

Makó Tamás¹ – Dr. Csongrádi Gyöngyi²

AI-alapú megközelítések a technikai elemzésben: Indikátorok és a gépi tanulás Vizsgálata

ÖSSZEFOGLALÁS

A kutatás során hagyományos technikai indikátorokat fogunk összevetni mesterséges intelligencia alapú modellekkel. Az indikátorokat több évtizede ismeri a befektetői közösség, azonban a technológiai fejlődésnek hála, a gépi tanulási módszerek egyre fontosabb szerephez jutnak. A kutatás fő célja meghatározni, hogy melyik megközelítéssel lehet nagyobb profitot elérni a részvényt piacon. Ehhez három indikátor és mesterséges intelligencia algoritmus teljesítményét vizsgáltuk meg öt darab amerikai részvény historikus adatain, 2017 január 1. és 2024 december 31. között, továbbá a gépi tanulási algoritmusok az 1996. január 1.-től 2017. december 31.-ig tartó időszak adataival lettek betanítva. Az eredményekből látható, hogy a Lineáris Regresszió generálta a legnagyobb profitot az Apple részvény esetében, azonban érdemes figyelembe venni az ezzel járó kockázatot és a nagyfokú volatilitást.

Kulcsszavak: részvény, technikai elemzés, indikátor, mesterséges intelligencia

JEL-kódok: C45, C50, G11, G17

BEVEZETÉS

A pénzügyi piacok kereskedésének története hosszú múltra tekint vissza, és már a kezdetektől fogva próbálták az emberek az árfolyammozgásokat megjósolni (When-Chuan, 2010). A kezdetleges megközelítések egyre fejlettebbé váltak, köszönhetően az elmúlt évtizedek információs forradalmának. A technikai fejlődés egyik jelentős eredménye a mesterséges intelligencia (AI) megjelenése, amely a kutatás központi témája. Az AI alapú rendszerek nagy mennyiségű adatot gyorsan és hatékonyan képesek feldolgozni, valamint olyan komplex mintázatokat felismerni, amelyeket az emberi szem és a hagyományos megközelítési módszerek nem tudnak azonosítani.

Fontos megjegyezni, hogy a technikai elemzés hagyományosan indikátorokra épül, azonban az utóbbi években a mesterséges intelligencia egyre nagyobb szerepet kapott a tőzsdei kereskedésben. (Bartram, 2020) Ez a tanulmány három AI-alapú modellt és három hagyományos technikai indikátor teljesítményét hasonlítja össze a részvényt piacon.

Technikai elemzés

A technikai elemzés kétségtelenül nagy népszerűségnek örvend. Elsősorban annak köszönhető, hogy ez a megközelítés nem foglalkozik az összes lehetséges gazdasági, politikai, vagy vállalati faktoral, ami befolyásolhatja egy részvény árfolyamát. Így az elemző sok időt és erőforrást tud megspórolni (Kirkpatrick, 2007). Lényegét tekintve a jövőbeli árfolyammozgások meghatározására használatos. Ehhez múltbéli adatokra, jellemzően az árra és a volumenre van szükség. Az elemzések során fontos szerepe van a matematikai képletek alapján kiszámítható indikátoroknak és a grafikonról leolvasható különféle alakzatoknak (Park, 2004).

Az elmélet azt mondja, hogy minden befolyásoló tényező automatikusan beépül a részvény árába. Ezzel el is érkeztünk a technikai elemzés első alapelvéhez, mely szerint a piac mindig diszkontál. A technikai elemzők szerint ez a legfontosabb mutató, amelyre szükségünk lehet az elemzések elvégzéséhez. Továbbá az árfolyammozgások vizsgálatával nagyon egyszerűen megállapíthatjuk a kereslet és kínálat alakulását: ha a kereslet meghaladja a kínálatot, akkor az árak emelkednek, hasonlóképpen, ha nagyobb a kínálat a piacon, mint a kereslet, akkor az árak csökkennek. Minden technikai elemző egyetért abban, hogy ezeket a mozgásokat valamilyen gazdasági tényező okozza, azonban ők maguk csak az ezt tükröző grafikonokkal foglalkoznak (Murphy, 1999).

A technikai elemzésnek viszonylag sok kritikusa van, akik a vizsgálat során felmerülő nagyfokú szubjektivitást kifogásolják (Scott, 2016). Burton Malkiel közgazdász professzor szerint sok logikai érv szól a technikai elemzés ellen. Úgy véli, hogy az események túl gyorsan történnek ahhoz, hogy a diagramok olvasásával le tudjuk őket követni. Mire vételi jelzést kapunk, már túl késő és ugyanez vonatkozik az eladási jelzésekre is. Továbbá felmerül a kérdés, ha mindenki ugyanazon séma alapján kereskedik, hogyan tudna az egyik fél a másik fölé kerekedni (Malkiel, 2007). Mindazonáltal nem hagyhatjuk figyelmen kívül azokat az empirikus tanulmányokat, melyek szerint a technikai elemzéssel lehetséges nyereséget termelni (Chopra, 1991; Brock, 1992).

Mesterséges intelligencia

A mesterséges intelligencia szerepe jelentősen nőtt minden iparágban. A pénzügyi szektorban alkalmazott AI modellek többsége gépi tanulási kategóriába sorolható, amelynek betanítása emberi felügyelet igényel és statisztikai technikákon alapulnak (Bartram, 2020). A befektetők az AI-nak köszönhetően megalapozottabb döntéseket képesek hozni, ami magasabb profitot termel, valamint segít csökkenti a kockázatot. A keres-

¹ PhD hallgató, Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola, Bergmann Könyvszakértő Kft., Budapest, BI elemző, makotamas1997@gmail.com,

² PhD, Egyetemi Docens, Budapest, Budapesti Gazdaságtudományi Egyetem, Üzleti Gazdaságtan Tanszék, csongradi.gyongyi@uni-bge.hu

kedési algoritmusok gépi tanulási technikákkal kiegészítve, ezek az algoritmusok képesek pénzügyi jelentések, záróárak, újságcikkek, közgazdasági mutatók stb. valós idejű elemzésére. Az AI-nak nem jelent problémát a bonyolult összefüggések felismerése, ezáltal sokkal pontosabb előrejelzéseket készítenek, valamint az emberi hibát minimalizálja. Mindazonáltal ügyelni kell a tanulási fázisban betáplált adatok minőségére ugyanis hibás, rossz minőségű adatokkal téves következtetésre jut az algoritmus (Chowdhury, 2019).

ANYAG ÉS MÓDSZERTAN

Indikátorok

A kutatásban használt indikátorok első csoportja az úgynevezett trendkövető indikátorok, melyeknek elsődleges feladata a trendek előrejelzése. Egyik nagy hátrányuk, hogy jellegükből adódóan késői jelzést adnak a vételi és eladási pozíciókhoz. A három leggyakoribb mozgóátlag: az egyszerű mozgóátlag (SMA), az exponenciális mozgóátlag (EMA) és a súlyozott mozgóátlag (WMA). Annak ellenére, hogy az SMA az egyik legegyszerűbb indikátor, elég nagy népszerűségnek örvend a kereskedők körében (Tóth, 2023). Számítása nagyon egyszerű, ahogy az (1) képlet alapján látható a vizsgált időszak napi árfolyamait összeadjuk majd elosztjuk az eltelt napok (n) számával.

$$SMA = \frac{\sum_1^n \text{Záró ár}}{n} \quad (1)$$

A gyakorlatban úgy működik, hogyha az árfolyam a mozgóátlagot alulról metszi akkor vételi jelzést kapunk, ha felülről, akkor pedig eladást. Minél hosszabb időszakra alkalmazzuk, annál pontosabb jelzéseket kapunk (Tóth, 2023).

A projekt során alkalmazott másik indikátor az úgynevezett MACD. Ez egy oszcillátor típusú mutató, vagyis egy központi vonal által fluktuál. Három mozgóátlag divergáló és konvergáló mozgását adja vissza, azonban a grafikonon csak két vonalat ábrázolunk ezek közül. Az egyik vonal az MACD vonal, melynek meghatározása általában egy 26 napos, valamint egy 12 napos exponenciálisan súlyozott mozgóátlag különbsége. A másik az úgynevezett szignál vonal, ami nem más, mint az MACD vonal 9 napos exponenciálisan súlyozott mozgóátlaga. Működésének a lényege a következő: ha az MACD a szignálvonal alá esik akkor azt egy eladási jelzésként kell értelmezni, ha pedig az MACD alulról áttöri a szignál vonalat, akkor az belépési pontot jelent (Kecskeméti, 2006).

Végül a harmadik alkalmazott indikátor a Momentum. Elsősorban az árfolyam változásának a mértékét mutatja egy meghatározott időintervallum alatt. Lényege, hogy a mai árat hasonlítjuk egy korábbi árhoz (Achelis, 2013). Az indikátor kalkulációját az alábbi (2) képlet alapján lehet elvégezni.

$$\text{Momentum} = (\text{Záróár} - N \text{ napla ezelőtti Záróár})$$

$$\text{Momentum mértéke \%} = \frac{\text{Záróár} - N \text{ nappal ezelőtti Záróár}}{N \text{ nappal ezelőtti Záróár}} \quad (2)$$

Számítása nagyon egyszerű, a mai átlagárból kivonjuk a mozgóátlagot (a projektben ez 14 nap), és ezt különbséget osztani kell a választott mozgóátlaggal, végül meg kell szorozni 100-al. A grafikonon fel kell venni egy központi viszonyítási pontot melynek az értéke 100. A 10-15%-os elmozdulás egy esetleges

trendváltozás bekövetkeztét jelezheti. A görbe mélypontját vételi jelként kell értelmezni, ebből kifolyólag a csúcsot pedig eladási pontként (Kecskeméti, 2006).

Lineáris Regresszió

A lineáris regresszió egy alapvető és gyakran használt felügyelt gépi tanulási algoritmus. Lényege, hogy x bemeneti változó alapján predikciót készítsen a kimeneti, más szóval y célváltozóra. A bemeneti változó kapcsolatban áll a kimeneti változóval, tehát ha az x értéke módosul, annak hatása lesz az y változóra. Regressziós modell használata során a célunk, hogy megtaláljuk azt az egyenest, amelyre legjobban illeszkednek a kimeneti változók (Bruce, 2020). Alább a lineáris regresszió képlete alább látható.

$$Y = b_0 + b_1 X$$

-
- b_0 = konstans, az a pont ahol
- b_1 = a regressziós vonal meredeksége
- X = bemeneti változó (független változó)
- Y = kimeneti változó (függő változó)
-

Az adatok nagyrésze általában nem esik rá a regressziós vonalra, így hibák keletkeznek (e_i). Ahhoz, hogy megkapjuk a legjobban illeszkedő egyenest, meg kell találnunk azokat a b_0 és b_1 értékeket, melyeknél a hibák a legkisebbek. Más szóval minimalizálnunk kell a modell illeszkedését mutató reziduális négyzetösszeget. Ennek kiszámításához a legkisebb négyzetek módszerét (OLS) használjuk (Hunyadi, 2019). A kalkuláció során használt képletek és összefüggések:

$$g = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - \hat{b}_0 - \hat{b}_1 x_i)^2 \quad (4)$$

$$\hat{b}_1 = \frac{\sum d_x d_y}{\sum d_x^2} \quad (5)$$

$$\hat{b}_0 = \bar{y} - \hat{b}_1 \bar{x} \quad (6)$$

Amikor értékelni akarjuk a modellünk pontosságát, az egyik legfontosabb tényező a maradványtagok négyzetösszege. Ezt az SSE (Sum of Squares of the Errors) mutatóval szoktuk kifejezni. Minél kisebb az SSE értéke, annál jobban illeszkednek a kimeneti változók a regressziós egyenesre (Hunyadi, 2019).

$$SSE = \sum_{i=1}^n e_i^2 \quad (7)$$

Ridge Regresszió

A lineáris regressziót különféle módszerekkel optimalizálhatjuk. Az egyik ilyen megoldás az L2 regularizáció alkalmazása, amit Ridge Regresszióknak nevezünk. Ez a megközelítés csökkenti azoknak az együtthatóknak az értékét, amelyek a lineáris modellt eltérítik, ezáltal elősegíti a regresszió általánosítási képességének a növekedését (Mueller, 2024). Alább látható a módosított OLS metódus, amelyet L2 regularizációval kibővítettünk.

$$\sum_{i=1}^n (y_i - \hat{b}_0 - \hat{b}_1 x_i)^2 + \lambda \sum_{i=1}^n b_i^2 = SSE + \lambda \sum_{i=1}^n b_i^2 \quad (8)$$


– λ = regularizációs paraméter

A λ paraméterrel tudjuk szabályozni a büntetési tag mértékét, amelyet gyakran hívnak zsugorítási tényezőnek is. Amennyiben $\lambda = 0$, a büntetési tagnak nincs jelentősége. Fontos kiemelni, hogy a büntetési tényező csakis a $b_1 \dots b_n$ paraméterekre vonatkozik, tehát a b_0 változatlan marad (James, 2013)

Long Short Term Memory (LSTM)

Az LSTM vagy másnéven Hosszú-Rövid Távú Memória a mély, visszatérő neurális hálózatok (RNN) egyik csoportja. Lényeges tulajdonsága, hogy képes legyen hosszútávon különböző adatok tárolására. Miután ezek az adatok felhasználásra kerültek, az algoritmus szelektálja, másszóval „elfelejti” őket. Fontos hangsúlyozni, hogy ez a folyamat emberi beavatkozás nélkül történik, vagyis a hálózat saját maga tanulja meg ezen döntések meghozatalát (Goodfellow, 2016).

Az LSTM egy összetett rendszer, amely különféle memória blokkokból épül fel. Ezek a memória blokkok három egységből állnak: bemeneti kapu, kimeneti kapu, felejtő kapu. A hosszú távú memóriát cellaállapotnak (cell state) is nevezik. A felejtőkapu, $f(t)$ meghatározza, hogy a cellaállapotból mely adatokat kell szelektálni. A bemeneti kapu, $i(t)$ azt szabályozza, hogy mely információkat kell hozzáadni a hosszú távú állapothoz, míg a kimeneti kapu, $o(t)$, azért felel, hogy az aktuális időpillanatban mely adatokat kell előállítani. Az LSTM cella felépítését az 1. ábra mutatja be, ahol $x(t)$ az aktuális input, $C(t)$ és $C(t-1)$ pedig a memóriacella aktuális és előző állapotát jelölik. A $h(t)$ és $h(t-1)$ az aktuális és előző rejtett állapotokat mutatják (Diniz, 2024).



1. ábra: LSTM cella váza.

Forrás: (Diniz, 2024)

Mintavétel

A vizsgálat során öt részvény historikus adatait használtuk fel. Ezeket az adatokat a Yahoo Finance API-n keresztül értük el. Emiatt nem szükséges a fájlokat letölteni majd később beimportálni, hanem közvetlenül a kódszerkesztőbe érkeznek az adatok. A felhasznált részvények rövid összefoglalóját az 1. táblázat tartalmazza.

1. táblázat: A vizsgált részvények adatai

Részvény rövidítése	Cégnév	Szektor
AAPL	Apple Inc.	IT
IBM	International Business Machines Inc.	IT
MSFT	Microsoft Corporation	IT
F	Ford Motor Company	Járműipar
BA	The Boeing Company	Repülőgépipar

Forrás: Saját szerkesztés

Az elemzést Python programozási nyelvvel hajtottuk végre. A választást az indokolta, hogy a Python olyan magas színvonalú könyvtárakkal rendelkezik, mint a Pandas, NumPy, Matplotlib, Scikit-learn, Pytorch, amelyekkel könnyen kezelhetők, elemezhetők és vizualizálhatók nagyobb mennyiségű részvényadatok. Kódszerkesztőként a Google Colab-ot használtuk, amely biztosítja a számítási erőforrásokat (például GPU és TPU hozzáférést), így nagyobb méretű adathalmazok is kezelhetők anélkül, hogy a saját gép erőforrásait megterhelné. A vizsgálat időtartama 2017 január 1.-től 2024 január 1.-ig tart (a gépi tanulási algoritmusok ezenfelül a 1996. január 1.-től 2017. december 31.-ig tartó időszak adataival lettek betanítva). A kutatásban három indikátor (SMA, MACD, Momentum), valamint három mesterséges intelligencia algoritmus (Lineáris Regresszió, Ridge Regresszió, LSTM) backtestjét hajtottuk végre. A backtest során arra vagyunk kíváncsiak, hogy ezek a megközelítések hogyan teljesítettek volna a vizsgált időtartamban.

Mindegyik módszer backtestjénél egy virtuális, \$10000 kezdőegyenleget helyeztünk el. A kutatás fő kérdése, hogy a felsorolt stratégiák közül melyikkel értük volna el a legnagyobb profitot, tehát a záróegyenleg maximalizálása volt a cél. Ezen túlmenően arra is kíváncsiak voltunk, hogy az egyes stratégiáknak mekkora volt az átlagos hozama, és ez milyen kockázattal, vagyis szórással párosult.

KÖVETKEZTETÉS

A backtest elvégzésével felállítható az a lista, amely rangsorolja ezeket stratégiákat a záróegyenlegek maximalizálása szempontjából. Az 2. táblázat tartalmazza a tíz legnagyobb hozamot elérő stratégiát a vizsgált részvényeknél.


2. táblázat: A legjobban teljesítő stratégiák

Helyezés	Stratégia	Záróegyenleg (USD)	Részvény
1.	Lineáris Regresszió	\$67 538.61	AAPL
2.	Ridge Regresszió	\$57 828.53	MSFT
3.	Momentum	\$53 974.05	AAPL
4.	MACD	\$51 184.07	AAPL
5.	Ridge Regresszió	\$46 993.55	AAPL
6.	SMA	\$37 684.28	MSFT
7.	Lineáris Regresszió	\$35 477.41	MSFT
8.	MACD	\$27 268.99	BA
9.	Momentum	\$25 219.68	F
10.	SMA	\$24 629.71	AAPL

Forrás: Saját szerkesztés

A táblázatból látható, hogy a top tízbe négy darab AI algoritmus is bekerült, ezen túlmenően a két legsikeresebb mind gépi tanulási modell. A kutatási kérdésre a válasz tehát: A Lineáris Regressziós modellel, az Apple részvénynél értük el a legnagyobb profitot. Az LSTM algoritmus gyenge teljesítménye ebben a vizsgálatban nagy meglepetés, mivel mind közül ez a legösszetettebb. Fontos azonban hangsúlyozni, hogy rengeteg olyan tényező van az LSTM modell esetében, amely jelentősen befolyásolhatja annak teljesítményét. Többek között megemlíthető a modell tanulási sebessége, epoch-ok száma, vagy akár a seed változó értéke (már amennyiben kívánjuk rögzíteni a modellt, ennek hiányában minden futtatásnál új eredményt kapunk). Mindezek figyelembevételével az LSTM algoritmusban továbbra is nagy potenciál rejlik, azonban ennek az algoritmusnak a mélyebb tanulmányozása meghaladja a vizsgálat kereteit.

Az 2. ábrán látható a stratégiák átlagos hozamai és szórásai. A vizsgálat során kiszámoltuk ezeket a mutatókat a Buy&Hold módszerre is, vagyis amikor az adott részvényt megvásároljuk és tartjuk az időszak végéig.



2. ábra: Stratégiák hozamai és szórásai.

Forrás: Saját szerkesztés

A későbbi elemzésekben érdemes lehet a különböző költségeket belekalkulálni a profitba, ezáltal a záróegyenleg realisztikusabb lenne. Ehhez jó ötlet az egyes stratégiáknál a kereskedések számának meghatározása, mivel több tranzakció nagyobb költséggel jár. Továbbá az indikátorok különböző kombinációinak alkalmazása, valamint ahogy azt már korábban említettük, az LSTM algoritmus hatékonyabb optimalizálásával és mélyebb megértésével szintén új eredményeket lehetne elérni.

IRODALMI FELDOLGOZÁS

- ACHELIS, S. B. (2013): Technical Analysis from A to Z, 2nd Edition. McGraw Hill Inc. ISBN 978-0071826297
- BARTRAM, S. M. – BRANKE, J. – MOTAHARI, M. (2020): Artificial Intelligence in asset management. CFA Institute Research Foundation. ISBN: 978-1-952927-02-7
- BROCK, W. – LAKONISHOK, J. – LEBARON, B. (1992): Simple Technical Trading Rules and the Stochastic Properties of Stock Returns. The Journal of Finance, Vol. 47, No. 5. (Dec., 1992), pp. 1731-1764.

- BRUCE, P. – BRUCE, A. – GEDECK, A. (2020): Practical Statistics for Data Scientists 50+ Essential Concepts Using R and Python, 2nd Edition. O'Reilly Media, Inc., 1005 Gravenstein Highway North, Sebastopol, CA 95472. ISBN: 978-1-492-07294-2
- CHOPRA, N. – LAKONISHOK, J. – RITTER, J. R. (1991): Measuring abnormal performance: Do stocks overreact? Journal of Financial Economics 31 (1992) 235-268. North Holland
- CHOWDHURY, E. K. (2019): Use of Artificial Intelligence in Stock Trading. Published in: Portfolio, Vol. 1, No. 22 (30 April 2019): pp. 17-28.
- DINIZ, A. P. M. – CIARELLI, P. M. – SALLES, E. O. T. – COCO, K. F. (2024): Use of deep neural networks for clogging detection in the Submerged Entry Nozzle of the continuous casting. Expert Systems With Applications 238 (2024) 121963. <https://doi.org/10.1016/j.eswa.2023.121963>
- GOODFELLOW, I. – BENGIO, Y. – COURVILLE, A. (2016): Deep learning. Cambridge, Massachusetts: MIT Press. ISBN: 978-0262035613
- HUNYADI, L. – VITA, L. (2019): Statisztika II. Akadémiai Kiadó. ISBN: 978 963 454 222 3
- JAMES, G. – WITTEN, D. – HASTIE, T. – TIBSHIRANI, R. (2013): An Introduction to Statistical Learning. Springer Science+Business Media New York 2013. ISBN: 978-1-4614-7137-0
- KECSKEMÉTI, I. (2006): Tőzsdei befektetések a technikai elemzés segítségével. Kecskeméti István és Tsa Bt., Budapest. ISBN: 2050000004247
- KIRKPATRICK, C. D. – DAHLQUIST, J. R. (2007): Technical Analysis: The complete resource for financial market technicians. Pearson Education, Inc., New Jersey 07458. ISBN 0-13-153113-1
- MALKIEL, B. G. (2007): A Random Walk Down Wall Street The Time-Tested Strategy for Successful Investing, 9th Edition. W. W. Norton & Company, 500 Fifth Avenue, New York, N.Y. 10110. ISBN: 978-0-393-33033-5
- MUELLER, J. P. – MASSARON, L. (2024): Adatelemzés Pythonnal. Panem Könyvek, Taramix Kft., Budapest, 2024. ISBN: 978-615-5186-99-8
- MURPHY, J. J. (1999): Technical Analysis Financial Markets: A comprehensive guide to trading methods and applications. New York Institute of Finance, Paramus. ISBN 0-7352-0066-1
- PARK, C. – IRWIN S. H. – (2004): The Profitability of Technical Analysis: A Review. AgMAS Project Research Report
- SCOTT, G. – CARR, M. – CREMONIE, M. (2016): Technical Analysis: Modern Perspectives. CFA Institute Research Foundation. ISBN 978-1-944960-11-7
- TÓTH, B. L. – FAZEKAS, B. (2023): A mozgóátlagokra épülő kereskedési stratégiák sikerességének vizsgálata a nagy kapitalizációjú vállalatok példáján keresztül. Economica XIV. évf., 3-4. sz. ISSN 2560-2322
- WHEN-CHUAN, A. – HASANHODZIC, J. (2010): The Evolution of Technical Analysis: Financial Prediction from Babylonian Tablets to Bloomberg Terminals. John Wiley & Sons, Inc., Hoboken, New Jersey. ISBN 978-1-57660-349-9