

LISZBAUER TAMÁS

Devizapiaci árfolyam-előrejelzés neurális hálózatokkal

Az előrejelzési módszerek között az utóbbi időben kiemelkedő fontossággal bírnak a mesterséges neurális hálózatok, amelyek a tőkepiacok világában is alkalmazhatók, így árfolyam-előrejelzések terén is.

A szakirodalom áttanulmányozásával több neurális hálózati modell alkalmazásának lehetőségét vizsgáltam, felügyelt és nem felügyelt tanítású hálózati struktúrát is górcső alá vettem, és használtam fel devizapiaci előrejelzésre. Hibrid megoldásként a kettő kombinációjával hoztam létre automatikus kereskedési rendszert.

A megépített rendszer elemzésével javaslatot tettem a nem felügyelt tanulású önszervező térkép kizárólagos alkalmazására. Előrejelző képességét nemcsak elméleti, hanem gyakorlati szinten is, valós piaci környezetet szimuláló kereskedési platformon elemeztem.

1. BEVEZETÉS

A pénzügyi piac árfolyam-előrejelzése manapság rendkívül felkapott, divatos téma, amely foglalkoztatja mind a pénzügyi befektetőket, mind a tudomány embereit, a kutatókat, így például matematikusokat és fizikusokat is. A téma azonban nem új keletű, hiszen már régóta kísérleteznek különféle módszerekkel, hogy a meglévő információk alapján megjósolják az árfolyamok jövőbeli alakulását. Egy megbízható előrejelzés döntések alapjául szolgálhat a vállalatirányításban, befolyással lehet az állami szervek vagy a jegybankok stratégiájára, vagy éppen alapját képezheti a spekulatív befektetéseknek.

Az árfolyam-előrejelzés az időszori előrejelzések kategóriájába tartozik. Hagyományosan a *Box–Jenkins*-féle ARIMA modell dominál ezen a területen (*Box–Jenkins* [1976]). Emellett számos más kutatásban fellelhető az ARCH modell és annak válfajai (*Engle* [1982]). Másutt fuzzy logikára vagy a genetikus algoritmusokra építő előrejelzésekről olvashatunk. Előbbi *Lotfi A. Zadeh* (1965), utóbbi *John Holland* (1975) nevéhez fűződik. Az előrejelzési módszereknél alkalmazható a K-legközelebbi szomszéd osztályozási módszer is, amelyet elsőként *E. Fix* és *J. L. Hodges* publikált (1951). Nem sokkal a megjelenésük után, a múlt évszázad második felétől kezdtek el alkalmazni a mesterséges neurális hálózatokat előrejelzésre. Alkalmazásukkal kapcsolatban a mai napig is számos nyitott kérdés maradt.

Dolgozatomban ezen nyitott kérdésekre keresem a választ, és egy olyan rendszer elkészítését tűztem ki célul, amely az előrejelzések alapján valós kereskedés folytatására is képes, hiszen ezáltal az eredmények a gyakorlatban is ellenőrizhetők, valamint alapját képezhetik egy automata kereskedési rendszernek.

A devizapiac, ahogy a neve is sugallja, nem más, mint az a piac, ahol a világ nemzetekinek fizetőeszközei cserélnek gazdát. A létrehozása 1972-re tehető, amikor a világ legnagyobb gazdaságainak kormányai feloldották a fizetőeszközök egymáshoz viszonyított, rögzített arányait, és kezdetét vehette az arányok kereslet-kínálat által meghatározott alakulása (Levinson [2009]).

A Forex (Foreign Exchange) mára a világ legnagyobb és leglikvidebb piacává nőtte ki magát. Egy 2010-es tanulmány adatai alapján naponta átlagosan 3981 billió dollár fordul meg a Forexen (Bank for International Settlements). A Forex a hétvégéket kivéve a nap 24 órájában (vasárnap 22:00 GMT – péntek 20:00 GMT) nyitva áll. A kereskedők három különböző típusát találhatjuk meg a piacon: nemzeti (központi) bankok (pl. Magyar Nemzeti Bank, Európai Központi Bank), befektetési alapok, valamint lakossági ügyfelek és vállalatok (IBFX [2012]).

A Forexen a devizák egymáshoz viszonyított aránya adja egy devizapár árfolyamát, így mind emelkedő, mind csökkenő árfolyam esetén nyereség, illetve veszteség könyvelhető el. A rendkívül magas tőkeáttételnek köszönhetően egyben a világ legvolatilisabb piaca is. Tovább növeli a kockázatot, hogy az árfolyam alakulását rengeteg tényező, a világ egészének eseményei befolyásolják a nap 24 órájában.

A Forexen a kereskedők a meglévő információik alapján piaci elemzéseket készítenek, és a várakozásaiknak megfelelően fektetik be a pénzüket. A befektetési időt tekintve mára már a milliszekundumoktól egészen a hónapokig tartó intervallumok is előfordulnak. Az piaci elemzések módszerét tekintve két csoport különíthető el: a fundamentális és a technikai elemzés. A következő részben a dolgozathoz kapcsolódó főbb devizapiaci fogalmakat mutatom be röviden.

2. NEURÁLIS HÁLÓZATI ISMERETEK

Mintegy 50 éve, jórészt biológiai kutatások eredményeképpen merült fel az a gondolat, hogy a természetes, „biológiai” neurális hálózatok mintájára is létrehozhatók számítógépes rendszerek (Horváth et al. [2006]). Így olyan rendszerek jöttek létre, amelyek a természetből ellesztett módon mintákból, példákából nyert tapasztalatok felhasználásával, tanulás útján alakítják ki feladatmegoldó képességüket.


A neurális számítástechnika mára önálló tudománnyá vált.

2.1. Neurális hálózatok felépítése, típusai

2.1.1. Felügyelt tanulású hálózatok

Az 1. ábra bemutatja a neurális hálózatok alapvető (processzáló) elemét, a neuront. Amint látható, egy neuronnak tetszőleges számú bemenete és egy kimenete van. Emellett egy összegzőből és egy (leggyakrabban) nemlineáris *aktivációs függvényből* áll.

A processzáló elem felépítése




Forrás: Rios [2010]

A feldolgozási folyamat a következő: a bemeneti értékeket súlyozottan összegezzük, majd az így kapott összeg nemlineáris leképezésével kapjuk a kimenetet.

A neuronokat jellemzően rétegekbe rendezik, és az így kialakított rétegek közti összeköttetések adják a neurális hálózatot. Egy többrétegű hálózatban definiálunk bemeneti, rejtett és kimeneti réteget (2. ábra).

Többrétegű előrecsatolt neurális hálózat



Forrás: Pranantha [2009]


Egy neurális hálózat használatát mindig a hálózat tanulása előzi meg, ennek során a múlt ismeretei, a tanító minták alapján kerülnek módosításra a hálózati súlyok. Ezt követően lehet a tanított hálózatot a kívánt célra felhasználni.

A tanuló algoritmus részleteit nem céloz b bemutatni, néhány alapvető lépést azonban igen. Az első lépésben az adathalmazt fel kell osztani tanító-, validációs- és tesztmintákra, amelyek a hálózat általánosító képességét javítják. Ezután a hálózati súlyok véletlenszerű kiválasztása, felinicializálása következik. Ezt követően egy újabb bemenet érkezésekor a neuronok aktiválásával a kimeneten megjelenő értéket egy célértékhez hasonlítjuk. Minden bemeneti mintához tartozik egy kimeneti minta, ami az előzetes megfigyeléseinkből származik. A neurális hálózat tanításánál ez a megfigyelt kimeneti minta lesz a cél (*target*). A hálózat tanítása az a tevékenység, amikor a hálózati súlyokat úgy módosítjuk, hogy a kimenetek minél közelebb legyenek a célértékekhez. Ezt úgy végezzük el, hogy a kimeneti hibát visszavezetjük a hálózati összeköttetésekre, azaz a hiba egy bizonyos mértékével (amelyet a tanulási tényező határoz meg) megváltoztatjuk a hálózati súlyokat (*Retter* [2003]).

Ekkor valójában nem teszünk mást, mint a kimeneti hibafelületen a negatív gradiens irányába haladunk mindaddig, amíg el nem érjük a kellő pontosságot, vagy a hiba nem csökkenthető tovább (3. ábra).

3. ábra

A negatív gradiens irányába történő súlymódosítások hatása



Forrás: *Giacomini* [2003]

A felügyelt tanulású neuronhálók képessége, hogy megfelelő kialakítás esetén tetszőleges be- és kimeneti kapcsolatot, leképezést képesek megvalósítani, vagyis a szokásos elnevezés szerint ezek a neuronhálók ún. *univerzális approximátorok* (*Horváth et al.* [2006]). Ezáltal a fő alkalmazási területeik a következők:

- függvényapproximáció és regressziós analízis,
- rendszeridentifikáció,
- szabályozástechnika és jelfeldolgozás,
- időszori előrejelzés.

2.1.2. Nem felügyelt tanulású hálózatok


A neurális hálózatok másik típusa a nem felügyelt (más néven nem ellenőrzött) tanulású hálózatok. Ezen hálózatok esetén induláskor nem ismerjük a helyes eredményeket (Retter [2003]). Mivel a kimenetek helyességére semmilyen információnk nem áll rendelkezésre, a hálózatnak a tanulást a bemenetek alapján kell elvégeznie. Így pl. a hálózat a bemeneti mintákat valamilyen jellegzetességük szerint önkényesen osztályokba sorolja. A nem ellenőrzött tanulású hálózatok alkalmazási területei így jelentősen eltérnek az ellenőrzött tanulású hálózatokétól:

- hasonlóságok megállapítása a bemeneti minták között,
- csoportok, klaszterek kialakítása a bemeneti mintatérben,
- adattömörítés,
- szövegbányászat.

Az előrejelzés során egy *Kohonen*-féle önszervező térképet használlok, így a továbbiakban ezt a típust mutatom be.

Kohonen önszervező térképe (*self-organizing map – SOM*) egy nem felügyelt tanulású (emiatt önszervező) neurális hálózat (Kohonen [1982]). Emellett pedig térkép, mert a kimeneti réteg neuronjai egy kétdimenziós síkbeli rácselrendezést mutatnak (4. ábra).

4. ábra



A hálózat fő feladata, hogy egy sokdimenziós folytonos teret egy alacsonyabb dimenziójú, legtöbbször kétdimenziós diszkrét térré képezzen le, miközben a többdimenziós vektortér fontos jellemvonásait a kétdimenziós tér topológiájában jelenítse meg. Ez utóbbi megállapítás rendkívüli fontossággal bír, hiszen ezáltal a térképen egymással szomszédos neuronok (osztályok) a bemeneti mintatérben is egymás mellett helyezkednek el.

2.2. Devizapiaci alkalmazási lehetőségek

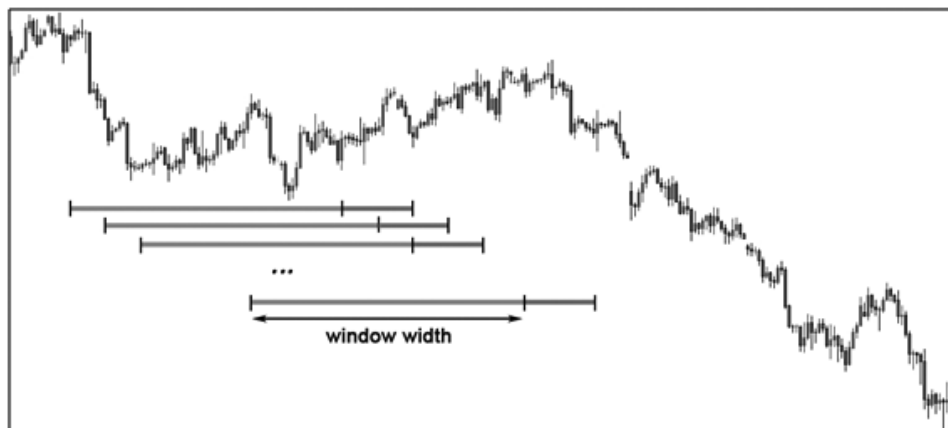
A neuronháló Forexen történő alkalmazása mind fundamentális, mind technikai értelemben lehetséges. Egy neurális háló bemenete ugyanis tetszőleges információ lehet, ha azt megfelelően, konzisztens módon, meghatározott matematikai formulával számadattá alakították. Nincsenek szabályok ezen a téren, véleményem szerint a leképezések megvalósításának csak a felhasználó fantáziája szab határt.

Fundamentális értelemben a hálózat bemeneteit képezhetik makroadatok, gazdasági indikátorok, de akár egy szövegfeldolgozás eredménye is (pl. a Bloomberg weboldalán egy adott ország gazdaságáról megjelenő, legfrissebb hír negatív és pozitív tartalmú kifejezéseinek aránya).

Technikai értelemben a leggyakrabban az árfolyamok, ún. chartok¹ elemzése jön szóba. Ekkor például az időszori értékeket egy adott méretű csúszóablak segítségével választják ki, és ez képezi a hálózat bemenetét (Chong [2009]). Az ablakban lévő adatok képezhetik a háló aktuális bemeneti értékeit, a háló kimenete pedig az adatsor adott időegységgel eltoltt értéke (5. ábra) lehet.

5. ábra

A csúszóablakkal történő előrejelzés



1 Chart: a devizakereszték árfolyamváltozását bemutató 2D-s grafikon. Az x tengelyen az abszolút idő, az y tengelyen a devizapár árfolyamának értéke látható.

3. A TÉMÁHOZ KAPCSOLÓDÓ SZAKIRODALOM

Az árfolyam-előrejelzés kapcsán a kutatások alapvetően két részre bonthatók. Az egyik oldalról azt bizonyítják, hogy az árfolyamok alakulása nem jósolható meg előre, ehhez kapcsolódik a *tőkepiaci hatékonyság* fogalma is. A másik oldalról viszont éppen ennek az ellenkezőjét igyekeznek bebizonyítani, azaz a legkülönbözőbb módszerekkel próbálják meg előre jelezni a jövőbeli emelkedéseket és eséseket. Ezek a különféle előrejelzési modellek.

3.1. A tőkepiaci hatékonyság

Tökéletes tőkepiaci árazásról beszélünk, ha a tőkepiaci árfolyamok minden pillanatban a rendelkezésre álló összes információra helyesen reflektálnak, egyensúlyban vannak, amely egyensúlyból csak új információ hatására mozdulhatnak ki.

Az 1950-es évek végéig viszonylag kevés elméleti vagy empirikus kutatási eredmény látott napvilágot a tőkepiacokról. A hatékony tőkepiacok hipotézisének (*Efficient Market Hypothesis – EMH*) témakörében az első igazi tudományos értekezés *Eugene Fama* nevéhez fűződik. Fama kiindulópontja az volt, hogy az adott eszköz árának tartalmaznia kell minden, a piacon hozzáférhető információt ahhoz, hogy a piacot hatékonynak tekinthessük (*Molnár [2006]*).

3.1.1. A tőkepiaci hatékonyság szintjei

Fama 1970-es alapművében a hatékonyság tesztjeit három csoportba osztotta, majd később (1991-ben) némileg átalakította a hatékonysági szintjeit:

- Gyenge szint: a változók sorozatának információit (például árak, volumenek, osztalékok, kamatok, számviteli eredmények) teljességgel tükrözik az árak;
- Félerős szint: az árak azonnal és helyesen tükrözik a nyilvánosan (*public*) bejelentett információkat;
- Erős szint: az árak a magán (*private*) információkat is teljességgel tükrözik.

Mivel a dolgozatom további részében a historikus adatok alapján történő előrejelzésekkel foglalkozom, a szintvizsgálatok közül csak a gyenge szint vizsgálati módszereit mutatom be.

3.2. A hatékonyság gyenge szintjének vizsgálata

3.2.1. Autokorrelációs elemzések

Az időszori korrelációs vizsgálatok egy komplexebb fajtája az ún. *autokorrelációs teszt*. Részvényeknél vagy devizapároknál ez azt jelenti, hogy az időben egymást követő hozamokra autokorrelációkat számítunk. Egy idősor autokorrelációja nem más, mint az időben egymástól eltolt értékek korrelációja. Diszkrét idejű esetet tekintve, a következőképp adhatjuk meg:

$$R(m) = \frac{1}{N} \sum_{n=0}^{N-1} x_n * x_{n+m}, \quad (1)$$

ahol x_n az idősor n . eleme, $m = 0 \dots M$ tetszőleges egész szám, R az autokorrelációs függvény értéke.

Az autokorrelációs vizsgálatokat általában valamilyen normalizálási folyamat előzi meg. Ekkor a normál differenciáláson kívül legtöbbször e két formula valamelyikét alkalmazzák (Wordpress [2011]):

$$r_i = \frac{p_i - p_j}{p_j}, \quad (2)$$

ami a normál hozamszámítás képlete, ahol r a hozam, p az árfolyam értéke, i és j periódus indexek, valamint a

$$\log(1 + r_i) = \log\left(\frac{p_i}{p_j}\right) = \log(p_i) - \log(p_j), \quad (3)$$

ami a logaritmusos hozamszámítás képlete.

Az utóbbi előnye, hogy leegyszerűsíti az egymást követő hozamok számítását:


$$\begin{aligned} \sum_{i=1}^n \log(1 + r_i) &= \log(1 + r_1) + \log(1 + r_2) + \dots + \log(1 + r_n) = \\ &= \log(p_n) - \log(p_0), \end{aligned} \quad (4)$$

azaz két időben egymástól távolabb eső logaritmusos hozam a közbenső hozamok összege.

Az autokorrelációs kutatások általában kis korrelációt mutatnak (még rövid távon is) részvény- és devizapiacra egyaránt. Példaként egy 2012-ben megjelent publikáció eredményeit mutatom be:

6. ábra

Az euro/dollár árfolyam 1 órás adatainak autokorrelációs értékei



Forrás: Vanstone [2012]

Mint látható, az autokorrelációs értékek rendre 0 közeliek (enyhe negatív korreláció látható az 1 időegységgel történő eltolás esetén). Az eredmények arra engednek következtetni, hogy az egymást követő hozamok véletlenszerűen alakulnak.

3.2.2. Keresztkorrelációs elemzések

Külön kezelendő egy másik időszorral vett korrelációs vizsgálat, az ún. *keresztkorreláció*. Nem kizárt ugyanis, hogy egy árfolyam időben eltolva követ egy másik árfolyamot. A devizapárok között nagy keresztkorreláció figyelhető meg, ha időbeli eltolás nélkül vizsgáljuk ezeket. Nem meglepő, hogy például az euró/dollár és a dollár/svájci frank árfolyama egymással (negatívan) korrelál, hiszen mindegyik függ a dollártól, annak erősségétől vagy gyengeségétől. Néhány hasonló korrelációs adatot mutat be az 1. táblázat is.

1. táblázat

Órás keresztkorrelációs értékek a fő devizapárok között

	AUDUSD	EURJPY	EURUSD	GBPUSD	NZDUSD	USDCAD	USDCHF	USDJPY	USDNOK	
AUDUSD	100	48.1	65.4	-54.6	83.7	-39.8	17	40	29.8	AUDUSD
EURJPY	48.1	100	63.7	-41	78.3	-30	-19.7	98.7	-13.4	EURJPY
EURUSD	65.4	63.7	100	-21.9	79	-1.8	-57.2	50.3	-29.8	EURUSD
GBPUSD	-54.6	-41	-21.9	100	-57.1	18.3	-38.7	-41.3	-55.4	GBPUSD
NZDUSD	83.7	78.3	79	-57.1	100	-31.5	-9.7	71	3.2	NZDUSD
USDCAD	-39.8	-30	-1.8	18.3	-31.5	100	-26.2	-33.1	6.2	USDCAD
USDCHF	17	-19.7	-57.2	-38.7	-9.7	-26.2	100	-10.1	77.7	USDCHF
USDJPY	40	98.7	50.3	-41.3	71	-33.1	-10.1	100	-8.8	USDJPY
USDNOK	29.8	-13.4	-29.8	-55.4	3.2	6.2	77.7	-8.8	100	USDNOK
	AUDUSD	EURJPY	EURUSD	GBPUSD	NZDUSD	USDCAD	USDCHF	USDJPY	USDNOK	

Forrás: ForexTicket.co.uk

2. táblázat

Napos keresztkorrelációs értékek fő devizapárok között

	AUDUSD	EURJPY	EURUSD	GBPUSD	NZDUSD	USDCAD	USDCHF	USDJPY	USDNOK	
AUDUSD	100	-4.8	-16.4	19	46.4	-33.7	6.7	13.7	22.5	AUDUSD
EURJPY	-4.8	100	59.8	41.8	26.1	-43.8	-51.3	42.9	-57.6	EURJPY
EURUSD	-16.4	59.8	100	84	43	-76.6	-95.9	-46.8	-98.1	EURUSD
GBPUSD	19	41.8	84	100	63.4	-92.1	-90.7	-48.4	-82.3	GBPUSD
NZDUSD	46.4	26.1	43	63.4	100	-72.6	-55.4	-19.7	-45.5	NZDUSD
USDCAD	-33.7	-43.8	-76.6	-92.1	-72.6	100	82.3	37.9	75.7	USDCAD
USDCHF	6.7	-51.3	-95.9	-90.7	-55.4	82.3	100	51.5	93.7	USDCHF
USDJPY	13.7	42.9	-46.8	-48.4	-19.7	37.9	51.5	100	47.2	USDJPY
USDNOK	22.5	-57.6	-98.1	-82.3	-45.5	75.7	93.7	47.2	100	USDNOK
	AUDUSD	EURJPY	EURUSD	GBPUSD	NZDUSD	USDCAD	USDCHF	USDJPY	USDNOK	


Forrás: ForexTicket.co.uk

Látható, hogy az említett EURUSD és USDCHF árfolyama $-95,9\%$ -os korrelációban áll egymással a napos árakat tekintve.

Abban az esetben, ha eltolást is alkalmazunk, a keresztkorrelációs értékek 0-hoz közeli értéket vesznek fel (7. ábra). Az ábrán látható a 0 időeltolással számított nagy negatív érték. Ennek megfelelően a keresztkorrelációs vizsgálatok is alátámasztják a gyenge szint fennállását.

7. ábra

**Az euró/dollár és dollár/svájci frank keresztkorrelációs értékei
(a vízszintes tengely órás időeltolásokat mutat)**



Forrás: forexautomaton.com

3.2.3. Naptári mintázatok vizsgálata

Szót kell ejteni még azokról a vizsgálattípusokról, amelyek a hozamok szezonálisitását feltételezik. Az ilyen jellegű elemzések során a hozamokat havi vagy napos elemzésben vizsgáljuk. Ezek a kutatások olyan szezonálisra kívánnak fényt deríteni, mint például a „január effektus”, amely szerint nemcsak az USA-ban, hanem sok más külföldi piacon is szignifikánsan magasabb hozamot figyeltek meg az év első hónapjában. Emellett a hétfői napok kiugróan alacsony hozamát és a pénteki (és némelyest a szerdai) magasabb hozamokat említik klasszikus konklúzióként. A jelenség mára már eltűnt (Andor–Ormos [2007]).

A gyenge szint fennállásának vizsgálatából arra a következtetésre juthatunk, hogy az árfolyamok eddigi alakulásából nem következtethetünk a további mozgásokra.

3.3. Előrejelzési kutatások neurális hálózatokkal

A téma kapcsán a szakirodalom rendkívül sokrétű. A kutatások a neurális hálózatok számos változatát vizsgálják. A neurális hálózatok legfőbb előnyeként említik a nemlinearitást, az univerzális függvényapproximációs és általánosító képességet.

Egy felügyelt tanítású hálózatot alkalmazva, általánosan és tömören megfogalmazva a feladatot a következő lépésekből áll (*Gallo* [2006]):

1. Azonosítani kell a targetértékeket.
2. Létre kell hozni az adathalmazt, mely a neurális hálózat bemenetét képezi.
3. A hálózat aktiválása: a hálózati architektúra és a paraméterek kiválasztása.
4. Az elkészült hálózat általánosító képességének vizsgálata (az előrejelző képesség meghatározása *out-of-sample*² adatokon).

A fenti csoportosítást alkalmazva, a szakirodalomban a következőkkel találkozhatunk leggyakrabban:

3.3.1. Inputok

Gyakori megközelítés, hogy az eszköz múltbéli árai képezik a neurális hálózat bemenetét (*Kalyvas* [2001]). Ekkor az árfolyam késleltetett, normalizált OHLC (*Open, High, Low, Close*) árait, valamint egyéb technikai indikátorok jelzéseit alkalmazzák (*Zhang–Hu* [1997]). Az indikátorok között leggyakrabban az *RSI*-vel, a *Stochastic oscillator*tal és az *MACD*-vel találkozhatunk (például *Pissarenko* 2002-es munkájában).

A technikai adatok mellett számos vizsgálat fundamentális adatokat is felhasznál (Pissarenko [2002]), ilyenek például az inflációs és munkanélküliségi ráta, a jegybanki alapkamat vagy GDP értéke.

3.3.2. Célértékek

Több kutatás említi a bemenethez illeszkedő célérték alkalmazását, azaz a bemeneti értékek jövőbeli értékét. Például, ha a bemenetként valamilyen exponenciális mozgóátlag differenciáit alkalmazzuk ($\Delta EMA(t), \dots, \Delta EMA(i)$), akkor a target lehet a $\Delta EMA(t+1)$, azaz a következő differencia. Nem számottevően, de találkozni olyan célfüggvénnyel is, mely egyfajta indikátorérték arra vonatkozóan, hogy milyen pozíciót érdemes felvenni (*Mizuno et al.* [2001]).

3.3.3. A hálózatok típusai

Mivel a legtöbb esetben valamilyen célfüggvény megtanulását, közelítését szeretnék elérni, a kutatások nagy többsége a többrétegű, előrecsatolt, hiba-visszaterjesztéses hálózatot alkalmazza. Emellett előszeretettel alkalmaznak visszacsatolt hálózatot is, Jordan- és Elman-struktúrákat egyaránt (*Kondratenko–Kuperin* [2003]).

3.3.4. A hálózatok paraméterei

A szakirodalomban hasonló módszerekkel mérik a hálózat hibáját, valamint az adathalmaz tanító-, validációs- és tesztadatokra történő bontása is konzisztensen történik. *Chew* és *Yao* az adathalmazt 70, 20, 10%-os arányban osztotta fel 2000-es munkájában, és a hálózat tesztjei során az NMSE mérőszámot rendelték a megtanított hálózathoz. Emellett az *MSE*, az *NRMSE* és a *MAPE* mutatók is használatosak, valamint az irányhelyesség (*Correct Directional Change – CDC*) is (*Kamruzzaman–Starker* [2004]).

2 Out-of-sample teszt: mintaadatokon kívüli vizsgálat. Olyan adathalmazon történő teszt, amely nem vett részt a tanulásban.

Az előrejelzési eredmények vizsgálatára két lehetséges irány merülhet fel. Az egyik az előrejelzéssel elérhető hozam meghatározása. Kereskedési stratégiaként azt az egyszerű feltevést szokás alkalmazni, amely szerint vételi pozíciót vesznek fel, ha a jósolt ár magasabb, mint az aktuális (és fordítva), a nap végén pedig megvizsgálják a kapott eredményt, azaz zárják a pozíciót.

Egy másik módja az eredmények vizsgálatának, ha a kapott modell előrejelző képességét valamilyen más előrejelző modellel hasonlítjuk össze. Rendszerint az ARIMA modellt alkalmazzák referenciaként (Chew–Yao [2000]), vagy a véletlen bolyongással vetik össze a hálózat előrejelző képességét (Zhang–Hu [1997]).

4. AZ ELŐREJELZÉSI RENDSZER BEMUTATÁSA

4.1. Az előrejelzés számítástechnikai háttere

Ha neurális hálózatokkal szeretnénk dolgozni, akkor vagy egy már megírt, jól konfigurálható szoftvert alkalmazunk (mint például a MATLAB), vagy saját magunk készítjük el a neurális hálózatot megvalósító programot. Utóbbi programozási ismereteket kíván meg, azonban ezáltal elkerülhetetlen, hogy pontosan megértsük a neurális hálózatok működését, ami nélkül nem érhetőek el érdemi eredmények. A lehetőségek felmérése után választásom az utóbbira esett.

A hálózatokat a *MetaTrader4* elnevezésű platformon alkalmaztam. A *MetaTrader4* (MT4) a devizapiaci kereskedők széles körében alkalmazott kereskedői szoftver. Népszerűségét annak köszönheti, hogy a végfelhasználók saját alkalmazásokat (scripteket, kereskedői robotokat) készíthetnek a program segítségével, amelyeket felhasználhatnak mind demó (virtuális pénzes számlán), mind az éles kereskedés során. Emiatt rengeteg MT4 alapú indikátor és robot jelenik meg világszerte. A platform programozói felületén az MT4 saját, beépített nyelvén, az MQL4 nyelven készíthető el a saját alkalmazás. A nyelv szintaktikája a C nyelvéhez hasonló. Az MQL4 könyvtárszerkezet lehetővé teszi, hogy saját programunk írása során felhasználjunk a chartok múltbéli adatait, a szoftverben lévő indikátorok értékeit, valamint külső dinamikus könyvtárakat (*DLL*). Emellett más, beépített függvények növelik a programozás hatékonyságát.

Az eredmények kiértékelésekor a Microsoft Excel 2010-es verzióját hívtam segítségül.

4.1.1. Többrétegű előcsatolt hálózat megvalósítása

Elsőként egy általános, többrétegű, hiba-visszaterjesztéses, előrcsatolt neurális hálózatot valósítottam meg C++ nyelven, amelyből *DLL*-t készítettem, így a hálózat közvetlenül felhasználható az MT4 platformon. A megvalósított hálózat a következő tulajdonságokkal rendelkezik:

- egyetlen rejtett réteget tartalmaz,
- a bemeneti, a rejtett és a kimeneti rétegben található neuronok száma tetszőlegesen választható,
- hiba-visszaterjesztéses tanulási képesség momentummódszerrel kiegészítve,
- tetszőleges tanulási (bátorsági) tényező, momentum- és flatspot-együttható alkalmazása,

- a súlyok véletlenszerű inicializálása egy megadott tartományon belül (minimum és maximum értékek definiálhatók),
- választható aktivációs függvény, amely a rejtett és a kimeneti rétegekre külön-külön megadható. A választható függvények: lineáris, unipoláris és bipoláris szigmoid,
- A következő hibaszámítási módszerek alkalmazása:

átlagos négyzetes hiba ($MSE = Mean\ Square\ Error$)	$MSE = \frac{1}{n} \cdot \sum_{i=1}^n (d_i - o_i)^2$
átlagos négyzetes hiba négyzetgyöke ($RMSE = Root\ Mean\ Square\ Error$)	$RMSE = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (d_i - o_i)^2}$
normalizált RMSE ($NRMSE = Normalized\ Root\ Mean\ Square\ Error$)	$NRMSE = \frac{RMSE}{\bar{o}}$
abszolút átlagos hiba ($MAPE = Mean\ Absolute\ Percentage\ Error$)	$MAPE = \frac{100}{n} \cdot \sum_{i=1}^n \left \frac{o_i - d_i}{d_i} \right $

ahol d a kívánt kimeneti érték, o a hálózat aktuális kimenete és n a tanulási ciklusok száma.

A megvalósított program képes a hálózati struktúra és a súlyok CSV³-fájlba mentésére, majd visszaolvasására, ezáltal egy megtanított hálózat a későbbiekben bármikor felhasználásra kerülhet anélkül, hogy újból el kellene végeznünk a tanítást.

4.1.2. Kohonen önszervező térképének bemutatása

A jobb előrejelzés érdekében egy önszervező térképet is alkalmaztam, amelynek a szerepét egy későbbi fejezetben mutatom be. Ezt a hiba-visszaterjesztéses hálózathoz hasonlóan készítettem el, és egy dinamikus könyvtárat hoztam létre, amely alkalmazható a MetaTrader rendszerében. A hálózat az alábbi tulajdonságokkal rendelkezik:

- választható négyzet- vagy hexagonális rácsszerkezetű térkép,
- tetszőleges számú kimenet (osztály),
- a súlyok kezdeti értékeinek beállítása adott minimum- és maximumértékek között, avagy az adathalmaz véletlenszerűen választott elemeiből,
- tanulási tényező kezdeti értékének állítása (a szomszédsági függvény szélességének kezdeti értéke automatikusan a térkép átlójának fele),
- időben csökkenő szomszédsági függvény szélesség és tanulási tényező.


3 CSV (Comma Separated Value): az adatok vesszővel elválasztva kerülnek egymás mellé a fájlban. Például az Excel képes a CSV-fájlok tartalmának megjelenítésére.

A hálózat megfelelő működését mindenképp célszerű ellenőrizni. Ez úgy tehető meg, ha a bemeneti minta 1, 2 vagy 3 dimenziós, hiszen ekkor ábrázolható a kapott eredmény. A teszt során 2 dimenziós bemenetet alkalmaztam (két, 1000 időegységgel késleltetett logaritmikusan hozam az EURUSD M1-es árfolyamán). Az eredményeket a 8. ábra szemlélteti.

Az ábrán látható x -ek jelölik a bemeneti mintákat, a körök a neuronokat. A szomszédos neuronok összekötésre kerültek oly módon, hogy csak az eggyel kisebb és nagyobb indexű neuronok kerültek összekötésre, ezért egy vonalat alkotnak, nem pedig teljes rácsszerkezetet. A hálózat összesen 50 000 bemeneti mintát rendezett 100 osztályba. Látható a topológiai rendezettség, valamint az is, hogy a kimeneti neuronok felveszik a bemeneti mintahalmaz eloszlását.

8. ábra

**Az önszervező térkép működése
(bal oldalon a tanulás előtti, jobb oldalon a tanulás utáni állapot)**



Forrás: saját szerkesztés

4.2. Historikus adatok, bemenetek és célértékek

A munka során nyilvánvalóan szükséges kiválasztani, hogy mely devizapár mely idősíkján vagy síkjain végzem a kutatást, hiszen az eredmények csak úgy vethetők össze egymással, ha a vizsgálatokat ugyanazon az adathalmazon végzem el. Választásom az alacsony idősíkjú (M1 és M5) euró/dollár devizapárra esett a következő indokok alapján:

- Az alacsony idősíkjú nagy mennyiségű adat áll rendelkezésre még akkor is, ha csak az elmúlt 1-2 évet vizsgálom (M1 esetén több mint 350 ezer gyertya/év).
- Az alacsony idősíkjú történő kereskedéshez alacsony spread és magas likviditás szükséges.⁴

A neurális hálózatok bemenetét tekintve a következő információkat alkalmaztam:

- **Mozgóátlag-különbségek egy adott méretű csúszóablakban:** a mozgóátlagok keresztettség sok kereskedési stratégiának az alapja. Ez a mintázat ezt az információt kívánja magában hordozni. Szintén változtatható a kezdeti mozgóátlag periódusának

4 Az EUR/USD az egyik leglikvidebb devizapár.

hossza, a perióduslépcső és az időlépcső mérete, az alkalmazott mozgóátlagok száma (pl. $MA_{25}[t-1] - MA_{50}[t-1]$, $MA_{25}[t-10] - MA_{50}[t-10]$, ..., $MA_{25}[t-n] - MA_{50}[t-n]$).

- **OHLC-információk:** adott idősíki OHLC-adatai (pl. a legnagyobb testű *bullish* és *bearish* gyertya mérete, az együtt futó *bullish*/*bearish* gyertyák száma, kanócok mérete). Idősíki független, azaz attól még, hogy az indikátort az egyperces grafikonon alkalmazom, érkehetnek ezek a mintázatok felettes (például 15 perces) grafikonról is.
- **Logaritmikus hozamok:** a logaritmikus hozamok számítását már bemutattam egy korábbi fejezetben. A megoldásban az árfolyamot tetszőleges időszakonként mintavételezhetjük, azaz beállítható itt is egy időlépcső (pl. 10 periódusnyira lévő logaritmikus hozamok). Egy másik paraméter a hozamok száma, azaz a múltbéli visszatekintés mértéke.
- **Indikátorértékek:** jellemzően RSI, Stochastic, ADX és egy saját fejlesztésű indikátor értékei. Itt is változtatható paraméter az idősíki, így más idősíkok adatai is alkalmazhatók.
- **Divergenciák:** az árfolyam két legutóbbi csúcsának/mélypontjának különbsége és a Stochastic oscillator vagy az MACD értékeinek különbsége az árfolyamcsúcsok/mélypontok helyén.
- **Volatilitás:** ATR- és Bollinger-szalagok, Keltner-csatorna szélessége.
- **Támasz- és ellenállásszintek:** A szintektől vett távolság képezi a bemeneti értéket. A támasz- és ellenállásszintek meghatározására egy saját megvalósítást alkalmaztam, amelynek az a működési elve, hogy a múltbéli árfolyamok eloszlása alapján határozza meg a szintek értékét. (Egy adott csúszóablak sűrűségfüggvényének lokális maximumai.)

A szakirodalomban a legtöbb esetben előfeldolgozást (normalizálást, stacionarizálást) végeznek a bemeneti mintákon. A bemenetek jelentéséből kiindulva azonban nem minden esetben alkalmaztam normalizálást vagy stacionarizálást. Ha árfolyamértékeket adunk a bemenetre, mindenképpen szükséges az előfeldolgozás elvégzése, az ún. *trendmentesítés*, amely úgy is megindokolható, hogy nem célja a hálózatnak, hogy az árfolyam konkrét értékeiből vonjon le következtetéseket. Azonban ha például egy RSI jelentéséből indulunk ki, akkor a 20-as szint alatti és a 80-as feletti értékek fontos információt hordoznak, túladottságot és túlvettséget jeleznek. A stacionarizálással ezeket az információkat eltávolíthatjuk az adatokból, ez azonban nem lenne helyes, így nem célszerű az RSI-t csak stacionarizált formában alkalmazni.

A targetértékek képzését úgy határoztam meg, hogy a target egy 1 dimenziós vektor legyen. Ez javíthatja a neurális hálózat teljesítőképességét, mert csak egyetlen kimeneti neuronon megjelenő hibát kell csökkentenie.

A hálózat tanításánál háromféle targetfüggvény közül lehet választani:

- **Adott periódusú mozgóátlag változása:** a mozgóátlag jelenlegi és a periódushosszal eltolt (jövőbeli) értékének a különbsége. (Az indikátor pozitív értékéhez az átlag emelkedése társul).
- **Jövőbeli deriváltak alapján számított érték:** egy adott méretű (jövőbeli) mintaablakban lévő deriváltak összege. (Pozitív összeghez az árfolyam emelkedése társul).
- **Virtuálisan nyitott pozíció eredménye alapján:** minden pillanatban képzeletben nyitok egy pozíciót vételi és eladási irányban. Amelyik irányban az árfolyam előbb

eléri a célárat, azt veszem alapul, majd megnézem, hogy a másik irányban mekkora mozgást tett meg az eszköz. A két mozgás aránya a célérték. Attól függően, hogy melyik irányban teljesült a célár, az előjelet pozitívrá vagy negatívra állítom.


A célfüggvények mindegyike oly módon kerül számításra, hogy a nagyobb negatív értékekhez nagyobb áresés, a nagyobb pozitív értékekhez nagyobb áremelkedés illeszkedik.

A célértékeket a $[-0.9, 0.9]$ -es tartományba normalizáltam, ezáltal az indikátor jelzései is ebben a tartományban vesznek fel értéket.

A megfelelő célérték alkalmazása kulcsfontosságú a megfelelő előrejelzés megalkotásához. Emiatt mindenképpen célszerű validálni az alkalmazott célfüggvényeket. Ezt legegyszerűbben úgy tehetjük meg, ha megvizsgáljuk, hogy mekkora hozam elérésére lenne képes a rendszer ideális esetben, azaz a célértékek használatával (ami ugyanaz, mintha a hálózat tökéletesen megtanulná a célértékek előállítását). Az ehhez készített teszt során a program a targetértékek alapján kereskedett egy virtuális számlán egy év távlatában az EURUSD 1 perces grafikonján. A validáció eredményeit mutatja be a 9. ábra.

9. ábra

A pozíciónyitások alapján számított célértékek validációja



Forrás: saját szerkesztés

A program az EURUSD grafikon 2011. 01. 01.–2012. 01. 01-ig tartó időszakában kereskedett. A kezdeti tőkét 10 000 euróra állítottam.

A virtuálisan nyitott vételi és eladási pozíciók aránya alapján képzett célértékek esetében több mint 52 027 000 eurón állt az egyenleg az időszak végére. Ez kb. 5202-szeres emelkedést jelent.

Látható, hogy az egyenleggörbe először exponenciálisan emelkedik, majd az emelkedés lelassul. Ez abból ered, hogy a program elérte a bróker cég által megengedett maximális kötésegységet, és a kötésegységek nem növekednek tovább. Az exponenciális növekedés ezt követően lineárisan folytatódik. A kötésegységeket az egyenleg alatti oszlopdiagram mutatja.

A validációs vizsgálatok alapján elmondható, hogy a targetértékek megfelelőek (valamint a pozíciók megnyitását végző kereskedési rendszer is a vártak megfelelően működik).

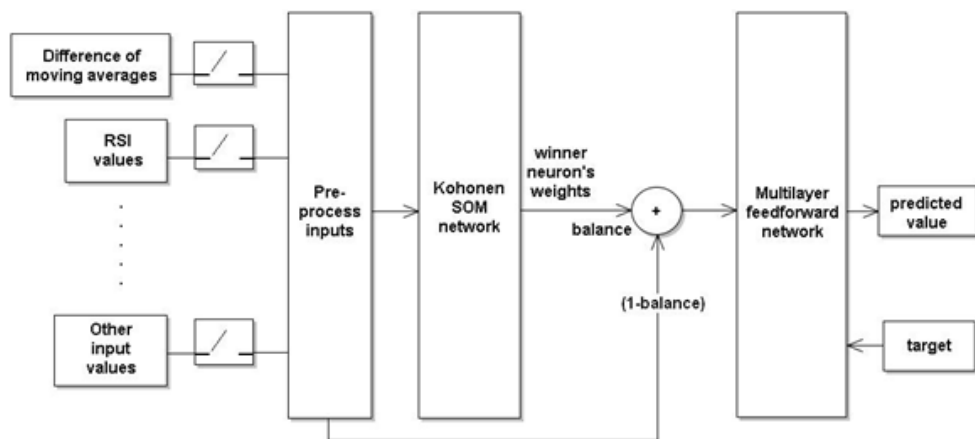
4.3. A neurális hálózati indikátorok bemutatása

Az előrejelzést úgy valósítottam meg, hogy a neurális hálózati működést egy indikátorban helyeztem el. A kereskedési rendszer ezen neurális indikátorok alapján nyit pozíciókat.

Attól függően, hogy új hálózatot szeretnék-e készíteni és tanítani, vagy egy meglévőt szeretnék alkalmazni, két részre bontható a működés. A funkcionális működési elvet a 10. ábra szemlélteti.

10. ábra

Az indikátorok neurális adatfeldolgozási láncja



Forrás: saját szerkesztés

Az indikátor a dinamikus könyvtárakat felhasználva, végigvezeti a bemeneti mintákat a képen látható elemeken, aminek az eredményeként létrejön az indikátor kimenete, a jósolt árfolyammozgás.

4.3.1. Új hálózat létrehozása

Mielőtt betöltjük az indikátort, be kell állítanunk néhány paramétert. Elsőként meg kell adnunk, hogy egy meglévő hálózatot szeretnénk-e betölteni, vagy egy újat szeretnénk-e létrehozni és tanítani. Egy új hálózat készítésénél a következő paraméterek beállítását kell elvégezni (ha az alapértelmezett paramétereken módosítani szeretnénk):

- a bemenetek paraméterei (például mozgóátlagok hossza, a csúszóablak mérete, a felhasznált indikátorok paraméterei stb.),
- az önszervező térkép paraméterei (osztályok száma, tanulási tényező, tanulási ciklusok száma),
- a hiba-visszaterjesztéses hálózat paraméterei (például a rejtett réteg neuronjainak száma, a bátorsági tényező és más tanulási együtthatók értéke, tanulási ciklusok száma,

a súlyok inicializálási tartománya, egyéb működési paraméterek beállítása, mint a korai leállítás⁵ vagy a *bootstrapping*⁶ stb.),

- a tanító mintahalmaz kiválasztása (a kezdeti- és végdátum megadása),
- a target kiválasztása,
- a *balance* (lásd 10. ábra) értékének megadása, $balance \in \mathbb{R}[0;1]$.

Elsőként az önszervező térkép tanítására kerül sor. Amint ez véget ért, az előrecsatolt perceptron hálózat tanítása, majd az eredmények tesztelése és mentése következik.

A mentés során az indikátor CSV-fájlokba menti a beállított paramétereket és mindkét neurális hálózatot. Ennek köszönhetően az indikátor egy későbbi időpontban is tökéletesen visszaállítható és használható anélkül, hogy az indikátor paramétereit be kellene állítani vagy új tanítást kellene végrehajtani.

A program automatikusan létrehozza azt a könyvtárstruktúrát, amelybe a paraméterek és a súlyok értékeit tartalmazó fájlok kerülnek.

Az indikátor grafikonra helyezésénél megadható, hogy az korábbi eredményeket és beállításokat használjon. Ahhoz, hogy működni tudjon a már korábban tanított neurális hálózatokkal, be kell másolni az erre kijelölt mappába az említett CSV-fájlokat. Az indítást követően az inicializáló függvény tehát feldolgozza a fájlokat, és betölti a neurális hálózatokat.

4.4. A hálózatok tárolása, mérése

Amikor a hálózatok tanítása véget ért, az eredmények vizsgálata és mentése következik. Ekkor a neuronokat összekötő súlyok már nem változnak, így a hálózat csak a kimenet és a hiba számítását végzi.

A teszt során a következő hibaleírók meghatározását végzem:


- MSE, RMSE, NRMSE, MAPE;
- korreláció (a célérték és a kimenet keresztkorrelációja);
- az irányhelyesség mérőszáma (Incorrect directional change).

A kalkulált értékeket az indikátor automatikusan bevezeti erre a célra készített Excel-táblázatba. Mint már korábban említettem, a tanítást követően egy megfelelő struktúrában tárolom a hálózati súlyokat, az indikátor paramétereit és az eredményeket (11. ábra).

5 Korai leállítás (*early stopping*): egy olyan neurális hálózattanítási módszer, amelynél minden tanítási ciklus végén megvizsgáljuk, hogy mekkora hiba mérhető a validációs mintákon, és ha ez szignifikánsan emelkedni kezd, akkor leállítjuk a tanulási folyamatot. A módszer lényege, hogy megvédjen a túltanulástól (*overfitting* – a tanító mintákra való [túl]illeszkedés már rontja a nem tanító mintákon mért teljesítményt), és ezáltal javítja a hálózat általánosító képességét (CARUANA et al. [2000]).

6 Bootstrapping: egy statisztikai vizsgálatok során alkalmazott módszer; az eredeti mintahalmazból visszatevéses mintavétellel kisebb (vagy akár az eredetivel megegyező méretű) csoportokat képeznek, és vizsgálják a csoport statisztikai tulajdonságait (EFRON [1993]).

Az eredmények tárolására szolgáló könyvtárszerkezet



Forrás: saját készítés

Az indikátor az NN_data könyvtárban létrehoz egy mappát saját maga számára, amelynek a nevébe az is bekerül, hogy mely devizapáron és mely időtávon került felhasználásra az indikátor (pl. NN_SOMClasses_EURUSD_M1). Ebben a mappában az aktuális dátum szerint létrehoz egy könyvtárat, amelyen belül a program a tanítás időpontja szerint menti az indikátorhoz tartozó szükséges információkat. A dátum szerinti könyvtárban található meg az az Excel-táblázat, amelyben visszakereshető, hogy mely hálózat teljesített a legjobban.

A 3. táblázat bemutatja a 11. ábra szerinti tanulási eredményeket.

3. táblázat

Az eredmények tárolása Excelben

Error	MSE	RMSE	NRMSE	MAPE	Correlation	Incorrect Directional Change	Calculated Euclidean distance
Ideal value	0.0	0.0	0.0	0.0	1.0	0.0	0.1041
2005	0.0099	0.0995	0.2307	283 2819	0.5724	0.2626	0.1123
2016	0.0098	0.0989	0.1704	253 0645	0.5767	0.2798	0.1089
2022	0.0233	0.1526	0.7359	201 6883	0.4525	0.3314	0.1975
2034	0.0093	0.0965	0.1502	264 7286	0.5968	0.2767	0.1041
2044	0.0096	0.0977	0.1473	276 6207	0.5909	0.2767	0.1049
empty	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.2000

Forrás: saját készítés

Az időpontok azonosítják a tanulásokat.

Mivel több mérőszám is szolgál a hálózat „jóságának” eldöntésére, nem egyértelmű a legjobban teljesítő kiválasztása, hiszen ha a rekordokat az egyes mérőszámok szerint rendeznénk, más és más hálózatot választanánk, ha egyszer az egyik, másszor a másik hibaleíró szerint döntenénk. A probléma feloldására a táblázat utolsó oszlopa szolgál. Ha az eredményeket képzeletben egy 6 dimenziós koordinátarendszerben ábrázolnánk, akkor számítható lenne azok távolsága az ideális esettől, a (0, 0, 0, 0, 1, 0) ponttól. Az ideális ponttól vett euklideszi távolságok szerint rendezve kapjuk azt a hálózatot, amely minden mérőszámot figyelembe véve, a legkisebb hibával rendelkezik.

4.4.1. Az Expert Advisor működése

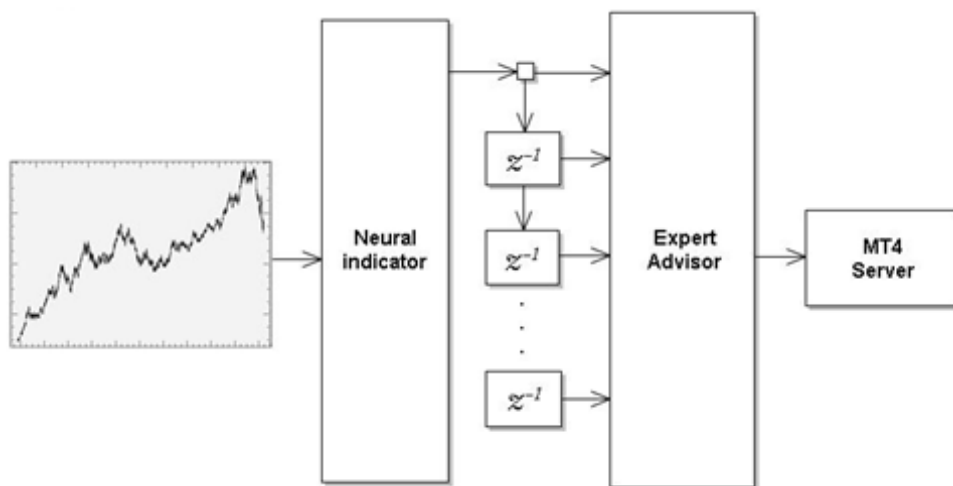
Az automata kereskedési rendszereket a MetaTraderben *Expert Advisor*-nak (röviden EA-nak) nevezik. Az EA feladata, hogy egy adott stratégia alapján nyisson, módosítson és zárjon kötések.

4.4.2. A kereskedési rendszer felépítése

A neurális hálózat alapú előrejelzés és kereskedés egyszerűsített blokkvázlatát mutatja be a 12. ábra.

12. ábra

Neurális hálózat alapú kereskedés blokkvázlata



Forrás: saját szerkesztés

Az EA az indikátor aktuális és múltbéli jelzései alapján hoz döntéseket, és az ezeknek megfelelő irányban vesz fel pozíciókat. A múltbéli jelzések ahhoz kelljenek, hogy észlelni tudja a változást éppúgy, mint egy mozgóátlag-keresztvezető.

4.4.3. Funkciók és beállítási lehetőségek

Az EA legfontosabb paramétere, hogy mely neurális indikátor alapján kereskedjen. Ez a grafikonra helyezés után adható meg. A kereskedési rendszer működése meglehetősen rugalmasan variálható, ez lehetőséget biztosít az optimalizáláshoz.

Az általam elkészített Expert Advisor a következő funkciókkal és beállítási lehetőségekkel rendelkezik:

- adott mértékű kockázat minden kötésnél (dinamikusan számított kötésegység a megadott érték és stop loss szint alapján), megadása %-ban lehetséges, például 0.5% minden pozícióban;
- a pozícióba lépés szintjének megadása (0 és 0.9 közötti érték, pl. belép, ha az indikátor jelzése a 0.5-öt vagy a -0.5-öt átlépi);
- osztályok alapján történő belépés (lásd az 5. fejezetben);
- pozícióba lépés csak pullback esetén + a pullback paramétereinek megadása;
- stop loss szint meghatározásának módja és ennek paraméterei (számítási módok: fixen megadott távolsággal, Donchian indikátor alapján, ATR alapján);
- RR-arány megadása (a take profit számítása a stop loss távolság és a megadott RR-arány szerint történik);
- stop loss módosítási lehetőségek: break evenbe húzás a take profit távolság egy adott százalékának elérésekor, folyamatos csúszó stop a stop loss meghatározási módja szerint;
- egyéb pozícióba lépési feltételek:
 - csak egy adott mozgóátlag közelében,
 - csak egy adott mozgóátlag irányába,
 - csak az árfolyam adott meredeksége alatt/felett,
 - csak támasz és ellenállás szint közelében,
 - csak adott időintervallumban;
- egyéb (a maximális slippage megadása, a pozíciók adatainak, környezetének mentése).

A MetaTrader a szimuláció végeztével egy HTML-alapú jelentést készít, amelyet a tesztelt hálózat mappájában helyezek el, így később könnyedén eldönthető, hogy az adott tanítást már teszteltem-e egy demószámlán. A jelentésekből a szimuláció néhány eredményt automatikusan átvezet abba az Excel-táblázatba, amelyben a vizsgált hálózat előrejelzési hibája van. Az átvezetett paraméterek a következők:

- **Profittényező (profit factor):** bruttó nyereség / bruttó veszteség.
- **Relatív visszaesés (relative drawdown):** a mindenkori könyvelt legnagyobb egyenleg és a maximálisan elszenvedett veszteség aránya százalékban.
- **Nettó profit (netto profit):** A bruttó profit és a bruttó veszteség különbsége.

Az Excel-táblázatba való átvezetéssel lehetőség nyílik a neurális hálózat hibájának és nyereségességének összevetésére.

5. AZ ELŐREJELZŐ RENDSZER TOVÁBBFEJLESZTÉSE


5.1. A bemutatott koncepció eredményei

A kifejlesztett indikátorok jól közelítik a célfüggvényt, 0,6–0,7 közötti korrelációs eredményeket és több mint 70%-os irányhelyességet értem el. Azonban ez még nem elég ahhoz, hogy a rendszer profitábilis legyen.

Az általam kifejlesztett módszer a célfüggvényt minden pontban pontosan igyekszik közelíteni. A pontos előrejelzési kísérlet azt eredményezi, hogy a bemeneti minta zajossága megjelenik a kimeneten is, és fals jeleket ad. A 13. ábra bemutatja, hogy nehéz megállapítani egy olyan belépési szintet, amellyel optimálisan lehet lekereskedni a közelgő mozgásokat. Az indikátorablakban a két folytonos vonal jelzi a célfüggvényt és az indikátor jelét, a vízszintes vonal pedig egy lehetséges short belépési szintet.

13. ábra

Az indikátor kimenete az eredeti algoritmus alapján



Forrás: saját szerkesztés

Az ideális belépési szint meghatározásához nem lehet egyértelmű szabályt rendelni. A nagy mozgásoknál érdemes lenne minél előbb belépni, ami a szint alacsonyra választását támogatja, ez azonban számos veszteséges pozíciót eredményez a kis mozgásoknál. Ez a jelenség alapvetően visszavezethető a technikai elemzés problémájára, amely szerint az indikátorok által adott jelek késve jelzik az árfolyammozgásokat (a magas jelzés későn érkezik).

5.2. Az osztályozás előtérbe helyezése

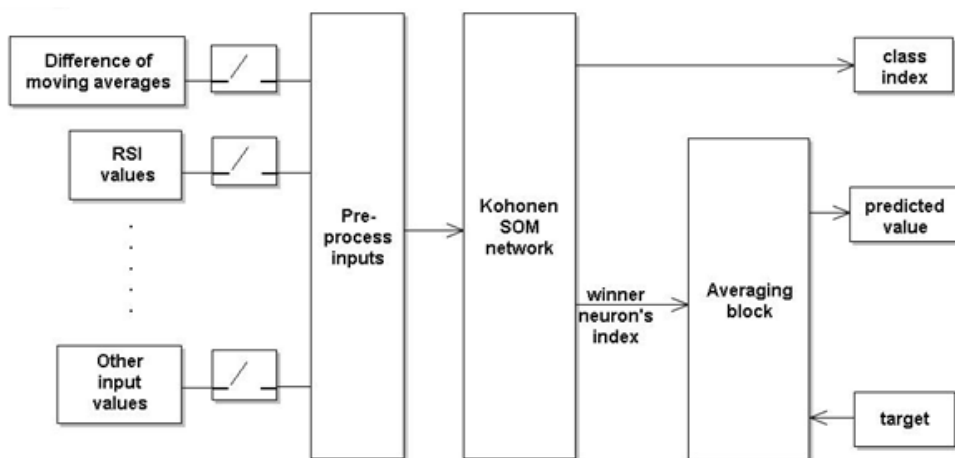
Az előzőekben leírt probléma elhárítására megváltoztattam az indikátor alapvető működését.

Az önszervező térkép a megadott számú osztályba rendezi a tanító mintákat. Ezen osztályokhoz a célértékek alapján alapvetően rendelhető egy-egy várható érték, amely megadja, hogy amikor az árfolyam mintázata egy adott osztályba sorolható, az várhatóan milyen valószínűséggel mozog vételi és eladási irányba. Ha minden osztályhoz hozzárendeljük ezt a várható értéket, akkor kiválaszthatók lesznek a legjobb osztályok, azaz azok, amelyekhez rendelt várható értékek abszolút értéke a legmagasabb (hiszen ezek valószínűsítik a nagy árfolyammozgást). A módosított szerkezetben ennek megfelelően működik az indikátor.

A kiválasztott osztályok száma tetszőlegesen választható. Az osztályokhoz történő várható értékek hozzárendelését végezhetné az önszervező hálózatot követő többretegű, hiba-visszaterjesztéses hálózat, de mivel lényegében az egyes osztályok fennállásakori célfüggvényértékek egyszerű átlagolásáról van szó, nem célszerű az átlagképzésre a neurális hálózatot alkalmazni, mert ezt jóval gyorsabban végzi el egy egyszerű átlagoló. Ennek megfelelően módosítottam a feldolgozási láncot, és helyettesítettem az előrecsatolt hiba-visszaterjesztéses hálózatot egy átlagszámítást végző blokkal (14. ábra).

14. ábra

A módosított működés blokkdiagramja




Forrás: saját szerkesztés

A 15. ábra mutatja a fent látott grafikonhoz képesti változásokat. Láthatóan egy letisztultabb kimenetet kaptunk.

15. ábra

A módosított működés eredménye azonos bemenet esetén




Forrás: saját szerkesztés

Az önszervező térkép tanulása eredményeképpen kialakult térképen a neuronok megőrzik a bemeneti minták topológiáját. A térkép szerveződését egy kétdimenziós ábrán már korábban bemutattam. Abban az ábrázolásban az osztályoknak csak x és y koordinátája volt. A módosított működés alapján az egyes osztályokhoz rendelt értékeket tekinthetjük az osztályok z koordinátájaként, és ily módon lehetőség nyílik a térkép háromdimenziós ábrázolására. Ennek segítségével vizuálisan is jól elkülöníthetők a térkép azon területei, amelyek emelkedést és esést valószínűsítenek (16. ábra).

16. ábra

Az osztályok várható értékeinek ábrázolása



Forrás: saját szerkesztés

A vételi és eladási osztályok kiválasztása két módon történhet:

- egy meghatározott sávba eső osztályok kiválasztásával (16. ábra, bal oldal);
- adott számú (legmagasabb abszolút várható értékű) osztály kiválasztásával (16. ábra, jobb oldal).

A feldolgozási folyamat és az indikátor kimenetének módosítása megszüntette a kijelölt szintek által okozott nehézségeket. Az indikátor fő feladata az árfolyamminta felismerése és annak a mintázatnak a megadása, amelyre leginkább hasonlít.

5.3. A módosított rendszer vizsgálata

Mivel az indikátornak rendkívül sok bemenő paramétere van, és emiatt nagyon hosszadalmas lenne egy minden kombinációs lehetőséget kiértékelő elemzés, szükség volt egy stratégiára, amelynek az alkalmazásával közelíthetők az optimális paraméterértékek. A megoldásomban azt a módszert követtem, hogy először egyenként optimalizáltam az egyes bemeneti ágenseket (a bemeneti vektor különálló elemeit, mint például egy RSI jelzéseit), és a legjobbakat kiválasztva alkottam meg a végső indikátort. A vizsgálatokat az EURUSD devizapár 5 perces adatain végeztem.

A historikus adatok idejét tekintve a következő felosztást alkalmaztam:

4. táblázat

A historikus adatok felhasználása

2011. 01. 01. – 2012. 01. 01.	2012. 01. 01. – 2013. 01. 01.	2013. 01. 01. – 2013. 04. 30.
A hálózat tanítása és egyszerűbb kereskedési tesztek	Egyszerűbb kereskedési tesztek, majd a kereskedés optimalizálása	Az optimalizált paraméterekkel történő (végső) teszt

Forrás: saját készítés

- *Hálózat tanítása:* A hálózat a már ismertetett módon a megadott intervallumban tanulást végez, majd ezt követően menti a vételi és eladási osztályokat. Ekkor a módosított működéssel nemcsak egyetlen célfüggvény alapján választja ki a vételi és eladási osztályokat, hanem mindhárom célfüggvény különféle változata szerint, így ugyanahhoz a hálózathoz több változat (továbbiakban variáns) is készül.
- *Egyszerűbb kereskedési teszt:* A létrejött variánsokat a stratégia teszterben futtatom adott, fix beállításokkal.
- *Kereskedés optimalizálása:* Az optimalizálás során már megengedett a stop loss szint módosítása, így a csúszó stop és a break evenbe húzás is. A kezdeti stopszint és az RR-arány optimális értéke is meghatározásra kerül.
- *Optimalizált teszt:* Hiba lenne, ha az optimalizálási adatokon kapott (optimalizált) eredményeket tekinteném a rendszer várható hozamának. Emiatt a végső tesztet olyan adatokon kell elvégezni, amelyek sem a tanulásban sem az optimalizálásban nem vettek részt. Ezt lehetőleg a legfrissebb adatokon kell végrehajtani.

5.4. Ágensek és eredményeik

Az említett módszert mindegyik ágensre elvégeztem.

Az ágensteszteket összehasonlítva, kiválaszthatók a legjobban teljesítő ágensek. Ha ezek mindegyikét hozzáadjuk a bemenethez, azt remélhetjük, hogy jobb eredményt kapunk, mintha csak egyetlen ágens alapján kereskednénk.

Néhány egyszerűbb kereskedési eredményt reprezentál az 5. táblázat. Látható, hogy az egyes mérőszámok alapján különböző sorrendbe rendezhetők az ágensek. A sötétebb színrel megjelölt ágenseket a profittényező alapján választottam ki, az összesített indikátorban ezeket az ágenseket alkalmaztam.

5. táblázat

Az ágenstesztekek eredményei


Agent name	Best profit factor	Best drawdown (%)	Best netto profit
<i>Xema</i>	1.3300	5.8500	66877
<i>XemaCross</i>	1.45	2.84	35445
<i>OHLC</i>	1.16	7.67	30500
<i>LogReturn</i>	1.15	6.45	28993
<i>RSI</i>	1.24	4.81	20930
<i>ADX</i>	1.29	5.28	31253
<i>Freedom</i>	1.44	3.15	23953
<i>Divergence</i>	1.17	4.81	8321

Forrás: saját készítés

Az optimalizálásra kiválasztott hálózat egyszerűbb kereskedési eredményeit szemlélteti a 17. ábra.

17. ábra

Egy optimalizálni kívánt hálózat egyenleggörbéje



Forrás: saját szerkesztés

Az optimalizálás során már csak a 2012-es évet vettem figyelembe. Ekkor a technikai jellegű paramétereket már nem változtattam. Kiválasztásra került az optimális stop loss távolság és annak meghatározási módja, a kezdeti kockázat/nyereség arány, valamint egyéb olyan funkciók engedélyezése, mint hogy érdemes-e break evenbe húzni a stopot, avagy csúszó stopot kell alkalmazni.

A kiválasztott hálózathoz tartozó optimális beállításokat a 6. táblázat mutatja be.

6. táblázat

Optimalizált kereskedési beállítások a kiválasztott hálózathoz


Paraméter neve	Optimális értéke
Stop loss szint meghatározási módja	ATR alapú stop loss
ATR faktor értéke	5.5
Kezdeti RR arány	1.0
Break even-be húzás	nem
Csúszó stop alkalmazása	nem
Kereskedési idő	7–18 óráig

Forrás: saját készítés

A 2012-es évre optimalizált egyenleggörbét ábrázolja a 18. ábra.

18. ábra

Az optimalizált kereskedés egyenleggörbéje



Forrás: saját szerkesztés

A dolgozat megírásakor az EURUSD historikus adatai 2013. április 30-ig álltak rendelkezésemre. Ez pontosan a 2013-as év egyharmada. Ezáltal könnyedén következtethetünk a kereskedési rendszer éves hozamára.

19. ábra

**A kereskedési rendszer eredménye
(2013. 01. 01. – 2013. 04. 30.)**



Forrás: saját szerkesztés

Amint azt a 19. ábra is szemlélteti, a kereskedési rendszer a 4 hónap alatt képes volt nyereséget realizálni, ennek pontos értéke 3230 euró az alkalmazott beállításokkal. A 100 000 eurós tőkére vetítve ez 3,23%, ami körülbelül 9-10%-os évi nyereséget jelent, ha figyelembe vesszük, hogy kamatos kamattal számolhatunk. Ez az eredmény némileg meghaladja a banki kamatokat.

Fontos megjegyezni, hogy a hozamgörbe optimalizálásánál sosem merült fel a pozíciókenti kockázat változtatása, annak értéke mindvégig a tőke 0,5%-a maradt.

A végső tesztet vizsgálva, a rendszer gyengeségeként említhető a csekély mértékű találati arány (53%). Öröndetes viszont, hogy mind a short, mint a long irányú pozíciók találati aránya 50% feletti úgy, hogy közel azonos számú short és long pozíciót nyitott a rendszer.

A vizsgálatok során érdekes összefüggésre derült fény, amely rendkívül nagy hatással van a hozamok alakulására. Azt tapasztaltam a vizsgálatokat végezve, hogy amikor a piacokon kereskedés folyt, más és más eredményt kaptam, ha ugyanazt a megtanított hálózatot két különböző időben teszteltem. Alaposabban megvizsgálva a problémát, arra a következtetésre jutottam, hogy ennek oka a spread, amely főleg akkor lehet nagy befolyással az eredményekre, ha alacsony idősíkon, ún. *scalpoló* stratégiát alkalmazunk.


A kereskedési platform stratégiatesztere úgy működik, hogy az adott devizapár legutoljára ismert spread értékét az egész tesztintervallumra vetíti. Ha ez az érték változik, az maga után vonhatja, hogy a pozíciók nyeresége és vesztesége eltér egy korábbi futtatáshoz képest.

Az MT4-ben lehetőség van offline tesztekre. Ekkor állíthatók a devizapár szerverről lementett, lokálisan tárolt paraméterei, így a spread értéke is. Ennek segítségével a hozam alakulásáról pontos elemzés készíthető a vételi és eladási ár közti különbség függvényében. A bemutatott tesztek során 20 pontos spreadet alkalmaztam, ami biztosan meghaladja az európai kereskedési időben szokásos értéket. A Dukascopy 2013-as jelentései szerint 2013 februárjában az EURUSD spread az európai kereskedési időben átlagosan 5 pont alatti értéket vett fel az ő általuk biztosított platformon. Így érdemes a hozamokat alacsony spreaddel is megvizsgálni.

Az 5 pontos spreaddel készített 2013-as szimulációt a 20. ábra szemlélteti. Láthatóan – a legelső esetet kivéve – nem megy az egyenleg a kezdeti érték alá, mint ahogy tette azt a 20 pontos spread esetén. A rendszer nyereségessége is javult, a csúcsok a 6%-os 4 havi hozamot is elérik.

20. ábra

A 2013-as év elején futtatott teszt 5 pontos spreaddel

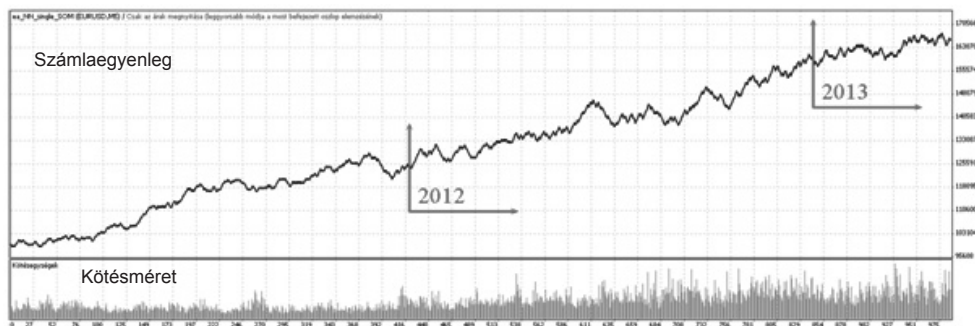


Forrás: saját szerkesztés

Végezetül bemutatom a teljes tesztintervallumra végzett szimulációt, amelyen feltüntettem az évek kezdetét is (21. ábra). A teljes időszakra vonatkozó szimulációt 5 pontos spreaddel végeztem.

21. ábra

A kereskedési rendszer hozamgörbéje (2011. 01. 01. – 2013. 04. 30.)



Forrás: saját szerkesztés

Az éves (becsült) hozamokat a 7. táblázat veti össze.

7. táblázat

A hozamokat összehasonlító táblázat

Időszak	Éves hozam (euró)	Éves hozam (%)	4 havi hozam (%)
2011. 01. 01. – 2012. 01. 01.	26 056 €	26.05%	8.02%
2012. 01. 01. – 2013. 01. 01.	32 961 €	26.14%	8.04%
2013. 01. 01. – 2013. 04. 30.	21 138 €*	13.3%*	4.25%

Megjegyzés: * Az értékek a befektetés hozamának 2013-ra várható értékét jelölik 0.5%-os pozícionkénti kockázat mellett.

Forrás: saját készítés

6. KONKLÚZIÓ

Megállapítható, hogy a múltbéli adatokon a tanulást megfelelően végzi a hálózat, ami a kereskedési eredményekből is látszik. Gyakran előfordul, hogy a múlt árfolyamváltozásait nagyon pontosan megtanulja a hálózat. A tanulásban részt nem vevő mintákon a hálózat általában már gyengébben teljesít, azonban ekkor is képes nyereséget elérni, esetenként a tanulási időszak hozamait meghaladó módon.

A kereskedés optimalizálásával javítottam a hálózat teljesítményét, majd az optimalizált rendszert a közelmúlt adataival is megvizsgáltam. A teljesen új adatokon a kereskedési rendszer nem tudja hozni azokat az eredményeket, amelyek az optimalizálás során kaptam. Megjegyezném, hogy ekkor csak a 4 havi hozam alapján becsültem az éves hozamot. A gyengébb teljesítmény ellenére, a szimulációt nyereségesen alkalmaztam a 2013-as adatokon is.

Ahhoz, hogy a kifejlesztett rendszert valódi befektetési eszközként lehessen használni, további tesztekre és paramétoptimalizálásra van szükség. Azonban véleményem szerint mindenképpen számítani lehet a jelenlegit meghaladó eredményekre.

IRODALOMJEGYZÉK

- AHN, J.-W.–SYS, S. Y. [2005]: SOM Tutorial. <http://www.sis.pitt.edu/~ssyn/som/som.html>, letöltve: 2013. 04. 10.
- ANDOR, G.–ORMOS, M. [2007]: Tőzsdei spekuláció. Budapest: BME
- ANDOR, G.–ORMOS, M.–SZABÓ, B. [1999]: Return Predictability in the Hungarian Capital Market. *Periodica Politechnica* 7. (1.), pp. 29–45.
- BIS [2010]: Triennial Central Bank Survey. Bank for International Settlements, Basel
- BOX, G. E. P.–JENKINS, G. M. [1976]: Time Series Analysis: Forecasting and Control. Holden-Day, San Francisco
- CARUANA, R., LAWRENCE, S.–GILES, L. [2000]: Overfitting in Neural Nets: Backpropagation, Conjugate Gradient and Early Stopping. In: LEEN, TODD K.–DIETTERICH, THOMAS G.–TRESP, VOLKER (eds) [2001]: Advances in Neural Information Processing Systems 13. MIT
- Institut, Aarhus Universitet, Dánia
- EFRON, B. [1993]: An Introduction to the Bootstrap, New York: Chapman-Hall
- ENGLER, R. F. [1982]: Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50. évf. 4. szám, pp. 987–1007.
- FAMA, E. [1970]: Efficient Capital Markets: A Review of Theory and Empirical Work. New York: Blackwell Publishing for the American Finance Association
- GALLO, C.–LETIZIA, C.–STASIO, G. [2006]: Artificial Neural Networks in Financial Modelling. Quaderni DSEMS, Università di Foggia
- GIACOMINI, E. [2003]: Neural Networks in Quantitative Finance. Berlin
- HORVÁTH, G. et al. [2006]: Neurális hálózatok. Budapest: Panem Könyvkiadó
- IBFX [2012]: FX: The Foreign Exchange Market – IBFX. <http://www.ibfx.com/Trade/The-Foreign-Exchange-Market>, letöltve: 2012. 11. 25.
- KALYVAS, E. [2001]: Using neural networks and genetic algorithms to predict stock market returns. Masters Thesis, University of Manchester
- KAMRUZZAMAN, J.–STARKER, R. A. [2004]: ANN-Based Forecasting of Foreign Currency Exchange Rates. *Neural Information Processing – Letters and Reviews* Vol. 3, No. 2, May
- KOHONEN, T. [1982]: Self-Organizing Maps. 3. kiadás szerk. Berlin: Springer.
- KONDRATENKO, V.–KUPERIN, Y. A. [2003]: Using Recurrent Neural Networks To Forecasting Forex. Cornell University Library
- LEVINSON, M. [2009]: Guide to Financial Markets (*The Economist*), London: Bloomberg Press
- MIZUNO, H.–KOSAKA, M.–YAJIMA, H.–KOMODA, N. [1998]: Application Of Neural Network To Technical Analysis Of Stock Market Prediction. *Studies in Informatic and Control*, Vol.7, No.3, pp.111–120.
- MOLNÁR, M. A. [2006]: A magyar tőkepiac vizsgálata pénzügyi viselkedéstani módszerekkel. Gazdálkodástani Doktori Iskola, BCE
- ORMOS, M. [2003]: Vállalatok gazdasági elemzéseinek egyes kérdései Magyarországon. BME
- PISSARENKO, D. [2002]: Neural Networks For Financial Time Series Prediction: Overview Over Recent Research. Bsc Computer Studies
- PRANANTHA, D. [2009]: Neural Network in Business Intelligence (Part 1). <http://danupranantha.wordpress.com/2009/10/15/neural-network-in-business-intelligence-part-1/>, letöltve: 2012. 11. 28.
- RETTNER, G. [2003]: Fuzzy, neurális, genetikus, kaotikus rendszerek. Budapest: Invest Marketing
- RIOS, D. [2010]: Artificial Neural Networks. [<http://www.learnartificialneuralnetworks.com/#Intro>], letöltve: 2012. 11. 28.
- TAN, C. L.–YAO, J. [2000]: A case study on using neural networks to perform technical forecasting of forex. *Neurocomputing* 34, pp. 79–98.
- TAN, CHONG [2009]: Financial Time Series Forecasting Using Improved Wavelet Neural Network. Datalogisk
- VANSTONE, B., HAHN, T.–FINNIE, G. [2012]: Developing high frequency foreign exchange trading systems. 25th Australasian Finance–Banking conference. Sydney, Australia
- Wordpress [2011]: Why Log Returns | *Quantivity*. <http://quantivity.wordpress.com/2011/02/21/why-log-returns>, letöltve: 2013. 04. 09.
- ZHANG, G.–HU, M. Y. [1997]: Neural Network Forecasting of the British Pound/US Dollar Exchange Rate. *Omega*, Vol. 26, Iss. 4, 24 August 1998, pp. 495–506.