

Lakatos Zsolt¹:

Devizaárfolyam előrejelzés neurális háló modell segítségével

Foreign Exchange Rate Forecast Using Neural Network

Modelljeimben a technikai indikátorok használatát kapcsolom össze a neurális hálós modellek előrejelző képességeivel. A technikai indikátorok használata mellett szól, hogy rövid távon a pénzügyi idősorok autokorreláltak, a neurális modellek pedig nemlineáris kapcsolatok modellezésére alkalmasak. A kapott eredmények révén azt a következtetést vontam le, hogy ugyan a neurális háló modellek optimalizációs képessége nagyon jó és alkalmazásukkal a megfelelő technikai indikátorok is meghatározhatók, de csak lassan képesek rátanulni az adatokra, így még a legkisebb tranzakciós költség alkalmazása mellett is csak a kezdeti befektetésünk elvesztését tudjuk halogatni.

My present paper is the shortened version of my master's thesis in finance presented in November 2015, in which I presented the results of the research implemented in the Training Center for Bankers. In my models I combine the use of technical indicators with predictive capabilities of neural network models. The use of a technical indicator suggests that in the short term the financial timeseries are autocorrelated, and neural models are suitable for modeling nonlinear relationships. Based on the results I concluded that although the optimization capabilities of the neural network models are very good and their application can be determined by the appropriate technical indicators, but learning from timeseries data takes too much time, so even with the smallest transaction cost we can only delay the loss of our initial investment.

1 Irodalom összefoglaló

A devizaárfolyam előrejelzéséhez kapcsolódó elméleteket Mačerinskiene és Balčiūnas [2014] három fő csoportba sorolta: a hatékony piacok elmélete, fundamentális elméletek és a technikai alapon történő előrejelzés. A hatékony piacok elmélete azt állítja, hogy minden információ beépül az árfolyamba és lényegében pont a piaci hatékonyság miatt nem lehet előrejelzést készíteni. A gyenge forma a technikai elemzés használatát kérdőjelezi meg, a közepesen erős forma a fundamentális elméleteket, míg az erős forma minden előrejelzési technikát, mivel ez már azt állítja, hogy a mindenkori árfolyamba a bennfentes információk is azonnal beépülnek. Ezzel szemben a technikai előrejelzés alkalmazásakor abban bíznak, hogy múltbeli chartok, árfolyammozgások a jövőben is be fogják következni.

Meese és Rogoff [1983] tanulmánya volt az első, amely az addigi elméleti modelleket összehasonlította a véletlen bolyongás modellel (random walk model) és azt az eredményt kapták, hogy ez a sem teljesít rosszabbul, mint az idősoros modellek vagy a strukturális árfolyam modellek.

Baillie és McMahon [1989] tanulmányukban arra utaltak, hogy a devizaárfolyamok lineáris modellekkel nem jelezhetők előre. Meese és Rose [1991] makroökonómiai árfolyam modelleket vizsgáltak és szerintük

¹ egyetemi tanársegéd, Budapesti Corvinus Egyetem, Befektetések és Vállalati Pénzügy Tanszék

ezen modellek alacsony magyarázó ereje ugyancsak azt támasztja alá, hogy nemlineáris modellekkel kellene leírni a devizák közötti kapcsolatokat.

Lyons és Evans [1999] modellje egy olyan új változót vezetett be, ami az eszközárzás mikroökonómiáját beleviszi a devizaárfolyam modelljébe. Ez az új változó az ún. *order flow*, ami a devizaárfolyam közelítő meghatározó tényezője. Ezzel a már létező makrogazdasági modelleket is képesek voltak javítani. Képesek voltak az *order flow* révén megragadni a napi árfolyammozgások 60 százalékát lineáris modell használatával.

Zhang and Hu [1998] olyan nemlineáris modellt alkotott, mely a devizaárfolyamot annak múltbeli értékei alapján modellezte. Modelljük előrejelző képessége felülmúlta az egyszerű lineáris modelleket, de ők a *random walk* modellel nem hasonlították össze a saját modelljüket.

Zhang and Hu [1998] neurális hálós modelljüket napi és heti adatokon tesztelték és úgy találták, hogy a neurális háló modellek robusztusabb előrejelzési képességekkel rendelkeznek, mint a véletlen bolyongás modell. A neurális háló modellek számos esetben sikeresek voltak rövid távú devizaárfolyam előrejelzés során [Kuan and Liu, 1995].

Már 2000-ben a Bank of Canada egy műhelytanulmányt jelentetett meg, amiben a szerzők röviden összefoglalták a neurális háló modellek akkoriban elért eredményeit [Gradojevic és Yang, 2000].

Rengeteg tanulmány foglalkozik devizaárfolyamok előrejelzése során a neurális hálózatok képességének a tesztelésével. Chew és Yao [2000], Kondratenko és Kuperin [2003] a tőkepiaci hatékonyságot vizsgálta, valamint tesztelték, hogy az árfolyam véletlen bolyongás mozgást végez-e. Tesztjüket az ún. *R/S* analízissel² végezték, aminek eredménye a Hurst-kitevő (Hurst-exponent). A Hurst-kitevő 0.5-es értéke azt jelenti, hogy egy tetszőlegesen választott deviza árfolyama véletlen bolyongási mozgást végez. A 0.5 feletti értékek enyhén trendszerű, memóriával rendelkező mozgásra utalnak. Tesztjeik eredményei 0.5 és 0.6 közötti értékeket mutattak.

Theofilatos és társai [2012] tanulmányukban a hagyományos stratégiákat (naiv stratégia és MACD³) hasonlítják össze a tanuló gépek segítségével megvalósított technikákkal (machine learning techniques). Naiv stratégiának azt nevezték, amikor az aktuális periódusbeli árfolyamváltozást használják, mint legjobb előrejelzőt a jövőbeli árfolyam meghatározására. Tanulmányukban az EURUSD árfolyam egy napos előrejelzését vizsgálták úgy, hogy az inputok az EURUSD árfolyam autoregresszív tagjai voltak, vagyis az 1-től 10 periódusig tartó késleltetettjei. Az évesített hozamok alapján a Random Forest⁴ eljárás lett a legjobb, megelőzve a tartó vektor gépek (support vector machines) módszert, az MACD-én alapuló technikai elemzést, valamint a neurális háló modellt. A végkövetkeztetésük az lett, hogy a tanító gépek segítségével végzett modellezések révén sokkal jobb előrejelzéseket lehet készíteni, mint a hagyományos ökonometria vagy idősorelemzésen alapuló elemzések révén.

Fahimifard és társai [2009] tanulmányukban 2002 és 2008 között az iráni Rial/USD (IRRUSD) és az iráni Rial/EUR (IRREUR) árfolyamot vizsgálták. A hagyományos ARIMA és GARCH modellek eredményeit hasonlították a neurális háló modellekhez, illetve az ANFIS-hoz (Adaptive Neuro-Fuzzy Inference Systems). Azt számszerűsítették, hogy a különböző módszerek alapján előrejelzett árfolyam mennyiben tért el a tényleges árfolyamtól. A következő előrejelzési kritériumok szerint osztályozták: R-négyszet,

² *R/S* analízis során különböző időperiódusokra kiszámoljuk a kumulált hozamok átlag körüli ingadozásainak terjedelmét (*R*) és ezt elosztjuk a hozamok szórásával (*S*). Ezt újraszkalázott terjedelem-analízisnek (Rescaled Range Analysis) nevezik, ezen folyamat eredményeként kapjuk a Hurst-kitevőt.

³ Az MACD (moving average convergence divergence) egy trendkövető indikátor, ugyan csak viszonylag későn ad jelzést a befektetőknek, viszont az indikátor szignáljai megbízható kereskedési jelnek számítanak. Használata során segít a trend felismerésében, illetve annak megerősítését is szolgálja.

⁴ Egy döntési fához hasonló klasszifikációs eljárás.

átlagos abszolút eltérés (Mean Absolute Deviation, MAD), átlagos négyzetes gyökeltérés (Root Mean Square Error, RMSE).

Az árfolyam 2, 4 és 8 napos előrejelzését vizsgálták többféle paraméterű beállítás mellett. Az eredményeik azt igazolták vissza, hogy nemlineáris módszerek révén (neurális hálók, ANFIS) pontosabb devizaárfolyam előrejelzést lehet adni, mint lineáris módszerekkel (ARIMA, GARCH). A legjobb eredményt az ANFIS mutatta, a legmagasabb R^2 értékkel és legalacsonyabb MAD és RMSE értékekkel. De a neurális háló modell (ANN) sem sokkal maradt el tőle.

A devizaárfolyamok neurális hálózatokkal történő előrejelezhetőségéről Yu és társai [2007] készítettek egy áttekintő tanulmányt. Publikációjukban 45 tanulmányt hasonlítottak össze a neurális hálókval való előrejelzés ellentmondásainak a feltárása érdekében. Arra keresték a válaszokat, hogy neurális hálókval való devizaárfolyam előrejelzés során miért eltérőek az eredmények, mely esetekben jelezhető előre a devizaárfolyamok, illetve mikor nem. A 45 tanulmány 60 százaléka esetében a neurális háló modell jobb, 35.5 százaléka pedig csak bizonyos szituációkban jobb előrejelzést produkált, mint egyéb időszerelemzési modellek. A tanulmányokat nyolc faktor alapján hasonlították össze, például előrejelzési horizont, adatok frekvenciája (napi, heti stb.). Arra a következtetésre jutottak, hogy rövid vagy közepes időtávra alkalmasak a neurális háló modellek előrejelzésre, ha legalább kétvényi adat áll rendelkezésre, többrétegű előrecsatolt hálózatos modell felhasználásával (multi-layer feed-forward neural network)⁵.

2 Az adatelemzés eszközei

2.1 Technikai indikátorok

Végh [2016] a technikai elemzés kapcsán megemlíti, hogy a technikai indikátorok használata több száz éves múltra tekint vissza. A fundamentális elemzéshez képest a technikai elemzés alapvetően matematikai és statisztikai alapokra épül. Technikai elemzés révén a piaci árfolyamok változásának az irányát szeretnék a befektetők előre jelezni. Ehhez a múltbeli és aktuális árfolyamokat, illetve forgalomnagyságot veszik figyelembe. A technikai elemzés két legfontosabb alapfeltevése, hogy a piaci ár minden lényeges információt magában hordoz, illetve a történelem ismétli önmagát. A befektetők viselkedésmintákat követnek.

A fundamentális elemzéshez képest még egy fontos szempont a befektetési időtáv. Technikai elemzést követő befektetők rövid távon gondolkodnak, néhány hetes, napos, óras vagy akár perces befektetésekből. Nagy [2011] könyvében az indikátorokat az árfolyamelemzés fontos kiegészítőjeként említi. Ezek statisztikai számításokon alapuló mutatók, az értéküket matematikai képletek alapján határozzuk meg, ezért segítségünkkel dönthetünk egy pozíció nyitásáról, zárásáról, illetve arról, hogy mikor számíthatunk fordulatra az árfolyam mozgásában. Az indikátorok révén automatizált kereskedési rendszerek létrehozására is van lehetőség. Az indikátorokat Nagy [2011] az alábbiak szerint csoportosítja:

1. Trendkövető indikátorok: mozgóátlagok, MACD (Moving Average Convergence Divergence), TRIX (Triple exponential).
2. Változással egyidejű vagy momentum indikátorok: ROC (rate of change) oszcillátor, RSI (Relative Strength Index), Stochastic⁶.
3. Forgalom alapú indikátorok : OBV (On Balance Volume), Chaikin oszcillátor.
4. Volatilitást mérő indikátorok: CCI (Commodity Channel Index), Bollinger-szalag.

⁵ Az adatok elemzése során én is hasonló neurális háló modellt alkalmaztam.

⁶ A technikai indikátorok esetén az angol nyelvű elnevezéseiket használom. A Stochastic indikátor esetében a magyar sztochasztikus szó használata megtévesztő lenne, mivel itt nincs szó sztochasztikus folyamatokról.

Nagy [2011] a technikai elemzés előnyei között sorolja fel a módszerek könnyű megértését és alkalmazását, a számtalan rendelkezésre álló eszközt, elemzői módszert (például belépési/kilépési jelek), nagyon sok pénzügyi termék egyszerre nyomon követhető (a fundamentális elemzés nagyon időigényes), rövid távon nagyon jól használható (rövid távon a fundamentumoknak nincs ideje beépülni az árfolyamokba). Hátrányok között említi, hogy múltbeli folyamatokból próbálunk következtetni a jövőre, a technikai elemzés során használt számos eszköz szubjektivitást tartalmaz, ami félrevezető lehet, illetve nem minden terméknel és nem minden időpontban működik a technikai elemzés. Elsősorban olyan pénzügyi termékek esetén lehet alkalmazni a technikai elemzést, melyeknek piaca kellően likvid.

Az egyes technikai indikátorok számítási képleteit a kiegészítő mellékletben mutatom be.

2.2 A neurális hálózat definíciója, képessége

Horváth és társai [2006] könyvükben úgy definiálják a neurális hálózatot, mint számítási feladatok megoldására létrejött párhuzamos feldolgozást végző adaptív eszközt, melynek eredete a biológiai rendszerektől származtatható. Fazekas [2013] ezt úgy nevezi, hogy a mesterséges neurális hálózat az idegrendszer felépítése és működése analógiájára kialakított számítási mechanizmus. Úgy írja, hogy a neurális hálózatot úgy érdemes felfogni, hogy nem a jelenségek modellezésére, törvényszerűségek megállapítására alkalmas, hanem a jelenséget mintegy fekete dobozként kezeli. A vizsgált jelenséget így nem tárja fel és a neurális hálózat maga sem hasonlít a jelenségre. Ez a fekete doboz tulajdonság a neurális hálózat legnagyobb hátránya. Működésükhöz csak adatok kellenek.

Horváth és társai [2006] a neurális hálózatok alábbi főbb jellemzőit foglalták össze:

- azonos vagy hasonló típusú – általában nagyszámú – lokális feldolgozást végző műveleti elem, neuron (processing element) többnyire rendezett topológiájú, nagymértékben összekapcsolt rendszerből áll,
- rendelkezik tanulási algoritmussal (learning algorithm), mely általában minta alapján való tanulást jelent, és amely az információfeldolgozás módját határozza meg,
- rendelkezik a megtanult információ felhasználását lehetővé tevő információ előhívási, vagy röviden előhívási algoritmussal (recall algorithm).

Az alábbi definíciójuk alapján alapvetően két fázist lehet megkülönböztetni: az első a tanulási, a második az előhívási. Az első fázisban kell kialakítani a hálózatot, ami során a mintákban rejtett információkat valamilyen módon beépítjük a hálózatba, vagyis eltároljuk. Ennek eredménye egy információfeldolgozó rendszer. Az előhívási fázisban kerül sor ennek a rendszernek a használatára. Míg az első fázis jellemzően lassú, hosszú iterációkkal és tanulási folyamattal rendelkezik, a második fázis tipikusan gyors feldolgozást jelent. A két fázis jellemzően időben szétválik egymástól, de ahogy könyvükben írják, adaptív viselkedésű hálózatok az információ előhívási szakaszban is módosítják a képességeiket, tulajdonságaikat, tanulnak.

A neurális hálózatok felépítése esetén Lieszbauer [2013] kétféle típust sorol fel: a felügyelt tanulású hálózatokat és a nem felügyelt tanulású hálózatokat. A neurális hálózatok alapvető vagy processzáló eleme a neuron, mely tetszőleges számú bemenetből és egy kimenetből áll, emellett egy összegzőből és általában egy nemlineáris aktivációs függvényből. A feldolgozási folyamat során 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. A felügyelt tanulású neuronhálózatok képessége, hogy megfelelő kialakítás esetén tetszőleges be- és kimeneti kapcsolatot, leképezést képesek megvalósítani. A szokásos elnevezés szerint ezek a neuronhálózatok ún. univerzális approximátorok [Horváth és társai, 2006]. A felügyelt tanulású hálózatok főbb felhasználási területei: függvényapproximáció és regressziós analízis, rendszeridentifikáció, szabályozástechnika és jelfeldolgozás, időszori előrejelzés.

Nem felügyelt tanulású hálózatok esetén induláskor nem ismerjük a helyes eredményeket [Retter, 2006]. Mivel a kimenetek helyességére semmilyen információnk nem áll rendelkezésre, a hálózatnak a tanulást a bemenetek alapján kell elvégeznie. Lieszbauer [2013] a következő alkalmazási területeket sorolja fel: hasonlóságok megállapítása a bemeneti minták között, csoportok, klaszterek kialakítása a bemeneti mintatérben, adattömörítés, szövegbányászat.

2.3 Devizapiaci alkalmazási lehetőségek

Horváth és társai [2006] a neurális háló, mint approximáló rendszer használata során említik, hogy előfordul, hogy a vizsgált folyamat, melyet optimalizálunk dinamikát mutat, vagy a környezet (zaj stb.) változik az időben (idővariáns folyamatok), vagy a folyamat pillanatnyi értéke nem csupán az adott bemeneti jeltől, hanem az előzményektől is függ. Ekkor a következő értéket vagy értékeket kell előre jelezni (jósolni). Ezeket a feladatokat időszori előrejelzési feladatoknak (time series prediction) szokás nevezni. Ilyen például a neurális hálózatok devizapiaci alkalmazási lehetősége.

Egy neurális háló bemenete bármilyen numerikus jellé konvertált adat lehet: makrogazdasági fundamentumok, technikai indikátorok értékei vagy a mikrostruktúra elméletek során alkalmazott order flow. Felügyelt tanulású neurális hálózatok esetén Gallo [2006] a következő lépéseket sorolja fel:

1. A célértékek (target) azonosítása.
2. A neurális háló bemenetét képező adathalmaz létrehozása.
3. A hálózat aktiválása, ami a hálózat architektúrájának a megalkotását és a paraméterek kiválasztását jelenti.
4. Az elkészült hálózat képességének tesztelése, javítása, az előrejelző képesség tesztelése mintán kívüli (out-of-sample) adatokon.

A neurális hálózatok kezdeti típusa 1958-ban Rosenblatt nevéhez köthető, az egyetlen neuronból (idegsejtből) álló perceptron volt. De hamar kiderült, hogy még több rétegbe rendezett neuron révén sem oldható meg lineárisnál bonyolultabb folyamat [Fazekas, 2013]. Az áttörést a többrétegű perceptron (Multi Layer Perceptron, MLP) tanítására szolgáló eljárás, a hiba visszaáramoltatása (hiba visszaterjesztéses, error back-propagation) módszer felfedezése jelentette [Fazekas, 2013]. A többrétegű perceptron az egyik legismertebb és leggyakrabban használt neurális hálózat. Rétegekbe rendezett perceptronokból áll, előrecsatolt hálózat (feedforward network) struktúrájú, továbbá struktúrája flexibilisen alakítható. Többféle numerikus eljárással betanítható, képes megoldani a szeparálás és az approximálás problémáját és nem csak lineáris esetben, komplex feladatok megoldására alkalmas [Fazekas, 2013].

A többrétegű perceptron háromféle rétegből (layer) épül fel: bemeneti (input), rejtett (hidden), valamint kimeneti (output) rétegből. Míg rejtett rétegből tetszőleges számú lehet, bemenetiből és kimenetiből csak egy-egy [Fazekas, 2013]. A hálózat tartalmazza a rejtett neuronok egy vagy több rétegét, amelyek nem részei a háló inputjának vagy outputjának és képes komplex rendszer megtanulására és rendkívüli nemlineáris feladatokra azáltal, hogy fokozatosan kinyeri az input mintákból az értelmes jellegzetességeket. A hálózat képes a különböző rétegek közötti összekapcsolhatóság kimutatására.

3 Adatok elemzése

A kutatás⁷ során az EUR/USD árfolyam előrejelezhetőségét vizsgáltam ún. technikai indikátorok segítségével. Ezeket a technikai indikátorokat egy matematikai képlettel szokás kiszámítani. Lényegében a pénzügyi idősor korábbi adataiból szeretnék következtetni a jövőbeli értékeire. Ehhez kiszámoltam az

⁷ A kutatás 2015 tavaszán a Bankárképző Központban zajlott.

egyes technikai indikátorok értékeit, majd ezeket normalizáltam, végül pedig minden indikátor esetén képeztem a 10 db késleltetett. Ezen késleltetetteket, mint magyarázó változókat alkalmaztam az eredményváltozó (Target2⁸) magyarázására, az árfolyamváltozás irányának előrejelzésére. A neurális háló optimalizációs képességét ekkor alkalmaztam, az egyes technikai indikátorok előrejelzés alapján fektettem be, ennek a befektetésnek a teljesítményét vizsgáltam.

$$\text{Target2_no_csokk} = \text{Indikátor}_{t-1} + \text{Indikátor}_{t-2} + \dots + \text{Indikátor}_{t-10} \quad (1)$$

A Target2_no_csokk az eredményváltozó, amely három értéket vehet fel. Ha növekszik az árfolyam, az értéke 1, csökkenés esetén -1, ha pedig nem változik, akkor nulla. Az aktuálisan használt indikátor késleltetettjei a magyarázó változók. A (t-1) késleltetett az 1 periódussal korábbi késleltetetre utal. Mivel 5 perces adatokat használtam, ez 5 perccel korábbi késleltetetteket jelentette. Tehát nem az árfolyam konkrét értékét szerettem volna előrejelezni, hanem csak az irányát.

Az inputváltozókat, vagyis a magyarázó változók értékeit normalizáltam. Ez azért is indokolt, mivel az egyes indikátorok esetén használt képletek nagyon különböző értékeket eredményeznek, amit a normalizálás révén ki tudunk egyenlíteni. A normalizálás egy [0, 1] intervallumra történő átskálázást jelent lineáris transzformáció segítségével.

$$\text{Indikátor}_{\text{normalizált}}^9 = \frac{\text{Indikátor}_{\text{aktuális}} - \text{Indikátor}_{\text{minimum}}}{\text{Indikátor}_{\text{maximum}} - \text{Indikátor}_{\text{minimum}}} \quad (2)$$

Az egyes indikátorok normalizált értékei során az adott indikátorra alkalmazandó számítási képlet során kiszámított, adott periódusbeli értékét normalizáltam az előbbi képlet segítségével, ahol a maximum és minimum értékek az adott periódusra jellemző értékek.

Ezen szakaszban egy nagy mintát alkalmaztam, lényegében a teljes mintát 1999. január 4-től 2014. október 31-ig, megbontva egy tanítási és egy tesztelési mintára.

EUR/USD 5 perces adatok: 1999. január 4. 10:20:00-tól 2014 október 31. 21:55:00-ig. Ez ötpercenkénti 1170084 darab árfolyamadat összesen, olyan bontásban, hogy nyitó, záró, illetve az adott 5 perces intervallumban lévő legalacsonyabb és legmagasabb árfolyam.

A tanítási minta 1999. január 4. 10:20:00 és a 2012. december 31. 18:45:00 adatokat tartalmazza, ez összesen 1034146 darab árfolyamadatot a korábban említett bontásban. A tesztelési minta pedig a 2013. január 1. 23:00:00 és 2014. október 31. 21:55:00 közötti adatokat tartalmazza, ami 135938 darab árfolyam adatot jelent.

Amikor a befektetés teljesítményének számításakor a bid és ask árfolyam közötti spreadet is figyelembe vettem, akkor egy Reuters jegyzéshez igazodva 3 bázispontos spreadet alkalmaztam.

Az adatok elemzése előtt a GRETLE program segítségével meghatároztam az EURUSD adatsor loghozamainak az ún. Hurst-kitevő értékét. Ez az érték azért érdekes, mert a 0,5-es érték arra utal, hogy az árfolyam véletlen bolyongási folyamat szerint változik.

A Hurst-kitevő értékére 0.52-os érték adódott, ami nagyon közel van a véletlen bolyongási folyamatra utaló 0.5-es értékhez. A 0.52-os érték arra is utal, hogy egy kis trendszerű mozgás azért megfigyelhető az árfolyam mozgásában. Ezért az volt a várakozásom, hogy az árfolyamváltozás irányának az előrejelzése nehéz lesz, és amíg a neurális háló modell nem tanul rá az adatokra, addig nyereség elérése sem várható.

⁸ A Target2_no_csokk érték elnevezés abból fakad, hogy a kutatás korábbi szakaszában a Target1 érték az árfolyam konkrét értékét jelentette.

⁹ Az RSI indikátor esetében számolok egy nem normalizált verzióval is.

Mivel az egyes technikai indikátorok alkalmazása révén épített neurális háló modellek összes ábrájának a bemutatása meghaladná a tanulmány kereteit, ezért a Stochastic indikátor esetén bemutatom, hogy a program eredményei alapján milyen ábrák készültek. Az összes többi indikátor esetén is az ábrák ugyanazok. Az elmondható az összes indikátorról, hogy a legjobb befektetési teljesítményt mutató indikátorok is ugyanolyan rossz teljesítményt értek el, amikor tranzakciós költséggel is kalkuláltam. Tranzakciós költség mellett mind lineáris, mind exponenciális stratégia alkalmazásával 10-14 nap alatt a kezdeti befektetés értékének fele elveszett. A Stochastic indikátor után egy összefoglaló táblázatban mutatom be, hogy az egyes indikátorok esetén a különböző modelleknek milyen lett az információtartalma a tanítási és tesztelési minta tekintetében. Ez azért érdekes összehasonlítás, mert ez mutatja a neurális háló modell tanulási képességét. Majd az egyes indikátorokhoz tartozó modellek befektetési teljesítményét is bemutatom ebben a táblázatban.

A modellezéshez az IBM SPSS Modeler programját használtam. A következőkben röviden ismertetem, hogy milyen outputokat adott a program. A Stochastic indikátorra épülő modell esetében az összes Stochastic indikátor (gyors Stochastic %K és %D és lassú Stochastic %D) mind az összes 10-10 késleltetettjét (összesen 30) mint magyarázó változót a programnak megadtam inputként. Végül a neurális háló maga optimalizált egy 10 magyarázó változóból álló modellt, amivel az árfolyamváltozás irányát próbálja előre jelezni. Az 1. ábra mutatja a modell pontosságát, a 2. ábra a magyarázó változók fontossági sorrendjét¹⁰.

A 3. ábra a klasszifikációs tábla a megfigyelt (observed) és az előrejelzett (predicted) értékek találati pontosságát mutatja. A teljes találati pontosság nem éri el az 50 százalékot, ez a folyamat (az EURUSD árfolyam alakulás) véletlen bolyongási jellegét támasztja alá.

A 4. és 5. ábra ún. nyereség-chartot (gains chart) ábrázol. A nyereség úgy van definiálva, mint a teljes találati arány minden egyes kvantilisben. A nyereség kiszámítási módja:

$$\text{Nyeresség} = \frac{\text{találatok száma a kvantilisben}}{\text{összes találatok száma}} \cdot 100 \% \quad (3)$$

A kumulatív nyereség-chartok mindig a 0%-ból indulnak és a 100%-ban végződnek, ahogy balról jobbra haladunk. Egy jó modell esetén a nyereség-chart meredeken emelkedik a 100% felé, majd kiegyenesedik. Olyan modell, ami nem szolgáltat információt, a 45°-os átlót követi, arra simul rá.

A modell információtartalma alacsony, közel van a véletlenszerű találati arányhoz, ami az 50%-os találati arány lenne, vagyis az átló. Mindazonáltal ez magas információtartalomnak számít, mivel a modellben az EURUSD árfolyam előrejelezhetőségét szeretném modellezni, viszont az EURUSD árfolyam majdnem véletlen bolyongási folyamat szerint változik, aminek az előrejelezhetősége lényegében véletlenszerű.

A befektetés teljesítményének kiszámítási módja (exponenciális növekedésű):

$$\text{Befektetés értéke}(t) = \text{Befektetés értéke}(t-1) + \text{Befektetés értéke}(t-1) \cdot \text{Modellelőrejelzés}(t-1) \cdot [\text{Záróárfolyam}(t) - \text{Záróárfolyam}(t-1)] \quad (4)$$

Exponenciális befektetési stratégia esetén a teljes befektetett összeget újra befektetem a modell által adott jelzés alapján. A 10 magyarázó változó közül a gyors Stochastic magyarázó változók dominálnak, az ún. lassú Stochastic változókból csak kettő került be a modellbe. A modell viszonylag lassan tanul, mert mintegy 7 évbe telik, amíg megduplázódik a befektetés értéke. De a befektetési időszak kétharmadától egy meredekebb emelkedést figyelhetünk meg, vagyis a modell képes volt jól rátanulni az adatokra.

A befektetés teljesítményének kiszámítási módja (lineáris növekedésű):

$$\text{Befektetés értéke}(t) = \text{Befektetés értéke}(t-1) + 100 \cdot \text{Modellelőrejelzés}(t-1) \cdot [\text{Záróárfolyam}(t) - \text{Záróárfolyam}(t-1)] \quad (5)$$

¹⁰ Az ábrák a tanulmány végén az Ábrajegyzékben szerepelnek.

Lineáris befektetési stratégia esetén 15 év alatt kb. 3.5-szeres növekedés érhető el. Ennél a típusú befektetési stratégiánál mintegy 1 évvel tovább tart, amíg megduplázódik a befektetés értéke. Az exponenciális befektetési stratégia előnye akkor válik láthatóvá, amikor a modell már rátanult az adatokra.

A befektetés teljesítménye bid-ask spread alkalmazásával (lineáris növekedésű):

$$\text{Befektetés értéke}(t) = \text{Befektetés értéke}(t-1) + 100 \cdot \text{Modell előrejelzés}(t-1) \cdot [\text{Záróárfolyam}(t) - \text{Záróárfolyam}(t-1)] - \text{Befektetés értéke}(t-1) \cdot 0,0003 \quad (6)$$

A kezdeti befektetés nagysága = 100

A befektetés kezdeti időpontja: 1999. január 4.

A befektetés vége: 2014. október 31.

Az 50-es vagy az alatti érték azt jelenti, hogy a modellnek nincs információtartalma.

Mindegyik technikai indikátor értékeit normalizáltam, csak az RSI indikátor esetén van normalizált, illetve nem normalizált indikátor. Ezért csak ennél van külön ez jelölve.

1. táblázat: Az egyedi technikai indikátorokon alapuló modellek teljesítményének összefoglaló táblázata (saját szerkesztés)

A modell indikátorai	A modell információ-tartalma		Mennyi idő alatt duplázódik a befektetés		Mennyi a befektetés értéke a végén	
	Tanítási modell	Tesztelési modell	Exponenciális növekedésű modell	Lineáris növekedésű modell	Exponenciális növekedésű modell	Lineáris növekedésű modell
<i>Stochastic_K</i> <i>Stochastic_D</i> <i>Stochastic_D_slow</i>	51.244	51.594	7.3 év	8.9 év	1000	350
<i>Stochastic_K</i>	51.423	51.735	7.1 év	7.8 év	1000	350
<i>Stochastic_D</i>	51.441	51.878	2.9 év	4.9 év	1500	400
<i>Stochastic_D_slow</i>	51.310	51.790	15.2 év	NEM	200	180
<i>RSI</i>	40.945	51.910	10.4 év	11.3 év	580	380
<i>RSI_norm</i>	51.290	51.590	3.5 év	4.6 év	3500	480
<i>MACD</i>	51.825	52.373	4.1 év	5.5 év	2700	450
<i>MACD_signal</i>	51.193	51.480	12.9 év	13.4 év	320	230
<i>PPO_EMA</i>	51.629	52.165	7.1 év	8 év	1800	400
<i>MACD,</i> <i>MACD_signal</i> <i>PPO_EMA</i>	50.751	50.541	3.5 év	4.9 év	2000	400
<i>Range</i>	50.245	50.302	NEM	NEM	150	150
<i>True Range</i>	49.852	50.644	NEM	NEM	72	81
<i>ATR</i>	49.270	49.739	NEM	NEM	103	117
<i>ADX</i>	49.793	49.784	NEM	NEM	103	116
<i>DI_poz</i>	50.638	51.162	10.1 év	10.6 év	500	275
<i>DI_neg</i>	51.565	51.230	7.4 év	9.4 év	850	330
<i>DI_poz és DI_neg</i>	50.811	50.882	2.4 év	3.2 év	3000	450
<i>APO</i>	50.867	51.216	12.3 év	14.3 év	300	225
<i>PO</i>	50.833	51.065	13.2 év	14.3 év	300	225
<i>UO</i>	50.939	51.071	6.6 év	7.9 év	1250	370
<i>Felső Bollinger</i>	50.147	49.026	NEM	NEM	31	0
<i>Alsó Bollinger</i>	49.939	50	NEM	NEM	160	160
<i>b százalék</i>	51.183	51.395	1.8 év	2.7 év	36000	700
<i>Felső és alsó Bollinger</i>	50.258	51.945	NEM	NEM	160	160
<i>Felső és alsó Bollinger és b százalék</i>	50.810	51.246	4.1 év	5.3 év	11300	600
<i>ENV</i>	50.775	50.572	3.6 év	8.1 év	1400	400
<i>Két mozgóátlag</i>	50.688	50.599	4.3 év	7.1 év	1750	400
<i>TRIX</i>	50.856	50.924	10.6 év	NEM	150	159
<i>CCI</i>	51.693	52.025	2 év	2.4 év	45000	750

A modell indikátorai	A modell információ-tartalma		Mennyi idő alatt duplázódik a befektetés		Mennyi a befektetés értéke a végén	
	Tanítási modell	Tesztelési modell	Exponenciális növekedésű modell	Lineáris növekedésű modell	Exponenciális növekedésű modell	Lineáris növekedésű modell
<i>ROC</i>	50.963	50.900	2.1 év	4.4 év	1600	400
<i>VOL</i>	49.700	48.636	NEM	NEM	113	127
<i>VOL_ENV</i>	49.985	49.995	NEM	NEM	153	157
<i>PVO</i>	50.318	50.324	10.5 év	NEM	180	174
<i>OBV</i>	50.026	50.277	NEM	NEM	136	145
<i>ACDI</i>	49.927	50	NEM	NEM	71	78
<i>MFV</i>	50.363	51.019	5.2 év	7.3 év	2000	400
<i>CMF</i>	50.712	50.511	2.3 év	4.1 év	2000	400
<i>Japán gyertya</i>	50.612	50.361	3.5 év	7.1 év	2000	400

A befektetés értéke exponenciális növekedésű befektetési stratégia mellett a leggyorsabban a következő indikátorok használata mellett duplázódott meg: b százalék (1.8 év), CCI (2 év), ROC (2.1 év), CMF (2.3 év), a DI_pozitív és DI_negatív együttes alkalmazása (2.4 év). Lineáris növekedésű stratégia mellett: b százalék 2.7 év, CCI 2.4 év, ROC 4.4 év, CMF 4.1 év, DI_pozitív és DI_negatív együttes alkalmazása 3.2 év.

Ezt követően több technikai indikátor egyidejű használatát is modelleztem, valamint főkomponens és faktorelemzés alapján legfontosabb technikai indikátorok használatával alkotott modellt is alkottam. Ennek a magyarázó változói a következő indikátorok lettek: MACD, MACD_signal, PPO_EMA, DI_poz, DI_neg, ENV, ROC, 2MA, QStick 10 db késleltetettje.

A 9. ábra exponenciális, míg a 10. ábra lineáris befektetési stratégia mellett ábrázolja a kezdeti befektetett összeg növekedését. A modell legfőbb érdekessége, hogy ugyan exponenciális befektetési stratégia mellett a kezdeti befektetés nagysága 65-szörösére növekszik a befektetési időszak végére, szemben a lineáris stratégia nagyjából nyolcszoros növekedésével, de tovább tart, amíg a kezdeti összeg megduplázódik. Exponenciális stratégia mellett ez több mint 5 év, míg lineáris stratégia esetén 2.9 év. Vagyis azt lehet megállapítani, hogy idő kell, amíg a neurális háló modell rátanul az adatokra és csak ezután nyilvánul meg az exponenciális stratégia előnye. További érdekesség, hogy egyedi technikai indikátorok alkalmazásával gyorsabban lehetett megduplázni a kezdeti befektetést, ugyanakkor a több indikátor egyidejű használatára optimalizált modellel a befektetési időszak végére nagyobb növekedést sikerült elérni.

Amit ezzel az optimalizált modellel sem lehetett kiküszöbölni, az a tranzakciós költség hatása. A 11. ábrán látható, hogy még 1 bázispontos költség esetén is lineáris stratégia mellett egy hónap alatt a kezdeti befektetés nagysága megfeleződött. Vagyis nyereséges stratégiát még ilyen optimalizált modellel sem sikerült létrehozni.

4 Konklúzió

A tanulmányomban a Bankárképzőben folytatott modellezést foglaltam össze röviden. A kutatás során arra kerestem a választ, hogy az ún. technikai indikátorok mennyiben lehetnek hasznosak devizaárfolyam előrejelzés esetén, illetve a neurális háló mennyire képes ezen indikátorok jelzései alapján nyereséges modellek megalkotására. Azt állapítottam meg, hogy rövid távú devizakereskedés esetén az ilyen indikátorok használata sajnos megkerülhetetlen, mivel a gyorsaság miatt egyszerűen más fundamentális

elemzési lehetőség nem áll rendelkezésre. Csak a devizaárfolyam múltbeli mozgásaiból lehet következtetni a jövőbeli mozgásaira. A kutatás során megerősítést nyert, hogy a devizaárfolyamot meghatározó fundamentális tényezők között nemlineáris kapcsolatok állhatnak fenn, melyeket neurális háló modellekkel már lehet modellezni. Mivel automatikus kereskedési rendszer létrehozása volt a cél, így a nagyszámú kereskedés következtében még a legkisebb tranzakciós költség mellett is csak a veszteségeket lehetséges elodázni. A modell egyszerűen nem tud olyan gyorsan rátanulni az adatokra, hogy ezzel kompenzálni tudja a tranzakciók költségeiből eredő veszteségeket. Így végül a kutatás eredményei között legfőképpen azt tudom megemlíteni, hogy meg tudtam határozni, hogy egyáltalán milyen típusú technikai indikátorokat érdemes használni devizaárfolyam előrejelzésben, továbbá milyen indikátorokat érdemes egyszerre egyidejűleg használni.

Felhasznált irodalom:

- Baillie, R. és McMahon, P. (1989): *The Foreign Exchange Market: Theory and Econometric Evidence*. New York: Cambridge University Press.
- Chew, L. T. és Yao, J. (2000): *A case study on using neural networks to perform technical forecasting of forex*, Neurocomputing 34 : 79-98. ScholarBank@NUS Repository.
- Evans, M.D.D. és Lyons, K.R. (1999): *Order Flow and Exchange Rate Dynamics*, NBER Working Paper No. W7317, 1–46.
- Fahimifard S.M. és Homayounifar, M. és Sabouhi, M. és Moghaddamnia, A.R. (2009): *Comparison of ANFIS, ANN, GARCH, and ARIMA Techniques to exchange rate forecasting*, Journal of Applied Sciences 9(20):3641-3651
- Fazekas, I. (2013): *Neurális hálózatok*, Debreceni Egyetem, Informatikai Kar, TÁMOP-4.1.2.A/1-11/1-2011-0103 tananyag
- Gallo, C. (2006): *Artificial Neural Networks in Financial Modelling*, Dipartimento di Scienze Economiche, Matematiche e Statistiche, Università di Foggia.
- Gradojevic, N. és Yang, J. (2000): *The Application of Artificial Neural Networks to Exchange Rate Forecasting: The Role of Market Microstructure Variables*, Bank of Canada, Working Paper 2000-23
- Horváth, G. és Altrichter, M. és Pataki, B. és Strausz, Gy. és Takács, G. és Vályon, J. (2006): *Neurális hálózatok és műszaki alkalmazásaik*. Budapest: Panem Könyvkiadó.
- Kondratenko, V.V és Kuperin, Yu. A. (2003): *Using Recurrent Neural Networks To Forecasting of Forex* , Cornell University Library
- Kuan, Ch-M. és Liu, T. (1995): *Forecasting Exchange Rates Using Feedforward and Recurrent Neural Networks*, Journal of Applied Econometrics, Vol. 10, 347-364 (1995)
- Lakatos, Zs. (2015): *Az Euró/dollár árfolyam előre jelezhetőségének a vizsgálata neurális hálózat segítségével* (Budapest Corvinus Egyetem Gazdálkodástudományi Kar Befektetések és Vállalati Pénzügy Tanszék Pénzügy Mesterszak szakdolgozat)
- Lieszbauer, T. (2013): *Devizapiaci árfolyam előre jelzés neurális hálózatokkal*, Hitelintézeti Szemle 12.évf., 5. sz.
- Mačerinškiene, I. és Balčiūnas, A. (2014): *Fundamental Exchange Rate Forecasting Models. Advantages and Drawbacks*, KSI Transactions on Knowledge Society
- Meese, R.A. és Rogoff, K. (1983): *Empirical exchange rate models of the seventies: Do they fit out of sample?*, Journal of International Economics, vol. 14, no. 1-2, pp. 3-24.
- Meese, R.A. és Rose, A.K. (1991): *An Empirical Assessment of Non-Linearities in Models of Exchange Rate Determination*, The Review of Economic Studies Vol. 58, No. 3, Special Issue: The Econometrics of Financial Markets (May, 1991), pp. 603-619
- Nagy, A. (2011): *Hogyan kereskedjünk a deviza- és részvénypiacokon kisbefektetőként rövid távon*, Invest-Project Kft., 2011

- Retter, G. (2006): *Fuzzy, neurális, genetikus, kaotikus rendszerek*, Budapest: Akadémiai Kiadó
- Theofilatos, K. és Likothanassis, S. és Karathanasopoulos, A. (2012): *Modeling and Trading the EUR/USD Exchange Rate Using Machine Learning Techniques*, ETASR - Engineering, Technology & Applied Science Research Vol. 2, No. 5, 2012, 269-272
- Végh, Z. (2016): *A technikai elemzés alapjai: chartok, pozíció felvétele és menedzselése*, MNB Oktatási füzetek, 8. szám, 2016. december
- Yu, L. és Lai, K.K. és Wang, S. (2007): *Are Foreign Exchange Rates Predictable? A Survey From Artificial Neural Networks Perspective*, IIGSS Academic Publisher, Scientific Inquiry, vol. 8, no. 2, 2007, pp. 207 – 228
- Zhang, G. és Hu, M.Y. (1998): *Neural Network Forecasting of the British Pound/US Dollar Exchange Rate*, International Journal of Management Science 26 (4): 495–506

Kiegészítő melléklet

A kutatás során használt technikai indikátorok számítási képletei

Stochastic indikátorok

Kétféle indikátort különböztetünk meg, %K és %D. A %K számítási képlete:

$$\%K = \frac{\text{záróár} - \%K \text{ periódus alatti legalacsonyabb ár}}{\%K \text{ periódus alatti legmagasabb ár} - \%K \text{ periódus alatti legalacsonyabb ár}} \times 100 \quad (7)$$

Relatív erősség index (RSI)

$$RSI = 100 - \frac{100}{1 + RS} \quad (8), \quad RS = \frac{x \text{ hosszú időszak emelkedésének átlaga}}{x \text{ hosszú időszak csökkenésének átlaga}} \quad (9)$$

MACD (Moving Average Convergence Divergence)

$$MACD = \frac{EMA(\text{Záróárak a rövidebb periódusban})}{EMA(\text{Záróárak a hosszabb periódusban})} \quad (10)$$

$$\text{vagy } MACD = EMA(\text{rövidebb periódus}) - EMA(\text{hosszabb periódus}) \quad (11)$$

$$EMA(\text{jelenlegi}) = (\text{Záróár} - EMA(\text{előző})) * \text{Szorzó} + EMA(\text{előző}) \quad (12)$$

$$\text{ahol periódus alapú EMA esetén a Szorzó} = 2/(1 + N) \quad (13)$$

Volatilitási indikátorok

Range indikátor

$$\text{Range} = \text{legmagasabb érték} - \text{legalacsonyabb érték} \quad (14)$$

True Range indikátor

$$TR = \text{Max}(\text{aktuális maximum} - \text{aktuális minimum}, \text{abs}(\text{aktuális maximum} - \text{előző záró érték}), \text{abs}(\text{aktuális minimum} - \text{előző záró érték})) \quad (15)$$

Average True Range indikátor

$$ATR_t = \frac{ATR_{t-1} * (x-1) + TR_t}{\text{az elmúlt időszak kiadás napok száma}} \quad (16)$$

ADX (Average Directional Movement Index)

$$DM+ = \begin{cases} \text{ha } (\text{Magas}_t - \text{Magas}_{t-1}) > (\text{Alacsony}_{t-1} - \text{Alacsony}_t) \\ \text{akkor } \max(\text{Magas}_t - \text{Magas}_{t-1}; 0) \end{cases} \text{ különben } 0. \quad (17)$$

$$DM- = \begin{cases} \text{ha } (\text{Alacsony}_{t-1} - \text{Alacsony}_t) > (\text{Magas}_t - \text{Magas}_{t-1}) \\ \text{akkor } \max(\text{Alacsony}_{t-1} - \text{Alacsony}_t; 0) \end{cases} \text{ különben } 0. \quad (18)$$

Ezután a DM+, a DM- és a TR mutatókból is ún. simított (smoothed) verziókat kell számolni.

$$\text{Smoothed } DM+ = \frac{\text{Smoothed } DM_{t-1} * (x-1) + DM+_t}{x} \quad (19)$$

$$\text{Smoothed } DM- = \frac{\text{Smoothed } DM_{t-1} * (x-1) + DM-_t}{x} \quad (20)$$

$$\text{Smoothed } TR = \frac{\text{Smoothed } TR_{t-1} * (x-1) + TR_t}{x} \quad (21)$$

Az x periódusra utal, ami a kereskedési napok számot mutatja.

$$DI+ = \frac{\text{simított } DM+}{\text{simított } TR} * 100 \quad (21) \quad \text{és} \quad DI- = \frac{\text{simított } DM-}{\text{simított } TR} * 100 \quad (22)$$

Ahol a DI jelentése Directional Indicator.

Az ADX értékeit a következő képlet alapján lehet kiszámolni, ahol az ADX értékeit a DX értékek exponenciális mozgóátlaga adja.

$$DX = \frac{\text{abs}(DI+ - DI-)}{(DI+ + DI-)} * 100 \quad (23)$$

Oszillátorok

APO (Absolute Price Oscillator)

APO = rövid periódusú (vagy gyors) mozgóátlag mínusz hosszú periódusú (vagy lassú) PPO (Percentage Price Oscillator)

$$PPO = \frac{APO}{\text{lassú periódusú SMA}} * 100 \quad (24)$$

Ultimate Oscillator (UO)

$$BP = \text{Záróár}_t - \text{Min}(\text{Alacsony}_t, \text{Záróár}_{t-1}). \quad (25)$$

Majd ki kell számítani a True Range értékeket. Ezt követően a BP/TR mozgóátlagokat kell kiszámolni x számú periódusra:

$$\text{Avg}_x = \frac{BP_{t-x+1} + BP_{t-x+2} + \dots + BP_t}{TR_{t-x+1} + TR_{t-x+2} + \dots + TR_t} \quad (26)$$

Végül magának az UO indikátornak az értékeit számoljuk ki:

$$UO = \frac{4 * \text{Avg}_{x1} + 2 * \text{Avg}_{x2} + 1 * \text{Avg}_{x3}}{4 + 2 + 1} \quad (27)$$

Bollinger-szalag

$$\text{szórás} = \sqrt{\frac{\sum_{j=1}^n (\text{záróár}_{j-n} \text{ periódusú mozgóátlag})^2}{n}}, \quad (28)$$

ahol n a periódus hossza napokban (vagy akkor egységekben amekkorát a napi gyakoriság helyett alkalmazunk), W paraméter meghatározása (W mint width vagy deviation, a szórást igazítja az időtávhoz a felső és alsó szalag:

$$\text{Bollinger szalagok} = x \text{ periódusú mozgóátlag} \pm W * \text{szórás} \quad (29)$$

$$\%b = \frac{\text{Záró-alsó Bollinger}}{\text{felső Bollinger-alsó Bollinger}} \quad (30)$$

Trendkövető indikátorok

ENV (Envelope)

$$\text{ENV}\% = \frac{\text{Záróár}}{x \text{ periódusú mozgóátlag}} - 1 \quad (31)$$

Trend esetén az ENV% előjele vételi vagy eladási jelet adhat átlag feletti vagy átlag alatti árfolyamok esetén. A kutatásban is ez alapján számolom az ENV indikátor értékeit.

TWO MA

$$\text{Two MA} = \frac{\text{rövidebb periódusú mozgóátlag}}{\text{hosszabb periódusú mozgóátlag}} - 1 \quad (32)$$

TRIX (Triple Exponential Average)

- kiszámítjuk a záróárak x periódusú mozgóátlagát, ez lesz az EMA_1 ,
- majd az EMA_1 -ből kiszámítjuk az EMA_2 értékeit (az EMA_2 az EMA_1 értékeinek x periódusú mozgóátlaga),
- végül az EMA_2 értékeiből az EMA_3 értékeit.

$$\text{EMA1}_t = (\text{Záróár} - \text{EMA1}_{t-1}) * \text{Szorzó} + \text{EMA1}_{t-1}, \quad (33)$$

ahol $\text{Szorzó} = 2/(1 + x)$.

A TRIX indikátor értékei az EMA_3 százalékos változása.

$$\text{TRIX} = \frac{(\text{EMA3}_t - \text{EMA3}_{t-1})}{\text{EMA3}_{t-1}} \quad (34)$$

Momentum indikátorok

ROC (Rate of Change) indikátor

$$ROC = \frac{(Záróár_t - Záróár_{t-x})}{Záróár_{t-x}} * 100 \quad (35)$$

CCI (Commodity Channel Index)

$$CCI = \frac{Tipikus\ ár - Tipikus\ ár\ x\ periódusú\ mozgóatlaga}{0,15 * x\ periódusú\ szórás} \quad (36)$$

Forgalmi indikátorok

PVO (Percentage Volume Oscillator)

$$PVO = \frac{(gyors\ periódusú\ EMA - lassú\ periódusú\ EMA)}{lassú\ periódusú\ EMA} * 100 \quad (37)$$

OBV (On Balance Volume)

$$OBV_t = \begin{cases} OBV_{t-1} + Mennyiség_t, & \text{ha } Záró_t > Záró_{t-1}, \\ 0, & \text{ha } Záró_t = Záró_{t-1}, \\ - Mennyiség_t, & \text{ha } Záró_t < Záró_{t-1}. \end{cases} \quad (38)$$

ACDI (Accumulation / Distribution)

$$ACDI_t = ACDI_{t-1} + \frac{(Záró_t - Alacsony_t) - (Magas_t - Záró_t)}{Magas_t - Alacsony_t} * Mennyiség_t \quad (39)$$

CMF (Chaikin Money Flow)

Ennek az indikátornak az értékeit az előző indikátor esetén ismertett Money Flow Volume alapján számoljuk.


$$Money\ Flow\ Volume = \frac{(Záró_t - Alacsony_t) - (Magas_t - Záró_t)}{Magas_t - Alacsony_t} * Mennyiség_t \quad \text{vagy} \quad (40)$$

$$CF = \frac{MFV_{t-x+1} + MFV_{t-x+2} + \dots + MFV_t}{Mennyiség_{t-x+1} + Mennyiség_{t-x+2} + \dots + Mennyiség_t} \quad (41)$$

Az indikátor értékei -1 és +1 között változnak és ritkán vesz fel szélsőséges értékeket.

Ábrajegyzék (az IBM SPSS Modeler program outputjai)**Japán gyertya**


1. ábra: Japán gyertya (Forrás: <https://www.portfolio.hu/uzlet/20070912/japan-gyertyak-es-a-milliardos-szamuraj-87585?page=2>)



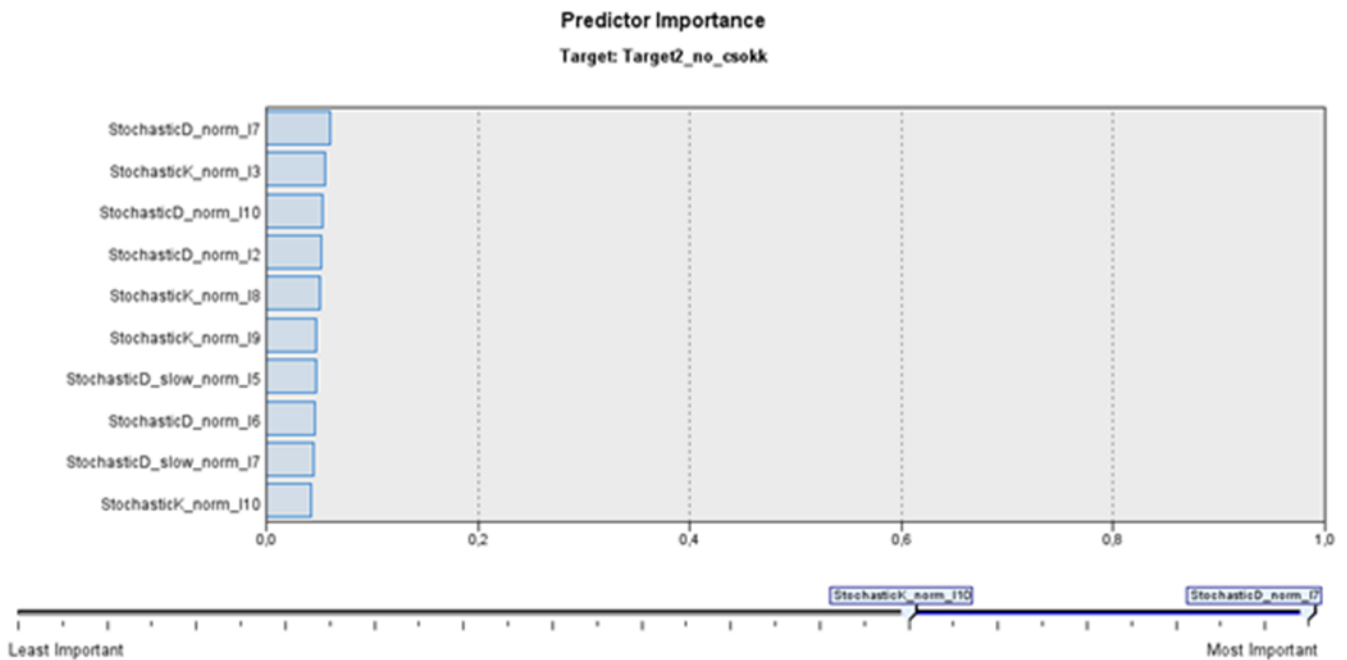
2. ábra: A modell pontossága

Model Summary

Target	Target2_no_csokk
Model	Multilayer Perceptron
Stopping Rule Used	Minimum relative change in error achieved
Hidden Layer 1 Neurons	2
Hidden Layer 2 Neurons	4



3. ábra: A magyarázó változók fontossági sorrendje




4. ábra: Klasszifikációs tábla

Classification for Target2_no_csokk


Overall Percent Correct = 44,6%

Observed	Predicted			Row Percent
	-1	0	1	
-1	48,1%	0,0%	51,9%	100,00
0	46,5%	0,0%	53,5%	80,00
1	44,4%	0,0%	55,6%	60,00


5. ábra: Az összes Stochastic indikátorra épülő modell tanítási mintájának információtartalma



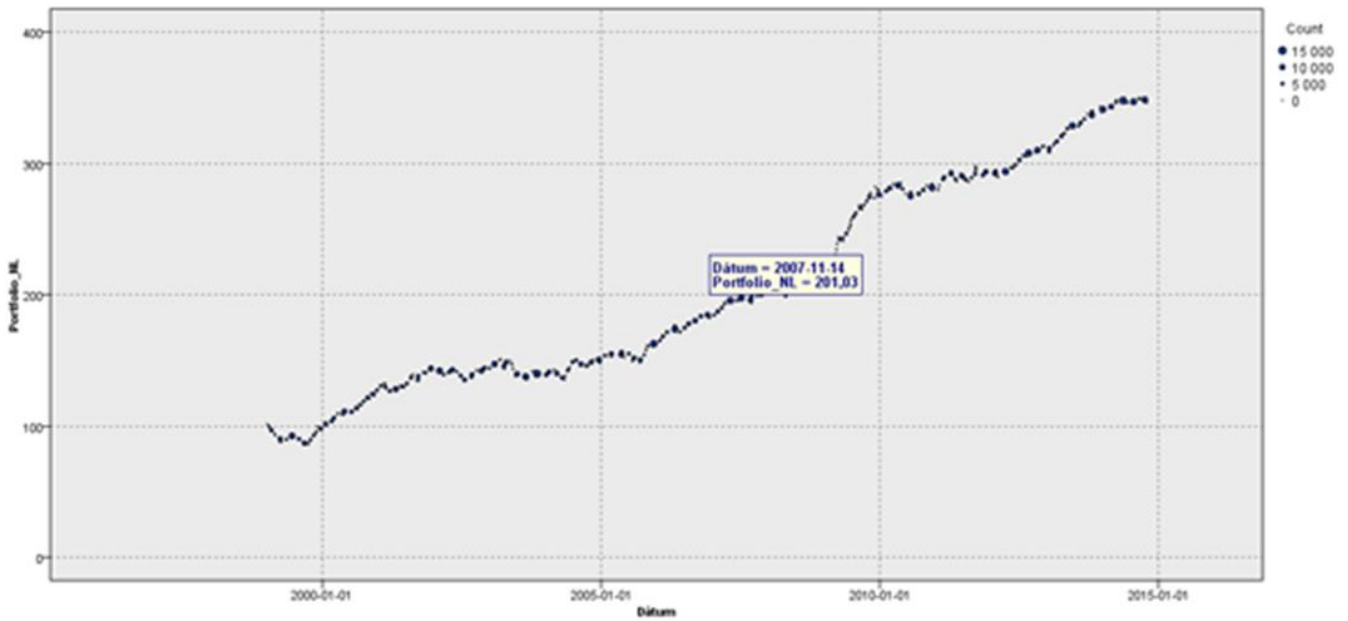
6. ábra: Az összes Stochastic indikátorra épülő modell tesztelési mintájának információtartalma




7. ábra: Az összes Stochastic indikátorra épülő modell befektetési teljesítménye exponenciális stratégia mellett



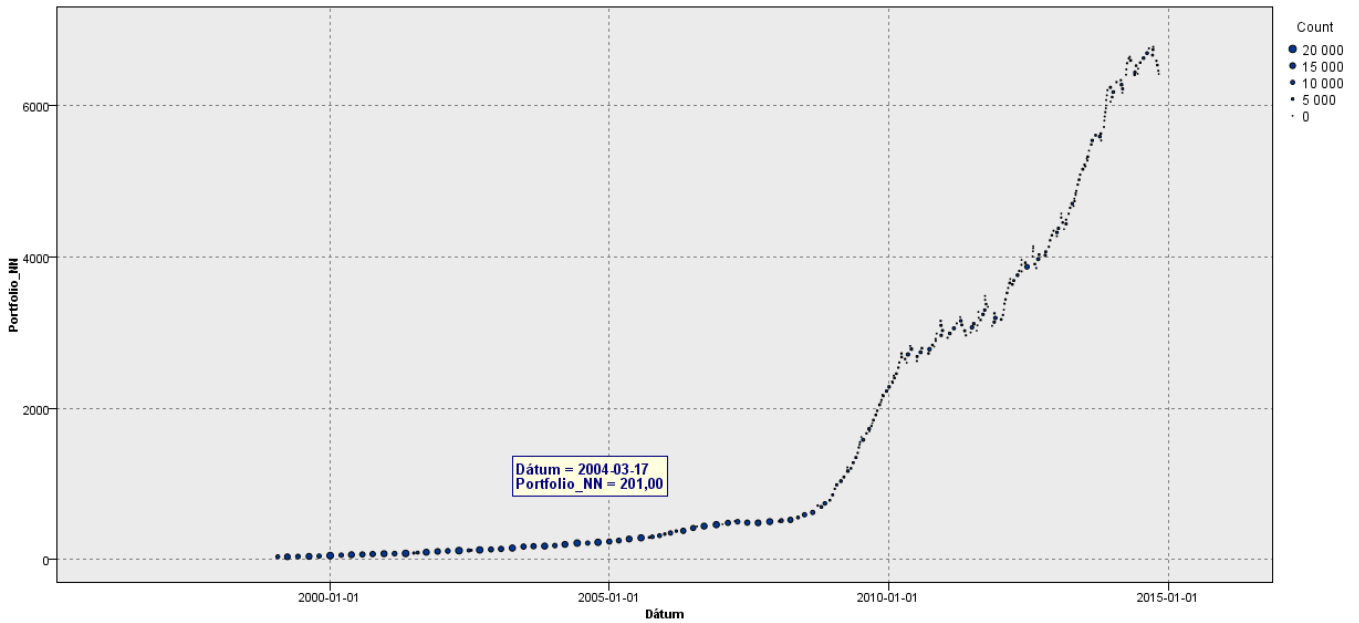
8. ábra: Az összes Stochastic indikátorra épülő modell befektetési teljesítménye lineáris stratégia mellett



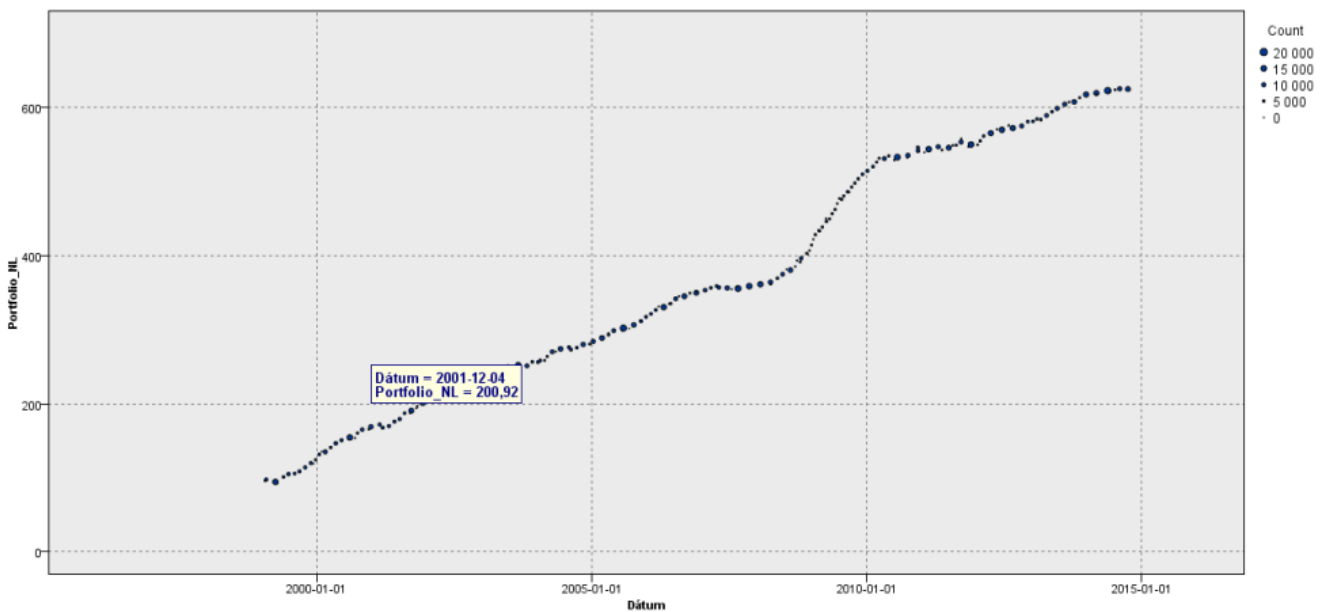
9. ábra: Az összes Stochastic indikátorra épülő modell befektetési teljesítménye lineáris stratégia és tranzakciós költség mellett



10. ábra: Több indikátor egyidejű használatára optimalizált modell exponenciális stratégia melletti befektetési teljesítménye



11. ábra: Több indikátor egyidejű használatára optimalizált modell lineáris stratégia melletti befektetési teljesítménye



12. ábra: Több indikátor egyidejű használatára optimalizált modell lineáris stratégia melletti befektetési teljesítménye 1 bázispontnyi tranzakciós költség alkalmazásával

