

Prediktív modellek teljesítményének vizsgálata Covid-19 és az orosz–ukrán háború időszakában

Vancsura László¹ – Bareith Tibor²

Összefoglaló

Tanulmányunkban arra a kérdésre keressük a választ, hogy mennyire hatékonyan lehet a mesterséges intelligencia segítségével előrejelezni a részvénypiaci trendeket a világ vezető részvénypiacain a 2010. 01. 01. és a 2022. 09. 16. közötti időszakban. A Covid-19 és az orosz–ukrán háború erőteljesen éreztette hatását a tőkepiacokon is, ezért egy rendkívül volatilitásintenzív környezetben folyt a vizsgálat. Az elemzés során három időintervallumon két különböző komplexitású gépi tanulási algoritmust (döntési fa, LSTM) és egy parametrikus statisztikai modellt (lineáris regresszió) alkalmaztunk. A kapott eredmények kiértékelését az átlagos abszolút százalékos hiba alapján (MAPE) értékeltük. Tanulmányunkban igazoltuk, hogy a prediktív modellek a kiemelt volatilitású időszakban jobban tudnak teljesíteni, mint a lineáris regresszió. Emellett fontos eredményünk, hogy az orosz–ukrán háborút követő időszakban jobban teljesítettek az előrejelző modellek, mint a Covid-19 kitörése után. Az árfolyam-előrejelzés a fundamentális és technikai elemzések során is fontos szerepet kaphat, beépíthető az algoritmikus kereskedés döntési szempontjai közé, azonban akár önmagában is alkalmas lehet a kereskedés automatizálására.

KULCSSZAVAK: árfolyam-előrejelzés, mesterséges intelligencia, prediktív algoritmusok

JEL KÓDOK: C45, C53, G11, G17


¹ Magyar Agrár- és Élettudományi Egyetem, vancsura.laszlo@phd.uni-mate.hu

² Közgazdaság- és Regionális Tudományi Kutatóközpont, btibor09@gmail.com

1. Bevezetés

Az inflációs nyomás már a fogyasztói árindexben is látszik, nem csak az eszközárakban. Különösen igaz ez a Covid-19 és az orosz–ukrán háború kirobbanásának időszakra, amikor a világ pénz- és tőkepiacai megremegtek. Az Egyesült Államok mellett más kormányok és jegybankok is eszközvásárlási programokat hirdettek meg, amelyekkel próbáltak enyhíteni a válságot (Báger & Parragh, 2020; Novák & Tatay, 2021). Ezt támasztja alá Török (2020) tanulmánya, aki az EU országainak államadósságát modellezte a koronavírus függvényében. Valamennyi ország esetében növekedés várható a GDP-hez mért államadósságban. Az 1. ábrán jól kirajzolódnak a válságos időszakok úgy, mint az 1987-es tőzsdekrach, a 2000-es dotcom-lufi, a 2008-as másodlagos jelzálogpiaci válság, valamint a 2020-ban globálissá nőtt koronavírus-krízis.

1. ábra: Az S&P500 index hozamainak szórásadatai 1978–2022 között



Forrás: saját szerkesztés Wall Street Journal adatai alapján

A technológiai fejlődésnek azonban még a válságok sem szabhatnak gátat. A mesterséges intelligencia terjedését mi sem jelzi jobban, hogy a magyar közigazgatásban is jelen van a technológia, bár egyelőre vannak jogi akadályok a teljes implementáláshoz (Fejes & Futó, 2021). A különféle tanulóalgoritmusok szépen lassan szivárognak be az életünk különböző területeire, megkönnyítve mindennapjainkat, és hatékonyabbá téve a folyamatokat. Ennek előnyei és hátrányai természetesen még rengeteg vitaalapot generálnak majd, de úgy véljük, hogy elkerülhetetlen ezeknek a technológiáknak az előretörése, különösen a magas tőkeerővel rendelkező iparágakban.

A különféle befektetési termékek árfolyamának előrejelzése mindig kihívást jelentett a statisztikával és a pénzügyekkel foglalkozó szakembereknek egyaránt (Nabipour et al., 2020). A prediktív modellek fejlesztésének legfőbb célja, hogy a piac által generált bizonytalanságokat minél pontosabban meg lehessen becsülni, és ezáltal a kockázati tényező minimalizálhatóvá váljon. A tőzsdei árfolyamok előrejelzésének kategorizálásában megoszlanak a nézetek. Vannak olyan kutatók, akik két (Nassirtoussi, 2014)

és akadnak, akik három (Dunne, 2015; Nti et al., 2020) típusba sorolják őket. Az első, a legrégebb óta alkalmazott módszer a fundamentális elemzés, a második módszertan a technikai elemzés eszközszerrendszere. A harmadik és legújabbnak tekinthető megközelítés a technológiai, amely a gépi tanulás és a számítási intelligencia technikáit elegyíti az árfolyamtrendek előrejelzése érdekében (Nti et al., 2020).

A gépi tanulási módszertanok elterjedése, valamint egyre szélesebb körű alkalmazása hozzájárult a prediktív modellek teljesítményének javulásához és az előrejelzések pontosságának növeléséhez (Maqsood et al., 2019). A részvénypiaci predikcióval foglalkozó szakértőknek a modellfejlesztések során alapvetően számos kihívással kell szembenézniük. A komplexitás, a zajos információk, a fejlődési sajátosságok és a nem lineáris kapcsolatok problémakörei többek között a tőzsde instabilitására, valamint a befektetői pszichológia és a piaci magatartás közötti összefüggésekre vezethető vissza (Duarte et al., 2017).

A prediktív modellek kialakítása során egyre nagyobb hangsúlyt kapnak tehát a gépi tanulás eszközei, amelyek segítséget nyújtanak a befektetőknek és a kereskedőknek az optimális döntések meghozatalában. Ezen módszerek elsődleges célja, hogy megtanulják és utána automatikusan felismerjék a különböző mintákat a nagy mennyiségű adathalmazokban. A legfejlettebb mély tanulási algoritmusok folyamatosan fejlődnek, és ezáltal egyre hatékonyabban képesek az árfolyam-ingadozások előrejelzésére a kereskedési stratégiák javítása érdekében.

A kockázatkezelés fontossága felértékelődik a magas volatilitású időszakban, mint pl. a 2008-as világválság, a Covid-19 vagy az orosz–ukrán háború miatti tőzsdei összeomlás. A jelenlegi globális és várhatóan tartósan magas inflációs környezet szintén rávilágít a minél hatékonyabb kockázatkezelési eszközök használatára. Napjainkban a legmodernebb kockázatkezelési technikák túlmutatnak az hagyományos diverzifikáción, és egyre inkább előtérbe kerülnek a mesterséges intelligencia alapú megoldások, amelyek egyre inkább a hétköznapijaink részévé válnak. A kereskedési stratégiák esetében az árfolyam-előrejelző modellek kulcsfontosságú árfolyamszinteket képesek meghatározni, amelyek felhasználhatók a fundamentális és a technikai elemzés során, illetve a kockázatkezelés és portfóliómenedzsment területén egyaránt. A kutatásunk legfőbb célja megvizsgálni, hogy a mesterséges intelligenciára alapozott árfolyam-előrejelzés vagy a statisztikai módszertanok közül melyik képes a legpontosabb előrejelzésre. Alapvető hipotézisként azt definiáltuk, hogy a legbonyolultabb és legösszetettebb metódus (LSTM) képes a legpontosabb előrejelzést adni magas volatilitású időszakban is, így ez a modell tekinthető leginkább „válságállóknak”. A tanulmány további újdonsága, hogy az előrejelzéseket három különböző időtávon hasonlítja össze.

2. Szakirodalmi áttekintés

A témával kapcsolatos szakirodalom alapján megállapítható, hogy számos modell áll rendelkezésre a hozam és a volatilitás előrejelzésére, melyeket a kutatók három fő csoportba sorolnak. Az elsőbe a hagyományos statisztikai (ARCH és ARIMA), a

másodikba a valamilyen mesterséges intelligencia alapú, míg a harmadikba az úgynevezett hibrid módszerek tartoznak (Kim & Won, 2018; Zolfaghari & Gholami, 2021). A hagyományos statisztikai modellekkel nem foglalkozunk a tanulmányban.

Mesterséges intelligencia alapúak az olyan tanulóalgoritmusok (Rather, 2021), mint az ANN-ek (Artificial Neural Networks), a DNN-ek (Deep Neural Networks), a GA (Genetic Algorithms), az SVM (Support Vector Machine), a FNN-ek (Fuzzy Neural Networks). A mesterséges intelligencia alapú modelleknek számos előnyük van a hagyományos statisztikai modellekkel szemben, mivel komplexitásukból fakadóan az előrejelző képességük jóval pontosabb. A tanulási képességük miatt a mesterséges intelligencia alapú modellek képesek felismerni az adatokban jelenlévő mintázásokat, így a nemlineáris mozgásokat. A részvényadatok nem állandó (non-stationary) és nemlineáris mozgásokat mutatnak, amelyeket a hagyományos statisztikai modellek nem képesek detektálni, ezért az AI-alapú módszertanok egy idő után átvették a vezető szerepet ezen a területen. *Ormoneit és Neuneier* (1996) kutatásukban a többrétegű percepciós és sűrűségbecslő neurális hálózatot alkalmazták a DAX index volatilitásának előrejelzésére az 1983. január és 1991. május közötti időszakban. A két modell összehasonlítása során arra a következtetésre jutottak, hogy a sűrűségbecslő neurális hálózat konkrét céleloszlás nélkül jobb teljesítményre volt képes a percepciós módszernél. *Gonzalez Miranda és Burgess* (1997) tanulmányukban az IBEX35 index opcióinak implikált volatilitását modellezte egy többrétegű percepciós neurális hálózattal az 1992 novembere és 1994 júniusa közötti időszakban. Tapasztalataik szerint a nemlineáris NN-ekkel történő előrejelzés általában olyan eredményeket produkál, amelyek dominálnak a hagyományos lineáris módszerek előrejelzéseivel szemben. Mindez annak köszönhető, hogy az NN figyelembe veszi a potenciálisan összetett nemlineáris kapcsolatokat, amelyeket a hagyományos lineáris modellek nem tudnak jól kezelni. *Hamid és Iqbal* (2004) az ANN módszertant alkalmazták az S&P 500 index határidős ügyletek volatilitásának előrejelzésére. Az empirikus elemzéseikből azt a következtetést vonták le, hogy az ANN-ek előrejelzései jobbak, mint az implikált volatilitásbecslési modellek. *Kieu Tran et al.* (2020) kutatásukban bizonyították, hogy a múltbeli információk időbeli hatását az ANN-ek nem veszik figyelembe az idősorok előrejelzéséhez, ezért az utóbbi időben egyre inkább a mély tanulási módszerek (DNN) kerülnek előtérbe. Ezek közül kiemelkedő csoportot képeznek az RNN-ek (Recurrent Neural Networks), amelyek előnye abban rejlik, hogy architektúrájukban rendelkezésre áll a visszacsatolás lehetősége is. A közelmúltban végzett kutatások (Lugt & Feelders, 2019; Hajiabotorabi et al., 2019), amelyek az ANN-ek és az RNN-ek előrejelző képességét hasonlítják össze, arra a következtetésre jutottak, hogy az RNN-ek jobb teljesítményre képesek a hagyományos neurális hálózatokkal szemben. Ezen módszerek közül is kiemelkedik a hosszú-rövid távú memória (LSTM) modell, amelyet a szekvenciális adathalmazok tekintetében széles körben alkalmaznak. A modellváltozat előnyös tulajdonsága, hogy nagyfokú alkalmazkodóképességet mutat az idősorok elemzésében (Petersen et al., 2019). *Nabipour et al.* (2020) 9 különböző gépi tanulási, valamint két mély tanulási algoritmus (Recurrent Neural Network, Long short-term memory) előrejelző képességét hasonlították össze a teheráni értéktőzsde pénzügyi, olajipari, nem fém jellegű ásványi és fém alapanyagokkal foglalkozó

vállalatok részvényadatain. Arra a következtetésre jutottak, hogy az RNN és az LSTM minden egyéb prediktív modell teljesítményét felülmúlta. *Long et al.* (2020) gépi tanulási (Random Forest, Adaptive Boosting), kétirányú mély tanulási (BiLSTM) és egyéb neurális hálós modelleket alkalmaztak, hogy megvizsgálják kínai részvényárfolyamok trendjeinek előrejelezhetőségét. A legnagyobb teljesítményre a BiLSTM volt képes, messze felülmúlva a többi előrejelzési metódust. *Hiransha et al.* (2018) az NSE és a NYSE részvényeinek árfolyam-alakulásával kapcsolatos előrejelzéseket készítettek. A következő modellekre alapozták a vizsgálatukat: többrétegű percepciós modell, RNN, LSTM és CNN (Convolutional Neural Network). Az empirikus elemzések alapján a CNN teljesített a legjobban. *Fischer és Krauss* (2018) az S&P500 index adatait vizsgálták 1992 és 2015 között. Az előrejelzésekhez a Random Forest, a logisztikus regresszió és az LSTM módszereket alkalmazták. A végső következtetésük az volt, hogy a hosszú–rövid távú memória algoritmusuk produkálta a legjobb eredményt. *Nelson et al.* (2017) a brazil tőzsde részvényadatain a többrétegű percepciós modelleket alkalmazták. Arra a következtetésre jutottak, hogy a pontosság tekintetében az LSTM volt a legmegfelelőbb. *Nikou et al.* (2019) az iShares MSCI UK tőzsdén kereskedett alap napi árfolyamadatait elemezték a 2015. január és 2018. június közötti időszakban. A prediktált értékek előállításához az ANN, Support Vector Machine (SVM), Random Forest és LSTM modelleket használták fel. A legjobb értékelést az LSTM szerezte meg, a második legpontosabbnak pedig az SVM módszer bizonyult. *Kaushik és Giri* (2020) az LSTM-et, a vektor autoregresszióval (VAR) és a SVM-mel hasonlította össze az árfolyamváltozások előrejelzésére. Az elemzésük rávilágított, hogy az előrejelzésben az LSTM modell felülmúlta az SVM és a VAR módszereket egyaránt. *Huang et al.* (2005) a NIKKEI 225 index heti trendjeinek előrejelezhetőségét vizsgálták a SVM-modell, a lineáris diszkriminancia, az Elman-féle neurális hálózati, valamint a kvadratus diszkriminancia módszerekkel. Eredmények alapján az SVM bizonyult a legjobb modellnek. Tíz adatbányászati módszert alkalmaztak *Ou et al.* (2009), a Hang Sheng index trendjeinek előrejelzésével kapcsolatos kutatást végeztek, melyhez a fa alapú klasszifikációt, a K-nearest neighbor-t (KNN), az SVM-t, a Bayesian-klasszifikációt és a neurális hálózati modellt használták. Az elemzés végeredményeként kiderült, hogy az SVM képes felülmúlni a többi prediktív metódust. *Ballings et al.* (2015) az AdaBoost, a Random Forest, a Kernel factory, a SVM, a KNN, a logisztikus regresszió és az ANN módszereket hasonlították össze európai vállalatok részvényárfolyam-adatainak felhasználásával. Egy évre előre próbálták megjósolni az árfolyampályákat. A végeredmény azt mutatta, hogy a Random Forest volt az, amely a legjobb teljesítményt produkálta. *Basak et al.* (2019) az XGBoost, a logisztikus regresszió, a SVM, az ANN és a Random Forest módszereket alkalmazták a részvénytőzsdén trendek előrejelzésére. Az eredmények azt mutatták, hogy a Random Forest teljesítménye kiemelkedett a többi közül. *Namini et al.* (2018) tanulmányukban az S&P500 és a Nikkei225 index adatait vizsgálták. A végső konklúzió szerint az LSTM fölénye érvényesült az ARIMA-val szemben. *Liu* (2019) a tanulmányában az S&P500 index és az Apple részvényárfolyam előrejelzésével foglalkozott. Arra a következtetésre jutott, hogy hosszabb előrejelzési időtávon az LSTM és a SVM jobb teljesítményre képes a GARCH modellnél. A fentiek alapján az LSTM meglehetősen jónak tekinthető, ami a prediktív teljesítményről illeti.

A különféle módszertanok hiányosságai hívták életre a harmadik kategóriát, amelybe az úgynevezett hibrid prediktív modellek tartoznak. Ezek kombinálják a hagyományos statisztikai, a mesterséges intelligencia alapú, valamint a technikai elemzéshez használt eszközöket a hatékonyabb előrejelzési eredmények érdekében (Reston et al., 2014). Azt a megállapítást tették, hogy a hibrid módszerek esetében a kiváló szekvenciális minta-tanulás jobb volatilitás-előrejelző teljesítménnyel párosul. Cao és szerzőtársai (2019) tanulmányukban egy új hibrid modellt fejlesztettek ki, ami a CEEMDAN (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise)-LSTM elnevezést kapta. Más kombinált, illetve hagyományos módszerekkel hasonlították össze, az S&P500 és HSI indexek adatain tesztelve. Az eredmények megerősítették, hogy a CEEMDAN-LSTM felülmúlta a CEEMD-SVM és a CEEMD-MLP, sőt még az egyénileg alkalmazott LSTM és SVM modelleket is. *Lin et al.* (2020) az USD–AUD árfolyam-ingadozásait vetítették előre a CEEMDAN-LSTM segítségével, valamint össze is hasonlították más modellekkel. Megerősítették, hogy ez a módszer nagyobb pontossággal rendelkezett az SVM, RNN, MRNN (Multilayer RNN), ARIMA és Bayes-modellekhez képest. *Jing et al.* (2021) a sanghaji értéktőzsde részvényeit vizsgálták, és arra a következtetésre jutottak, hogyha az LSTM modell bemeneteként valamilyen technikai elemző indikátor adatait használják, akkor ez a hibrid módszer jóval pontosabb becslést ad, mintha ezeket külön-külön alkalmaznák az előrejelzésekhez. *Banik et al.* (2022) is hasonló következtetésre jutottak. Ők szintén az LSTM modellt kombinálták a technikai indikátorokkal. Elemzésükhöz az indiai tőzsde részvényeit használták.

3. Anyag és módszer

Az elemzéseinkhez a CAC40, a DAX, a Dow Jones Industrial Average, az FTSE100, a Hang Seng, a NASDAQ composite, a Nikkei225 és az S&P500 index napi árfolyamadatait használtuk fel, amelyeket a Yahoo Finance portálról gyűjtöttük össze. Adataink majdnem 12 éves periódust ölelnek fel 2010. 01. 01. és 2022. 09. 16. között. Az időszak megválasztásánál figyelembe vettük, hogy mind a Covid-19, mind az orosz–ukrán háború tőzsdéken megjelenő hatásainak vizsgálatát legalább 10 évnyi rendelkezésre álló adat előzze meg, ezáltal próbáltunk optimális tanulási adatbázist definiálni a modelljeinkhez. Az általunk kiválasztott indexek mindegyike jól diverzifikált portfóliónak tekinthető, így az egyedi kockázatok nem vagy minimálisan befolyásolják a hozamok volatilitását. A felhasznált adatok leíró statisztikái az 1. táblázatban találhatóak. Kutatásunkban heti (5 nap), havi (21 nap) és féléves (125 nap) előrejelzési periódusokra bontva mutatjuk be az egyes modellek becsléseit.

A kutatásunk alapjául a lineáris regresszió, a döntési fa és az LSTM modellek szolgáltak. Az modellfejlesztések esetében egységesen az adatbázisok 80%–20% arányban történő particionálását választottuk (80% tanulási és 20% tesztelő részminták). Az elemzésekhez szükséges prediktív modellek megépítését Python programozási nyelven végeztük (3.8-as verzió), melyekhez a Scikit-learn és a TensorFlow könyvtárakat használtuk. A neurális hálózati modell esetében a Keras interfészt alkalmaztuk.

1. táblázat: Leíró statisztika

Megnevezés	N	Átlag	Medián	Szórás	Min	Max
CAC40	3251	4742,78	4630,99	991,16	2781,68	7376,37
DAX	3223	10457,24	10689,26	2853,54	5072,33	16271,75
DJIA	3199	20505,34	18050,17	7414,96	9686,48	36799,65
FTSE100	3209	6583,12	6686,60	707,65	4805,80	7877,50
Hang Seng	3131	24014,04	23484,30	3164,33	16250,27	33154,12
NASDAQ composite	3199	6381,37	5082,93	3695,87	2091,79	16057,44
Nikkei225	3109	17992,54	18723,52	6268,91	8160,01	30670,10
S&P500	3199	2368,78	2108,58	975,69	1022,58	4796,56

Forrás: saját szerkesztés

4. Eredmények

Az eredmények bemutatásához szorosan kapcsolódik, hogy meghatározzuk azokat az érékelési szempontokat, amelyek nélkülözhetetlenek az egyes modellek becslési pontosságának megállapítása miatt. A kalkulált eltérésmutatók lehetővé teszik, hogy szektorális, időbeli és módszertani összehasonlítást is végezhesünk. Így gyakorlatilag három különböző aspektusból is képesek vagyunk megvizsgálni a valós és becslt adatok közötti összefüggéseket. Elsőként az egyes modellek szektorokra és előrejelzési periódusokra vonatkozó összevetését végezzük el. A tanulmány zárásaként egy scoring-rendszer segítségével értékeljük a módszerek egymáshoz viszonyított teljesítményét.

4.1. A modellek értékelése

Az előrejelzésre használt modellek kiértékeléséhez és pontosságuk megállapításához a szakirodalomban a leggyakrabban a következő mérőszámokat szokták alkalmazni: az átlagos négyzetes hiba négyzetgyöke (RMSE), az átlagos abszolút hiba (MAE), az átlagos abszolút százalékos hiba (MAPE) (Nti et al. 2020).

- a) Átlagos négyzetes hiba négyzetgyöke (RMSE): ez a teljesítménymutató a tényleges és az előrejelzett értékek közötti eltérések (maradéktagok) értékét mutatja.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

ahol \hat{y}_i a modell által előállított becslt érték, y_i a tényleges érték és az n pedig a megfigyelések száma.

- b) Átlagos abszolút hiba (MAE): Ez a mutató az előrejelzések hibáinak átlagos nagyságát méri.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- c) Átlagos abszolút százalékos hiba (MAPE): Ez a mutató az előrejelzések hibáinak átlagos nagyságát méri, és százalékos formában mutatja meg az eltéréseket.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

Minél alacsonyabb a fenti mérőszámok értéke, annál megbízhatóbbak és pontosabbak lesznek az előrejelzések. Fontos megemlíteni, hogy az RMSE a nagyobb eltéréseket jobban bünteti a négyzetre emelés miatt, ezért ennél az értékelési mutatónál szélsőségesebb értékeket kaphatunk, mint a MAE esetében. Az előbbiek értékben, míg a MAPE százalékos formában értelmezendők (az eltérések az eredeti értékhez viszonyított arány százalékban kifejezve). Emiatt a MAPE különböző instrumentumok összehasonlításánál is használható, mert nem függ az árfolyam nominális nagyságától. Mivel tanulmányunkban a világ számos pontjáról származó indexeket, valamint két különböző negatív gazdasági esemény hatásait vizsgáltuk, ezért az összehasonlíthatóság miatt a MAPE-mutatót használtuk fel a modellek átfogó értékelésénél.

4.2. Döntési fa

Az egyik legegyszerűbb, de legsikeresebbnek mondható tanulási algoritmus. Ez egy döntéshozatalban használt grafikus felépítésű modell, ami vizuálisan egy fára hasonlít ágakkal, elágazásokkal (csomópontok) és levelekkel (részeredmények). A döntési fa bemeneti adatként egy attribútumokkal leírt objektumot vagy szituációt kap, ami aztán egy „döntést” ad vissza eredményül. Gyakorlatilag a döntési lehetőségeket ábrázolja, figyelembe véve a lehetséges következményeket, esélyeket, hasznosságot és erőforrásokat attól függően, hogy mire használják fel. A döntési fa egy olyan faszerkezetű gráf, amelyben minden egyes belső csúcs egy az értékére vonatkozó előrejelzést jelent. A csúcsból kiinduló élek az ellenőrzés egy-egy kimenetének feleltethetők meg. Ez teszi lehetővé, hogy fa formában lehessen ábrázolni a függvényeket. Induktív tanulási módszer, amely mindig csak egy eredményt ad vissza magyarázattal. Nagyon érzékeny a tanulóhalmazban jelen lévő hibákra, és a további tanuláshoz újabb döntési modellt kell felvázolni. Rendkívül egyszerű algoritmusról van szó, amely könnyen megérthető (Nabipour et al., 2020). Ami az előnye, az a hátránya is, mivel túlságosan primitív, ezért nem használható komplex összefüggések feltárásánál. Általában más, összetettebb szerkezetű modellekkel kombinálva alkalmazzák (Russell & Norvig, 2003).

A paraméterek tekintetében a döntési fa esetén a maximális mélységet 10 egy-
ségben határoztuk meg, mivel a szakirodalom is jellemzően ezt a számot tekinti

irányadónak (Nabipour et al., 2020; Sadorsky, 2022). A döntési fa előrejelzési eredményei a 2. táblázatban találhatók.

2. táblázat: A valós és becsült árfolyamok eltéréseinek MAPE-mutatója a döntési fa esetén a Covid-19 és az orosz–ukrán háború viszonylatában

Döntési fa	5 nap		21 nap		125 nap	
	Covid-19	Háború22	Covid-19	Háború22	Covid-19	Háború22
CAC40	0,0129	0,0011	0,0290	0,0118	0,0129	0,0126
DAX	0,0050	0,0371	0,0359	0,0173	0,0277	0,0221
DJIA	0,0034	0,0159	0,0771	0,0099	0,0191	0,0084
FTSE100	0,0544	0,0037	0,1028	0,0220	0,0469	0,0124
Hang Seng	0,0489	0,0051	0,0205	0,0413	0,0290	0,0458
NASDAQ composite	0,0360	0,0278	0,0108	0,0146	0,0068	0,0140
Nikkei225	0,0240	0,0082	0,0143	0,0107	0,0141	0,0107
S&P500	0,0145	0,0137	0,0373	0,0107	0,0168	0,0087
Átlagos MAPE	0,0249	0,0141	0,0410	0,0173	0,0217	0,0168

Forrás: saját szerkesztés

A 2. táblázat eredményei alapján elmondható, hogy időtávtól függetlenül a döntési fa pontosabb előrejelzést ad az orosz–ukrán háború alatt, mint a Covid-19 okozta tőzsdei összeomlásnál. Kiemelkedően rosszul teljesített az előrejelző modell az FTSE100-nál 5 és 21 napos időszakra vonatkozóan. A legpontosabb előrejelzést a francia tőzsdeindex (CAC40) esetén tapasztaltunk, a valós árfolyamhoz képest mindössze 0,11%-os az eltérés. Az 5 napos időtávot vizsgálva a nyolc indexből mindösszesen kettő (DAX és DJIA) esetében volt pontosabb a Covid-19 alatti előrejelzés. A 21 napos vizsgálatnál szintén két esetben volt pontosabb a koronavírus-időszaki becslés, azonban itt a Hang Seng és NASDAQ az érintett indexek. A 125 napos előrejelzés eredményei megegyeznek a 21 napossal. Az eredmények alapján a döntési fa nagyságrendekkel pontosabb előrejelzési adatokat szolgáltatott az 5 és 21 napos periódusban a másik két modellnél.

Lineáris regresszió

A lineáris regressziós modell azt feltételezi, hogy a kimeneti adatok eredménye a bemeneti információk valamilyen lineáris kombinációja lesz. A becslés során a mintavételi adatok pontfelhőjére igyekszünk egy egyenest illeszteni. A modell tartalmaz egy véletlenszerű hibátagot is, amely lehetővé teszi minden egyes megfigyelés

esetében, hogy eltérhessenek az elvárt lineáris kapcsolattól. A legáltalánosabb és a legegyszerűbb becslési módszer a legkisebb négyzetek módszere. A lineáris regresszió előrejelzési eredményei a 3. táblázatban találhatók.

3. táblázat: a valós és becsült árfolyamok eltéréseinek MAPE-mutatója a lineáris regresszió esetén a Covid-19 és az orosz–ukrán háború viszonylatában

Lineáris regresszió	5 nap		21 nap		125 nap	
	Covid-19	Háború22	Covid-19	Háború22	Covid-19	Háború22
CAC40	0,0215	0,0274	0,1974	0,0296	0,1852	0,0647
DAX	0,0477	0,0483	0,1982	0,0813	0,1217	0,0958
DJIA	0,0276	0,0692	0,1777	0,0559	0,1338	0,0940
FTSE100	0,0369	0,0532	0,2044	0,0384	0,1906	0,0378
Hang Seng	0,0494	0,0743	0,0806	0,1729	0,0697	0,1798
NASDAQ composite	0,0419	0,1414	0,1169	0,1538	0,0615	0,2364
Nikkei225	0,0512	0,0270	0,1200	0,0847	0,0881	0,0599
S&P500	0,0322	0,0699	0,1389	0,0643	0,0802	0,1341
Átlagos MAPE	0,0386	0,0638	0,1543	0,0851	0,1164	0,1128

Forrás: saját szerkesztés

A lineáris regresszió minden időtávon rosszabbul teljesített, mint a döntési fa, néhány esetben ötször-hatszor magasabb MAPE-értékeket láthatunk. Érdekeség, hogy a pontatlan becslés mellett a „tévedés iránya” is megváltozott 5 napos előrejelzésnél, csupán egyetlen (Nikkei225) esetben volt pontosabb az orosz–ukrán háború alatti előrejelzés. A hosszabb időszakra vonatkozó becslések esetében hasonló eredményeket látunk, mint a döntési fánál, azaz döntő többségében az orosz–ukrán háború alatt alacsonyabb a tévedési hiba.

4.3. LSTM

A neurális hálózatok rendszerébe tartozik a gráfolapú modell, amelyben rétegekbe rendezett mesterséges neuronok kommunikálnak egymással nem lineáris aktivációs függvényeken keresztül. Az LSTM-architektúra rendkívül összetett és komplex feladatok megoldását teszi lehetővé. A neurális hálózatokban az információ a bemenetről a rejtett rétegeken át a kimenetre áramlik. Ez lekorlátozza a hálózatot egyetlen állapot kezelésére. Az ismétlődő neurális hálózatokban (RNN), melynek egy altípusa az LSTM, az információáramlás egy cikluson keresztül történik, ami lehetővé teszi a hálózat számára, hogy emlékezhessen a korábbi outputokra. Ezért kiválóan alkalmas

szekvenciák és idősorok elemzésére. Az LSTM kapukat használ a bemeneti szekvencia elemei között, ezért képes elrejteni (elfelejteni) vagy felfedni (emlékezni) a korábbi információkra, és mindkét esetben eltérő súlyozással tudja ezeket kezelni. A kapuk által felfedett cellák összekapcsolódhatnak, feltárva az adatok közötti összefüggéseket. Ennek többek között a szélsőséges értékek kiszűrésében is nagy szerepe van. Egy tipikus LSTM-egység négy paraméterezett réteget ötvöz, amelyek kapcsolatba lépve egymással lehetővé teszik az információ áramlását (Roondiwala et. al., 2017).

A 4. táblázatban található az elemzésben használt LSTM modell hiperparaméterei.

4. táblázat: Az LSTM modell hiperparaméterei

Hiperparaméterek	Alkalmazott értékek
Rejtett rétegek száma	2
Az első és a második réteg neuronjainak száma	150, 150
Kiesési arány	0,3
Tanulási arány	0,001
Batch méret	60
Epoch méret	100
Aktiválási függvény	lineáris
Optimalizáló	Adam

Forrás: saját szerkesztés Nabipour et al. (2020) alapján

A nemzetközi szakirodalom alapján az LSTM modellek adják a legpontosabb becslést, az eredményeink alapján azonban a döntési fa esetében az átlagos MAPE-értékek valamennyi időtávon alacsonyabbak voltak, mint az LSTM esetében. Az LSTM esetében az 5 és 21 napos előrejelzésnél dominál az orosz-ukrán háború, azaz ebben az időszakban pontosabbak az előrejelzések. A 125 napos előrejelzésnél fele-fele arányban ad pontosabb becslést a modell a Covid-19-re és az orosz-ukrán háborúra, sőt az átlagos MAPE szinte teljesen megegyezik erre az időszakra vonatkozóan. Az eredmények alapján azt is megállapíthatjuk, hogy az LSTM a hosszabb távú előrejelzések esetében kisebb hibaszázalékkal dolgozik.

5. táblázat: A valós és becsült árfolyamok eltéréseinek MAPE-mutatója az LSTM esetén a Covid-19 és az orosz–ukrán háború viszonylatában

LSTM	5 nap		21 nap		125 nap	
	Covid-19	Háború22	Covid-19	Háború22	Covid-19	Háború22
CAC40	0,0373	0,0330	0,0740	0,0431	0,0327	0,0447
DAX	0,0838	0,0364	0,1013	0,0356	0,0353	0,0182
DJIA	0,0787	0,0198	0,0876	0,0193	0,0324	0,0188
FTSE100	0,0379	0,0122	0,0551	0,0171	0,0229	0,0109
Hang Seng	0,0085	0,0309	0,0238	0,0401	0,0176	0,0228
NASDAQ composite	0,0773	0,1034	0,0877	0,0852	0,0329	0,0784
Nikkei225	0,0508	0,0130	0,0692	0,0283	0,0245	0,0277
S&P500	0,0515	0,0219	0,0683	0,0207	0,0399	0,0202
Átlagos MAPE	0,0532	0,0338	0,0709	0,0362	0,0298	0,0302

Forrás: saját szerkesztés

Következtetések

Tanulmányunkban a világ meghatározó tőzsdeindexein teszteltük a döntési fa, a lineáris regresszió és az LSTM modellek árfolyam-előrejelző képességét teszteltük a Covid-19 és az orosz–ukrán háború kitörésétől számított 5, 21 és 125 napra vonatkozóan. A becslések pontosságának ellenőrzésére az átlagos abszolút százalékos hiba (MAPE) mutatót használtuk. A szakirodalom alapján a legtöbb esetben az LSTM modell bizonyult a legpontosabb becslési módszertannak (Nelson et al., 2017; Fischer & Krauss, 2018; Nikou, 2019; Liu, 2019; Nabipour et al., 2020). Az általunk végzett kutatás alapján a lineáris regresszió a legkevésbé alkalmas a vizsgálatba bevont tőzsdeindexek előrejelzésére. Az LSTM modell a második helyen végzett, és valamennyi időtávon a döntési fa rendelkezett a legpontosabb előrejelzéssel. További megállapításunk, hogy az orosz–ukrán háború alatti tőzsdemozgásokat pontosabban lehetett megbecsülni, mint a koronavírus miatti árfolyamváltozásokat.

A 2020-ban bekövetkezett rövid távú tőzsdei összeomlás jelentősen megnövelte a világ tőkepiacainak kockázatát (lásd *1. ábra*). A 2020-as koronavírus miatti tőzsdei összeomlás volt az első jelentős tőzsdei krach, az elmúlt tíz év tőzsdei mámore nem készítette fel a befektetőket a kockázatkezelésre. Ezt követően pedig az orosz–ukrán háború idézett elő olyan helyzetet, amivel a világ már régen szembesült. Tanulmányunkban igazoltuk, hogy a prediktív modellek a kiemelt volatilitású időszakban is megfelelően tudnak teljesíteni. Önmagában a diverzifikáció kevés, ha hirtelen 20–30%-os csökkenés

jelentkezik a tőkepiacon, erre azonnal kell reagálni, illetve fel lehet készülni, ha a megfelelő módszerrel próbáljuk a tőzsdei árfolyamokat előre jelezni. Az árfolyam-előrejelzés a fundamentális és technikai elemzések során is fontos szerepet kaphat, beépíthető az algoritmikus kereskedés döntési szempontjai közé, azonban akár önmagában is alkalmas lehet a kereskedés automatizálására. ■

Függelék

1. függelék: az elemzésekhez használt indexek log hozamaiból számolt korrelációs mátrix

	CAC40	DAX	DJIA	FTSE100	Hang Seng	NAS-DAQ Comp.	Nikkei225	S&P500
CAC40	1							
DAX	0,9337	1						
DJIA	0,6300	0,6173	1					
FTSE100	0,8696	0,8375	0,6137	1				
Hang Seng	0,3922	0,3791	0,2190	0,4139	1			
NASDAQ Comp.	0,5536	0,5531	0,8748	0,5175	0,2260	1		
Nikkei225	0,3066	0,2930	0,1897	0,3109	0,4887	0,1691	1	
S&P500	0,6196	0,6071	0,9689	0,5950	0,2234	0,9498	0,1832	1

Irodalom

1. BÁGER, G., PARRAGH, B. (2020). A koronavírus-válság, a fenntartható fejlődés és az ösztönző állam modellje. Pénzügyi Szemle, 65(2. különszám), 86–113. oldal https://doi.org/10.5121/csit.2016.60609doi.org/10.35551/PSZ_2021_k_1_2
2. BALLINGS, M., VAN DEN POEL, D., HESPEELS, N., GRYP, R. (2015). Evaluating multiple classifiers for stock price direction prediction. *Expert systems with Applications*, 42(20), 7046–7056. <https://doi.org/10.1016/j.eswa.2015.05.013>
3. BANIK, S., SHARMA, N., MANGLA, M., MOHANTY, S. N., SHITHARTH, S. (2022). LSTM based decision support system for swing trading in stock market. *Knowledge-Based Systems*, 239, 107994. <https://doi.org/10.1016/j.knosys.2021.107994>

4. BASAK, S., KAR, S., SAHA, S., KHAIDEM, L., DEY, S. R. (2019). Predicting the direction of stock market prices using tree-based classifiers. *The North American Journal of Economics and Finance*, 47, 552-567. <https://doi.org/10.1016/j.najef.2018.06.013>
5. CAO, J., LI, Z., LI, J. (2019). Financial time series forecasting model based on CE-EMDAN and LSTM. *Physica A: Statistical Mechanics and its Applications*, 519, pp. 127-139. <https://doi.org/10.1016/j.physa.2018.11.061>
6. DUARTE DUARTE, J. B., TALERO SARMIENTO, L. H., SIERRA JUÁREZ, K. J. (2017). Evaluation of the effect of investor psychology on an artificial stock market through its degree of efficiency. *Contaduría y Administración*, 62(4), 1361-1376. <https://doi.org/10.1016/j.cya.2017.06.014>
7. DUNNE, M. (2015). Stock market prediction. University College Cork.
8. FEJES, E., FUTÓ, I. (2021). Mesterséges intelligencia a közigazgatásban – az érdemi ügyintézés támogatása. *Pénzügyi Szemle*, 66 (1. különszám), 24-51. oldal https://doi.org/10.35551/PSZ_2021_k_1_2
9. FISCHER, T., KRAUSS, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669. <https://doi.org/10.1016/j.ejor.2017.11.054>
10. GONZALEZ MIRANDA, F., BURGESS, N. (1997). Modelling market volatilities: the neural network perspective. *The European Journal of Finance*, 3(2), pp. 137-157. <https://doi.org/10.1080/135184797337499>
11. HAJIABOTORABI, Z., KAZEMI, A., SAMAVATI, F. F., GHAINI, F. M. M. (2019). Improving DWT-RNN model via B-spline wavelet multiresolution to forecast a high-frequency time series. *Expert Systems with Applications*, 138, 112842. <https://doi.org/10.1016/j.eswa.2019.112842>
12. HAMID, S. A., IQBAL, Z. (2004). Using neural networks for forecasting volatility of S&P 500 Index futures prices. *Journal of Business Research*, 57(10), pp. 1116-1125. [https://doi.org/10.1016/S0148-2963\(03\)00043-2](https://doi.org/10.1016/S0148-2963(03)00043-2)
13. HIRANSHA, M., GOPALAKRISHNAN, E. A., MENON, V. K., SOMAN, K. P. (2018). NSE stock market prediction using deep-learning models. *Procedia computer science*, 132, pp. 1351-1362. <https://doi.org/10.1016/j.procs.2018.05.050>
14. HUANG, W., NAKAMORI, Y., WANG, S. Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers & operations research*, 32(10), pp. 2513-2522. <https://doi.org/10.1016/j.cor.2004.03.016>
15. JING, N., WU, Z., WANG, H. (2021). A hybrid model integrating deep learning with investor sentiment analysis for stock price prediction. *Expert Systems with Applications*, 178, 115019. <https://doi.org/10.1016/j.eswa.2021.115019>
16. KAUSHIK, M., GIRI, A. K. (2020). Forecasting Foreign Exchange Rate: A Multivariate Comparative Analysis between Traditional Econometric, Contemporary Machine Learning & Deep Learning Techniques. arXiv preprint arXiv:2002.10247. <https://doi.org/10.48550/arXiv.2002.10247>
17. KIM, H. Y., WON, C. H. (2018). Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models. *Expert Systems with Applications*, 103, 25-37. <https://doi.org/10.1016/j.eswa.2018.03.002>

18. LIN, H., SUN, Q., CHEN, S. Q. (2020). Reducing exchange rate risks in international trade: a hybrid forecasting approach of CEEMDAN and multilayer LSTM. *Sustainability*, 12(6), 2451. <https://doi.org/10.3390/sui2062451>
19. LIU, Y. (2019). Novel volatility forecasting using deep learning–long short term memory recurrent neural networks. *Expert Systems with Applications*, 132, pp. 99–109. <https://doi.org/10.1016/j.eswa.2019.04.038>
20. LONG, J., CHEN, Z., HE, W., WU, T., REN, J. (2020). An integrated framework of deep learning and knowledge graph for prediction of stock price trend: An application in Chinese stock exchange market. *Applied Soft Computing*, <https://doi.org/106205>. 10.1016/j.asoc.2020.106205
21. LUGT, B. J., FEELDERS, A. J. (2019). Conditional forecasting of water level time series with RNNs. In *International Workshop on Advanced Analysis and Learning on Temporal Data* (pp. 55–71). Springer, Cham. https://doi.org/10.1007/978-3-030-39098-3_5
22. MAQSOOD, H., MEHMOOD, I., MAQSOOD, M., YASIR, M., AFZAL, S., AADIL, F., MUHAMMAD, K. (2019). A local and global event sentiment based efficient stock exchange forecasting using deep learning. *International Journal of Information Management*. <https://doi.org/10.1016/j.ijinfomgt.2019.07.011>
23. NABIPOUR, M., NAYYERI, P., JABANI, H., SHAHAB, S., MOSAVI, A. (2020). Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis on the Tehran stock exchange. *IEEE Access*, 1–1. <https://doi.org/10.1109/access.2020.3015966>
24. NASSIRTOUSSI, A. K., AGHABOZORGI, S., WAH, T. Y., NGO, D. C. L. (2014). Text mining for market prediction: A systematic review. *Expert Systems with Applications*, 41(16), pp. 7653–7670. <https://doi.org/10.1016/j.eswa.2014.06.009>
25. NELSON, D. M., PEREIRA, A. C., DE OLIVEIRA, R. A. (2017). Stock market's price movement prediction with LSTM neural networks. In *2017 International joint conference on neural networks*, pp. 1419–1426. <https://doi.org/10.1109/IJCNN.2017.7966019>
26. NIKOU, M., MANSOURFAR, G., BAGHERZADEH, J. (2019). Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms. *Intelligent Systems in Accounting, Finance and Management*, 26(4), 164–174. <https://doi.org/10.1002/isaf.1459>
27. Novák, Z., Tatay, T. (2021). 'Captivated by Liquidity'–Theoretical Traps and Practical Mazes. *Public Finance Quarterly*, 66(1), 50–67. https://doi.org/10.35551/PFQ_2021_1_3
28. NTI, I. K., ADEKOYA, A. F., WEYORI, B. A. (2020). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, 53(4), pp. 3007–3057. <https://doi.org/10.1007/s10462-019-09754-z>
29. ORMONEIT, D., NEUNEIER, R. (1996). Experiments in predicting the German stock index DAX with density estimating neural networks. In *IEEE/IAFE 1996 Conference on Computational Intelligence for Financial Engineering (CIFER)* (pp. 66–71). IEEE. <https://doi.org/10.1109/CIFER.1996.501825>

30. OU, P., WANG, H. (2009). Prediction of stock market index movement by ten data mining techniques. *Modern Applied Science*, 3(12), 28–42.
31. PETERSEN, N. C., RODRIGUES, F., PEREIRA, F. C. (2019). Multi-output bus travel time prediction with convolutional LSTM neural network. *Expert Systems with Applications*, 120, pp. 426–435.
32. RATHER, A. M. (2021). LSTM-based Deep Learning Model for Stock Prediction and Predictive Optimization Model. *EURO Journal on Decision Processes*, 9, 100001. <https://doi.org/10.1016/j.ejdp.2021.100001>
33. RESTON FILHO, J. C., AFFONSO, C. D. M., DE OLIVEIRA, R. C. (2014). Energy price prediction multi-step ahead using hybrid model in the Brazilian market. *Electric power systems research*, 117, 115–122. <https://doi.org/10.1016/j.epsr.2014.08.006>
34. ROONDIWALA, M., PATEL, H. VARMA, S (2017). Predicting Stock Prices Using LSTM. *International Journal of Science and Research*, 6(4), pp. 1754–1756. <https://www.ijsr.net/archive/v6i4/ART20172755.pdf>
35. RUSSELL S. NORVIG P. (2003). Artificial Intelligence. A Modern Approach. New Jersey, Pearson Education, 4, 20.
36. SADORSKY, P. (2022). Forecasting solar stock prices using tree-based machine learning classification: How important are silver prices? *The North American Journal of Economics and Finance*, 101705. <https://doi.org/10.1016/j.najef.2022.101705>
37. THI KIEU TRAN, T., LEE, T., SHIN, J. Y., KIM, J. S., KAMRUZZAMAN, M. (2020). Deep learning-based maximum temperature forecasting assisted with meta-learning for hyperparameter optimization. *Atmosphere*, 11(5), 487. <https://doi.org/10.3390/atmos11050487>
38. TÖRÖK, L. (2020). A koronavírus miatti államadósság-növekedés az Európai Unió országában: A válságból való kilábalás utáni államadósság-ráták eltérő recessziós scenáriók mentén. *Pénzügyi Szemle*, 65(3), 350–363. https://doi.org/10.35551/PSZ_2020_3_2
39. ZOLFAGHARI, M., GHOLAMI, S. (2021). A hybrid approach of adaptive wavelet transform, long short-term memory and ARIMA-GARCH family models for the stock index prediction. *Expert Systems with Applications*, 182, 115149. <https://doi.org/10.1016/j.eswa.2021.115149>