

Mutatószám-halmaz kialakítása autóiipari vállalatok tőzsdei előrejelzéséhez

Development of an Indicator Set for Stock Market Forecasting of Automotive Companies

SZABÓ TAMÁS BSc hallgató, Budapesti Gazdaságtudományi Egyetem
Pénzügy és Számvitel Kar, email: szabó.tamás.63@unibge.hu

DR. GÁSPÁR SÁNDOR egyetemi adjunktus, Magyar Agrár- és Élettudományi
Egyetem Vidék fejlesztés és Fenntartható Gazdaság Intézet, email:
sandor.gaspar1994@gmail.com

DR. HEGEDŰS SZILÁRD egyetemi docens tudományos kari vezető
Budapesti Gazdaságtudományi Egyetem PSZK Kontrolling Tanszék, email:
hegedus.szilard@uni-bge.hu

DOI: <https://doi.org/10.65513/MaMi.2026.1.52>

Abstract

Reliable prediction of automotive companies' stock prices is crucial for investment decisions and financial analysis. In our study, we investigated the applicability of the Adaptive Neuro-Fuzzy Inference System (ANFIS) for predicting stock prices based on fundamental financial indicators. The primary objective was to examine how the prediction accuracy of the ANFIS model changes when individually removing one of the four validated fundamental indicators Return on Assets (ROA), Return on Equity (ROE), Earnings per Share (EPS), and Profit Margin (PM) thus identifying the relative importance of each indicator. For our analysis, we utilized financial data from the ORBIS database covering 103 publicly listed automotive companies for the period 2019–2023. A Sugeno-type ANFIS model was developed and evaluated using the root mean square error (RMSE) and normalized root mean square error (nRMSE). Our results indicate that removing the ROA indicator caused the most significant deterioration in model performance, whereas the removal of PM resulted in the smallest decrease. Based on these findings, the fundamental indicators ranked in terms of predictive importance were ROA, ROE, EPS, and PM. Our research strongly supports the effectiveness of ANFIS models in fundamental financial analysis and stock price forecasting, highlighting the differential significance of individual financial indicators in the valuation of automotive companies' stocks.

Keywords: ANFIS; Neuro-Fuzzy; Fundamental Analysis; Automotive Industry; Stock Price; Financial Forecasting

JEL codes: C45; C53; G11; G17

Absztrakt

Az autóiipari vállalatok részvényárfolyamának megbízható előrejelzése kulcsfontosságú a befektetői döntéshozatalban és a pénzügyi elemzésben. Kutatásunkban az adaptív neuro-fuzzy inferencia rendszer (ANFIS) alkalmazhatóságát vizsgáltuk fundamentális pénzügyi mutatók alapján történő részvényárfolyam-előrejelzésben. A vizsgálat elsődleges célja az volt, hogy felmérjük, milyen mértékben változik az ANFIS modell előrejelzési teljesítménye, ha a szakirodalom által validált négy fundamentális mutatót (eszközarányos nyereség (ROA), saját tőke arányos nyereség (ROE), egy részvényre jutó eredmény (EPS) és árbevétel-arányos nyereség (Profit Margin – PM)) egyenként eltávolítjuk és ezzel azonosítjuk a mutatók relatív fontosságát. Módszertanunk során az ORBIS pénzügyi adatbázisból származó, 2019 és 2023 közötti 103 tőzsdén jegyzett autóiipari vállalat adatát használtuk fel. Az adatok elemzésére Sugeno-típusú ANFIS modellt alakítottunk ki, amelynek teljesítményét a gyök négyzetes átlagos hiba (RMSE) és annak normalizált értéke (nRMSE) segítségével értékeltük. Az eredmények szerint a ROA eltávolítása okozta a legjelentősebb, míg a PM eltávolítása a legkisebb teljesítménycsökkenést. Következtetéseink alapján a fundamentális mutatók fontossági sorrendje: ROA, ROE, EPS és PM. Kutatásunk egyértelműen alátámasztja, hogy az ANFIS módszer hatékony eszköz a fundamentális pénzügyi elemzés és a részvényárfolyam-előrejelzés támogatásában, továbbá kiemeli az egyes mutatók szerepének eltérő jelentőségét az autóiipari szektor részvényértékelésében.

Kulcsszavak: ANFIS; Neuro-Fuzzy; Fundamentális Elemzés; Autóiipar; Részvényárfolyam; Pénzügyi előrejelzés

JEL-kódok: C45; C53; G11; G17

1. Bevezetés

A globális pénzügyi piacokon az autóiipari szektor vállalatainak részvényárfolyamai az utóbbi évtizedben rendkívül érzékenyvé váltak a gazdasági változásokra, technológiai fejlődésekre, valamint az egyre szigorúbb szabályozási környezetre. Ezzel párhuzamosan a pénzügyi előrejelzések pontossága és megbízhatósága a befektetői döntéshozatal alapvető követelményeivé váltak. Az utóbbi évek szakirodalmában kiemelt szerepet kapott a fundamentális pénzügyi elemzés, amely a vállalatok pénzügyi teljesítményét különböző mutatószámokkal értékeli és ennek alapján próbál előrejelzéseket tenni a részvényárfolyamok várható alakulásáról (Prohaska et al., 2011; Sampurnaningsih & Hanifah, 2017). Az előrejelzési módszerek között az adaptív neuro-fuzzy inferencia rendszer (ANFIS) az utóbbi időszakban jelentős figyelmet kapott, mivel ez a technika képes hatékonyan kezelni a pénzügyi piacokra jellemző komplex, nemlineáris összefüggéseket és bizonytalanságokat (Mosavi et al., 2021). Az ANFIS modellek sikeresen ötvözik a neurális hálózatok adaptív tanulási mechanizmusait és a fuzzy logika intuitív, szabályalapú érvelését, ezáltal robusztusabb és megbízhatóbb előrejelzési eredményeket képesek produkálni, mint a hagyományos lineáris statisztikai modellek (Boyacioglu & Avcı, 2010). Korábbi kutatásunkban, amelynek továbbfejlesztésére vállalkoztunk jelen tanulmányunkkal, az ANFIS modell alkalmazásával négy alapvető pénzügyi mutató (ROA, ROE, EPS, PM) együttes szerepét

vizsgáltuk az autóiipari vállalatok részvényárfolyamának előrejelzésében. Bár az eredeti, négy mutató modell igen magas pontosságot és megbízhatóságot mutatott, felmerült a kérdés, hogy ezek a mutatók önállóan milyen relatív prediktív erővel rendelkeznek. Ezért jelen kutatásunkban arra helyeztük a hangsúlyt, hogy részletesen feltárjuk a fent említett fundamentális mutatók egyedi jelentőségét az autóiipari vállalatok részvényárfolyam-előrejelzésében. Ennek érdekében egyesével távolítottuk el a mutatókat, majd értékeltük a keletkező hárommutatós modellek teljesítményének változásait az eredeti négy mutatós modellhez viszonyítva. Ezáltal világosan feltártuk, hogy az egyes mutatók eltávolítása milyen mértékben befolyásolja a modell prediktív képességét, továbbá azt is vizsgáltuk, hogy a fundamentális mutatók közül melyik mutató bizonyul a legerősebb prediktív tényezőnek az autóiipari vállalatok részvényárfolyamainak előrejelzésében. Tanulmányunk eredményei révén átfogó és pontos képet nyújtunk az ANFIS modellek alkalmazhatóságáról és megbízhatóságáról az autóiipari szektor részvényárfolyam-előrejelzési feladataiban. A kutatásunk eredményei továbbá jelentős gyakorlati és tudományos relevanciával bírhatnak a befektetői döntéshozatalban, pénzügyi elemzésben, valamint további kutatások kiindulópontjául szolgálhatnak a neuro-fuzzy alapú modellezési technikák és fundamentális pénzügyi mutatók alkalmazásában.

2. Irodalmi áttekintés

2.1 A tőzsde intézménye és történeti fejlődése

A tőzsde intézményes keretek között, előre meghatározott szabályok mentén, koncentrált piacot teremt az áruk és az értékpapírok adásvétele számára. E piac mellett információs központként is funkcionál: az ott kialakuló árfolyamok nem pusztán a tőzsdei ügyletekben bírnak kötelező erővel, hanem referenciaként szolgálnak a tőzsdén kívüli tranzakciókhoz is (Rubóczky, 1999). Működési logikája alapján megkülönböztetünk árutőzsdéket és értéktőzsdéket. A tőzsdei kereskedelem gyökerei a 11–12. századig vezethetők vissza: ekkor Franciaországban már akadtak olyan közvetítők, akik a bankok megbízásából agrárközösségek adósságait kezelték, adósságpapírokkal kereskedve őket tekinthetjük a legkorábbi brókereknek. Az árutőzsdék prototípusai a 14. századi Észak-Itáliában jelentek meg, míg az első valódi értéktőzsdét Amszterdamban alapították. A részvény- és értékpapír-piac születését 1595-re datálja a szakirodalom, amikor a Kelet-Indiai Társaság részvénykibocsátással jött létre; értékpapírjait kezdetben az utcán, majd 1602-től az első hivatalos részvénytőzsdén, az amszterdami börzén lehetett adni-venni (Gál, 2016). A tőzsde zárt intézményként alakult ki: a kereskedésben csak tagok vehettek részt, szigorú protokoll szerint, szakosodott közvetítők révén. E zártságot szimbolizálta maga a tőzsde-épület is, amelyhez a külső befektetők csupán brókereiken keresztül kapcsolódhattak. A Londoni Értéktőzsde 1801-es megalakulása ezt a közvetítői modellt erősítette: a befektetők személyes utasításokat adtak brókereknek, miközben a távolsági kommunikáció lassúsága jelentős információs hátrányt okozott a vidékről vagy külföldről kereskedőknek (Michie, 1997). Az Egyesült Államokban az 1920-as évek elejétől látványos fellendülés bontakozott ki, amelyet a részvényárfolyamok tartós emelkedése kísért. A gazdasági és társadalmi optimizmust jól illusztrálja, hogy 1928 decemberében az amerikai elnök „példátlanul kedvező” kilátásokról beszélt, míg Irving Fisher közgazdász a tőzsdekrach előestéjén a részvényárakat „tartósan magas szinten” levőnek minősítette. A rövid életű eufóriát 1929. október 29-én a New York-i tőzsde összeomlása zárta le, globális válságot indítva útjára (Muraközy, 2016). A technológiai fejlődés radikálisan átalakította a kereskedelmet. A NASDAQ 1971-es létrehozásával megjelent az első teljes mértékben elektronikus tőzsde, amely az elektronikus árjegyzés után fokozatosan az üzletkötéseket is digitális térbe helyezte. Az 1980-as években az úgynevezett program trading legalább 15 értékpapír egyidejű, minimum 1 millió USD értékű ügylete a forgalom

jelentős hányadát adta, az 1990-es években pedig az internet terjedése nyitott utat az online kereskedés tömeges elterjedésének (Varga, 2021). A 2008-as pénzügyi krízist egy, az expanzív monetáris politika által felfújtt ingatlanpiaci buborék kipukkanása váltotta ki. A laza hitelfeltételek miatt a lakásárak csökkenése gyorsan saját tőkét meghaladó veszteségeket generált, amelyek strukturált értékpapírokon keresztül a pénzügyi rendszer egészére áterjedtek (Gjerstad & Smith, 2009). A Lehman Brothers 2008. szeptember 15-i csődje a válság kulminációs pontját jelentette és megrázta a globális pénzügyi rendszert (Wiggins et al., 2019). Az elmúlt öt évtized mélyülő globalizációja a nemzetközi részvénybefektetések iránti keresletet, ezzel párhuzamosan pedig a devizapiaci aktivitást is fellendítette (Insaïdoo et al., 2024). A nagyfrekvenciás kereskedés (HFT) a modern platformok egyik meghatározó innovációja mára domináns szereplővé vált: az Egyesült Államok részvényforgalmának mintegy 52 %-át adta 2018-ban (Hossain, 2022).

2.2 A technikai elemzés elméleti kerete

A technikai elemzés a historikus árfolyammozgások és a kereskedési volumen statisztikai vizsgálatával kívánja előre jelezni a piaci trendek alakulását, míg a fundamentális megközelítés a vállalati pénzügyi adatokra és a makrogazdasági környezetre épít (Vasantha et al., 2012). A leggyakrabban alkalmazott indikátorok közé sorolható a relatív erőindex (RSI), a Bollinger sávok, a mozgóátlag konvergencia divergencia (MACD), az egyszerű mozgóátlag (SMA), a sztochasztikus oszcillátor és a Williams százalékos tartomány (W%R), amelyek elsősorban rövid távú ármozgások elemzésére és lehetséges piaci fordulópontok detektálására szolgálnak (Lee et al., 2022). A mutatók izolált, transzformáció nélküli használata ugyanakkor pontatlanságot eredményezhet, mivel a kereskedési szabályokat számos külső tényező befolyásolja (Wiiava et al., 2022). A trendkövető stratégiák, például a Trend Follow, az árfolyam-trendek kitarthatóságára építenek, így az időzítés elsődleges a hozam maximalizálása érdekében (Rout & Muppidi, 2019). A technikai elemzésben megkülönböztetett alakzatok az árfolyamdiagramon megjelenő szabályszerű formációk, amelyek közé a fej és vállak, az inverz fej és vállak, a dupla csúcs, a dupla alj, továbbá az emelkedő, csökkenő és szimmetrikus háromszögek, valamint a párhuzamos csatornák tartoznak; ezek a struktúrák a trendforduló vagy a trendfolytatás valószínűségét jelzik (Nguyen et al., 2023; Tripathi et al., 2023). A gyertyatartó diagramok segítik ezen minták vizuális felismerését, míg a lineáris regresszió automatizált eszközként csökkenti a szubjektív döntéshozatal hibáit (Tripathi et al., 2023). A mintafelismerés pontossága a gépi tanulás és a mély neurális hálózatok, például az LSTM vagy a BiLSTM bevezetésével tovább növelhető; a főkomponens-elemzés révén pedig kiszűrhetők a legprediktívőbb indikátorok (Bandara et al., 2015; Uçkan, 2024). A módszertan korlátai között szerepel a minták szubjektív interpretációja, amely a vizsgált időszak és skála függvényében eltérő lehet; emellett a technikai indikátorok teljesítménye érzékeny a kereskedési gyakoriságra és a pozíciózársi szabályokra, különösen volatilis, zajos piaci környezetben (Postolache et al., 2010).

2.3 A fundamentális elemzés jelentősége

A fundamentális elemzés a vállalati teljesítmény átfogó értékelésére törekszik a pénzügyi beszámolók, a vezetés minősége, az üzleti modell és a makrogazdasági tényezők vizsgálatán keresztül, elsődlegesen hosszú távú befektetési horizonttal (Ajha et al., 2024). A vállalat belső értéke a várható pénzáramlások diszkontált jelenértékén alapul, aminek célja az alul- illetve túlértékelt részvények azonosítása (Hasaballah et al., 2019). A makroszintű elemzés a GDP-növekedés, az infláció, a kamatlábak és a fiskális politika összefüggéseit értelmezi, míg az iparági vizsgálat a piaci versenyhelyzetet, a belépési korlátokat és a szabályozási környezetet méri fel ez utóbbihoz gyakori keretet ad a Porter-féle Öt Erő

modell (Kandi et al., 2023). A vállalati szintű diagnózis a likviditási, jövedelmezőségi és tőkeáttételi mutatók (például ROA, ROE, Current Ratio, DER) analizálására épül, kiegészítve az értékelési (P/E) és növekedési indikátorokkal (Cam et al., 2017). A fundamentális megközelítés hátránya, hogy nehezen ragadja meg a rövid távú piaci hangulatot és a befektetői pszichológiát, továbbá a gyors árfolyam-ingadozásokat sem képes maradéktalanul modellezni (Spritzer & Freitas, 2006). Mindazonáltal hosszú távú befektetési döntéseknél továbbra is nélkülözhetetlen, mivel az üzleti ciklusok és a vállalatspecifikus fundamentumok mélyebb megértését biztosítja (Prohaska et al., 2011).

2.4 A mesterséges intelligencia fogalma és történeti–technológiai kontextusa

A mesterséges intelligencia (MI) a számítógépes algoritmusok azon osztályát jelöli, amely képes olyan korábban az emberi kognícióhoz kötött feladatok ellátására, mint a tanulás, a problémamegoldás vagy a döntéshozatal (Cappello et al., 2023). Az MI egyik centrális építőeleme a gépi tanulás, amely példából és tapasztalattól kiindulva teszi lehetővé a mintázatok felismerését, a nyelv feldolgozását és az autonóm döntések meghozatalát (Zhang et al., 2021). A konvencionális programozással szemben az MI rendszerei nem előre rögzített eljárásokat hajtanak végre, hanem az adatok alapján finomítják belső modelljeiket (Sloane & Silva, 2019). A modern MI alapjait az 1956-os Dartmouth-konferencia jelölte ki, ahol John McCarthy bevezette a “mesterséges intelligencia” terminust, megteremtve a szimbolikus és a konnekcionista irányzatok párhuzamos fejlődésének keretét (Anurag, 2024). A kutatástörténeti folyamatot az ősi automaták víziójától az első szakértői rendszereken át a mély neurális hálózatok diadaláig számos technológiai és elméleti mérföldkő jellemzi (Aleksseeva, 2020). A publikációs aktivitás exponenciális növekedése az elmúlt hat évtizedben jól tükrözi a gépi tanulás előretörését és az alkalmazási spektrum folyamatos bővülését (Audibert et al., 2023). Az MI etikai diskurzusa már az 1960-as években körvonalazódott; a leggyakrabban vizsgált normatív elvek a jótékony hatás, az ártalom minimalizálása, az autonómia, az igazságosság és a magyarázhatóság (Morley et al., 2020). A kormányzati szabályozás különösen az Európai Unióban intézményesített értékelési kereteket vezet be, hogy e normákat a kutatás-fejlesztési gyakorlatban is érvényesítse. A korai kutatások a formális problémamegoldásra, a természetesnyelv-feldolgozásra és a tudásalapú rendszerekre fókuszáltak. Az ezredforduló után a big data infrastruktúrák, a felhőszolgáltatások és az eszközök internetének terjedése tette lehetővé a mély neurális hálózatok hatékony képzését, amelyeket ma az autonóm járművektől a beszédfelismerő platformokig számos alkalmazásban használnak (Suryana & Anggadini, 2020). A technológiai ugrások ugyanakkor új etikai kérdéseket hoztak felszínre, elsősorban az autonómia, a méltányosság és a felelősségeloszlás terén (Aleksseeva, 2020).

2.4.1 Az MI kategóriái és módszertani megközelítései

A képességek szerint megkülönböztetünk szűk (ANI), általános (AGI) és szuperintelligens (ASI) rendszereket, bár az utóbbi kettő jelenleg inkább elméleti konstrukció (Gai, 2021). Funkcionalitás alapján a reaktív gépek nem támaszkodnak memóriára, a korlátozott memóriájú rendszerek például az önvezető autók a közelmúlt tapasztalatait is hasznosítják, a fejlesztés alatt álló “elme elmélete” típus az emberi érzelmek és intenciók modellezésére törekszik, az önreflexív MI pedig egyelőre hipotetikus (Alsubaie et al., 2019). A technikai perspektívából az MI gerincét a gépi tanulás különböző paradigmái felügyelt, felügyelet nélküli és megerősítéses tanulás alkotják (Aswin Kumer et al., 2021; D'Angelo et al., 2022). E keretre épülnek a mesterséges neurális hálózatok, köztük a konvolúciós és az ismétlődő architektúrák, amelyek rendre vizuális, illetve szekvenciális adatok feldolgozására specializálódtak (Asif et al., 2021). A hibrid rendszerek például a szabályalapú, fuzzy logikai és evolúciós elemeket

ötvöző megoldások a komplex, magas dimenziójú problémák kezelésében kínálnak előnyt (Lewandowski, 2008).

Neurális hálózatok

A mesterséges neurális hálózatok az agyi szinaptikus plaszticitást imitálva tanulnak; a súlyparamétereket általában a visszaterjesztési algoritmus optimalizálja, miközben az aktivációs függvények biztosítják a szükséges nemlinearitást (Carbonnelle & De Vleeschouwer, 2019; Galimberti & Repetto, 2023). A tanulási folyamat teljesítménye a hiperparaméterek hálózati mélység, tanulási ráta, optimalizáló eljárás gondos kalibrációjától függ (Kollmannsberger et al., 2021). Az újabb technikák, például a feladatfüggő előfeszítő egységek vagy a hasonlóság-súlyozott interleaved learning, mérsékelhetik a katasztrofális felejtés jelenségét (Saxena et al., 2022).

Neuro-fuzzy rendszerek

Az adaptív neuro-fuzzy következtetési rendszer (ANFIS) a neurális hálózatok adaptív tanulási képességét kombinálja a fuzzy logika interpretálhatóságával; a modellt jellemzően Takagi–Sugeno szabályok, Gauss vagy trapéz tagsági függvények és hibrid (gradiens–LSE) tanulás jellemzik (Duy & Van Cuong, 2014; Mosavi et al., 2021). Az adatvezérelt klaszterezés és a metaheurisztikus optimalizálók például részecskeraj vagy genetikai algoritmus tovább javíthatják a predikciós pontosságot (Farhat & Cheok, 2017).

Fuzzy logika

A fuzzy logika, Zadeh többértékű logikája, a bináris igaz–hamis dichotómiát részleges igazságértékek kontinuumára cseréli, így különösen alkalmas bizonytalan, homályos információk kezelésére (Ababou et al., 2023). A klasszikus Mamdani rendszer fuzzy kimenetet generál, majd defuzzifikálással alakít éles értéké, míg a Sugeno modell lineáris vagy konstans kimeneti függvényének köszönhetően elkerüli a számítás-igényes defuzzifikációt, ezért valós idejű vezérlési feladatokra is hatékony (Haq et al., 2021; Ontiveros-Robles et al., 2020). A Sugeno keretrendszer a pénzügyi kockázatelemzésben és az opcióárzásban is bizonyítottan magas pontossággal alkalmazható (Maltoudoglou et al., 2016).

2.5 Tőzsdei árfolyam-előrejelzés ANFIS keretrendszerben

A részvényárfolyamok előrejelzése stratégiai versenyelőnyt kínál a piaci szereplőknek, ugyanakkor a pénzügyi idősorok zajossága és nemlinearitása miatt kifejezetten komplex probléma. Empirikus vizsgálatok szerint az adaptív neuro-fuzzy következtetési rendszer (ANFIS) az Isztambuli Értéktőzsde National 100 indexének havi hozamát 98,3 %-os pontossággal prognosztálta, ami a hagyományos időbeli modellekkel szemben ígéretes alternatívát mutat (Boyacioglu & Avci, 2010). Hasonlóan, a dhakai részvényindex esetében az ANFIS felülmúlta az ARIMA és a hátulterjesztéses neurális hálózatok teljesítményét (Banik et al., 2007).

2.6 Az adatstruktúra összetettsége és a modell prediktív képessége

Az ANFIS különösen alkalmas a részvénypiacokra jellemző magas fokú bizonytalanság és nemlinearitás kezelésére, így hatékonyan használható trendek és árfolyamok előrejelzésére (Barlybayev et al., 2023). Az előrejelzési pontosságot ugyan befolyásolja a bemeneti változók száma és típusa, de a kutatások azt mutatják, hogy az ANFIS már korlátozott számú releváns változó mellett is versenyképes teljesítményt nyújt. Az ISE National 100 esetében két-három bemeneti tényező elegendőnek bizonyult (Ok et al., 2011). Jellemző kiválasztási algoritmusok például az Imperialist Competitive Algorithm vagy a Particle Swarm Optimization tovább növelik a modell hatékonyságát azáltal, hogy kiszűrik a legtöbb

információt hordozó változókat (Barak et al., 2015; Chandar, 2021). Az alacsonyabb RMSE-értékek alapján az ANFIS rendszerint felülírja a lineáris regresszió és a döntési fák teljesítményét, amikor a piaci adatok komplex, nemlineáris kapcsolatokat hordoznak (Barlybayev et al., 2023).

2.7 Korlátok és gyakorlati megfontolások

Az ANFIS előnyei ellenére több kritikus tényezőt is mérlegelni kell. A generált szabályhalmaz gyakran nehezen interpretálható, ami csökkentheti a befektetők bizalmát az eredmények iránt (Wei et al., 2014). A bemeneti változók kiválasztása sokszor szakértői ítélettől függ, ami szubjektivitást visz a modellépítésbe. Nagy dimenziójú adatok mellett a modell komplexitása gyorsan növekszik, ami rontja a számítási hatékonyságot, továbbá fontos piaci tényezők tranzakciós költségek vagy a kereskedési időablakok gyakran kimaradnak a szimulációkból (Chen et al., 2016; Vella & Ng, 2014). Bár az ANFIS alkalmas a nemlineáris mintázatok megragadására, a pénzügyi piacok gyorsan változó dinamikája továbbra is kihívást jelent a hosszú távú pontosság fenntartásában (Koulouriotis et al., 2005).

3. Módszertan

A jelen kutatás egy korábbi kutatásunk továbbfejlesztése, amelyben eredetileg négy fundamentális pénzügyi mutató alkalmazásával vizsgáltuk az autóiipari vállalatok részvényárfolyamainak előrejelzési lehetőségeit. Ezek a mutatók az alábbiak voltak:

- Eszközarányos nyereség (ROA)
- Saját tőke arányos nyereség (ROE)
- Egy részvényre jutó eredmény (EPS)
- Árbevétel-arányos nyereség (PM)

Az eredeti négyes mutatókészlet validációját korábbi szakirodalmi elemzések és saját, korábban végzett szakértői interjúk alapján végeztük el. Az akkori eredményeink igazolták, hogy ezen mutatók együttesen képesek pontos és megbízható előrejelzést biztosítani az autóiipari vállalatok részvényárfolyamainak jövőbeli alakulására. Ugyanakkor felmerült a további kutatás igénye, amely során azt vizsgáljuk meg, hogy egyes mutatók eltávolítása milyen hatással van a modell előrejelzési teljesítményére. Így jelen kutatásunk fő célkitűzése annak feltárása volt, hogy az egyes fundamentális mutatók eltávolítása hogyan befolyásolja az ANFIS modell teljesítményét, valamint hogy ezen az adathalmazon melyik mutató bizonyul a leghangúlyosabbnak.

3.1. Adatgyűjtés és előkészítés

Az elemzéshez szükséges pénzügyi adatokat az ORBIS pénzügyi adatbázisból gyűjtöttük, amely nemzetközi szinten széleskörű vállalati adatokkal rendelkezik. Kutatásunk során kizárólag tőzsdén jegyzett autóiipari vállalatok kerültek be a mintába. Az elemzéshez felhasznált időszak 2019–2023 közötti időtartam volt, amely lehetővé tette, hogy releváns, friss és reprezentatív adatokat nyerjünk. A kiinduló adathalmaz több száz vállalat pénzügyi adatait tartalmazta, azonban a hiányos és pontatlan adatok miatt alapos adatellenőrzést és tisztítást végeztünk. Ennek eredményeképpen a végleges mintánkban 103 vállalat pénzügyi adatai szerepeltek, amely megfelelő nagyságú és minőségű volt ahhoz, hogy statisztikailag megbízható elemzést végezzünk.

3.2. Kiválasztott fundamentális pénzügyi mutatók és normalizáció

Az általunk vizsgált fundamentális pénzügyi mutatók szakirodalmi validáción és korábbi szakértői interjúkon alapultak. Jelen kutatásunk során azt a négy mutatót használtuk kiindulópontként, amelyeket korábbi kutatásunkban már sikeresen alkalmaztunk: ROA, ROE, EPS és PM. A mutatók adatainak homogenizálása és összehasonlíthatóságának biztosítása érdekében Min-Max normalizációt végeztünk, amellyel minden mutató értékét 0 és 1 közötti skálára helyeztük:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

Ez a normalizáció biztosította, hogy a bemeneti adatok egységes formában kerüljenek az ANFIS modellbe, minimalizálva a torzító hatásokat és az esetleges numerikus instabilitást.

3.3. ANFIS modell struktúrájának kialakítása

Az alkalmazott ANFIS modellünk egy Sugeno-típusú fuzzy inferencia rendszer volt, amelyben a fuzzy logika szabályalapú döntési mechanizmusát és a neurális hálózatok adaptív tanulási képességét integráltuk. Minden bemeneti változóhoz (ROA, ROE, EPS, PM) három Gauss-típusú tagsági függvényt társítottunk, amelyek az alacsony, közepes és magas értékeket reprezentálták. Ebből összesen 81 fuzzy szabályból álló szabálybázist alakítottunk ki, amely a mutatók kombinált értékeit tükrözte. Ezek a szabályok lehetővé tették, hogy a modellünk hatékonyan kezelje a pénzügyi adatokban rejlő bizonytalanságokat és komplex kapcsolatokat.

3.4. Tanítási folyamat és modelloptimalizáció

Az ANFIS modellünk tanítása során hibrid tanulási algoritmust alkalmaztunk, amely a lineáris paraméterek optimalizációjához a legkisebb négyzetek módszerét (LSE), míg a nemlineáris paraméterek optimalizációjához a gradiens süllyedés módszerét használta. A tanulási folyamat iteratív módon zajlott, amely során a modell paramétereit lépésről lépésre finomítottuk, hogy minimalizáljuk az előrejelzési hibát. Az adatokat véletlenszerűen osztottuk tréning (80%) és validációs (20%) mintára, így biztosítva, hogy a modell általánosító képessége megfelelő legyen és elkerüljük a túltanulás jelenségét.

3.5. Modell teljesítményének értékelése

Az ANFIS modell előrejelzési pontosságának mérésére két fő statisztikai mérőszámot alkalmaztunk: a gyök négyzetes átlagos hibát (RMSE) és annak normalizált változatát (nRMSE). Ezekkel az indikátorokkal objektív módon értékeltük, hogy az egyes mutatók eltávolítása milyen mértékű változást okoz a modell pontosságában. A két mutató együttes alkalmazása lehetővé tette számunkra, hogy mind abszolút értelemben (RMSE), mind a részvényárfolyamok értéktartományához viszonyítva (nRMSE) értelmezni tudjuk az előrejelzési hibákat.

Az RMSE számítása az alábbi módon történt:

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{Y}_k)^2}$$

ahol y_k a megfigyelt (valós) érték, míg \hat{Y}_k a modell által becsült érték.

A normalizált RMSE (nRMSE) kiszámítása pedig:

$$NRMSE = \frac{RMSE}{y_{max} - y_{min}}$$

ahol y_{max} és y_{min} a megfigyelt értékek maximális, illetve minimális értékei.

3.6. A mutatók jelentőségének értékelése az egyesével való eltávolítás alapján

Az eredeti négy mutatóból álló modellhez képest jelen kutatásunkban azt vizsgáltuk, hogy ha egyesével eltávolítjuk valamelyik mutatót, akkor milyen mértékben változik a modell teljesítménye. A mutatók eltávolításával létrehozott hárommutatós modelleket (például ROA, ROE, EPS; ROA, ROE, PM; stb.) külön-külön tanítottuk és validáltuk, majd összehasonlítottuk az eredeti modell eredményeivel. Ezzel a módszerrel lehetőségünk volt arra, hogy meghatározzuk, melyik mutató eltávolítása okozza a legjelentősebb romlást az előrejelzési pontosságban, azaz melyik mutató rendelkezik a legnagyobb prediktív erővel az autóiipari vállalatok részvényárfolyamának előrejelzésében. Ez a módszertani megközelítés biztosította, hogy világosan megértsük a különböző fundamentális mutatók relatív fontosságát és információértékét a vizsgált adathalmaz esetében, így hozzájárult a kutatási eredményeink mélyebb és alaposabb szakmai értelmezéséhez.

4. Eredmények

4.1. A mutatószámok kiválasztásának folyamata szakértői interjúk alapján

A modell bemeneti változóinak kiválasztása alapvetően meghatározta a későbbi előrejelzési eredmények minőségét és megbízhatóságát. Ezért kiemelten fontosnak tartottuk, hogy a kutatás kezdeti szakaszában alapos szakmai validáció során, szakértői interjúk segítségével határozzuk meg azokat a pénzügyi mutatókat, amelyek a leginkább relevánsak lehetnek az autóiipari vállalatok részvényárfolyamainak előrejelzésében.

A szakirodalmi áttekintést követően félig strukturált interjúkat készítettünk pénzügyi elemzőkkel, befektetési tanácsadókkal, valamint portfóliómenedzserekkel, hogy a szakmai gyakorlatban alkalmazott és kiemelten relevánsnak tartott pénzügyi mutatók körét meghatározzuk. Az interjúk során a szakértők egybehangzóan négy olyan fundamentális mutatót emeltek ki, amelyek szerintük leginkább relevánsak az autóiipari vállalatok pénzügyi teljesítményének és részvényárfolyamainak előrejelzéséhez:

- Eszközarányos nyereség (ROA)
- Saját tőke arányos nyereség (ROE)
- Egy részvényre jutó eredmény (EPS)
- Árbevétel-arányos nyereség (PM)

Korábbi kutatásunkban ezt a négy mutatót alkalmaztuk az ANFIS-modell bemeneti változóiként, ugyanakkor jelen kutatásunkban azt vizsgáljuk meg, milyen mértékben változik a modell előrejelzési teljesítménye, ha az eredetileg validált négy mutatóból (ROA, ROE, EPS, PM) egyesével eltávolítunk egy-egy mutatót és az így kapott hárommutatós modellek alapján értékeljük a predikciók pontosságát. Ez a módszertani megközelítés lehetőséget ad számunkra arra, hogy átfogóan megértsük az egyes mutatók relatív fontosságát és pontosan felmérjük, hogy milyen mértékben járulnak hozzá az autóiipari részvényárfolyamok előrejelzéséhez. A létrehozott új modellekkel különös figyelmet fordítunk arra,

hogyan részletesen elemezzük, milyen mértékű változást eredményez az egyes mutatók (ROA, ROE, EPS, PM) kizárása a modell előrejelzési teljesítményében és stabilitásában. Így pontos képet kapunk arról, hogy melyik fundamentális mutató rendelkezik a legerősebb önálló prediktív képességgel, illetve milyen mértékben csökken a modell hatékonysága az egyes mutatók kizárásával. Az interjúk eredményeként kialakult mutatószámhalmaz tehát nemcsak szakmailag validált alapokat teremtett kutatásunk számára, hanem lehetőséget adott arra is, hogy módszertanilag új nézőpontból, részletesen vizsgáljuk meg az autóiipari részvényárfolyamok fundamentális előrejelzésének lehetőségeit, korlátait, valamint a kiválasztott mutatók egyedi és kombinált szerepét a részvényárfolyamok megbízható előrejelzésében.

4.2. Az ANFIS modell kialakítása, tanítása és a mutatószámok szerepének vizsgálata

Az ANFIS modell konkrét gyakorlati kialakítását, tanítását és finomhangolását követően, a korábban ismertetett általános módszertani elvek alapján dolgoztuk ki. Az elemzésünkben kiemelten fontos szempont volt annak vizsgálata, hogy a különböző fundamentális pénzügyi mutatók milyen szerepet játszanak az autóiipari vállalatok részvényárfolyamának előrejelzésében, ezért modellünket a szakirodalomban széles körben alkalmazott Sugeno-típusú fuzzy inferencia rendszerként hoztuk létre (Mosavi et al., 2021). Első lépésként, a korábbi kutatásunkból kiindulva négy mutató (ROA, ROE, EPS, PM) felhasználásával létrehoztuk a kezdeti ANFIS modellt, amely minden mutató tekintetében három Gauss-típusú fuzzy tagsági függvényt tartalmazott, az „alacsony”, „közepes” és „magas” kategóriákba sorolva a változókat. Ezáltal a kezdeti modellünk összesen 81 fuzzy szabályból épült fel. A modellt az ORBIS adatbázisból származó, gondosan tisztított és normalizált adatokon képeztük ki. Az adathalmazt véletlenszerűen osztottuk fel tréning (80%) és validációs (20%) részre, így lehetővé téve a modell tanításának objektív értékelését, valamint a túltanulás elkerülését.

A modell kialakításának első fázisában minden mutatót bevontunk, majd ezt követően a kutatásunk fókuszpontja arra irányult, hogy részletesen feltárjuk, melyik mutatónak milyen szerepe van a modell prediktív képességében. Ennek érdekében lépésről lépésre eltávolítottuk az egyes mutatókat, így minden alkalommal új, hárommutatós ANFIS modelleket hoztunk létre. Ez a módszertani megközelítés lehetőséget adott arra, hogy pontosan meghatározzuk, melyik mutató eltávolítása milyen mértékben változtatja meg az előrejelzési teljesítményt.

A konkrét lépések a következők voltak:

1. Először kialakítottuk a négy mutatót (ROA, ROE, EPS, PM) tartalmazó alapmodellt és elvégeztük a modell tanítását az előzetesen ismertetett hibrid tanulási algoritmussal. A lineáris paramétereket a legkisebb négyzetek módszerével (LSE), míg a tagsági függvények nemlineáris paramétereit a gradiens süllyedés algoritmusával optimalizáltuk. A modell paramétereinek kezdeti beállítását az adatok eloszlásának figyelembevételével automatikusan állítottuk be, ezzel gyorsítva a tanulási folyamat kezdeti konvergenciáját.
2. Ezután három különböző hárommutatós modellt alakítottunk ki oly módon, hogy minden alkalommal eltávolítottunk egy-egy mutatót a négyből. Ennek eredményeképpen az alábbi modellváltozatokat kaptuk:
 - Modell 1: ROE, EPS, PM (ROA eltávolítva)
 - Modell 2: ROA, EPS, PM (ROE eltávolítva)

- Modell 3: ROA, ROE, PM (EPS eltávolítva)
- Modell 4: ROA, ROE, EPS (PM eltávolítva)

Minden egyes hárommutatós modellt ugyanolyan gondossággal és azonos módszertani lépésekkel képeztünk ki, mint az eredeti négyes modell esetében. Az iteratív optimalizáció során következetesen alkalmaztuk a hibrid tanulási algoritmust, rendszeresen ellenőrizve a validációs mintán mutatott teljesítményeket az RMSE és nRMSE mutatók segítségével. Így biztosítottuk, hogy a modellek összehasonlítása objektív és statisztikailag megbízható eredményeket nyújtson.

Az iteratív paraméteroptimalizáció folyamatában különös figyelmet fordítottunk arra, hogy minden modellváltozat tanulása során azonos feltételek mellett, konzisztensen végezzük el a paraméterek finomhangolását. Ennek érdekében a modelleket azonos számú iteráció során optimalizáltuk és minden esetben vizuálisan is ellenőriztük a tagsági függvények elhelyezkedését és illeszkedését az adatokhoz. A paraméteroptimalizáció során több kísérleti futtatást végeztünk, hogy biztosítsuk: a kapott paraméterezés nemcsak lokálisan, hanem globálisan is optimális legyen. Ez a módszertani megközelítés lehetőséget adott számunkra, hogy részletesen vizsgáljuk, melyik fundamentális mutató eltávolítása vezet a legjelentősebb változashoz a modell előrejelzési pontosságában és ezáltal egyértelmű következtetéseket vonhassunk le az egyes mutatók prediktív képességéről és információértékéről az autóiipari vállalatok részvényárfolyam-előrejelzése során. A hárommutatós modellek előállítására és összehasonlítására révén pontos képet kaptunk arról, hogy ezen az adathalmazon melyik mutató eltávolítása okozza a legnagyobb romlást az előrejelzés pontosságában, tehát melyik fundamentális mutató rendelkezik a legnagyobb súllyal a vizsgált autóiipari vállalatok részvényárfolyam-előrejelzésében. Ezzel a módszertani lépéssel nem csupán a modellünk hatékonyságát ellenőriztük, hanem a fundamentális elemzésben alkalmazott mutatók egyedi prediktív szerepét is alaposan feltártuk, hozzájárulva ezzel a további kutatásokhoz és a gyakorlati alkalmazásokhoz is.


4.3. Az ANFIS modell előrejelzési teljesítményének értékelése

Az ANFIS modellek előrejelzési teljesítményét, külön hangsúlyt fektetve arra, hogy az egyes fundamentális mutatók (ROA, ROE, EPS, PM) eltávolítása milyen hatással volt a modell pontosságára. Az eredményeket validációs adathalmazon, 20 autóiipari vállalat tényleges és prediktált részvényárfolyamainak összevetésével szemléltetjük. A modellek prediktív képességét a gyök négyzetes átlagos hiba (RMSE) és annak normalizált változata (nRMSE) alapján értékeljük.

4.3.1 Eredeti, négy mutatót tartalmazó modell (ROA, ROE, EPS, PM)

Az eredeti ANFIS modellünk, amely mind a négy fundamentális mutatót tartalmazta, az alábbi eredményeket produkálta a validációs adathalmazon:

- RMSE: 2,395
- nRMSE: 1,066%



1. ábra: A teljes modell


Forrás: saját kutatás alapján

4.3.2 ROA mutató eltávolításának hatása

A ROA mutató eltávolítása után, három mutatót (ROE, EPS, PM) alkalmazva a modell az alábbi eredményeket mutatta:

- RMSE: 135,595

- nRMSE: 60%



2. ábra: ROE, EPS, PM mutatószámokkal a modell

Forrás: saját kutatás alapján

4.3.3 ROE mutató eltávolításának hatása

A ROE mutató eltávolítása esetén, a fennmaradó három mutatóval (ROA, EPS, PM) működő ANFIS modell az alábbi eredményeket adta:

- RMSE: 119,417

3. ábra: ROA, EPS, PM mutatószámokkal a modell

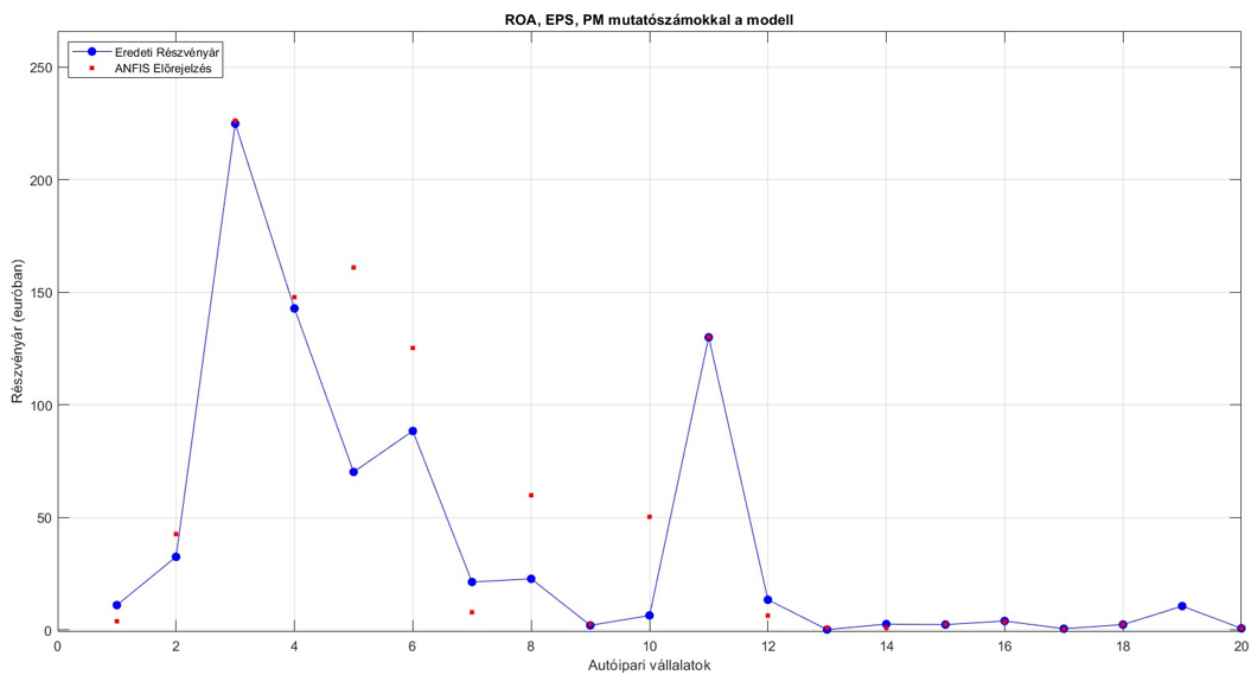
Forrás: saját kutatás alapján

4.3.4. EPS mutató eltávolításának hatása


Az EPS mutató eltávolítása után létrejövő három mutatóval rendelkező modell (ROA, ROE, PM) az alábbi eredményeket hozta:

- RMSE: 72,432

- nRMSE: 53%



- nRMSE: 32%



4. ábra: ROA, ROE, PM mutatószámokkal a modell


Forrás: saját kutatás alapján

5.

4.3.4 PM mutató eltávolításának hatása

A PM mutató eltávolítását követően kialakított ANFIS modell, amelyben a ROA, ROE és EPS mutatókat tartottuk meg, a következő eredményeket mutatta:

- RMSE: 51,876
- nRMSE: 23%



5. ábra: ROA, ROE, EPS mutatószámokkal a modell

Forrás: saját kutatás alapján

4.4 A hárommutatós ANFIS modellek összehasonlítása az eredeti, négy mutatót tartalmazó modellel

Az ANFIS-modellek teljesítményének pontos értékelése érdekében részletes összehasonlító elemzést végeztünk az eredeti, négy mutatót (ROA, ROE, EPS, PM) tartalmazó modell és az egyes mutatók eltávolításával létrehozott hárommutatós modellek között. Ennek során arra fókuszáltunk, hogy a fundamentális pénzügyi mutatók egyedi eltávolítása milyen mértékben befolyásolja a modell előrejelzési pontosságát, azaz mekkora prediktív információvesztést okoz egy adott mutató kizárása. Az eredeti, mind a négy fundamentális mutatót magában foglaló ANFIS-modellünk az elemzés során rendkívül magas pontosságot mutatott. Az eredeti modell validációs adathalmazon mért RMSE értéke mindössze 2,395, normalizált RMSE (nRMSE) értéke pedig 1,066% volt. Ezek az eredmények azt jelzik, hogy a négy mutató (ROA, ROE, EPS, PM) együttes alkalmazása optimális módon ragadja meg az autóipari vállalatok részvényárfolyamainak mozgását, biztosítva a magas szintű megbízhatóságot és pontosságot. Ez a kiemelkedően alacsony hiba arra utal, hogy a négy mutató között erős szinergikus kapcsolat áll fenn, amelyek együttes alkalmazása jelentős mértékben növeli a modell előrejelző

képességét. A mutatók egyenkénti eltávolításával létrehozott modellek eredményei azonban számottevően romló tendenciát mutatnak. A részletes eredmények összehasonlításából egyértelműen kirajzolódik, hogy a ROA eltávolítása eredményezte a legjelentősebb teljesítményromlást. A ROA nélküli modell RMSE értéke drámaian, 135,595-re nőtt, ami az eredeti modellhez képest 5563%-os növekedést jelent. Hasonlóképpen, a normalizált RMSE (nRMSE) értéke 60%-ra emelkedett, ami az eredeti modell nRMSE értékéhez viszonyítva 5562,6%-os relatív növekedést jelent. Ez a jelentős teljesítményromlás azt jelzi, hogy a ROA mutató kulcsfontosságú szerepet tölt be az autóiipari vállalatok árfolyamváltozásainak megbízható előrejelzésében. A mutató eltávolítása után a modell képtelen volt megfelelően leképezni az operatív hatékonyságból eredő árfolyamváltozásokat, ami a modell prediktív erejének drámai csökkenéséhez vezetett. A ROE mutató eltávolítása szintén jelentős, bár valamivel kisebb teljesítménycsökkenést eredményezett, mint a ROA esetében. A ROE nélküli modell RMSE értéke 119,417-re növekedett, amely 4887%-os növekedést mutat az eredeti modellhez képest. A normalizált RMSE értékének növekedése is jelentős volt, elérve az 53%-ot, ami 4887%-os relatív romlást jelentett az eredeti modellhez képest. A ROE eltávolítása utáni teljesítményromlás egyértelműen alátámasztja a saját tőke arányos nyereség prediktív jelentőségét, amely a befektetői értékteremtés egyik kulcsfontosságú indikátora az autóiipari szektorban. Az EPS mutató eltávolítása mérsékeltbb teljesítményromláshoz vezetett az előző két mutatóhoz képest. Az EPS nélküli modell RMSE értéke 72,432 volt, amely 2925%-os növekedést mutatott az eredetihez viszonyítva. Ezzel együtt az nRMSE értéke is jelentősen, 32%-ra nőtt, amely 2924,8%-os relatív emelkedést jelentett az eredeti négyes mutatós modellhez képest. Ezek az eredmények világosan jelezték, hogy az EPS, bár nem okozott olyan drámai teljesítményromlást, mint a ROA vagy ROE, mégis kulcsfontosságú szerepet tölt be a modell előrejelzési pontosságában, különösen a profitabilitás közvetlen indikátoraként. Végül PM mutató eltávolítása eredményezte a legkevesbé jelentős, de még így is észrevehető teljesítménycsökkenést. A PM nélküli modell RMSE értéke 51,876-ra emelkedett, amely az eredeti modellhez képest 2066%-os növekedést jelentett. A normalizált RMSE értéke pedig 23%-ra emelkedett, ami 2066,4%-os relatív romlást mutatott. Bár ez a romlás a legkisebb volt az összes mutató eltávolítása közül, továbbra is érzékelhető változás, ami azt jelzi, hogy a PM mutató is releváns információkat hordoz a részvényárfolyamok előrejelzésében, habár relatív jelentősége az előző három mutatóhoz képest kisebb.

Az eredmények összehasonlítása alapján az alábbi táblázat foglalja össze a különböző modellek teljesítményét:

1. táblázat: *Modellek összehasonlítása*

Modellváltozat	RMSE	nRMSE (%)	ΔRMSE (%) az eredetihez képest	ΔnRMSE (%) az eredetihez képest
Eredeti (ROA, ROE, EPS, PM)	2,395	1,07%	0%	0%
ROA nélküli (ROE, EPS, PM)	135,595	60%	5563%	5562,60%
ROE nélküli (ROA, EPS, PM)	119,417	53%	4887%	4887,00%
EPS nélküli (ROA, ROE, PM)	72,432	32%	2925%	2924,80%

Forrás: saját kutatás alapján

6. Következtetés

Az ANFIS modellek részletes összehasonlító elemzését követően a jelen kutatásunk során lehetőségünk nyílt arra, hogy mélyebb betekintést nyerjünk a vizsgált fundamentális pénzügyi mutatók egyedi prediktív jelentőségébe. A különböző mutatók eltávolításával létrehozott hárommutatós modellek teljesítményének szisztematikus összevetésével világossá vált, hogy az egyes mutatók milyen relatív fontossággal bírnak az autóiipari részvényárfolyamok előrejelzésében.

A normalizált RMSE (nRMSE) értékek alapján az egyes mutatók eltávolítása okozta teljesítményromlások mértékét összevetve felállítottuk a fundamentális mutatók prediktív fontossági sorrendjét az alábbi módon:

- **Eszközarányos nyereség (ROA):** Az elemzések során egyértelműen kirajzolódott, hogy az ROA mutató eltávolítása okozta a legnagyobb teljesítményromlást. Az nRMSE értékének jelentős, 5562,6%-os relatív növekedése arra enged következtetni, hogy az eszközök kihasználtságát jelző ROA mutató kritikus fontosságú az autóiipari vállalatok részvényárfolyamainak előrejelzésében. Ez azt jelzi, hogy a vizsgált adathalmazon a vállalatok operatív hatékonysága, amit az ROA közvetlenül tükröz, kiemelt jelentőséggel bír a piaci árfolyamok alakulásában és nélkülözhetetlen információt hordoz a befektetői döntések szempontjából.
- **Saját tőke arányos nyereség (ROE):** A második legjelentősebb prediktív szerepet a ROE mutató töltötte be. Eltávolítása során az nRMSE értékének relatív növekedése 4887%-os volt, ami szintén jelentős, bár valamivel mérsékeltebb, mint a ROA mutató esetében. A ROE fontossága azzal magyarázható, hogy ez a mutató közvetlenül kapcsolódik a vállalat befektetői értékteremtési képességéhez. A befektetők számára különösen fontos mutatónak tekinthető, mivel az autóiipari vállalatok versenyképességére és pénzügyi fenntarthatóságára vonatkozóan kulcsfontosságú információkat nyújt.
- **Egy részvényre jutó eredmény (EPS):** Az EPS eltávolítása mérsékeltebb, de továbbra is számottevő, 2924,8%-os relatív nRMSE emelkedést eredményezett. Ez azt jelzi, hogy bár az EPS mutató közvetlenül kifejezi a vállalat profitabilitását, ezen az adathalmazon a mutató relatív prediktív ereje valamivel kisebb volt, mint a ROA és ROE mutatóké. Mindazonáltal az EPS még mindig kritikus információt biztosít a részvényárfolyamok alakulásával kapcsolatban, különösen a vállalat jövedelmezőségének és profitabilitásának jelzésére.
- **Árbevétel-arányos nyereség (Profit Margin – PM):** Az elemzés során a legkisebb, de még mindig érzékelhető, 2066,4%-os relatív nRMSE változás volt megfigyelhető a PM mutató eltávolításakor. Ez azt mutatja, hogy bár a PM fontos és releváns információkat hordoz, szerepe és jelentősége a vizsgált adathalmazon a másik három mutatóhoz képest kevésbé hangsúlyos volt. A PM mutató hozzáadott értéke így kisebb, azonban nem elhanyagolható a modell maximális prediktív pontosságának biztosításában.

Az eredmények részletes összehasonlítása és elemzése alapján világossá vált, hogy a fundamentális mutatók közül az eszközarányos nyereség (ROA) és a saját tőke arányos nyereség (ROE) kulcsszerepet játszanak az autóiipari részvényárfolyamok előrejelzésében. Ezek a mutatók az elemzett adathalmazon egyértelműen kiemelkedő prediktív jelentőséggel rendelkeznek, ami arra utal, hogy a befektetői döntések során az operatív hatékonyságot és az értékteremtő képességet jelző mutatók a legfontosabb tényezők közé tartoznak. Az EPS mutató közvetlenül a vállalatok profitabilitásával kapcsolatos információkat hordozza, így szintén jelentős, bár relatív értelemben kisebb súllyal bír. A PM mutató,

bár releváns információkat hordoz, a többi mutatóhoz képest kisebb prediktív jelentőséget mutatott az elemzett adathalmazon.

7. Ajánlás

A jelen kutatás eredményei alapján számos olyan ajánlást és javaslatot fogalmazhatunk meg, amelyek mind a további tudományos kutatások, mind pedig a gyakorlati alkalmazások szempontjából relevánsak és értékesek lehetnek. Az adaptív neuro-fuzzy inferencia rendszer (ANFIS) modellünk eredményeinek elemzésével egyértelműen kimutattuk, hogy a különböző fundamentális pénzügyi mutatók eltérő prediktív erővel rendelkeznek az autóiipari vállalatok részvényárfolyamainak előrejelzésében. Ezen tapasztalatok alapján az alábbi ajánlásokat fogalmazzuk meg:

1. Elsőként, javasoljuk a befektetők és pénzügyi elemzők számára, hogy kiemelten kezeljék a ROA és ROE mutatók szerepét az autóiipari vállalatok pénzügyi értékelése során. Az eredményekből világosan látható volt, hogy az eszközarányos nyereség (ROA) és a saját tőke arányos nyereség (ROE) kritikus információkat hordoz a vállalatok operatív teljesítményével, hatékonyságával, illetve a részvényesek számára teremtett értékkel kapcsolatban. A befektetőknek és elemzőknek célszerű ezeket a mutatókat nagyobb súllyal figyelembe venniük a döntéshozatal során, különösen az autóiipari részvények értékelésekor. Ezáltal pontosabb befektetési döntéseket hozhatnak és hatékonyabban kezelhetik a piaci kockázatokat.
2. Második ajánlasként kiemeljük, hogy bár az EPS mutató relatív fontossága a ROA és ROE mutatókhoz képest valamivel kisebb volt, továbbra is jelentős szerepet tölt be a vállalatok profitabilitásának közvetlen jelzőjeként. Ezért azt javasoljuk, hogy a befektetők és elemzők ne hagyják figyelmen kívül az EPS mutatót sem, mivel annak változásai jelentős hatással lehetnek a piaci befektetői percepciókra, illetve a részvényárfolyamok alakulására. Az EPS információtartalma különösen a rövid és középtávú befektetési döntésekben lehet kiemelt fontosságú, ezért ennek rendszeres monitorozását ajánljuk a befektetési stratégiák kialakítása során.
3. Harmadik ajánlásunk, hogy az árbevétel-arányos nyereség (Profit Margin – PM) mutatót sem érdemes figyelmen kívül hagyni, noha annak relatív prediktív ereje kisebbnek bizonyult a többi vizsgált mutatóhoz képest. A PM mutató különösen releváns lehet olyan autóiipari vállalatok esetében, amelyek árbevételük dinamikus növekedésével, illetve intenzív piaci terjeszkedéssel rendelkeznek. Javasoljuk, hogy a vállalati pénzügyi értékelések során továbbra is figyeljék ennek a mutatónak a változásait, mert bár a közvetlen árfolyam-előrejelzésben kisebb súllyal bír, hosszabb távú stratégiai döntésekben és a vállalat fenntartható profitabilitásának értékelésében kritikus információkat hordozhat.
4. Negyedik javaslatként további kutatásokat ajánlunk a neuro-fuzzy alapú modellezési technikák finomítására és bővítésére. A jelen kutatásunk eredményei egyértelműen kimutatták, hogy a fundamentális elemzés neuro-fuzzy technikákkal való kombinálása jelentős potenciált rejt a részvényárfolyamok pontosabb előrejelzésében. Ugyanakkor további kutatásokra van szükség a modellek általánosíthatóságának és robusztusságának vizsgálatára, különböző iparágak és piaci körülmények között. Különösen érdekes lehet a különböző gépi tanulási és neurális hálózati módszerek összevetése az ANFIS modellekkel, annak érdekében, hogy a befektetők és pénzügyi elemzők számára olyan robusztus és adaptív eszközöket hozzunk létre, amelyek még pontosabb és megbízhatóbb előrejelzéseket képesek nyújtani.

5. Ötödik ajánlásunk, hogy az autóiipari vállalatok részvényárfolyamainak előrejelzésénél az ANFIS modelleket kiegészítsük további pénzügyi vagy nem pénzügyi mutatókkal, például makrogazdasági vagy technológiai indikátorokkal. Az autóiipari szektor különösen érzékeny a gazdasági ciklusok változásaira, a szabályozási környezetre, valamint a technológiai fejlődésre (például elektromos autók terjedése, új szabályozási előírások). Ezeknek a külső tényezőknek a figyelembevételével a modellek prediktív ereje jelentősen javítható lehet és még átfogóbb támogatást nyújthatnak a pénzügyi döntéshozóknak.
6. Hatodik, módszertani ajánlasként javasoljuk a pénzügyi elemzők és kutatók számára, hogy a fundamentális elemzési módszereiket kiegészítsék az ANFIS-hez hasonló, neuro-fuzzy alapú modellezési technikákkal. A jelen kutatás bizonyította, hogy az ilyen hibrid modellek hatékonyan kezelik a pénzügyi piacokon jellemző komplexitást és bizonytalanságokat, ezért ezek a technikák értékes kiegészítői lehetnek a hagyományos fundamentális elemzési eszköztárnak.
7. Végül, hetedik ajánlasként a gyakorlati felhasználóknak és pénzügyi döntéshozóknak is azt javasoljuk, hogy az ANFIS alapú modelleket használják rendszeresen a pénzügyi teljesítmény értékelésekor és az előrejelzési folyamatok során. Ezek a modellek nemcsak a befektetési döntések pontosságát javíthatják, hanem segíthetnek abban is, hogy gyorsabban és hatékonyabban reagáljanak a piaci változásokra. Az ANFIS alapú elemzések rendszeres használata stratégiai versenyelőnyt biztosíthat a befektetők és elemzők számára, segítve őket abban, hogy időben felismerjék a fundamentális mutatók változásainak következményeit a részvényárfolyamok alakulására.

Ezekkel az ajánlásokkal tehát arra ösztönözzük a további kutatókat és gyakorlati szakembereket, hogy mélyítsék tovább a fundamentális mutatók neuro-fuzzy alapú elemzését, mivel ezek a módszerek nagy potenciállal bírnak a pénzügyi előrejelzések pontosságának és robusztusságának további fejlesztésében, különösen az autóiipari szektorban.

Irodalomjegyzék

- Ababou, R., Côme, J. M., Chastanet, J., Marcoux, M., & Quintard, M. (2023). Fuzzy Set Characterization of Uncertainty (Fuzzy Variables). In *SpringerBriefs in Applied Sciences and Technology* (Vol. Part F1978, pp. 35-51). https://doi.org/10.1007/978-981-99-6241-9_4
- Ajha, O., Das, S., Dutta, T., Das, S., Mishra, S., & Abualigah, L. (2024). A LSTM Based Intelligent Framework for Financial Stock Prediction. *Lecture Notes in Networks and Systems*,
- Alekseeva, E. (2020). The opposition of symbolism and connectionism in the history of artificial intelligence development [Review]. *Istoriya*, 11(11). <https://doi.org/10.18254/S207987840013021-2>
- Alsubaie, Y., Hindi, K. E., & Alsalman, H. (2019). Cost-Sensitive Prediction of Stock Price Direction: Selection of Technical Indicators [Article]. *IEEE Access*, 7, 146876-146892, Article 8861031. <https://doi.org/10.1109/ACCESS.2019.2945907>
- Anurag, A. S. (2024). Early beginnings of AI: The field of research in computer science. In *Cases on AI Ethics in Business* (pp. 1-20). <https://doi.org/10.4018/9798369326435.ch001>
- Asif, R., Hu, Y. F., Ali, M., Li, J. P., & Abdo, K. (2021). Signal Classification for Safety Critical Aeronautical Communications for Anti-Jamming using Artificial Intelligence. *AIAA/IEEE Digital Avionics Systems Conference - Proceedings*,

- Aswin Kumer, S. V., Kanakaraja, P., Sairam Nadipalli, L. S. P., Ramesh, N. V. K., & Kotamraju, S. K. (2021). The Categorization of Artificial Intelligence (AI) Based on the Autonomous Vehicles and Its Other Applications. *Lecture Notes in Networks and Systems*,
- Audibert, R. B., Lemos, H., Avelar, P., Tavares, A. R., & Lamb, L. C. (2023). On the Evolution of A.I. and Machine Learning: Towards a Meta-level Measuring and Understanding Impact, Influence, and Leadership at Premier A.I. Conferences [Article]. *Journal of Applied Logics*, 10(5), 693-817. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85203359595&partnerID=40&md5=c25ec3b5092d305c4a731b0740c9a145>
- Bandara, M. N., Ranasinghe, R. M., Arachchi, R. W. M., Somathilaka, C. G., Perera, S., & Wimalasuriya, D. C. (2015). A Complex Event Processing Toolkit for Detecting Technical Chart Patterns. *Proceedings - 2015 IEEE 29th International Parallel and Distributed Processing Symposium Workshops, IPDPSW 2015*,
- Banik, S., Chanchary, F. H., Rouf, R. A., & Khan, K. (2007). Modeling chaotic behavior of Dhaka Stock Market Index values using the neuro-fuzzy model. *2007 10th International Conference on Computer and Information Technology, ICCIT*,
- Barak, S., Dahooie, J. H., & Tichý, T. (2015). Wrapper ANFIS-ICA method to do stock market timing and feature selection on the basis of Japanese Candlestick [Article]. *Expert Systems with Applications*, 42(23), 9221-9235. <https://doi.org/10.1016/j.eswa.2015.08.010>
- Barlybayev, A., Zhetkenbay, L., Karimov, D., & Yergesh, B. (2023). DEVELOPMENT NEURO-FUZZY MODEL TO PREDICT THE STOCKS OF COMPANIES IN THE ELECTRIC VEHICLE INDUSTRY [Article]. *Eastern-European Journal of Enterprise Technologies*, 4(4(124)), 72-87. <https://doi.org/10.15587/1729-4061.2023.281138>
- Boyacioglu, M. A., & Avci, D. (2010). An Adaptive Network-Based Fuzzy Inference System (ANFIS) for the prediction of stock market return: The case of the Istanbul Stock Exchange. *Expert Systems with Applications*, 37(12), 7908-7912. <https://doi.org/https://doi.org/10.1016/j.eswa.2010.04.045>
- Cam, A. V., Tosunoglu, B., & Gurtay, E. (2017). The role of financial ratios on evaluation of stock values: An application in Bist. In *Research on Humanities and Social Sciences: Communication, Social Sciences, Arts* (pp. 263-274). <https://doi.org/10.3726/978-3-631-69829-7>
- Cappello, G., Defeudis, A., Giannini, V., Mazzetti, S., & Regge, D. (2023). Artificial intelligence in oncologic imaging. In *Multimodality Imaging and Intervention in Oncology* (pp. 585-597). https://doi.org/10.1007/978-3-031-28524-0_24
- Carbonnelle, S., & De Vleeschouwer, C. (2019). Experimental study of the neuron-level mechanisms emerging from backpropagation. *ESANN 2019 - Proceedings, 27th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*,
- Chandar, S. K. (2021). Forecasting intraday stock price using ANFIS and bio-inspired algorithms [Article]. *International Journal of Networking and Virtual Organisations*, 25(1), 29-47. <https://doi.org/10.1504/IJNVO.2021.117754>
- Chen, Y. S., Cheng, C. H., Chiu, C. L., & Huang, S. T. (2016). A study of ANFIS-based multi-factor time series models for forecasting stock index [Article]. *Applied Intelligence*, 45(2), 277-292. <https://doi.org/10.1007/s10489-016-0760-8>
- D'Angelo, T., Caudo, D., Blandino, A., Albrecht, M. H., Vogl, T. J., Gruenewald, L. D., Gaeta, M., Yel, I., Koch, V., Martin, S. S., Lenga, L., Muscogiuri, G., Sironi, S., Mazziotti, S., & Booz, C. (2022). Artificial intelligence, machine learning and deep learning in musculoskeletal imaging: Current applications [Review]. *Journal of Clinical Ultrasound*, 50(9), 1414-1431. <https://doi.org/10.1002/jcu.23321>
- Duy, T. H., & Van Cuong, N. (2014). Enhancement and FPGA implementation of ANFIS algorithm in digital image processing. *2014 IEEE 5th International Conference on Communications and Electronics, IEEE ICCE 2014*,
- Farhat, A., & Cheok, K. C. (2017). Improving adaptive network fuzzy inference system with Levenberg-Marquardt algorithm. *11th Annual IEEE International Systems Conference, SysCon 2017 - Proceedings*,

- Gai, F. (2021). When Artificial Intelligence Meets Daoism. In *Intelligence and Wisdom: Artificial Intelligence Meets Chinese Philosophers* (pp. 83-100). https://doi.org/10.1007/978-981-16-2309-7_6
- Gál, Z. (2016). *Pénzügyi piacok a globális térben*. <https://doi.org/10.1556/9789630598118>
- Galimberti, C., & Repetto, M. (2023). Neural Networks and Deep Learning. In *Impact of Artificial Intelligence in Business and Society: Opportunities and Challenges* (pp. 58-81). <https://doi.org/10.4324/9781003304616-5>
- Gjerstad, S., & Smith, V. L. (2009). MONETARY POLICY, CREDIT EXTENSION, AND HOUSING BUBBLES: 2008 AND 1929. *Critical Review*, 21(2-3), 269-300. <https://doi.org/10.1080/08913810902934117>
- Haq, S. S., Lenine, D., & Lalitha, S. V. N. L. (2021). Performance Enhancement of UPQC Using Takagi–Sugeno Fuzzy Logic Controller [Article]. *International Journal of Fuzzy Systems*, 23(6), 1765-1774. <https://doi.org/10.1007/s40815-021-01095-w>
- Hasaballah, A. S., Zenad, Y. S., & Shlaka, J. K. (2019). The role of fundamental analysis in determining the market value of hospitality, tourism and company shares [Article]. *African Journal of Hospitality, Tourism and Leisure*, 8(4). <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85071593715&partnerID=40&md5=daa38c2fbe4c83f07e18582e1ce9232f>
- Hossain, S. (2022). High-Frequency Trading (HFT) and Market Quality Research: An Evaluation of the Alternative HFT Proxies. *Journal of Risk and Financial Management*, 15(2), 54. <https://www.mdpi.com/1911-8074/15/2/54>
- Kandi, V. S. P., Kamal, P. V. R., & Pavan, B. N. L. (2023). Fundamental Analysis of Selected Companies in the Pharma Sector in India. AIP Conference Proceedings,
- Kollmannsberger, S., D'Angella, D., Jokeit, M., & Herrmann, L. (2021). Neural Networks. In *Studies in Computational Intelligence* (Vol. 977, pp. 19-45). https://doi.org/10.1007/978-3-030-76587-3_3
- Koulouriotis, D. E., Diakoulakis, I. E., Emiris, D. M., & Zopounidis, C. D. (2005). Development of dynamic cognitive networks as complex systems approximators: Validation in financial time series [Article]. *Applied Soft Computing Journal*, 5(2), 157-179. <https://doi.org/10.1016/j.asoc.2004.06.004>
- Lee, M. C., Chang, J. W., Yeh, S. C., Chia, T. L., Liao, J. S., & Chen, X. M. (2022). Applying attention-based BiLSTM and technical indicators in the design and performance analysis of stock trading strategies [Article]. *Neural Computing and Applications*, 34(16), 13267-13279. <https://doi.org/10.1007/s00521-021-06828-4>
- Lewandowski, S. (2008). Basic elements of the artificial intelligence and examples of their applications in the textile industry. Part Ic: Kinds and characteristics of the artificial intelligence elements [Article]. *Przegląd Włokienniczy*, 62(7), 33-35+32. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-49649087941&partnerID=40&md5=7d980d6bcd4565e7269f94177b5d79a0>
- Maltoudoglou, L., Boutalis, Y., & Loukeris, N. (2016). A fuzzy system model for financial assessment of listed companies. IISA 2015 - 6th International Conference on Information, Intelligence, Systems and Applications,
- Michie, R. C. (1997). Friend or foe? Information technology and the London Stock Exchange since 1700. *Journal of Historical Geography*, 23(3), 304-326. <https://doi.org/https://doi.org/10.1006/jhge.1996.0056>
- Morley, J., Floridi, L., Kinsey, L., & Elhalal, A. (2020). From What to How: An Initial Review of Publicly Available AI Ethics Tools, Methods and Research to Translate Principles into Practices [Article]. *Science and Engineering Ethics*, 26(4), 2141-2168. <https://doi.org/10.1007/s11948-019-00165-5>
- Mosavi, M. R., Ayatollahi, A., & Afrakhteh, S. (2021). An efficient method for classifying motor imagery using CPSO-trained ANFIS prediction [Article]. *Evolving Systems*, 12(2), 319-336. <https://doi.org/10.1007/s12530-019-09280-x>
- Muraközy, L. (2016). *Allamok kora*. <https://doi.org/10.1556/9789630597692>

- Nguyen, T. D., Tran, Q. B., Tran, D. A., Than, T. D., & Tran, Q. D. (2023). Object Detection Approach for Stock Chart Patterns Recognition in Financial Markets. *ACM International Conference Proceeding Series*,
- Ok, Y., Atak, M., & Akçayol, M. A. (2011). A simple neuro fuzzy model for ISE 100 index prediction [Article]. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 26(4), 897-904. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84855362245&partnerID=40&md5=40b4478e4c9ed2504b4ca242fd7af37c>
- Ontiveros-Robles, E., Melin, P., & Castillo, O. (2020). Study of the Relevance of Polynomial Order in Takagi-Sugeno Fuzzy Inference Systems Applied in Diagnosis Problems. In *Studies in Computational Intelligence* (Vol. 827, pp. 19-33). https://doi.org/10.1007/978-3-030-34135-0_2
- Postolache, F., Elena, T. C., Ariron, D., & Constantin, F. A. (2010). Assessment of exchange transactions in AUDUSD parity by technical and fundamental analysis. *Knowledge Management and Innovation: A Business Competitive Edge Perspective - Proceedings of the 15th International Business Information Management Association Conference, IBIMA 2010*,
- Prohaska, Z., Uroda, I., & Suljić, S. (2011). SP A computer program for fundamental analysis of stocks. *MIPRO 2011 - 34th International Convention on Information and Communication Technology, Electronics and Microelectronics - Proceedings*,
- Rout, A. K., & Muppidi, S. (2019). Adoptive trend following strategy in financial time series with multi-objective function [Article]. *International Journal of Scientific and Technology Research*, 8(12), 3746-3755. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85076907379&partnerID=40&md5=25c57385afafd5320f3c18cc8f41022f>
- Rubóczky, I. (1999). Tőzsdei fogalomtár/összeáll. Czékus Mihály (Könyvismertetés). *Vezetéstudomány-Management and Business Journal*, 30(4), 52-53.
- Sampurnaningsih, S. R., & Hanifah, A. (2017). Determinant of stock price : A empirical study at state owned enterprises in Indonesia [Article]. *International Journal of Applied Business and Economic Research*, 15(20), 1-10. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85032576119&partnerID=40&md5=2644971bfa18cc1703a2f6655fb6b18d>
- Saxena, R., Shobe, J. L., & McNaughton, B. L. (2022). Learning in deep neural networks and brains with similarity-weighted interleaved learning [Article]. *Proceedings of the National Academy of Sciences of the United States of America*, 119(27), Article e2115229119. <https://doi.org/10.1073/pnas.2115229119>
- Sloane, E. B., & Silva, R. J. (2019). Artificial intelligence in medical devices and clinical decision support systems. In *Clinical Engineering Handbook, Second Edition* (pp. 556-568). <https://doi.org/10.1016/B978-0-12-813467-2.00084-5>
- Spritzer, A. S., & Freitas, C. M. D. S. (2006). A visual tool to support technical analysis of stock market data. *Proceedings of the Workshop on Advanced Visual Interfaces*,
- Suryana, N., & Anggadini, S. (2020). Analysis of Stock Prices Affected by Current Ratio. *International Journal of Science, Technology & Management*, 1, 190-197. <https://doi.org/10.46729/ijstm.v1i3.44>
- Tripathi, A., Mathure, J., Deotarse, S., Rai, D., & Gadhikar, L. (2023). Linear Regression Approach for Stock Chart Pattern Recognition. *5th Biennial International Conference on Nascent Technologies in Engineering, ICNTE 2023*,
- Uçkan, T. (2024). Integrating PCA with deep learning models for stock market Forecasting: An analysis of Turkish stocks markets [Article]. *Journal of King Saud University - Computer and Information Sciences*, 36(8), Article 102162. <https://doi.org/10.1016/j.jksuci.2024.102162>
- Varga, J. Z. (2021). A mintavételezés hatása a pénzügyi adatok statisztikai tulajdonságaira és alkalmazása a kockázatkezelésben= Effect of various sampling methods on the statistical properties of financial data and their application in risk management. *STATISZTIKAI SZEMLE*, 99(3), 233-252.
- Vasantha, S., Dhanraj, V., & Varadharajan, R. (2012). Stock price movement through technical analysis: Empirical evidence from the information technology sector [Article]. *Indian Journal of*

- Finance*, 6(10), 4-17. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84919681936&partnerID=40&md5=33f209829963623fffb728abdf840164>
- Vella, V., & Ng, W. L. (2014). Enhancing risk-adjusted performance of stock market intraday trading with Neuro-Fuzzy systems [Article]. *Neurocomputing*, 141, 170-187. <https://doi.org/10.1016/j.neucom.2014.03.026>
- Wei, L. Y., Cheng, C. H., & Wu, H. H. (2014). A hybrid ANFIS based on n-period moving average model to forecast TAIEX stock [Article]. *Applied Soft Computing Journal*, 19, 86-92. <https://doi.org/10.1016/j.asoc.2014.01.022>
- Wiggins, R. Z., Piontek, T., & Metrick, A. (2019). The Lehman brothers bankruptcy a: overview. *Journal of financial crises*, 1(1), 39-62.
- Wiiava, A. Y., Faticah, C., & Saikhu, A. (2022). Stock Price Prediction with Golden Cross and Death Cross on Technical Analysis Indicators Using Long Short Term Memory. ICOIACT 2022 - 5th International Conference on Information and Communications Technology: A New Way to Make AI Useful for Everyone in the New Normal Era, Proceeding,
- Zhang, L., Pan, Y., Wu, X., & Skibniewski, M. J. (2021). Introduction to Artificial Intelligence. In *Lecture Notes in Civil Engineering* (Vol. 163, pp. 1-15). https://doi.org/10.1007/978-981-16-2842-9_1

Nyilatkozatok

Köszönetnyilvánítás:

Ezúton szeretnénk köszönetünket kifejezni a Nemzeti Kutatási, Fejlesztési és Innovációs Hivatalnak (NKFIH), valamint az Egyetemi Kutatói Ösztöndíj Programnak (EKÖP) a kutatás során nyújtott támogatásért. Az NKFIH és az EKÖP által biztosított anyagi és szakmai háttér jelentős mértékben hozzájárult kutatásunk megvalósításához és eredményeink eléréséhez.

Érdeklődés // Összeférhetetlenség: A szerzők nem jelentenek be egymással versengő érdekeltséget, illetve összeférhetetlenséget.

Az adatok elérhetősége:

A tanulmányban elemzett adatok, valamint az ANFIS modell kidolgozása során használt programozási kódok az első szerzőtől kérésre elérhetőek.

Etikai jóváhagyás:

Ez a cikk nem tartalmaz a szerzők által emberi résztvevőkkel végzett vizsgálatokat.

Tájékoztató beleegyezés: Ez a cikk nem tartalmaz a szerzők által emberi résztvevőkkel végzett vizsgálatokat.

A mesterséges intelligencia használata: A szerzők kijelentik, hogy semmilyen területen nem használtak mesterséges intelligenciát.

Szerzői hozzájárulások:

Szerző 1 (Szabó Tamás): Konceptióalkotás, adatstrukturálás, módszertan kidolgozása, adatok elemzése, eredeti kézirat megírása, formai elemzés, vizualizáció.

Szerző 2 (Dr. Gáspár Sándor): Konceptióalkotás, felügyelet, szakmai ellenőrzés, kritikai áttekintés és szerkesztés.

Szerző 3 (Dr. Hegedűs Szilárd): Konceptióalkotás, módszertani támogatás, finanszírozás megszerzése, szakmai tanácsadás, kritikai áttekintés és szerkesztés.