

Ivan Danko, dipl. oec.

Doc. dr. sc. Marijana Zekić-Sušac

MODEL NEURONSKE MREŽE ZA PREDVIĐANJE CILJNE KAMATNE STOPE DRŽAVNIH REZERVI

Cilj rada bio je kreirati model za predviđanje ciljne kamatne stope federalne banke SAD-a (FED) s pomoću neuronskih mreža. Model je temeljen na podacima o kretanju makroekonomskih varijabli SAD-a u razdoblju od 1959 do 2005. godine. Korišteno je dvanaest ulaznih varijabli, dok je izlazna varijabla bila ciljna kamatna stopa na prekonočne zajmove kojom FED održava monetarnu stabilnost zemlje. Različite arhitekture neuronskih mreža testirane su pomoću backpropagacijon algoritma višeslojne perceptron mreže, te je izabran najbolji model na temelju greške na uzorku za testiranje. Provedena je analiza osjetljivosti, na temelju koje je otkriveno da najveći utjecaj na izlaznu varijablu ima promjena cijene zlata, te promjena tržišnih indeksa (Dow Jones i S&P500). Rezultati modeliranja pokazuju da neuronska mreža neupitno uočava i usvaja međuodnose ulaznih i izlaznih varijabli. Kreirani model ukazuje na značajne mogućnosti metoda umjetne inteligencije u području predviđanja kamatnih stopa i može se koristiti za daljnja istraživanja u tom području.

Ključne riječi: ciljna kamatna stopa, neuronske mreže, predviđanje, višeslojni perceptron

* Slavonska banka d.d. Osijek

** Ekonomski fakultet u Osijeku

1. Uvod

Globalna finansijska tržišta, čiji su sudionici veliki investicijski i mirovinski fondovi, osiguravajuća društva te bankarske grupacije u umreženom i telekomunikacijski povezanim svijetu dobivaju sve veći značaj za razvitak nacionalnih i svjetskih gospodarstava. Kapital koji posjeduju u velikoj mjeri određuje kretanje stope rasta bruto domaćeg proizvoda zemalja, stope inflacije, nezaposlenosti, trgovinske i platne bilance, te niz drugih makroekonomskih pokazatelja.

Finansijska tržišta današnjice određuje velik broj sudionika s različitim preferencijama rizika, različitim vremenskim horizontima u ulaganju, motivacijama ulaganja i reakcijama na neočekivane i iznenadne vijesti. U skladu s tim, metode i modeli korišteni u predviđanju finansijskih tržišta također postaju sve sofisticirаниji, a ulagači, posrednici i analitičari traže nove načine za postizanje prednosti nad svojim konkurentima. Jedan od mehanizama za regulaciju i usmjeravanje tržišta neke zemlje jesu instrumenti monetarne politike, među kojima su (Hrvatska narodna banka, 2006): (1) operacije na otvorenom tržištu (kada se ciljevi monetarne politike postižu kupnjom i prodajom vrijednosnih papira, primjerice državnih obveznica ili trezorskih zapisa, na finansijskom tržištu), (2) politika ekonome (diskontne) kamatne stope kada mijenjanjem ekonome stope središnja banka utječe na ponudu i potražnju za kreditima, tj. na ponudu i potražnju za novcem ali i na njegovu cijenu, (3) određivanje visine obvezne rezerve (direktno utječe na kreditni potencijal banaka). Razdoblja recesije obično prati smanjenje stopa obveznih rezervi, dok se tijekom razdoblja ekspanzije one povećavaju.

Rad se bavi predviđanjem kretanja ciljne kamatne stope središnje banke Sjedinjenih američkih država koja se, s obzirom na kretanje gospodarstva i usmjeravanje u svrhu postizanja stabilnosti, najavljuje uvijek za razdoblje unaprijed. Kamatnu stopu na prekonočne zajmove možemo nazvati i bezričičnom kamatnom stopom te ona predstavlja

osnovu za kretanje svih ostalih kamatnih stopa (na kratkoročne vrijednosne papire, dugoročne vrijednosne papire, kratkoročne kredite, dugoročne kredite, hipotekarne kredite).

Na značaj predviđanja ciljne kamatne stope ukazuje istraživanje Lobo-a (2000), kojim se pokazalo da najave promjene ciljne kamatne stope donose značajnu novu informaciju na tržište dionica. Poseban utjecaj na sklonost riziku, te na tržišnu volatilnost imaju najave istovremene promjene ciljne i diskontne stope. Usmjeravanje kamatne stope, koju središnja banka želi postići na tržištu, kreće se u malim pomacima od 0,25 do 0,50 postotnih poena, koji dugoročno imaju efekta, dok se drastične promjene zbog svoje nepredvidljivosti u dužem periodu, izbjegavaju. Za predviđanje tako malih promjena u kamatnoj stopi traže se metode koje mogu s velikom točnošću predvidjeti visinu promjene, a upravo su neuronske mreže u brojnim istraživanjima pokazale veću točnost od standarnih statističkih metoda (Li, 1994).

Istraživanje se temelji na podacima prikupljenim iz baze podataka banke Federalnih rezervi St. Louis (Thornton, 2006). U nastavku je dan pregled rezultata prethodnih istraživanja u tom području, opis metodologije neuronskih mreža, te rezultati kreiranog modela sa smjernicama za daljnja istraživanja.

2. Pregled prethodnih istraživanja

U zadnjih nekoliko desetljeća istraživanja iz područja finansijskog modeliranja učestalo su se bavila predviđanjem kamatnih stopa. Neki od poznatijih parametrijskih modela su: (a) Chan, Karolyi, Longstaff, Sanders, (b) Brennan i Schwartz, (c) Cox, Ingersoll, Ross; te (d) Vasicek (Nowman and Saltoglu, 2003). Oni se uglavnom temelje na općim metodama Gauss-ove procjene i koriste diskretnu aproksimaciju i Gauss-ovu metodu kvazi-maksimalne vjerojatnosti (QML) (Nowman i Saltoglu, 2003). Dvofaktorski modeli s proširenom QML procjenom pokazali su se također uspešnima u nekim istraživanjima (Nowman and Saltoglu, 2003). Međutim, upotreba neparametrijskih metoda, kao npr. neuronskih mreža i drugih u ovom području još uvijek nije dovoljno istražena.

Prema Wong et al. (1997) najčešća područja primjene neuronskih mreža u poslovanju su: (1)

proizvodnja i operacije (53,5%), (2) financije i ulaganje (25,4%), te (3) marketing i trgovina. Ako se promatra samo područje financija i ulaganja, problemi za čije se rješavanje učestalo koriste neuronske mreže su: procjena zajmova, odobrenje hipotekarnih i drugih kredita, prognoziranje kategorije rizika, predviđanje na tržištu vrijednosnih papira (određivanje povoljnog trenutka kupovine i prodaje dionica, obveznica, predviđanje kretanja cijena dionica, predviđanje povrata na tržištu dionica i dr.), prepoznavanje uzoraka za kupovinu i prodaju na tržištu budućih roba, te brojni drugi (Zahedi, 1996).

Predviđanje kamatnih stopa na korejskom i američkom tržištu novca temeljem ekonomskih i finansijskih varijabli pomoću neuronskih mreža istraživali su Kim i Noh (1997). Kao izlazna varijabla na korejskom skupu podataka korištena je kamatna stopa na korporativne korejske obveznice s rokom dospijeća od 3 godine, dok su trezorski zapisi s rokom dospijeća od 1 godine predviđani na američkom skupu podataka. Kamatne stope u prošlom razdoblju, novčana masa, indeks potrošačkih cijena, indeks industrijske proizvodnje, cijena nekretnina, te burzovni indeks, bile su ulazne varijable u modelima. Upotrijebljen je individualni i integrativni pristup backpropagation algoritma neuronske mreže, te sustava za zaključivanje na temelju slučajeva (eng. case-based reasoning) koji je služio za prethodnu obradu znanja. Najveću točnost predviđanja korejskih kamatnih stopa pokazao je model neuronskih mreža (iako razlika nije bila statistički značajna), dok je američke kamatne stope najbolje predviđao integrativni inteligentni sustav, koji je bio i statistički značajno superiorniji u odnosu na model slučajnog hoda (eng. random walk model). Quah et al. (2000) koristili su neuronske mreže za predviđanje ciljne kamatne stope na federalne fondove. Njihov model koristi varijable iz kategorija indikatora inflacije, ekonomskih indikatora realnog sektora gospodarstva, monetarnih agregata, indikatora otvorenog tržišta). Upotrijebljena je neuronska mreža opće regresije (eng. general regression neural network), a izlazna varijabla se predviđa za više vremenskih intervala (na mjesечноj razini, tromjesečnoj i šestomjesečnoj). Pokazalo se da neuronska mreža može predvidjeti smjer kretanja ciljne kamatne stope s točnošću do 85%, dok je najveća točnost predviđanja same vrijednosti stope bila 65%. Oh i Han (2000) su uspoređivali kamatne

stope na američkom tržištu vrijednosnica različitog roka dospijeća kao i njihovu međuvisnost kroz tri faze istraživanja. U prvoj su fazi detektirane ključne točke promjene distribucije kamatnih stopa u pro-matranom uzorku, kao i homogene grupe između tih točaka. Druga je faza obuhvatila predviđanje ključnih točaka grupa, a posljednja faza predviđanje promjene izlazne varijable za svaku grupu. Tako kreirani model pokazao je statistički značajno veću točnost predviđanja od običnog modela.

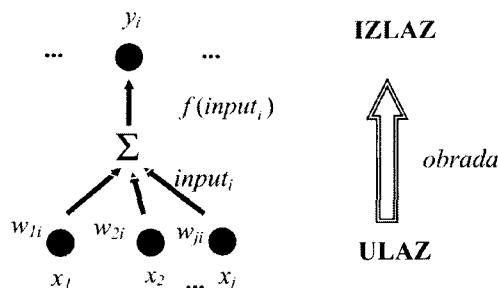
Nowman i Saltoglu (2003) uspoređuju neuronske mreže s drugim neparametrijskim modelima (k najблиžih susjeda, lokalna linearna regresija), te parametrijskim modelima na predviđanju 1-mjesečnih i 12-mjesečnih kamatnih stopa na štednjku u Eurima u SAD-u. Na temelju korijena srednje kvadratne greške (RMSE) rezultati su pokazali su da je Vasicek-ov model bio najuspješniji u predviđanju (RMSE=0.0016 za 1-mjesečne i 0.0015 za 12-mjesečni model), dok je od neparametrijskih metoda k-najблиžih susjeda dala najnižu RMSE i za 1-mjesečni model (RMSE=0.0017), kao i za 12-mjesečni model (RMSE=0.018). Kako je u njihovom radu korišten samo jedan algoritam neuronskih mreža (višeslojni perceptron), sa sigmoidnom (logističkom) prijenosnom funkcijom.

Može se zaključiti da su prethodna istraživanja pokazala uspješnost metodologije neuronskih mreža, kako u predviđanju različitih varijabli na finansijskim tržištima, tako i u modeliranju i simuliranju tih tržišta. Međutim, modeliranje ciljne kamatne nije dovoljno zastupljeno u radovima, a budući da rezultati variraju ovisno o upotrijebljenom algoritmu neuronskih mreža i podacima, za pronaalaženje uspješnog modela nužno je ispitati više arhitektura neuronskih mreža, što je i cilj ovog rada.

3. Metodologija neuronskih mreža

Prema Winston-u (1979), umjetna inteligencija obuhvaća metode i postupke koji koriste znanje da bi se upravljalo informacijama (podacima) tako da nastaju novi zaključci koji nisu eksplicitno programirani. Neuronske mreže su, uz ekspertne (stručne) sustave, genetičke algoritme, prepoznavanje govora, obradu prirodnog jezika, inteligentne agente i robotiku, jedna od metoda umjetne inteligencije čija je upotreba sve učestalija u različitim problemskim područjima.

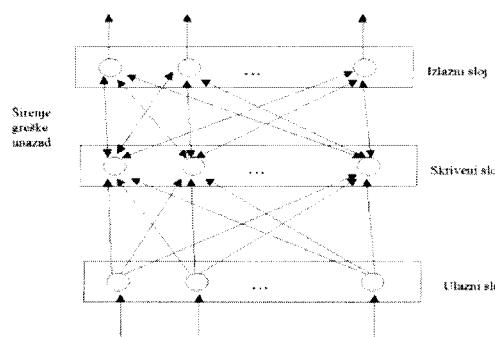
Neuronska mreža je međusobno povezana nakupina jednostavnih elemenata obrade, jedinica ili čvorova, čiji se načini djelovanja temelje na načinu djelovanja neurona kod živih bića. Sposobnost obrade mreže je posljedica jačine veza među tim jedinicama, a postiže se u procesu adaptacije ili učenjem iz skupa primjera za uvježbavanje (Gurney, ...). Drugim riječima, neuronske mreže su programi ili hardverski sklopovi koji, najčešće iterativnim, postupkom iz prošlih podataka nastoje pronaći vezu između ulaznih i izlaznih varijabli modela, kako bi se za nove ulazne varijable dobila vrijednost izlaza. Umjetni je neuron (Slika 2.) jedinica za obradu podataka (varijabli) koja prima ponderirane ulazne vrijednosti od drugih varijabli, prema nekoj formuli transformira primljenu vrijednost te šalje izlaz drugim varijablama. Učenje se odvija promjenom vrijednosti "težina" među varijablama (težine w_{ji} su ponderi kojima se množe ulazne vrijednosti u neki "neuron").



Slika 1. Proces prolaska informacija kroz umjetnu neuronsku mrežu (Zekić-Sušac, 2000)

S obzirom na broj slojeva, tip učenja, tip veze između neurona, veza između ulaznih i izlaznih podataka, ulazne i prijenosne funkcije, namjenu, razlikuju se brojni algoritmi neuronskih mreža. Jedan od najčešće korištenih algoritama je višeslojni perceptron. Mreža "višeslojni perceptron" je unaprijedna mreža (eng. feed forward), u kojoj se slojevi mreže povezuju na način da signali putuju samo u jednom smjeru, od ulaza ka izlazima mreže. Najpoznatiji i najčešće upotrebljavani algoritam primijenjen za učenje i treniranje višeslojnih perceptron mreža je tzv. mreža "širenje unatrag" (eng. backpropagation). Algoritam mreže "širenje unatrag" bio je presudan za široku komercijalnu upotrebu ove metodologije, te je neuronske mreže

učinio široko upotrebljavanom i popularnom metodom u različitim područjima. Standardni algoritam mreže "širenje unatrag" uključuje optimizaciju greške koristeći deterministički algoritam gradijentnog opadanja (eng. gradient descent). Glavni nedostatak ovog algoritma je problem čestog pronaalaženja lokalnog umjesto globalnog minimuma greške, stoga novija istraživanja uključuju njegovo unapredavanje nekim drugim determinističkim (npr. metode drugoga reda) ili stohastičkim metodama (npr. simulirano kaljenje). Strukturu mreže čine ulazni sloj, izlazni sloj i najmanje jedan skriveni sloj s vezom unaprijed. Tipična arhitektura "širenje unatrag" prikazana je na slici 3 (zbog jasnoće je prikazan samo jedan skriveni sloj):



Slika 2. Arhitektura mreže "širenje unatrag"
(Zekić-Sušac, 2000)

Arhitektura neuronske mreže sastojala se od tri sloja, a broj jedinica (neurona) u skrivenom sloju i duljina učenja dobiveni su postupkom unakrsne validacije. Učenje mreže odvijalo se na uzorku za treniranje (60% ukupnog uzorka), duljina učenja mreže dobivena je postupkom unakrsne validacije, pri čemu mreža u iterativnom postupku uči na uzorku za treniranje koristeći različite parametre (npr. različit broj skrivenih neurona), a svaka kombinacija se testira na uzorku za validaciju (20% ukupnog uzorka). Cilj je pronaći onu duljinu učenja i strukturu mreže koji daju najbolji rezultat na uzorku za validaciju. Na kraju se tako dobivena mreža testira na uzorku za testiranje (20% ukupnog uzorka), a dobiveni rezultat nakon faze testiranja bio je konačno mjerilo uspješnosti mreže.

Od izlaznih funkcija testirane su sigmoidna i tangens hiperbolna funkcija, dok je kao pravilo učenja korišteno delta pravilo s momentumom 0.7

i dinamičkim koeficijentom učenja od 0.1 do 0.9 prema formuli:

$$\Delta w_{ji(k)}^t = \eta_k \cdot y_{cj} \cdot \epsilon_i + \alpha_k \Delta w_{ji(k)}^{t-1}, \quad (1)$$

gdje je η koeficijent učenja, α momentum, a w_{ji} razlike u težinama između neurona j i neurona i , y_{cj} je output izračunat u mreži, dok je ϵ greška.

Za izračunavanje greške neuronske mreže najčešće se koriste srednja kvadratna greška (eng. mean square error – MSE) ili korijen srednje kvadratne greške (RMSE) (Masters, 1995). U radu je korištena MSE greška prema formuli (Masters, 1995):

$$MSE = \frac{1}{n} \sum_{i=0}^{n-1} (y_d - y_c)^2, \quad (2)$$

gdje je n veličina uzorka za testiranje, y_d je stvarna (željena) vrijednost izlazne varijable, dok je y_c izračunata vrijednost izlazne varijable. Ukoliko su podaci u mreži normalizirani na interval $[0,1]$, govori se o normaliziranoj srednjoj kvadratnoj grešci (NMSE), koja u tom slučaju ukazuje na prosječno postotno odstupanje od stvarnih rezultata.

4. Opis modela i podataka

Uzorak se sastoji od ukupno 562 promatranja obuhvaćajući mjesecne podatke u razdoblju od siječnja 1959. godine do kraja 2005. godine. U modelu je korišteno 12 ulaznih varijabli, na temelju kojih se predviđa vrijednost izlazne varijable - ciljne kamatne stope na američkom tržištu novca (eng. Federal funds target rate – **FFR_TARGET**) u trenutku $t+1$. Ulazne varijable su sljedeće: (1) **S&P500** - indeks cijena 500 najvećih američkih kompanija (prema tržišnoj kapitalizaciji), čije dionice kotiraju na dva najveća tržišta kapitala u SAD-u (New York Stock Exchange i NASDAQ), (2) **DJIE** (Dow Jones Industrial Average) - indeks cijena 30 najvećih i vlasničkom strukturon najdiverzificirajnijih američkih kompanija, sektorski podjednako zastupljenih, (3) **INFL** - stopa inflacije u SAD izražena u % na godišnjoj razini, (4) **UNEMPLOY** - stopa nezaposlenosti također izražena u % na godišnjoj razini, (5) **BANK_PLR** (primary loan rate - minimalna aktivna kamatna

stopa koju velike banke naplaćuju svojim klijentima), (6) **DISC RATE** (discount rate) - kamatna stopa na kratkoročne zajmove koju Fed naplaćuje komercijalnim bankama, a također predstavlja i determiniranu fiksno određenu kamatnu stopu koja je jedan od instrumenata monetarne politike, (7) **1Y TREASURY** (1 year treasury rate) - kamatna stopa na vrijednosne papire s rokom dospijeća do 1 godine, (8) **10Y TREASURY** (10 year treasury rate) - kamatna stopa na vrijednosne papire s rokom dospijeća do 10 godina, (9) **3M TREASURY** (3 month treasury bill rate) - kamatna stopa na emitirane kratkoročne vrijednosne papire (trezorske zapise) s rokom dospijeća do 3 mjeseca, koji se prodaju na sekundarnom tržištu, (10) **6M TREASURY** (6 month treasury bill rate) - kamatna stopa na emitirane trezorske zapise s rokom dospijeća do 6 mjeseci, na sekundarnom tržištu vrijednosnih papira, (11) **GOLD** - cijena zlata, kao jednog od nezamjenjivih sredstava monetarne stabilnosti i čuvara vrijednosti u kriznim vremenima, te (12) vrijednost **FFR** Federal funds rate u trenutku t .

Dakle, kreiran je nelinearni kauzalni model s vremenskom komponentom, s jednom zavisnom i p prediktornih varijabli prema ovom općem modelu (Zhang et al., 1998):

$$y_{t+1} = f(y_t, x_{1t}, x_{2t}, \dots, x_{pt}) + \epsilon_t \quad (3),$$

gdje je y_{t+1} zavisna varijabla (odnosno u našem slučaju FFR) u razdoblju $t+1$, $t=1, \dots, n$, dok su y_t, x_{it} prediktori za $i=1, \dots, p$, a ϵ_t je greška u razdoblju t .

Sve ulazne varijable svedene su na postotne promjene kako bi se izbjegao utjecaj trenda na rezultat neuronske mreže. Deskriptivna statistika (srednja vrijednost i standardna devijacija) za originalne vrijednosti varijabli, kao i za njihove transformirane vrijednosti (relativne postotne promjene) dana je u tablici 1.

Tablica 1. Deskriptivna statistika varijabli u modelu

| Varijabla | Srednja vrijednost | St. devijacija |
|-----------|--------------------|----------------|
| S&P500 | 366,7083 | 404,2873 |
| DJIE | 3100,9598 | 3419,4860 |
| INFL | 4,1994 | 2,9610 |
| UNEMPLOY | 5,8923 | 1,4371 |
| BANK_PLR | 7,9239 | 3,2281 |

| Varijabla | Srednja vrijednost | St. devijacija |
|--------------|--------------------|----------------|
| DISC RATE | 5,5475 | 2,5578 |
| 1Y TREASURY | 6,1247 | 2,9160 |
| 10Y TREASURY | 6,965 | 2,5561 |
| 3M TREASURY | 5,5233 | 2,7684 |
| 6M TREASURY | 5,6790 | 2,7250 |
| GOLD | 244,36190 | 163,6083 |
| FFR | 6,0681 | 3,3420 |
| FFR TARGET | 6,0702 | 3,3383 |

Velika odstupanja od aritmetičke sredine prisutna su kod varijabli DJIE (koeficijent varijacije iznosi 110,27%) i S&P500 (koeficijent varijacije 110,25%), dok ostale varijable posjeduju relativnu raspršenost uglavnom oko 50% ili manju.

Nakon izračunatog Pearsonovog koeficijenta korelacije između ulaznih i izlazne varijable, dobiveno je da s izlaznom varijablom FFR_TARGET snažno koreliraju: tržišna kamatna stopa, stopa inflacije, primarna kamatna stopa, diskontna stopa, te vrijednosni papiri (1-godišnji, 10-godišnji, 3-mjesečni, te 6-mjesečni), dok kod ostalih varijabli nije uočena značajna linearna veza s izlaznom varijablom.

Ukupan uzorak raspodijeljen je na tri dijela. Prvi i najveći dio služi mreži za treniranje (60% uzorka), 20% za unakrsnu validaciju i 20% za testiranje na podacima koji mreži nisu bili dostupni u fazi učenja i unakrsne validacije (tzv. vanjski podaci, eng. out-of-sample).

5. Rezultati

Promjenom broja skrivenih slojeva, jedinica u skrivenom sloju, izlazne funkcije, pravila učenja, te koeficijenta učenja i momentuma, dobiveno je dvadeset različitih arhitektura višeslojne perceptron mreže. Rezultati deset najboljih arhitektura prikazani su u tablici 2. Za svaku mrežu prikazana je srednja kvadratna greška (MSE) dobivena nakon faze treniranja, te MSE i normalizirana srednja kvadratna greška (NMSE) nakon faze testiranja mreže. Kao kriterij za ocjenjivanje uspješnosti mreže uzima se greška dobivena na uzorku za testiranje.

Tablica 2. Tablica rezultata u fazi učenja i testiranja neuronskih mreža

| Rb | Broj skrivenih slojeva | Broj skrivenih jedinica | Duljina učenja (epoha) | Momentum | Izlazna funkcija | Rezultati treniranja | | Rezultati testiranja | |
|----|------------------------|-------------------------|------------------------|----------|------------------|----------------------|---------------|-----------------------------|--|
| | | | | | | MSE greška | MSE greška | Normalizirana greška (NMSE) | |
| 1 | 1 | 4 | 1000 | 0,7 | tangh* | 0,0017 | 0,3380 | 0,0933 | |
| 2 | 2 | 2 | 1000 | 0,7 | tangh | 0,0025 | 0,2725 | 0,0752 | |
| 3 | 1 | 4 | 2000 | 0,7 | tangh | 0,0022 | 0,1034 | 0,0286 | |
| 4 | 1 | 4 | 2000 | 0,8 | tangh | 0,0018 | 0,1499 | 0,0414 | |
| 5 | 1 | 4 | 2000 | 0,6 | tangh | 0,0021 | 0,2095 | 0,0578 | |
| 6 | 1 | 4 | 2000 | 0,7 | sigmoid** | 0,0014 | 0,9518 | 0,2628 | |
| 7 | 1 | 8 | 2000 | 0,7 | tangh | 0,0011 | 0,1358 | 0,0375 | |
| 8 | 1 | 4 | 2000 | 0,7 | tangh | 0,0015 | 0,2092 | 0,0577 | |
| 9 | 1 | 20 | 1000 | 0,7 | tangh | 0,0013 | 0,0938 | 0,0259 | |
| 10 | 1 | 20 | 2000 | 0,7 | tangh | 0,0023 | 0,1678 | 0,0357 | |

*tangens hiperbolna izlazna funkcija

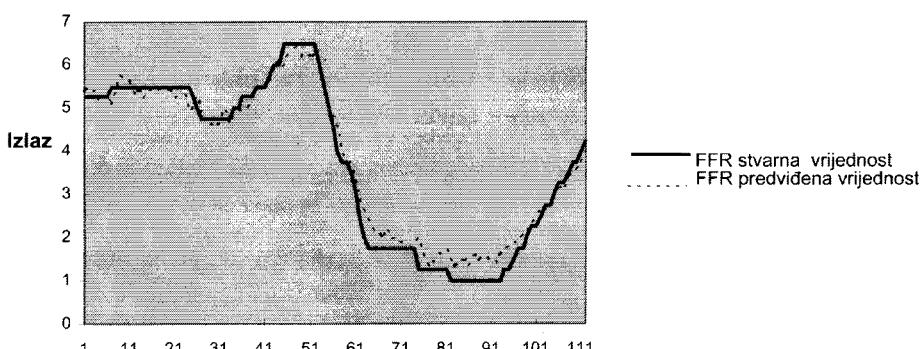
** sigmoidna izlazna funkcija

Iz tablice je vidljivo da je najbolji rezultat i u smislu MSE i NMSE na uzorku za testiranje dobiven s pomoću neuronske mreže pod rednim brojem 9, čija se arhitektura sastoji od jednog skrivenog sloja, 20 jedinica u skrivenom sloju, kao izlazna funkcija korištena je tangens hiperbolna, momentum je 0,7, a mreža je trenirana na 1000 epoha, što znači da je 1000 puta učitan uzorak za treniranje i na njemu iterativno proveden postupak učenja mreže. Također je vidljivo da povećanje duljine učenja (epohe) sa 1000 na 2000 ne doprinosi smanjenju greške, već je povećava, što ukazuje na pojavu pretreniranja mreže ukoliko se koristi 2000 epoha učenja.

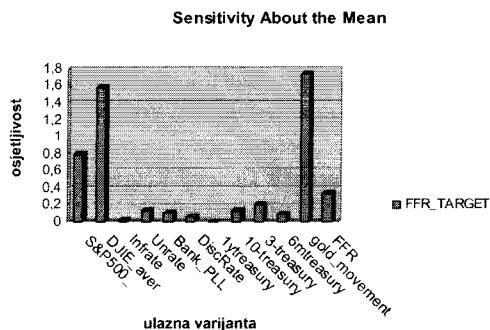
Grafički prikaz kretanja stvarne vrijednosti izlazne varijable i mrežom predviđene, odnosno izračunate vrijednosti prikazan je na Slici 3.

Grafikon 3 pokazuje da se mrežom predviđena i stvarna vrijednost ciljne kamatne stope kod nekih promatranih u uzorku za testiranje poklapaju, dok kod drugih postoje manja ili veća odstupanja. Najveće odstupanje mreža je napravila prilikom predviđanja kretanja kamatne stope između svibnja 2003. i svibnja 2004. (između 81. i 91. promatranih) kada je ciljna kamatna stopa dosegla svoju najnižu razinu u posljednjih 50 godina. Na jaku povezanost stvarnog i predviđenog rezultata ukazuje i Pearsonov koeficijent korelacije između tih dviju veličina koji za najbolju mrežu iznosi 0,99.

Nakon izabranoga najboljeg modela neuronske mreže korisno je napraviti analizu značajnosti ulaznih varijabli koja je u radu provedena kroz analizu osjetljivosti na način da je izračunata promjena izlazne varijable ako se pojedina ulazna varijabla promjeni za određeni interval (+-5%) vrijednosti. Slika 4 prikazuje kolika je osjetljivost ciljne kamat-

**Slika 3.** Kretanje stvarne i mrežom predviđene vrijednosti ciljne kamatne stope (FFR)

ne stope (FFR_TARGET) na svaku od ulaznih varijabli u modelu.



Slika 4. Analiza osjetljivosti ciljne kamatne stope na ulazne varijable u modelu

Vidljivo je da promjena cijene zlata najviše utječe na output, zatim promjena kretanja indeksa cijena (Dow Jones i S&P500). Varijabla koja najslabije reagira je kamatna stopa na vrijednosnice s rokom dospijeća do godine dana. Brojčano je utjecaj ulaznih varijabli na izlaznu prikazan u Tablici 3.

Tablica 3. Osjetljivost ciljne kamatne stope na ulazne varijable u modelu

| Ulazna varijabla | Osjetljivost FFR_Target varijable |
|------------------|--------------------------------------|
| S&P500 | 0,799767673 |
| DJIE | 1,580636859 |
| INFL | 0,01960768 |
| UNEMPLOY | 0,132061794 |
| BANK_PLI | 0,110096999 |
| DISC_RATE | 0,059020061 |
| 1Y_TREASURY | 0,00729966 |
| 10Y_TREASURY | 0,136470169 |

| Ulazna varijabla | Osjetljivost FFR_Target varijable |
|------------------|--------------------------------------|
| 3M_TREASURY | 0,20775409 |
| 6M_TREASURY | 0,093965754 |
| GOLD | 1,738016963 |
| FFR | 0,338881195 |

6. Zaključak

Rad je potvrdio pretpostavku o postojanju snažnih veza među varijablama uključenim u istraživanje o predviđanju ciljne kamatne stope državnih rezervi SAD-a s pomoću neuronskih mreža. Na temelju dvadeset različitih arhitektura izabran je najbolji model neuronske mreže koji s visokom točnošću može predvidjeti kretanje izlazne varijable. Rezultati najboljeg modela neuronske mreže pokazuju da mreža prilikom učenja neupitno uočava i usvaja nelinearne međuodnose ulaznih i izlaznih varijabli, a u predviđanju prosječno odstupanje rezultata mreže od stvarnih vrijednosti izlazne varijable zadržava u granici od 2,6%, što je veća točnost u usporedbi s rezultatima prethodnih istraživanja u predviđanju ciljne kamatne stope državnih rezervi (Quah et al, 2005).

Dobiveni model može poslužiti kao temelj za daljnja istraživanja u ovom području, stavljajući naglasak na mogućnosti metoda umjetne inteligencije, posebno neuronskih mreža i genetskih algoritama. Smjernice za buduća istraživanja uključuju i nadogradnju promatranog modela, u koji bi bilo uključeno više ulaznih varijabli s više različitih tržišta, podijeljenih na sektore gospodarstva, s ciljem praćenja i prognoziranja više izlaznih varijabli, ovisno o preferencijama korisnika sustava, što bi omogućilo kreiranje modela upotrebljivog za potporu odlučivanju u finansijskom managementu.

Literatura

1 U. Anders, O. Korn, Model selection in neural networks, *Neural Networks*, Vol. 12, 1999, pp. 309-323.

2 K.C. Chan, G.A. Karolyi, F.A. Longstaff, A.B. Sanders, An empirical comparison of alternative models of the short-term interest rate, *Journal of Finance*, 47, 1992, pp.1209-1227.

3 P.E. Gaynor, R.C. Kirkpatrick, *Introduction to Time-Series Modeling and Forecasting in Business and Economics*, McGraw-Hill, Inc., New York, 1994.

4 Hrvatska narodna banka, Instrumenti monetarne politike, <http://www.hnb.hr/monet/hmonet.htm>, 01.12.2006.

5 M.Y. Hu, G. Zhang, C.X. Jiang, B.E. Patuwo, A crossvalidation analysis of neural network out-of-sample performance in exchange rate forecasting, *Decision Sciences*, Vol. 30, No. 1, 1999, pp. 197-216.

6 N.B. Karayannidis, G.M. Weigun, Growing Radial Basis Neural Networks: Merging Supervised and Unsupervised Learning with Network Growth Techniques, *IEEE Transactions on Neural Networks*, Vol. 8, No. 6, 1997, pp. 1492-1505.

7 Y. Liu, Unbiased estimate of generalization error and model selection in neural network, *Neural Networks*, Volume 8, Issue 2, 1995, pp. 215-219.

8 B.J. Lobo, Asymmetric Effects of Interest Rate Changes on Stock Prices, *The Financial Review*, Vol. 35, No. 3, 2000, pp. 125-144.

9 T. Masters, Advanced Algorithms for Neural Networks, A C++ Sourcebook, John Wiley & Sons, 1995.

10 K. B. Nowman, B. Saltoglu, Continuous time and nonparametric modelling of U.S. interest rate models, *International Review of Financial Analysis*, Volume 12, 2003, pp. 25-34.

11 K.J. Oh, I. Han, Using change-point detection to support artificial neural networks for interest rates forecasting, *Expert Systems with Applications*, Volume 19, 2000, pp. 105-115.

12 D.W. Patterson, *Artificial Neural Networks*, Prentice Hall, 1995.

13 T. Quah, B. Srinivasan, W. Chong, Predicting Federal Funds Target Rate using Neural Network, www.ntu.edu.sg/eee/icis/cv/publications/QTS/c_35.pdf, School of Electrical & Electronic Engineering, 13.01.2005.

14 S. Russel, P. Norvig, *Artificial Intelligence - A modern approach*, Prentice Hall, New York, 2003.

15 D.F. Specht, A General Regression Neural Network, *IEEE Transactions on Neural Networks*, Vol. 2, No. 6, 1991, pp. 568-576.

16 D.L. Thornton, A New Federal Funds Rate Target Series: September 27, 1982. – December 31, 1993., Working paper 2005-032A, The Federal Reserve Bank of St. Louis, 2005, <http://research.stlouisfed.org/wp/2005/2005-032.pdf>, 15.01.2006.

17 F. Zahedi, A Meta-Analysis of Financial Applications of Neural Networks, *International Journal of Computational Intelligence and Organizations*, Vol. 1, No. 3, 1996, pp. 164-178.

18 M. Zekić-Sušac, Neuronske mreže u predviđanju profitabilnosti ulaganja, doktorska disertacija, Sveučilište u Zagrebu, Fakultet organizacije i informatike Varaždin, 2000.

19 G. Zhang, B.E. Patuwo, M.Y. Hu, Forecasting with artificial neural networks: The state of the art, *International Journal of Forecasting*, Volume 14, 1998, pp. 35-62.

Ivan Danko, grad. oec., Marijana Zekić-Sušac, Ph. D.

NEURAL NETWORK MODEL FOR PREDICTING TARGET INTEREST RATE OF FEDERAL FUNDS

Summary

The aim of the paper was to create a model for predicting the US federal funds target rate using neural networks. The model is based on macroeconomic data of the USA covering the period from 1959 to 2005. The input variables were used while the output one was the federal funds target rate that is used by American Federal Bank (FED) to ensure the monetary stability in the country. Different neural network architectures were tested using the backpropagation algorithm and the best neural network model is selected based on test error. The sensitivity analysis was also conducted revealing that the most influential input variables are the gold change and the change of market indices (Dow Jones and S&P500). The modeling results show that the neural network is able to incorporate the relationship among input variables and output ones. The created model reveals that artificial intelligence methods have great potential in the area of interest rate prediction and could be used for future research in that area.

Key words: target interest rate, neural networks, prediction, multilayer perceptron