promjene višefaktorske produktivnosti kao odnosa dviju input ili output funkcija udaljenosti. Na nju se čekalo 31 godinu. Malmquistov indeks promjene višefaktorske produktivnosti prvi je put predložen u radu Caves, Christensen i Diewert (1982a). Danas se ti indeksi nazivaju parcijalno orijentiranim indeksima promjene višefaktorske produktivnosti. Za proizvodnu tehnologiju koja zadovoljava aksiom konstantnih prinosa indeksi su jednaki.

<sup>3</sup> Za izračunavanje Malmquistova indeksa promjene višefaktorske produktivnosti potrebno je izračunati četiri indeksa relativne udaljenosti (riješiti četiri linearna programa), kako je predloženo u radu Färe i sur. (1989). Za matematički zahtjevnije čitatelje, koji traže veći metodološko-preskriptivni fokus, vidjeti Lovell (2003).

indeks promjene višefaktorske produktivnosti danas je stekao veliku popularnost. Za grafičku ilustraciju Malmquistova indeksa promjene produktivnosti koristit ćemo opisom poduzeća (banke) sa dva inputa i jednim outputom.

Slika 3. Ilustracija Malmquistova indeksa promjene produktivnosti



Ako sa  $d(A,B)$  označimo euklidsku udaljenost točaka  $A$  i  $B$ , Malmquistov indeks promjene produktivnosti poduzeća prezentiranog točkom  $B_t$  u trenutku  $t$  i točkom  $B_{t+1}$  u trenutku  $t+1$  geometrijska sredina je:

$$MI = \sqrt{\frac{\frac{d(0, P_t(B_{t+1}))}{d(0, B_{t+1})} \cdot \frac{d(0, P_{t+1}(B_{t+1}))}{d(0, B_{t+1})}}{\frac{d(0, P_t(B_t))}{d(0, B_t)} \cdot \frac{d(0, P_{t+1}(B_t))}{d(0, B_t)}}} \quad (13)$$

Ona se može rastaviti na indeks promjene relativne tehničke efikasnosti i indeks pomaka granice<sup>4</sup> na način:

$$MI = EFF \cdot TECH = \frac{\frac{d(0, P_{t+1}(B_{t+1}))}{d(0, B_{t+1})}}{\frac{d(0, P_t(B_t))}{d(0, B_t)}} \cdot \sqrt{\frac{d(0, P_t(B_{t+1}))}{d(0, P_{t+1}(B_{t+1}))} \cdot \frac{d(0, P_t(B_t))}{d(0, P_{t+1}(B_t))}} \quad (14)$$

<sup>4</sup> Indeks pomaka granice u radu Färe i sur. (1994a) nazvan je indeksom tehnološkog progresa. Tada se smatralo da pomak *benchmarking* granice, u skladu s ekonomskom teorijom tržišta savršene konkurencije, odražava tehnološki progres. Istaknimo da se prilikom računanja indeksa tehnološkog progresa pretpostavljaju konstantni prinosi s obzirom na opseg djelovanja. Zato je poznata dekompozicija indeksa promjene relativne tehničke efikasnosti za proizvodnu tehnologiju izvedenu iz aksioma varijabilnih prinosa na promjenu čiste tehničke efikasnosti i promjenu efikasnosti s obzirom na opseg djelovanja (Färe i sur., 1994b) praktično neupotrebljiva kao dodatak dekompoziciji (14).

Prva komponenta određuje promjenu relativne tehničke efikasnosti promatranog poduzeća između vremenskih razdoblja  $t$  i  $t+1$ , odražavajući pomak poduzeća s obzirom na efikasnu granicu uzorka poduzeća. Ako je veća od 1, analizirano se poduzeće primaknulo granici uzorka poduzeća, a ako je manja od 1, poduzeće se udaljilo od granice. Druga komponenta određuje pomak same granice između vremenskih razdoblja  $t$  i  $t+1$  i odražava “tehnološki progres” koji se dogodio unutar uzorka poduzeća. Pomak granice mjeren je geometrijskom sredinom omjera udaljenosti od ishodišta točaka projekcije na granicu u razdobljima  $t$  i  $t+1$  za točke  $B_t$  i  $B_{t+1}$ . Iznos te komponente veći od 1 odražava “tehnološki napredak” koji se dogodio unutar uzorka poduzeća, jednako kao što bi iznos te komponente manji od 1 odražavao “tehnološko nazadovanje”.

### 3.1. Objašnjenje interpretacije

Nakon što smo intuitivno objasnili MPI i njegovu dekompoziciju za proizvodnu tehnologiju izvedenu iz aksioma konstantnih prinosa, spremni smo ga zapisati u obliku operativno upotrebljive matematičke forme koja dodatno objašnjava indeks. Koristeći se grafom *benchmark* proizvodne tehnologije izvedene iz aksioma konstantnih prinosa  $c$  u vremenskom razdoblju  $s$ , output funkciju udaljenosti  $D_o$  možemo zapisati kao  $D_o^{cs}(y, x)$ . Output orijentirani Malmquistov indeks promjene višefaktorske produktivnosti između razdoblja  $t$  i  $t+1$  za *benchmark* proizvodnu tehnologiju u vremenskom razdoblju  $s$  definiramo ovako:

$$M_o^{cs}(y^t, x^t, y^{t+1}, x^{t+1}) = \frac{D_o^{cs}(y^{t+1}, x^{t+1})}{D_o^{cs}(y^t, x^t)} \quad (15)$$

Dakle, omjerom vrijednosti koje funkcija udaljenosti poprima ako se proizvodna jedinica promatra u razdobljima  $t$  i  $t+1$ . Kako želimo mjeriti promjenu višefaktorske produktivnosti između razdoblja  $t$  i  $t+1$ , kao *benchmark* proizvodna tehnologija može se uzeti tehnologija iz jednoga od tih razdoblja. Naravno, kako funkcije udaljenosti daju mjeru koja je relativna prema tehnologiji, za tehnologiju iz razdoblja  $s = t$  i perioda  $s = t+1$  mogu se dobiti različiti rezultati. Zato je u članku Caves, Christensen i Diewert (1982b) Malmquistov indeks promjene višefaktorske produktivnosti između razdoblja  $t$  i  $t+1$  definiran kao njihova geometrijska sredina, tj.:

$$M_{OC}^{t,t+1}(y^t, x^t, y^{t+1}, x^{t+1}) = \sqrt{M_o^{c,t}(y^t, x^t, y^{t+1}, x^{t+1}) \cdot M_o^{c,t+1}(y^t, x^t, y^{t+1}, x^{t+1})} \quad (16)$$

Indeks  $C$  smo, radi preglednosti zapisa, prebacili u nazivnik iako i dalje opisuje proizvodnu tehnologiju izvedenu iz aksioma konstantnih prinosa. Vrijednost

$$M_{OC}^{t,t+1}(y^t, x^t, y^{t+1}, x^{t+1})$$

veća od 1 upućuje na rast višefaktorske produktivnosti, vrijednost jednaka 1 upućuje na stagnaciju, a vrijednost manja od 1 upućuje na smanjenje višefaktorske produktivnosti između razdoblja  $t$  i  $t+1$ .

Jednadžba (14) može se preko output funkcija udaljenosti (11) zapisati u obliku:

$$M_{OC}^{t,t+1}(y^t, x^t, y^{t+1}, x^{t+1}) = TE\Delta_C^{t,t+1}(y^t, x^t, y^{t+1}, x^{t+1}) \cdot T\Delta_C^{t,t+1}(y^t, x^t, y^{t+1}, x^{t+1}), \quad (17)$$

gdje

$$TE\Delta_C^{t,t+1}(y^t, x^t, y^{t+1}, x^{t+1}) = \frac{D_O^{c,t+1}(y^{t+1}, x^{t+1})}{D_O^{c,t}(y^t, x^t)} \quad (18)$$

određuje promjenu relativne tehničke efikasnosti, a

$$T\Delta_C^{t,t+1}(y^t, x^t, y^{t+1}, x^{t+1}) = \sqrt{\frac{D_O^{c,t}(y^{t+1}, x^{t+1})}{D_O^{c,t+1}(y^{t+1}, x^{t+1})} \cdot \frac{D_O^{c,t}(y^t, x^t)}{D_O^{c,t+1}(y^t, x^t)}} \quad (19)$$

geometrijsku sredinu magnituda pomaka granice duž zraka kroz  $(y^{t+1}, x^{t+1})$  i  $(x^t, y^t)$ .  
 Ta je promjena u radu Färe i sur. (1994a) nazvana *tehnološkom promjenom*.

### 3.2. Ilustracija Malmquistova indeksa promjene produktivnosti na uzorku banaka unutar hrvatskoga bankarskog sektora

U ovom odjeljku slijedimo rad Färe i sur. (1994a), koji je prvi empirijski proveo mjerenje na osnovi prezentirane teorije.

Koliko je Malmquistov indeks popularan, pokazuje činjenica da je do danas korišten u više od 1000 znanstvenih i stručnih radova objavljenih u 68 zemalja (Fethi i Olgu, 2004a), a od radova u kojima je korišten za analizu bankovnog sektora spomenimo sljedeće radove.<sup>5</sup>

Prije upuštanja u interpretaciju dobivenih rezultata, prisjetimo se da MPI promatra banku kao “crnu kutiju” ne ulazeći u analizu njezine specifičnosti sa stajališta inputa i outputa te ograničenja što ih model treba uzeti u obzir. Ideja MPI-ja jest uočiti promjenu u poslovanju banke na temelju statističkih podataka, te sugerirati praktičaru koje “crne kutije” istražiti sa stajališta menadžerske strategije ili troškovnog računovodstva.

Iz tablice 2. vidljivo je da je uzrok promjene Malmquistova indeksa promjene produktivnosti u sektoru komercijalnih banaka u Hrvatskoj prije svega pomak granice. Pomak produktivne granice za većinu je banaka bio relativno stabilan i negativan,  $T\Delta < 1$ , dok su pozitivne promjene, “tehnološki napredak” –  $T\Delta > 1$ , zabilježene u neznatnog broja banaka u uzorku, tj. samo na pojedinim dijelovima granice. Rezultat je očekivan zbog već navedene ekonomske interpretacije indeksa. Uzrok tehnološkog nazadovanja proizlazi iz stabilizacije bankovnog sektora. S porastom konkurencije i postupnim smanjenjem kamatnjaka smanjivala se profitabilnost banaka, a pošto su varijante profita outputi u promatranom modelu, razumljiv je izgled granice numerički opisan u tablici. Usto, indeks promjene efikasnosti u nekih se banaka dramatično mijenjao. I taj je rezultat očekivan jer je primijenjena *metodologija po konstrukciji osjetljiva na varijabilnost outputa*<sup>6</sup>, a oni su se u većine promatranih banaka u analiziranom razdoblju značajno mijenjali.

<sup>5</sup> Casu i Girardone (2004); Fixler i Zieschang (1999); Gilbert i Wilson (1998); Grifell-Tatje i Lovell (1996; 1997); Jun i Sourafel (2004); Mohan i Ray (2004); Mukherjee, Ray i Miller (2001); Rebelo i Mendes (2000); Rime i Stiroh (2003); Rogers, 1998; Sathye, 2002; Stiroh, 2000; Wheelock i Wilson (1999) te Worthington (1999).

<sup>6</sup> Dobit prije oporezivanja Zagrebačke banke, između 2000. i 2001. godine, smanjila se na 50,3%. Rezultat navedene promjene, između ostaloga, jest i iznos njezine relativne radijalne tehničke efikasnosti, koja je 2001. godine bila 53,9%.

Tablica 2. Malmquistov indeks promjene produktivnosti, indeks promjene relativne tehničke efikasnosti i indeks pomaka granice hrvatskoga bankarskog sektora<sup>a</sup>

Broj	Banka	Malmquistov indeks			Promjena efikasnosti			Pomak granice		
		00-01.	01-02.	02-03.	00-01.	01-02.	02-03.	00-01.	01-02.	02-03.
1.	Centar banka	0,901	1,301	0,766	1,116	1,455	0,834	0,807	0,894	0,919
2.	Credo banka	1,369	1,558	0,504	1,777	1,681	0,528	0,771	0,927	0,955
3.	Gospodarska kred. banka	0,557	0,286	1,334	0,842	0,342	1,551	0,662	0,834	0,860
4.	Hrvatska poštan. banka	1,548	7,191	0,940	1,844	7,747	1,000	0,839	0,928	0,940
5.	HVB splitska banka	2,231	1,048	0,716	2,194	1,189	0,900	1,017	0,882	0,796
6.	Hypo Alpe-Adria	1,304	0,860	0,738	1,034	1,000	1,000	1,261	0,860	0,738
7.	Imex banka	1,217	0,866	0,938	1,347	1,000	1,000	0,903	0,866	0,938
8.	Istarska kreditna banka	1,077	0,961	1,023	1,258	1,035	1,113	0,856	0,928	0,919
9.	Jadranska banka	3,427	0,405	2,699	4,069	0,434	2,799	0,842	0,934	0,964
10.	Karlovačka banka	0,414	2,092	0,696	0,394	2,405	0,868	1,050	0,870	0,802
11.	Kreditna banka Zagreb	0,871	1,696	2,651	1,085	1,861	2,644	0,803	0,911	1,002
12.	Kvarner banka	1,764	0,979	0,920	2,093	1,157	1,059	0,842	0,846	0,869
13.	Nava banka	0,401	1,755	0,843	0,514	1,824	0,876	0,780	0,962	0,962
14.	Partner banka	1,851	0,830	1,261	2,444	0,917	1,279	0,758	0,905	0,986
15.	Podravska banka	2,653	1,726	1,022	4,113	1,951	1,028	0,645	0,885	0,994
16.	Požeška banka	0,616	0,619	0,077	1,000	0,717	0,078	0,616	0,864	0,989
17.	PBZ	1,181	1,033	0,851	1,484	1,116	1,000	0,796	0,925	0,851
18.	PB – Laguna banka	1,274	1,130	0,935	1,861	1,272	0,931	0,684	0,889	1,004
19.	Raiffeisenbank	1,177	0,542	1,072	1,007	0,646	1,407	1,169	0,839	0,762
20.	Riadria banka	3,670	0,982	1,035	4,615	1,082	1,068	0,795	0,907	0,969
21.	Samoborska banka	1,460	1,753	0,070	1,900	1,923	0,068	0,769	0,911	1,027
22.	Slatinska banka	1,164	1,400	0,738	1,547	1,524	0,729	0,752	0,918	1,013
23.	Štedbanka	0,770	0,989	1,077	1,000	1,000	1,000	0,770	0,989	1,077
24.	Varaždinska banka	1,699	1,047	1,124	2,103	1,146	1,192	0,808	0,914	0,943
25.	Volksbank	0,887	0,537	0,767	0,843	0,624	0,979	1,052	0,860	0,784
26.	Zagrebačka banka	0,487	1,262	1,180	0,539	1,361	1,360	0,902	0,927	0,868

<sup>a</sup> Podaci na temelju kojih je napravljen proračun preuzeti su iz analize bankovnog sektora objavljene u časopisu "Privredni vjesnik".

Kako je u većini primjera pomak granice bio negativan i konstantan, možemo zaključiti da su varijacije MPI-ja najvećim dijelom uzrokovane promjenom relativne tehničke efikasnosti.  $MPI > 1$  prezentira pozitivnu promjenu višefaktorske produktivnosti, dok  $MPI < 1$  označava negativnu promjenu višefaktorske produktivnosti. Prva komponenta MPI-ja, promjena relativne tehničke efikasnosti, značajno se mijenjala.  $TE\Delta > 1$  znači pozitivnu promjenu relativne tehničke efikasnosti, tj. približavanje određene banke efikasnoj proizvodnoj granici, dok vrijednost  $TE\Delta < 1$  označava udaljavanje od navedene

granice, koje ne mora nužno označavati pad produktivnosti pojedine banke, već može biti uzrokovano pozitivnim pomakom granice. Banke čija je vrijednost  $TE\Delta=1$  zadržale su isti relativni položaj u odnosu prema granici.

U drugom koraku analize uobičajeno je regresijskim modelom objasniti svaku komponentu promjene produktivnosti egzaktno određenu determinističkom metodom. Nažalost, statistička analiza za tako turbulentan bankarski sektor kao što je hrvatski pokazala se beskorisnom, potvrđujući rad Fethi, Shaaban i Weyman-Jones (2004b).

#### 4. Zaključak

Velik broj fuzija i akvizicija banaka unutar hrvatskoga bankarskog sektora, nekoliko propalih manjih banaka te velik broj banaka koje su u razdoblju od 2000. do 2004. godine povremeno poslovale s negativnom dobiti, navele su nas da se u provedenoj analizi orijentiramo samo na dio bankarskog sektora koji čine banke koje su u promatranom vremenskom razdoblju ostvarivale dobit na kraju svake poslovne godine. Razmišljajući o odabiru adekvatnih inputa i outputa, a u želji da oni budu što reprezentativniji, u početku smo smatrali da dobit ne bi smjela biti jedan od odabranih outputa. Naime, dobit kao pozicija u računu dobiti i gubitka ne odražava samo poslovnu uspješnost banke, već ovisi i o njezinim ciljevima, strategijama i poslovnoj politici raspodjele nove vrijednosti. Međutim, zaključili smo da je pogrešno pokušavati odrediti output koji će biti reprezentativan za sve banke iz sektora, te smo uvidjeli da *analitičar može razviti svoju intuiciju o poslovnim strategijama i financijskim kretanjima unutar analiziranog sektora samo ako se bude koristio s više različitih odabira inputa i outputa.*

Na kraju istaknimo da je primarni cilj ovog rada bio prezentiranje nove znanstvene metodologije, uz ilustraciju njezine primjene na bankovnom sektoru Hrvatske. Detaljnu analizu bankovnog sektora Hrvatske provest ćemo u budućim radovima. Sukladno tome, možemo konstatirati da su radom uspješno zadovoljeni postavljeni ciljevi. Osim lako uočljivih prednosti korištenja opisane metodologije, njezin glavni nedostatak proizlazi iz činjenice da *u praktičnim primjenama svi inputi i outputi nemaju jednaku važnost.* Stoga se nameće potreba njezine prilagodbe tako da *analitičaru omogući ugrađivanje njezinih stručnih znanja i prosudbi u mjeru efikasnosti.* Zaključimo: prije izgradnje ozbiljnijeg modela za ocjenu uspješnosti poslovanja zasnovanoga na analitičarovim preferencijama, MPI se treba koristiti isključivo za dopunu klasične analize financijskih pokazatelja. Uz prihvaćanje navedenog ograničenja, ta metodologija ima perspektivu primjene u procesu analize svake grupe djelatnosti.

#### LITERATURA

**Berger, S. A., Forsund, F. R. and Jensen, E. S., 1992.** "Malmquist Indices of Productivity Growth during the Deregulation of Norwegian Banking, 1980-89". *Scandinavian Journal of Economics*, 94 (Supplement), 211-228.

**Casu, B. and Girardone, C., 2004.** "An Analysis of the Relevance of Off-Balance Sheet Items in Explaining Productivity Change in European Banking". Paper presented at the North American Productivity Workshop 2004.

**Caves, D. W., Christensen, L. R. and Diewert, W. E., 1982a.** "The Economic Theory of Index Numbers and the Measurement of Input, Output and Productivity". *Econometrica*, 50 (6), 1393-1414.

**Caves, D. W., Christensen, L. R. and Diewert, W. E., 1982b.** "Multilateral Comparisons of Output, Input and Productivity using Superlative Index Numbers". *Economic Journal*, 92, 73-86.

**Charnes, A., Cooper, W. W. and Rhodes, E., 1978.** "Measuring the Efficiency of Decision Making Units". *European Journal of Operational Research*, (2), 429-444.

**Coelli, T. J. [et al.], 2005.** *An Introduction to Efficiency and Productivity Analysis*. 2<sup>nd</sup> ed. Springer.

**Debreu, G., 1951.** "The Coefficient of Resource Utilisation". *Econometrica*, (19), 273-292.

**Färe, R. [et al.], 1989.** "Productivity Developments in Swedish Hospitals: A Malmquist Output Index Approach". *Discussion paper*, No. 89-3. Illionis: Southern Illinois University.

**Färe, R. [et al.], 1994a.** "Productivity Growth, Technical Progress and Efficiency Change in industrialized Countries". *American Economic Review*, 84, 66-83.

**Färe, R. and Grosskopf, S., 1994b.** "Understanding the Malmquist productivity index". *Discussion Paper*, No. 94-5 Illionis: Southern Illinois University.

**Farrell, M. J., 1957.** "The Measurement of Productive Efficiency". *Journal of the Royal Statistical Society, Series A*, 120 (3), 253-290.

**Fethi, M. and Olgu, O., 2004a.** "Productivity Decomposition in European Banking with Accession Economies: An Application of Parametric & Nonparametric Malmquist Techniques". Paper presented at the North American Productivity Workshop 2004.

**Fethi, M., Shaaban, M. and Weyman-Jones T., 2004b.** "Egyptian Banking in Transition and Liberalisation: Parametric & Nonparametric Malmquist Applications". Paper presented at the North American Productivity Workshop 2004.

**Fixler, D. and Zieschang, K., 1999.** "The Productivity of the Banking Sector: Integrating Financial and Production Approaches to Measuring Financial Service Output". *Canadian Journal of Economics*, 32 (2), 547-569.

**Gilbert, R. A. and Wilson, P. W., 1998.** "Effects of deregulation on the productivity of Korean Banks". *Journal of Economics and Business*, 50 (2), 133-155.

**Grifell-Tatje, E. and Lovell, C. A. K., 1996.** "Deregulation and Productivity Decline: the Case of Spanish Saving Bank". *European Economic Review*, 40 (6), 1281-1303.

**Grifell-Tatje, E. and Lovell, C. A. K., 1997.** "The Sources of Productivity Change in Spanish Banking". *European Journal of Operational Research*, 98 (2), 364-380.

**Guzowska, M. [et al.], 2005.** "Efficiency of the Polish Banking Sector – Assessing the Impact of Transformation". *Data Envelopment Analysis and Performance Management*, 163-170.

**Jemrić, I. and Vujčić, B., 2002.** "Efficiency of Banks in Croatia: A DEA Approach". *Comparative Economic Studies*, 44, 169-193.

**Jun, D. and Sourafel, G., 2004.** "The Cost Efficiencies of Chinese Banking Industry". Paper presented at the North American Productivity Workshop 2004.

**Kirikal, L., 2005.** "Stabilisation Period and Malmquist Index of Productivity Change: An Empirical Study of Estonian Banks". *Data Envelopment Analysis and Performance Management*, 353-360.

**Kumbhakar, S. C. and Lovell, C. A. K., 2003.** *Stochastic Frontier Analysis*. Cambridge: Cambridge University Press.

**Li, C. F., 2005.** "Inefficiency, Technical Progress and Productivity Change in German Banking: A Category-Based Empirical Study". *Data Envelopment Analysis and Performance Management*, 206-212.

**Lovell, C. A. K., 2003.** "The Decomposition of Malmquist Productivity Indexes". *Journal of Productivity Analysis*, 20, 437-458.

**Malmquist, S., 1953.** "Index Numbers and Indifference Surfaces". *Trabajos de Estadística*, 4, 209-242.

**Mohan, R. and Ray, S., 2004.** "Ownership and performance: A comparison of efficiency and productivity at India's public and private sector banks". Paper presented at the North American Productivity Workshop 2004.

**Mukherjee, K., Ray, S. C. and Miller, S. M., 2001.** "Productivity Growth in Large US Banks: The Initial Post-Deregulation Experience". *Journal of Banking & Finance*, 25 (5), 913-939.

**Rebelo, J. and Mendes, V., 2000.** "Malmquist Indices of Productivity Change in Portuguese Banking: The Deregulation Period". *IAER*, 6 (3), 531-543.

**Rime, B. and Stiroh, K. J., 2003.** "The Performance of Universal Banks: Evidence from Switzerland". *Journal of Banking and Finance*, 27 (11), 2121-2150.

**Rogers, K. E., 1998.** "Non-traditional Activities and the Efficiency of US Commercial Banks". *Journal of Banking and Finance*, 22, 467-482.

**Sathye, M., 2002.** "Measuring Productivity Changes in Australian Banking: an Application of Malmquist Indices". *Managerial Finance*, 28 (9), 48-59.

**Shephard, R. W., 1953.** *Cost and Production Functions*. New York: Princeton University Press.

**Simar, L. and Wilson, P. W., 2002.** "Nonparametric tests of returns to scale". *European Journal of Operational Research*, 139, 115-132.

**Stiroh, K. J., 2000.** "How Did Bank Holding Companies Prosper in the 1990s?". *Journal of Banking and Finance*, 24 (11), 1703-1745.

**Wheelock, D. C. and Wilson, P. W., 1999.** "Technical Progress, Inefficiency and Productivity Change in U.S. Banking 1984-1993". *Journal of Money, Credit and Banking*, 31 (2), 212-234.

**Wilson, P. W., 2005.** "FEAR: A Package for Frontier Efficiency Analysis with R". Unpublished working paper, Department of Economics, University of Texas at Austin, Austin, Texas.



**Worthington, A., 1999.** “Malmquist indices of Productivity change in Australian financial services”. *Journal of International Financial Markets*, 9 (3), 303-320.

**Zhu, J., 2000.** “Multi – factor performance measure model with an application to Fortune 500 companies”. *European Journal of Operational Research*, 123 (1), 105-124.

**Marko Primorac and Zvonimir Troškot: Measuring the Efficacy and Productiveness of Croatian Banks with the Malmquist Index of Change in Total Factor Productivity**

*Abstract*

*In the literature that deals with the empirical measurement of relative technical efficacy and change in the productiveness of banks over time the Malmquist index of change of total factor productivity has become the most often-used analytical tool. It has been shown that the Malmquist index helps both central and commercial bank analysis to monitor trends within the banking sector, and that it can be used as assistance in controlling the system and in strategic planning.*

*This investigation is directed at the relative comparison of banks within the banking sector of Croatia in the period from 2000 to 2003, and is the first paper in which the Croatian banking sector has been analysed with the application of the Malmquist index of change in total factor productivity. The scientific contribution deriving from this is heightened by the interdisciplinarity that informs the paper. The primary objective of the investigation is the monitoring of relative trends of banks inside the very dynamic Croatian banking sector. Focus is placed on the need for the development of additional models to cover alternative and above all off-balance-sheet indicators.*

*Key words: Malmquist Total Factor Productivity Index, banking performance, Croatia*