

**METODE ZA ANALIZU FINANSIJSKIH PODATAKA I RAZVOJ ALGORITAMSKIH
STRATEGIJA ZA AUTOMATSKO TRGOVANJE
METHODS FOR ANALYSIS OF FINANCIAL DATA AND DEVELOPMENT OF
ALGORITHMIC STRATEGIES FOR AUTOMATED TRADING**

Velibor Ilić

REZIME: Na tržištu stranih valuta sve više se automatski trguje pomoću softverskih metoda čime se znatno ubrzava proces trgovanja. Softver za automatsko trgovanje omogućava praćenje velikog broja parametara i donošenje odluka u realnom vremenu. Softverske metode trgovanja smanjuju uticaj ljudskih emocija na donošenje odluka i omogućavaju prevazilaženje problema koji mogu nastati usled nedostatka koncentracije. Savremena tehnologija, softver i podaci koji pristižu u realnom vremenu sami po sebi nisu dovoljni da bi rezultati trgovanja bili uspešni. Tehnologija obezbeđuje samo više informacija i brži proces trgovanja, međutim da bi rezultati trgovanja bili uspešni i dalje je potrebno pronaći odgovarajući način na koji iskoristi dostupne informacije i na koji način doneti ispravne odluke. U radu je opisana primena neuronskih mreža, data mining-a i evolutivnih metoda za analizu finansijskih podataka i traženje profitabilnih strategija trgovanja.

KLJUČNE REČI: neuronske mreže, data mining, evolutivne metode, genetski algoritam, strategije trgovanja, tržište stranih valuta, Forex

ABSTRACT: Automatic trading software speeds up the process of trading on foreign exchange market. Automated trading software allows monitoring a large number of parameters and make decisions in real time. Software trading methods reduce the impact of human emotions in decision making process and allow to overcome problems that may arise due to lack of concentration. Modern technology, software, and real-time information does not guaranty successful trading results. Technology provides more information and a faster process of trading, however, for successful trading results is still necessary to find an appropriate approach how to use of available information and how to make correct decisions. This paper describes the application of neural networks, data mining and evolutionary methods for the analysis of financial data and search for profitable trading strategies.

KEY WORDS: neural networks, data mining, evolutionary methods, genetic algorithm, trading strategies, foreign exchange market, Forex

UVOD

Tržište stranih valuta (*Forex* ili *FX*) omogućava jednostavnu kupovinu i prodaju stranih valuta. Predstavlja jedno od najvećih i najlikvidnijih finansijskih tržišta na kome učestvuju banke, centralne banke, finansijske institucije, vlade, korporacije, osiguravajuće kompanije ali i individualni trgovci. Tržište stranog novca je specifično zbog obima trgovanja, velike likvidnosti tržišta, globalne rasprostranjenosti, dostupno je 24 časa dnevno osim vikendom. Na ovakvom tržištu profit se ostvaruje kupovinom i prodajom valuta po različitom kursu. Glavne valute kojima se trguje na berzi stranog novca su: američki dolar (USD), evro (EUR), japanski jen (JPY), britanska funta (GBP), švajcarski franak (CHF), australijski dolar (AUD), kanadski dolar (CAD), novozelandski dolar (NZD) i druge valute.

TRGOVANJE NA TRŽIŠTU STRANIH VALUTA

Trgovanje na finansijskom tržištu predstavljaju niz uzastopnih operacija u kojima se vrši prodaja ili kupovina. Trgovanje na finansijskom tržištu počinje u momentu otvaranja pozicije (kupovinom ili prodajom) a završava se u momentu zatvaranja pozicije. Otvaranje pozicije predstavlja momenat od koga se računa razlika u ceni. Prilikom otvaranja pozicije korisnik bira valutni par, vrstu transakcije tj. da li će izvršiti BUY ili SELL nalog (kupovina ili prodaja) i iznos kojim se trguje. Ostvareni

profit (ili gubitak) izračunava se kao razlika između cene kada je pozicija otvorena i cene kada je pozicija zatvorena. Pored razlike u ceni, profit (ili gubitak), zavisi i od iznosa kojim se trguje. Pozicije na tržištu se otvaraju i zatvaraju pomoću naloga za trgovanje.

Na raspolaganju je veći broj softverskih platformi za trgovanje ili terminala koji korisnicima omogućava da se uključe u trgovanje na berzi stranog novca, na primer MetaTrader, VT Trader i drugi. Ovakve softverske platforme, klijentski terminali prikazuju promene cena na tržištu u realnom vremenu i omogućava korisnicima da šalju naloge za trgovanje preko kojih upravljaju svojim pozicijama takođe u realnom vremenu^[1].

ALGORITAMSKE STRATEGIJE ZA AUTOMATSKO TRGOVANJE

Na tržištu stranog novca se sve više automatski trguje pomoću softverskih metoda čime se znatno ubrzava proces trgovanja. Softver za automatsko trgovanje omogućava praćenje velikog broja parametara i donošenje odluka u realnom vremenu. Softverske metode trgovanja smanjuju uticaj ljudskih emocija na donošenje odluka i omogućavaju prevazilaženje problema koji mogu nastati usled nedostatka koncentracije. Ovakvim strategijama se okvirno može proceniti efikasnost i nivo rizika testiranjem na istorijskim podacima pre nego što se upotrebe u realnom trgovanju. Savremena tehnologija,

softver i podaci koji pristižu u realnom vremenu nisu sami po sebi dovoljni da bi rezultati trgovanja bili uspešni. Tehnologija obezbeđuje samo više informacija i brži proces trgovanja, međutim da bi rezultati trgovanja bili uspešni i dalje je potrebno pronaći odgovarajući način na koji iskoristi dostupne informacije i na koji način doneti ispravne odluke^[2].

Tehnička analiza predstavlja skup metoda koje se koriste da bi se odredio smer kretanja cena i intenzitet trgovanja u određenim vremenskim periodima na tržištu. Ovakav pristup trgovanja bazira se na pretpostavci da se cene na finansijskom tržištu kreću u trendovima, i da se mogu uočiti obrasci cena koji se ponavljaju. Tehničkom analizom se pokušava odrediti odnos ponude i potražnje, intenzitet trgovanja, i pokušavaju se odrediti nivoi na kojima se može očekivati promena smera kretanja cena. Tehnički indikatori predstavljaju matematičke instrumente kojima se analiziraju cene u određenim vremenskim periodima i na osnovu ovih parametara se pokušava proceniti dalje kretanje cena na tržištu.

Kada se pokušava odrediti trend kretanja cena na tržištu, treba obratiti pažnju na to da ne postoji samo jedan trend kretanja cena nego više različitih trendova na koji se javljaju različitim periodima (dugoročni, srednji i kratkoročni trendovi). Ovi trendovi se često mogu istovremeno kretati u različitim pravcima što znatno otežava postupak traženja optimalne strategije trgovanja.

TEHNIČKI INDIKATORI

Tehnički indikatori predstavljaju matematičke funkcije koje se primenjuju na tekućim i istorijskim podacima o kretanju cena (vrednosti *open*, *high*, *low* i *close*) i obimu trgovanja. Vrednosti indikatora nose veoma malo informacija o tome šta će se događati u budućnosti, oni prvenstveno opisuju što se dogodilo i opisuju trenutnu situaciju na tržištu u odnosu na period na koji se indikator odnosi. Prema funkcijama, indikatori se mogu klasifikovati na indikatore trenda, oscilatore i indikatore koji ukazuju na obim trgovanja.

Indikatori trenda se koriste za procenu smer kretanja cena i situacija u kojima se može očekivati promena smera kretanja cena. Indikatori trenda mogu biti sinhronizovani sa kretanjem cena, ali se kod ove vrste indikatora može javiti i kašnjenje u odnosu na cenu na tržištu. Primeri indikatora trenda su: Average Directional Movement Index (ADX), Bollinger Bands, Commodity Channel Index, Moving Average, Parabolic SAR, Standard Deviation.

Oscilatori ukazuju na intenzitet promene cena na tržištu. Oscilatori se mogu koristiti za identifikovanje situacija u kojima se može očekivati promena smera kretanja cena na tržištu. Oscilatori mogu biti sinhronizovani sa kretanjem cena na tržištu ili ovakvi indikatori mogu "lažno" signalizirati na promene pravca kretanja cene znatno pre nego što se promena stvarno dogodi. Primeri oscilatora su: Stochastic Oscillator, Average True Range, Bears Power, DeMarker, Envelopes, Force Index, Ichimoku Kinko Hyo, MACD, Momentum, Moving Average

of Oscillator, Relative Strength Index, Relative Vigor Index, Williams' Percent Range.

Indikatori koji ukazuju na obim trgovanja kao što su: Accumulation/Distribution, Money Flow Index, On Balance Volume, Volumes.

MODELOVANJE I ANALIZA FINANSIJSKIH PODATAKA

Strategija trgovanja predstavlja niz pravila kojima se precizno definiše postupak trgovanja. Algoritmi za automatsko trgovanje najčešće koriste vrednosti tehničkih indikatora kao ulazne signale na osnovu kojih se procenjuje kada je povoljan trenutak da se otvori ili zatvori pozicija i određuje se visina uloga kojim se trguje^[3].

Istorijski podaci sadrže detaljan prikaz kako se kretala cena na finansijskom tržištu u određenim vremenskim periodima (vrednosti *open*, *high*, *low*, *close* i *volume*). Ovakvi podaci se mogu upotrebiti kao polazna osnova za traženje profitabilne strategije trgovanja. Analizom istorijskih podataka pokušava napraviti izbor tehničkih indikatora koji bi se mogli upotrebiti kao ulazni parametri za strategiju trgovanja i odrediti optimalni periodi na koje su primenjeni takvi indikatori. Cilj ovakve analize je takođe određivanje optimalnih situacija kada zatvoriti otvorene pozicije. Neke od metoda koje se mogu upotrebiti za analizu istorijskih podataka su neuronske mreže, data mining, evolutivni algoritmi, klaster analiza i druge metode. Razvoj strategija za trgovanje najčešće se sastoji iz sledećih koraka definisanje problema, analiza podataka, konstrukcija modela, testiranje modela, optimizacija i procena efikasnosti strategije.

NEURONSKE MREŽE


Neuronske mreže pokazuju dobre rezultate kada je potrebno izvršiti klasifikaciju i generalizaciju nepreciznih ulaznih podataka^[4,5,6]. Neuronske mreže se često upotrebljavaju za prepoznavanje oblika. Postižu dobre rezultate prilikom modelovanja sistema u kojima procesi nisu u potpunosti jasni ili su veoma kompleksni. Prednost neuronskih mreža predstavlja visok nivo tolerancije na poremećaje u ulaznim podacima (šum). Pogodne kada su treba doneti odluke u novo nastalim situacijama. Neuronske mreže često mogu uspešno da reše probleme koji su previše kompleksni za konvencionalne tehnologije (na primer, problem za koji ne postoji algoritamsko rešenje ili ako je problem previše kompleksan bi se algoritamski rešavao). Zbog ovakvih osobina neuronske mreže se mogu upotrebiti za procenu trenutne situacije kako bi se odredili povoljni momenti da se aktivira trgovanje i da se odredi smer trgovanja.

Da bi se neuronska mreža mogla upotrebiti za analizu finansijskih podataka potrebno je odabrati pogodnu arhitekturu mreže, kreirati obučavajući skup i izvršiti obučavanje mreže. Vrednosti tehničkih indikatora mogu predstavljati ulazne podatke za neuronsku mrežu, dok bi izlazi takve mreže predstavljali vrednosti na osnovu koje se procenjuje trenutna situacija.

Neuronske mreže se obučavaju na osnovu primera. Obučavanje neuronskih mreža vrši se na trening skupu podataka, tj. pomoću skupa ulazno-izlaznih parova. Svaki od ovih parova sadrži ulazne podatke tj. niz vrednosti indikatora u odabranom trenutku vremena, dok izlazni podaci (očekivani podaci) sadrže ocenu koliko bi trgovanje bilo povoljno da je aktivirano u tom trenutku. Pošto su u pitanju istorijski podaci poznato je kako se na dalje kretala cena, tako da se obradom daljeg kretanja cene može izračunati ocena koliko bi to bio povoljan trenutak da se upravo tada aktivira trgovanje.

Prilikom obučavanja neuronske mreže na ulaze mreže se postavljaju ulazni podaci, a zatim se očitavaju dobijeni podaci na izlazu mreže. Vrednosti na izlazu mreže se upoređuju sa očekivanim vrednostima, a zatim algoritam obučavanja koriguje težinske koeficijente kako bi mreža na izlazu davala vrednosti koji su bliži očekivanim vrednostima. Postupak se iterativno ponavlja dok se ne postigne zadovoljavajući nivo tačnosti za sve parove iz trening skupa. Neuronske mreže imaju sposobnost generalizacije, što znači da se obučene mreže mogu uspešno prepoznati i oblike i situacije koji se nisu nalazili u obučavajućem skupu podataka.

Na izlazima neuronske mreže se nalaze signali sa određenim procentom tačnosti. Kombinovanjem više neuronskih mreža mogu se postići bolji rezultati (slika 1). Ovako povezane neuronske mreže mogu imati različitu arhitekturu i poželjno je da se obučavaju na različitim trening skupovima.



Slika 1. – Skup više neuronskih mreža

DATA MINING

Data mining predstavlja proces izdvajanja potencijalno korisnih informacija iz “sirovih” podataka koji se nalaze u

bazama podataka. Data mining se može upotrebiti za analizu istorijskih podataka u cilju otkrivanja pravilnosti i poboljšanje budućih odluka. Prilikom analize podataka prvo se vrši klasifikacija (*Clustering* ili *Classification*), zatim pridruživanje pravila (*Association Rules*) i na kraju sekvencijalna analiza (*Sequence Analysis*)^[7,8,9].

Klasifikacija podataka (*data classification* ili *data clustering*) predstavlja razvoj modela za grupisanje tipova podataka koji se nalaze u bazi podataka. U postupku klasifikacije se analizira skup podataka i generiše skup pravila za grupisanje koji se mogu koristiti da bi se klasifikovali budući podaci. Postoji više vrsta klasifikacije podataka kao što su stablo odlučivanja (*decision-tree*), statistički algoritmi, fazi logika (*fuzzy logic*), neuronske mreže (*neural networks*), genetski algoritam (*genetic algorithms*), metod najbližih suseda (*nearest neighbor method*) ili pravila indukcije (*rule induction*).

Ukoliko bi se pravila oštra granica razdvajanja podataka na kategorije, podaci koji bi se nalazili na granici između kategorija u velikoj meri mogu uticati na rezultate analize podataka (npr. ukoliko bi se objekat *x* nalazio na granici kategorija *A* i *B*, velika je razlika kojoj će kategoriji podataka pripasti). Klasifikovanjem podataka pomoću *fuzzy* skupova omogućava postepeni prelaz između kategorija.


Drugim rečima, podaci se mogu “delimično” nalaziti u više kategorija. Prednost *fuzzy* analize je upravo mogućnost delimične pripadnosti različitim kategorijama, jer na taj način se lakše mogu obrađivati podaci koji se nalaze na granicama dve ili više kategorija.

Na primer, vrednosti indikatora Stochastic se kreću u opsegu od 0 do 100. Ukoliko je potrebno klasifikovati vrednosti indikatora Stochastic na tri kategorije (npr. male vrednosti (0-33), srednje (34-66) i visoke vrednosti (67-100)). Kod ovakvog metoda klasifikovanja vrednosti, može se primetiti da broj 33 pripada kategoriji malih vrednosti, a već broj 34 pripada kategoriji srednjih vrednosti, slika 2. Podaci koji se nalaze u blizini granica često imaju osobine obe kategorije, što može uticati na rezultate analize podataka. *Fuzzy* skupovi se mogu upotrebiti ukoliko je potrebno obezbediti fleksibilnost u klasifikaciji brojeva.


Pridruživanje pravila predstavlja postupak kreiranja liste sa parovima polja baze podataka koja mogu biti interesantna za analizu u narednoj fazi to jest u sekvencijalnoj analizi. Da bi se jednostavnije objasnio postupak analize podataka, podaci



Indikator Stochastic



Segmentacija promenljive na tri kategorije primenom segmentacije sa oštrim granicama između klasa



Segmentacija promenljive *x* na tri podkategorije pomoću fazi funkcija

Slika 2. – Primeri segmentacije podataka

iz baze podataka su prikazani kao matrica na slici 3. Tabela sadrži dve grupe polja *postavljeni ciljevi* i *vrednosti indikatora*. Softver bira jedno ili više polja iz grupe postavljenih ciljeva vrši segmentaciju podataka u tabeli prema podacima koji se nalaze u datom polju (poljima) i pokušava da pronađe korelaciju sa podacima iz grupe vrednosti indikatora.

Softver bira jedno ili više polja iz grupe postavljenih ciljeva vrši segmentaciju podataka u tabeli prema sadržaju podataka odabranih polja.

Naziv	Postavljeni ciljevi			Vrednosti indikatora				
	C_1	C_2	...	C_j	I_1	I_2	...	I_j
Record 1	c_{11}	c_{12}	...	c_{1j}	i_{11}	i_{12}	...	i_{1j}
Record 2	c_{21}	c_{22}	...	c_{2j}	i_{21}	i_{22}	...	i_{2j}
.
Record i	c_{i1}	c_{i2}	...	c_{ij}	i_{i1}	i_{i2}	...	i_{ij}
.
Record n	c_{n1}	c_{n2}	...	c_{nj}	i_{n1}	i_{n2}	...	i_{nj}

Slika 3. – Šemaatski prikaz podataka koji se prikupljaju na sistemu

U narednom koraku (*sekvencijalna analiza*) analiziraju sve grupe podataka kreirane u prethodnom koraku. Unutar takvih grupa se pokušava pronaći korelacija između podataka koji predstavljaju vrednosti indikatora. Cilj ovakve analize predstavlja pokušaj da se identifikuju indikatori i opseg vrednosti u kojima takvi indikatori mogu ukazivati na povoljne situacije ali i nepovoljne ili opasne situacije koje je potrebno izbeći.


EVOLUTIVNE METODE

Evolutivni algoritmi su stohastičke metode optimizacije koje oponašaju tok biološke evolucije. Upotrebljavaju se kada je potrebno odrediti parametre za koje funkcija postiže optimalne rezultate. Evolutivni pristup rešavanja problema se primenjuje kada problem nije moguće rešiti matematičkim metodama. Evolutivni algoritmi ne daju uvek najoptimalnije rešenje za razliku od matematičkih metoda. Potraga za odgovarajućim rešenjem se najčešće završava kada se ispuni kriterijum koji zadaje korisnik. Evolutivni algoritmi se baziraju na operacijama sekcije, rekombinacije i mutacije^[10,11].

Selekcija je proces u kome se biraju ona rešenja koja će koristiti za generisanje nove generacije rešenja, obično se biraju rešenja sa najvećim stepenom efikasnosti tj. ona koja su najbliže očekivanim vrednostima koje je zadao korisnik. U procesu selekcije prvo se vrši procena efikasnosti svakog od pojedinačnog rešenja unutar populacije, a zatim im se dodeljuje verovatnoća razmnožavanja, koja zavisi od koeficijenta efikasnosti tog rešenja, ali i od iznosa efikasnosti ostalih rešenja. Što je veća efikasnost rešenja u odnosu na druga rešenja,

povećava se verovatnoća da će se takvo rešenje koristiti kao model za kreiranje nove generacije rešenja, dok se manje efikasna rešenja odbacuju.

Rekombinacija ili ukrštanje je proces u kome se od dva ili više prethodno izabranih rešenja, kombinovanjem parametara, kreiraju rešenja za novu generaciju, slika 4.



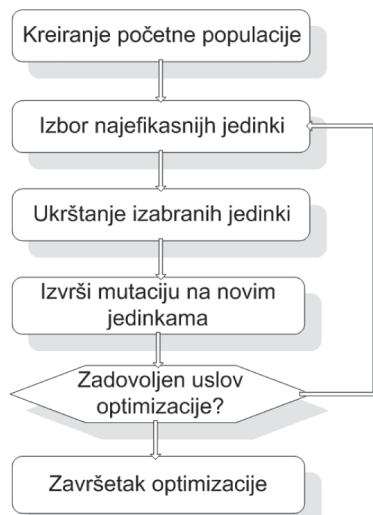
Slika 4. – Rekombinacija parametara

Mutacija je proces koji se upotrebljava da bi se obezbedila raznolikost u narednoj generaciji rešenja u odnosu na postojeću populaciju. Mutacija obezbeđuje raznovrsnost rešenja u narednoj generaciji i sprečava da neka rešenja unutar populacije postanu previše slična i time uspore ili zaustave evoluciju. Na taj način genetski algoritam prevazilazi probleme koji mogu nastati tokom optimizacije zbog lokanih minimuma/maksimuma.

Genetski algoritam (GA, Genetic algorithm) je najpopularnija vrsta evolutivnih algoritama. Genetski algoritam omogućava da se pozitivna iskustva prethodnih generacija prenose na naredne generacije. Kod genetskog algoritama pojedinačna rešenja su najčešće predstavljena u obliku binarnih nizova (0101...1.). Vrednost svakog binarnog niza predstavlja referencu na određeni način rešavanja problema u zadatom okruženju. Nakon što se definiše oblik kodiranja pojedinačnih rešenja potrebno je definisati funkciju cilja, tj. model po kome će se vršiti selekcija pojedinačnih rešenja i ocenjivati njihova efikasnost.

Početna populacija se najčešće generiše tako da se pojedinačnim jedinkama dodeljuju parametri slučajnim izborom. Iz tekuće populacije se bira određen broj jedinki koje se koriste za generisanje naredne generacije. Jedinke se biraju u zavisnosti od funkcije cilja, pri tome jedinke sa većim stepenom efikasnosti imaju veću verovatnoću da će biti izabrane kao uzorci na osnovu kojih se generiše nova generacija.

Prilikom generisanja nove populacije jedinki koriste se operatori za rekombinaciju i mutaciju. Sve nove jedinke u narednoj generaciji kreirane su ukrštanjem parova jedinki iz prethodne generacije. Nove jedinke sadrže osobine jedinki koje su se koristile za kreiranje. Za svaku novu jedinku se biraju novi roditelji, a proces se nastavlja dok ne nastane nova populacija jedinki odgovarajuće veličine. Na taj način nastaje sledeća generacija jedinki koja je drukčija od prethodne generacije. Nova generacija je obično efikasnija od prethodne generacije, jer su za razmnožavanje većinom birana najefikasnija rešenja. Ovakav se postupak ponavlja sve dok se ne zadovolji uslov za završetak evolutivnog procesa (slika 5).



Slika 5. – Struktura genetskog algoritma

Evolutivni pristup se može koristiti za određivanje profitabilnih pravila trgovanja. Binarnim nizovima mogu se kodirati tehnički indikatori (*moving average, volume, stochastic, itd*), vremenski period na koje se indikatori odnose, relacije (<, >, =), parametri, logičke operatore (AND, OR, NOT) i operacije koja će se izvršiti u slučaju ako je uslov ispunjen (BUY, SELL, DO NOTHING).

IF [INDICATOR₁(Period₁)(<, >, =)VALUE₁](AND, OR, NOT)[INDICATOR₂(Period₂)(<, >, =)VALUE₂]
 THEN (BUY, SELL, DO NOTHING)

Cilj evolutivnog algoritma je da odredi vrednosti parametara kojima se postiže najveći profit prilikom trgovanja. U prvom koraku se kreira inicijalna populacija rešenja, a zatim se određuju se performanse svakog od pojedinih rešenja iz inicijalne populacije na test podacima. Zatim se vrši izbor onih rešenja koja postizu najveći profit i na osnovu takvih rešenja se kreira nova generacija. Ovakav postupak se iterativno ponavlja sve dok se ne postignu rezultati koji kakve korisnik očekuje i tada se očitavaju vrednosti parametara.

ZAKLJUČAK

Savremena tehnologija, softver i podaci koji pristižu u realnom vremenu sami po sebi nisu dovoljni da bi rezultati trgovanja bili uspešni. Tehnologija obezbeđuje samo više informacija i brži proces trgovanja, međutim da bi rezultati trgovanja bili uspešni i dalje je potrebno pronaći odgovarajući način na koji iskoristi dostupne informacije i na koji način doneti ispravne odluke.

Strategijama trgovanja se precizno definiše u kojim situacijama se aktivira trgovanje, smer trgovanja, visina uloga kojim se trguje i u kojim situacijama se trgovanje završava. Softverske metode trgovanja smanjuju uticaj ljudskih emocija na donošenje odluka i omogućavaju prevazilaženje problema koji mogu nastati usled nedostatka koncentracije.

Za analizu finansijskih podataka mogu se upotrebiti neuronske mreže, data mining ili evolutivne metode, a rezultati analiza se mogu iskoristiti da bi se definisala strategija trgovanja prema potrebama, mogućnostima i očekivanjima korisnika. Osim što se koriste za analizu podataka ovakve metode mogu i biti integrisane u same strategije trgovanja.

LITERATURA

- [1] Miner R. C., (2009), "*High Probability Trading Strategies - Entry to Exit Tactics for the Forex, Futures, and Stock Markets*", John Wiley & Sons, Inc
- [2] Pardo R., (2008), "*Evaluation and Optimization of Trading Strategies*", John Wiley & Sons, Inc.
- [3] Ilić V., (2010): "*Struktura softvera za automatsko trgovanje na tržištu stranih valuta*", X Međunarodna konferencija o elektronskoj trgovini i elektronskom poslovanju E-trgovina 2010, Palić
- [4] Zhang P., (2004) "*Neural Networks in Business Forecasting*", Idea Group Publishing, ISBN:1591402158
- [5] Ilić, V., (2000): "*NeuroVCL components for Delphi*", Seminar on Neural Network Applications in Electrical Engineering "NEUREL 2000", Belgrade, Sponsored by IEEE Signal Processing Society, pp 130-134, IEEE Catalog Number 00EX278, ISBN 0-7803-5512-1 (Softbounded Edition), ISBN 0-7803-5512-X (Microfishe Edition), Library of Congress: 99-60930, http://solair.EU.net.rs/~ilicv/NeuroVCL_eng.html
- [6] Ilić, V. (2000): "*Force learn algorithm – training neural networks with patterns which have highest errors*", Seminar on Neural Network Applications in Electrical Engineering "NEUREL 2000", Belgrade, Sponsored by IEEE Signal Processing Society, IEEE Catalog Number 00EX278, pp 46-48, ISBN 0-7803-5512-1 (Softbounded Edition), ISBN 0-7803-5512-X (Microfishe Edition), Library of Congress: 99-60930, http://solair.EU.net.rs/~ilicv/FLA1g_eng.html
- [7] Hand P., Mannila H., Padhraic S., (2001) "*Principles of Data Mining*", The MIT Press, ISBN: 026208290x
- [8] Kantardzic M., (2003) "*Data Mining: Concepts, Models, Methods, and Algorithms*", John Wiley & Sons Massachusetts, Massachusetts Institute of Technology
- [9] Ilić V., (2009) "*Integration of Agents and Data Mining in Interactive Web Environment for Psychometric Diagnostics*", Chapter 17 in edited book: Data Mining and Multiagent Integration, Longbing Cao (Ed.), Springer, ISBN: 978-1-4419-0521-5, 15 p., in press (August 2009), <http://www.springer.com/computer/database+management+&+information+retrieval/book/978-1-4419-0521-5>
- [10] Brabazon A., O'Neill M. (2006), "*Biologically Inspired Algorithms for Financial Modeling*", New York: Springer-Verlag
- [11] Ilić V., (2002): "*Evolutionary Neuro Autonomous Agents*", Neurel 6th - Seminar on Neural Network in Electrical Engineering, pp 37-40, IEEE Catalog Number 02EX609, ISBN 0-7803-7593-9, Library of Congress: 2002108419



dr Velibor Ilić

Kontakt: ilicv@EU.net.rs, <http://SOLAIR.EU.net.rs/~ilicv>

Oblasti interesovanja: neuronske mreže, data mining, evolutivne metode, genetski algoritam, strategije trgovanja